

<https://doi.org/10.15388/vu.thesis.214>  
<https://orcid.org/0000-0002-9998-0824>

VILNIAUS UNIVERSITETAS  
KLAIPĖDOS UNIVERSITETAS  
GAMTOS TYRIMŲ CENTRAS

Justinas  
KILPYS

# Sniego dangos rodiklių tyrimas nuotoliniais metodais lyguminėse teritorijose

**DAKTARO DISERTACIJA**

Gamtos mokslai,  
Fizinė geografija (N 006)

---

VILNIUS 2021

Disertacija rengta 2016– 2021 metais Vilniaus universitete.

**Mokslinis vadovas:**

**prof. dr. Egidijus Rimkus** (Vilniaus universitetas, gamtos mokslai, fizinė geografija, N 006).

Disertaciją galima peržiūrėti Vilniaus universiteto, Gamtos tyrimų centro, Klaipėdos universiteto bibliotekose ir VU interneto svetainėje adresu:  
<https://www.vu.lt/naujienos/ivykiu-kalendorius>

<https://doi.org/10.15388/vu.thesis.214>  
<https://orcid.org/0000-0001-2345-6789>

VILNIUS UNIVERSITY  
KLAIPĖDA UNIVERSITY  
NATURE RESEARCH CENTRE

Justinas  
KILPYS

# Determination of snow cover characteristics in flat land areas using remote sensing methods

**DOCTORAL DISSERTATION**

Natural Sciences,  
Physical Geography (N 006)

---

VILNIUS 2021

This dissertation was written between 2016 and 2021 at Vilnius University.

**Academic supervisor:**

**Prof. dr. Egidijus, Rimkus** (Vilnius University, Natural Sciences, Physical Geography, N 006)

The text of this dissertation can be accessed at the libraries of Vilnius University, Nature Research Centre, Klaipėda University, as well as on the website of Vilnius University: [www.vu.lt/lt/naujienos/ivykiu-kalendarius](http://www.vu.lt/lt/naujienos/ivykiu-kalendarius)

## TURINYS

SANTRUMPOS.....	7
ĮVADAS.....	9
1. LITERATŪROS APŽVALGA.....	16
1.1. Palydovinių jutiklių tipai ir jų panaudojimas Žemės paviršiaus ir sniego dangos stebėsenai.....	16
1.2. Snygio nustatymas.....	18
1.3. Sniego dangos nustatymas.....	21
1.4. Vandens atsargų sniege nustatymas.....	27
1.5. Sniego dangos tyrimai Baltijos valstybėse.....	30
2. PRADINIAI DUOMENYS.....	33
2.1. Duomenų tipai ir tyrimo regionai.....	33
2.2. Sniego dangos stebėjimai meteorologijos stotyse.....	35
2.3. ATMS jutiklio, GFS modelio duomenys ir kritulių duomenys iš antžeminių stočių.....	38
2.4. MODIS jutiklio duomenys.....	42
2.5. Sentinel-1 SAR duomenys.....	43
2.6. HSAF vandens atsargų sniege duomenys.....	46
3. DUOMENŲ APDOROJIMO METODIKA.....	49
3.1. Antžeminių stočių duomenų homogeniškumo ir statistinių rodiklių vertinimas.....	49
3.2. MODIS duomenų trūkių, atsirandančių dėl debesuotumo, panaikinimas.....	51
3.3. Snygio nustatymas naudojant ATMS duomenis.....	55
3.4. Sentinel-1 SAR duomenų apdorojimas.....	57
3.5. Vandens atsargų sniege duomenų skiriamosios gebos didinimas naudojant dirbtinius neuroninius tinklus.....	61
4. SNIEGO DANGOS CHARAKTERISTIKŲ NUSTATYMAS NAUDOJANT PALYDOVINIUS DUOMENIS.....	64

4.1. Sniego dangos charakteristikų kaita Baltijos valstybėse 1961–2015 m.....	64
4.2. Snygio duomenų nustatytų naudojant ATMS palyginimas su kritulių stebėjimais antžeminėse stotyse.....	80
4.3. Dienų su sniego danga skaičiaus nustatymas Lietuvoje naudojant MODIS duomenis.....	90
4.4. Sniego dangos nustatymas Šventosios baseine naudojant SAR duomenis.....	104
4.5. Palydovinių vandens atsargų sniege duomenų validacija Baltijos valstybėse.....	113
IŠVADOS.....	120
APIBENDRINIMAS.....	122
LITERATŪROS SĄRAŠAS.....	125
PRIEDAI.....	146
PADĖKA.....	150
PUBLIKACIJŲ SĄRAŠAS.....	151

## SANTRUMPOS

Santrumpa	Reikšmė anglų kalba	Vertimas / paaiškinimas
ACC	<i>Accuracy</i>	Tikslumas
DNT	<i>Artificial Neural Network</i>	Dirbtinis neuroninis tinklas
ATMS	<i>Advanced Technology Microwave Sounder</i>	Pažangus zonduojantis mikrobangų radiometras
CLC	<i>CORINE Land Cover</i>	CORINE žemės dangos duomenys
CSI	<i>Critical Success Index</i>	Kritinės sėkmės indeksas
DEM	<i>Digital Elevation Model</i>	Skaitmeninis reljefo modelis (rastriniai duomenys)
DSS	<i>Days with snow cover</i>	Dienų skaičius su sniego danga
ESA	<i>European Space Agency</i>	Europos kosmoso agentūra
E-OBS	<i>Europe-wide precipitation and temperature observations</i>	Europos kritulių ir temperatūros matavimų duomenų bazė
EUMETSAT	<i>European Organisation for the Exploitation of Meteorological Satellites</i>	Europos meteorologinių palydovų eksploatavimo organizacija
FAR	<i>False Alarm Ratio</i>	Neteisingo identifikavimo santykis
FBI	<i>Frequency Bias</i>	Dažnio paklaida
FOV	<i>Field of View</i>	Jutiklio matymo laukas
GFS	<i>Global Forecasting System</i>	NOAA globali prognozavimo sistema (skaitmeninis modelis)
GLCF	<i>Global Land Cover Facility</i>	Projektas skirtas pasaulinei Žemės dangos stebėsenai
HSAF	<i>Satellite Application Facility on Support to Operational Hydrology and Water Management</i>	EUMETSAT padalinys skirtas teikti operatyvinius hidrologinius ir vandentvarkos duomenis
HSS	<i>Heidke Skill Score</i>	Heidke įvertis
IR	<i>Infrared</i>	Infraraudonoji spinduliuotė
DRM	<i>Linear Regresion Model</i>	Tiesinės daugianarės regresijos modelis

Santrumpa	Reikšmė anglų kalba	Vertimas / paaiškinimas
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>	Vidutinės skiriamosios gebos spektroradiometras
MAE	<i>Mean absolute error</i>	Vidutinė absoliuti paklaida
ME	<i>Mean error</i>	Vidutinė paklaida
MS	<i>Meteorological Station</i>	Meteorologijos stotis
NASA	<i>National Aeronautics and Space Administration</i>	JAV Nacionalinė aeronautikos ir kosmoso administracija
NDSI	<i>Normalized Difference Snow Index</i>	Normalizuotas sniego skirtumo indeksas
NDVI	<i>Normalized Difference Vegetation Index</i>	Normalizuoto augalijos skirtumo indeksas
NOAA	<i>National Oceanic and Atmospheric Administration</i>	JAV Nacionalinė vandenynų ir atmosferos administracija
NSIDC	<i>National Snow and Ice Data Center</i>	JAV Nacionalinis sniego ir ledo duomenų centras
POD	<i>Probability of Detection</i>	Aptikimo tikimybė
POFD	<i>Probability of False Detection</i>	Klaidingo aptikimo tikimybė
RF	<i>Random Forest</i>	Atsitiktinių miškų metodas
RMSE	<i>Root mean square error</i>	Vidutinė kvadratinė paklaida
SAR	<i>Synthetic aperture radar</i>	Sintetinės apertūros radaras
SLC	<i>Single Look Complex</i>	SAR sudėtinis stebėjimo ruožas
SRTM	<i>Shuttle Radar Topographic Mission</i>	NASA Žemės topografavimo misija iš erdvėlaivio radaro
$SS_{\text{clim}}$	<i>Climatological Skill Score</i>	Klimatologinis vertės indeksas
SWIR	<i>Short Wave Infrared</i>	Trumpųjų infraraudonųjų bangų spinduliuotė
UTC	<i>Coordinate Universal Time</i>	Pasaulinis koordinuotasis laikas
VAS	<i>Snow Water Equivalent</i>	Vandens atsargos sniege
VIS	<i>Visible spectrum</i>	Regimoji spinduliuotė
$\lambda$	<i>Wavelength</i>	Elektromagnetinės bangos ilgis
$\sigma_0$	<i>Backscattering coefficient</i>	Atgalinės sklaidos koeficientas



## ĮVADAS

Iš pirmo žvilgsnio gali atrodyti, kad sniegas yra tik laikinas žiemos sukeliamas nepatogumas, kuris nevertas gilesnių apmąstymų ar mokslinių tyrimų. Tačiau sniego danga vaidina svarbų vaidmenį reguliuojant Žemės paviršiaus energijos apytakos srautus ir klimatą – sniegas keičia paviršiaus albedą, o sniego dangos ir jūros ledo ploto mažėjimas sustiprina klimato šiltėjimą (Armstrong, Brun, 2008; Vaughan ir kt., 2013). Žiemą šiauriniame pusrutulyje sniegu padengtas plotas yra didesnis nei 50 milijonų km<sup>2</sup> ir užima 34 % sausumos paviršiaus (Pulliainen, 2006). Todėl ignoruoti sniego nevertėtų – jis sudaro didelę dalį žmonių gyvenamosios aplinkos ir jo įtaka nesibaigia tik poveikiu klimatui ir sezoniniams orams.

Sezoninė sniego danga padeda papildyti gėlo vandens išteklius – kai kuriose pasaulio vietose sniego tirpsmas yra pagrindinis gėlo vandens šaltinis ir jį naudoja iki 2 milijardų žmonių (Mankin ir kt., 2015). Be to, sniego danga ir jos kaita yra svarbūs turizmo, transporto, statybų bei žemės ūkio sektoriams (WMO, 2016). Dėl vykstančių klimato pokyčių sniego dangos plotas ir storis daugelyje pasaulio šalių mažėja (Déry, Brown, 2007; Vaughan ir kt., 2013; Wegmann ir kt., 2017), ir tai turi bei turės įtakos tiek žmogaus veiklai, tiek gamtinėms sistemoms.

Dėl minėtų priežasčių informacija apie sniego dangą yra renkama kasdien ir naudojama orų bei hidrologinių prognozių sudarymui, ilgalaikių gėlo vandens išteklių ir klimato kaitos tendencijų nustatymui (Beniston ir kt., 2018; IPCC, 2013). Baltijos šalyse (Lietuvoje, Latvijoje ir Estijoje) sniego danga yra svarbi vandens išteklių valdymui, žemės ūkiui ir ekosistemoms (Rimkus ir kt., 2014). Tradiciškai sniego dangos matavimai atliekami meteorologinėse stotyse (MS). Jose stebimas sniego dangos storis, vietovės padengimo sniegu balas (0–10), vandens atsargos sniege (VAS), pirmojo sniego ir sniego nutirpimo datos. Tačiau, per pastaruosius kelis dešimtmečius patrauklia alternatyva šiems matavimams tapo nuotoliniai palydoviniai stebėjimai, kurie leidžia nustatyti sniego dangos charakteristikas skirtinguose erdvės ir laiko masteliuose (Hüsler ir kt., 2014; König ir kt., 2001). Nuotoliniai stebėjimai yra plačiai naudojami sezoninio sniego stebėsenai vidutinėse ir aukštose platumose (Dietz ir kt., 2012; Metsämäki ir kt., 2012). Atliekant nuotolinius Žemės stebėjimus palydoviniais jutikliais yra registruojama nuo paviršiaus atspindėta Saulės spinduliuotė arba pačio paviršiaus skleidžiama elektromagnetinė spinduliuotė. Susidarius sniego dangai keičiasi šios spinduliuotės intensyvumas.

Antžeminiai matavimai labai tiksliai įvertina sniego dangos rodiklius konkrečiame taške ir paprastai turi ilgas stebėjimų sekas, kurios leidžia analizuoti ilgalaikes klimato svyravimų ir kaitos tendencijas (Bulygina ir kt. 2011; Rasmus ir kt., 2015; Rimkus ir kt., 2014). Tačiau dėl santykinai reto meteorologinių stebėjimų tinklo norint gauti informaciją apie sniego dangą ten, kur nėra stoties, duomenis reikia interpoluoti. Tokie interpoluoti duomenys pasižymi mažu tikslumu, ypač vietovėse su nevienalyčiu reljefu (Wang, Xie, 2009). Palyginti su antžeminiais matavimais, palydoviniai duomenys suteikia informacijos apie sniego dangą net ir sunkiai prieinamuose regionuose, be to, jie atliekami reguliariai ir tai yra privalumas lyginant su kai kuriomis pavienėmis matavimų ekspedicijomis (Foppa, Seiz, 2012).

Tačiau palydoviniai duomenys nėra be savo trūkumų. Priklausomai nuo palydovinio jutiklio tipo jų paviršiaus skiriamoji geba svyruoja nuo 20 m iki 25 km. Regimojo spektro jutikliai nors ir pasižymi aukšta skiriamąja geba, tačiau juos naudojant iškyla problema dėl debesuotumo. Esant dideliame debesuotumui jutiklis negali užfiksuoti spinduliuotės, ateinančios nuo Žemės paviršiaus, o esant daliniam debesuotumui kai kurie debesys gali būti priskirti sniegui ir atvirkščiai. Mikrobangų jutikliai nėra veikiami debesų – mikrobangos lengvai prasiskverbia pro debesis (žinoma, tai priklauso nuo elektromagnetinių bangų dažnio).

Pasyvieji mikrobangų radiometrai matuoja natūraliai Žemės paviršiaus skleidžiamą spinduliuotę, tačiau norint ją užfiksuoti reikia arba milžiniškos antenos arba reikia stebėti didelį Žemės plotą. Dėl šios priežasties pasyviųjų mikrobangų jutiklių skiriamoji geba yra 15–25 km. Tokia skiriamoji geba neleidžia gauti tikslių duomenų apie lokalaus masto sniego dangos parametrų kaitą ir labiau tinka globaliems arba pusrutulio masto tyrimams.

Aktyvūs mikrobangų spektro prietaisai – radarai – pasižymi labai aukšta erdvine skiriamąja geba (20–40 m), tačiau jų žvalgos juosta (angl. *swath*) yra gana siaura. Tai leidžia gauti detalius duomenis apie Žemės paviršių, tačiau tą pačią vietą jie gali stebėti tik kas 6–12 dienų arba dar rečiau. Nustatant sniego dangos rodiklius naudojant radarų duomenis iškyla problemų dėl tankios augalijos ir dirvos drėgmės. Dalis radarų visiškai negali matyti paviršiaus po augalija, o radaro signalo atgalinė sklaida (angl. *backscattering*) labai priklauso nuo vandens kiekio ant stebimo paviršiaus. Todėl esant drėgnam, neįšalusiam Žemės paviršiui gali būti sudėtinga atskirti sniegą nuo dirvos drėgmės.

Visi paminėti palydoviniai jutikliai turi savo privalumų ir trūkumų. Mokslininkai kuria ir tobulina įvairius algoritmus, kurie leidžia išgauti kuo tikslesnę informaciją apie sniego dangą, atsižvelgiant į palydovinių jutiklių

trūkumus. Šio disertacijos darbo tikslas yra toliau plėtoti kitų mokslininkų metodologiją, skirtą sniego dangos rodiklių nustatymui iš palydovų, ir pritaikyti algoritmus vidutinių platumų žemumoms. Tyrimui pasirinkta Baltijos valstybių teritorija, tačiau sudaryta metodika yra tinkama bet kuriam regionui vidutinėse platumose, kur vietovės aukštis mažesnis nei 500 m. Tikimasi, kad sukurta ir patobulinta sniego dangos aptikimo metodika leis lengviau taikyti palydovinius duomenis operatyviniame darbe ir klimato tyrimuose.

### **Mokslinių tyrimų motyvacija**

Jau kelis dešimtmečius tęsiasi meteorologinių stebėjimų automatizavimo procesas. Automatiniai stebėjimai leidžia duomenis gauti dažniau ir išvengiama žmogiškų klaidų, tačiau kai kuriais atvejais sumažėja stebėjimų apimtis ir kokybė. Automatizuojant meteorologines stotis sniego dangos storis matuojamas ultragarsiniais arba lazeriniais jutikliais, kartais vaizdo kameromis, tačiau šie jutikliai matuoja sniego storį labai siaurame taške (1–30 cm skersmens plote). Dėl natūralios sniego dangos rodiklių erdvinės kaitos, šie taškiniai matavimai nebūtinai atspindi realias sąlygas stoties apylinkėse. Atliekant matavimus šiais jutikliais nebelieka informacijos apie padengimą sniegu tiek MS teritorijoje, tiek apylinkėse.

Lietuvoje nuo 2000 iki 2021 m. meteorologinių stočių, įvertinančių vietovės padengimo sniegu laipsnį, sumažėjo 86,2 % (nuo 65 iki 9), matuojančių sniego storį 58,5 % (nuo 65 iki 27). Meteorologinių stočių, atliekančių sniego nuotraukas, per pastaruosius 20 metų sumažėjo daugiau nei dvigubai (nuo 65 iki 31). Panašios tendencijos fiksuojamos ir kitose Baltijos valstybėse. Tai lemia, kad tikslios informacijos apie vietovės padengimą sniego danga, sniego tankį ir vandens atsargas sniege yra nedaug, o tai svarbūs rodikliai sudarant pavasario potvynio prognozes ir vertinant ilgalaikes klimato kaitos tendencijas.

Atsirandančių sniego dangos rodiklių stebėjimų spragą galima užpildyti naudojant palydovinius duomenis. Palydoviniai duomenys gali suteikti informacijos apie sniego dangos erdvinę kaitą ir apie įvairius sniego dangos parametrus. Nors palydovinių stebėjimų ir duomenų apimtis kasmet didėja, tačiau skiriasi palydovinių jutiklių veikimo principai, skiriamoji geba, stebėjimų dažnumas. Norint gauti naudingos informacijos apie sniego dangą reikalingi palydovinių duomenų apdorojimo algoritmai, kurie išnaudoja stipriąsias skirtingų jutiklių savybes.

## **Tyrimo objektas**

Sniego dangos rodiklių nustatymo metodika iš palydovinių duomenų.

## **Darbo tikslas**

Nustatyti sniego dangos charakteristikas bei jų kaitą Baltijos valstybėse bei įvertinti sniego rodiklių nustatymo iš palydovinių duomenų galimybes ir tikslumą.

## **Darbo uždaviniai**

1. Išanalizuoti sniego dangos charakteristikų erdvinį pasiskirstymą Baltijos valstybėse ir jų kaitą 1961–2015 m.
2. Sukurti snygio nustatymo algoritmą panaudojant pasyviojo mikrobangų radiometro ATMS duomenis.
3. Apskaičiuoti metinį dienų su sniego dangą skaičių remiantis radiometro MODIS duomenimis bei įvertinti šio metodo tikslumą.
4. Patobulinti sintetinės apertūros radaro (SAR) sniego dangos aptikimo algoritmą lyguminėse (vietovės aukštis < 500 m), skirtingo žemės dangos tipo teritorijose su plona sniego danga.
5. Padidinti HSAF vandens atsargų sniege duomenų skiriamąją gebą naudojant papildomus erdvinius geografinius ir meteorologinius duomenis.

## **Ginami teiginiai**

1. Pasyviųjų mikrobangų jutiklių duomenys virš sausumos yra tinkami atskirti snygį nuo atvejų be kritulių.
2. Pašalinus duomenų trūkius susidarančius dėl debesuotumo, palydoviniai regimojo spektro jutikliai yra tinkami sezoniniams sniego dangos rodikliams apibūdinti.
3. Sniego dangos nustatymo tikslumą naudojant SAR duomenis galima padidinti įvertinant atgalinės sklaidos ypatumus skirtinguose žemės dangos tipuose.

## **Darbo mokslinis naujumas**

Pasaulyje palydoviniai duomenys yra plačiai taikomi sniego ir ledo dangos stebėsenai kalnuotose teritorijose ir poliariniuose regionuose. Sniego dangos algoritmai dažnai yra pritaikyti būtent šioms vietovėms ir trūksta tyrimų skirtų vidutinėms platumoms ir vietovėms su įvairia ir kintančia žemės paviršiaus danga. Šis disertacijos darbas skirtas užpildyti minėtas spragas ir

pristatyti sniego dangos nustatymo iš palydovinių duomenų algoritmų patobulinimus. Darbe pasiūlytos mokslinės naujovės:

1. Sudaryta kietųjų kritulių klasifikacijos metodika naudojant ATMS jutiklio duomenis ir atsitiktinių miškų (angl. *random forest*) mašininio mokymosi algoritmą.
2. Pasiūlyta MODIS sniego dangos duomenų rinkinio duomenų trūkių, atsirandančių dėl debesuotumo, užpildymo metodika panaudojant papildomą minimalios oro temperatūros filtrą.
3. Patobulintas SAR sniego dangos aptikimo algoritmas įvedant kritines SAR santykio klasifikacijos reikšmes priklausomai nuo žemės dangos tipo.
4. Sudaryta metodika kaip, atsižvelgiant į kraštovaizdžio rodiklius ir meteorologines sąlygas, padidinti HSAF vandens atsargų sniege duomenų skiriamąją gebą nuo ~25 km iki ~5 km.

Doktorantūros metu sukurti metodikos patobulinimai skirti vidutinių platumų lygumų teritorijoms. Norint šiuos sniego dangos nustatymo būdus taikyti globaliai bei kalnuotose vietovėse reikalingi papildomi tyrimai, kurie įvertintų vietovės aukščio ir klimato sąlygų kaitą. Tačiau pasiūlytą metodiką yra lengva naudoti ir ją galima nesunkiai pritaikyti kitiems pasaulio regionams.

### **Darbo aktualumas ir pritaikomumas**

Baltijos valstybėse mažėjant antžeminių sniego dangos matavimų kyla iššūkis kaip užtikrinti stebėjimų tęstinumą, bei meteorologinių ir hidrologinių prognozių tikslumą. Vietoje sniego dangos matavimų MS, kaip įvesties duomenis į skaitmeninius hidrologinius ir meteorologinius modelius galima panaudoti palydovinius stebėjimus.

Šiame darbe pasiūlytą metodiką galima lengvai pritaikyti operatyviniame nacionalinių meteorologijos ir hidrologijos tarnybų darbe. Naudojant darbe aprašytus algoritmus galima gauti kasdieninę informaciją apie snygį (šviežią sniegą), sniego dangos plotą, vandens atsargas sniege. Juos pritaikius meteorologiniuose modeliuose, galima operatyviai stebėti sniego dangos kaitą ir vertinti jos poveikį kitiems meteorologiniams rodikliams bei padidinti prognozių tikslumą.

Tyrimo rezultatai taip pat rodo, kad palydovinius duomenis galima taikyti klimato kaitos tyrimuose. Yra palydovinių jutiklių, kurių stebėjimai apima daugiau nei du dešimtmečius, o tai leidžia įvertinti ilgalaikes sniego dangos kaitos tendencijas.

Daugėjant įvairių aplinkos stebėsenos duomenų, vis didesnę reikšmę turi šių duomenų integravimas ir apjungimas. Šiame darbe pasiūlyti mašininio

mokymosi (angl. *machine learning*) algoritmai geba apdoroti didelius duomenų kiekius ir surasti ryšius tarp rodiklių net ir tais atvejais kai fizinis ryšys nėra akivaizdus. Mašininio mokymosi algoritmų taikymas meteorologijoje ir hidrologijoje didėja ir šio darbo rezultatai prisideda prie šių metodų praktinio taikymo nustatant sniego dangos rodiklius.

### **Rezultatų aprobacija**

Disertacijos darbo rezultatai pristatyti 4 tarptautinėse ir 3 nacionalinėse mokslinėse konferencijose. Tarptautinės konferencijos:

- 31st Nordic meteorological meeting (NMM31). Reikjavikas, Islandija, 2018 m. birželio 18-20 d. *Žodinis pranešimas* „Creating a cloud-free MODIS snow cover product using spatial and temporal interpolation and temperature thresholds“ J. Kilpys, E. Rimkus, S. Pipiraitė.
- COST Action ES1404 baigiamoji konferencija „Towards a better harmonization of snow observations, modeling and data assimilation in Europe“. Budapeštas, Vengrija, 2018 m. spalio 30-31 d. *Žodinis pranešimas* „Comparison of statistical downscaling methods of satellite-based snow water equivalent product“ J. Kilpys, S. Aniskeviča, K. Vint.
- NOAA NESDIS Cooperative Research Program (CoRP) simpoziumas Marylando universitete, JAV. 2019 m. rugpjūčio 27-29 d. *Stendinis pranešimas* „Application of random forest algorithm to detect snowfall from ATMS measurements“ J. Kilpys, H. Meng, Y. You, J. Dong, R. Ferraro.
- MODIS/VIIRS Science Team Meeting. College Park, Maryland, JAV. 2019 m. lapkričio 19-21 d. *Stendinis pranešimas* „A snow climatology in Lithuania based on the cloud-free MODIS snow cover product“ J. Kilpys, S. Pipiraitė-Januškienė, E. Rimkus.

Nacionalinės konferencijos:

- Konferencija skirta Ignoto Domeikos 215-osioms gimimo metinėms "Be praeities nėra ir ateities. Mokslas XIX-XXI a. sandūroje". Vilnius, 2017 m. liepos 28-30 d. *Stendinis pranešimas* „Downscaling of satellite-based snow data using auxiliary environmental information“ J. Kilpys.
- 11-toji jaunųjų mokslininkų konferencija „BIOATEITIS: gamtos ir gyvybės mokslų perspektyvos“. Vilnius, 2018 m. gruodžio 14 d. *Žodinis pranešimas* „Statistinis palydovinių vandens atsargų sniege

duomenų skiriamosios gebos didinimas“ J. Kilpys, S. Aniskeviča, K. Vint.

- Konferencija „Klimato kaita Lietuvoje: globalūs ir nacionaliniai iššūkiai, stebėseną ir politikos gairės“. Vilnius, 2020 m. gegužės 22 d. *Žodinis pranešimas* „Sniego dangos ir jos charakteristikų matavimo būdai, paklaidos ir taikymas klimato tyrimuose“ J. Kilpys, E. Rimkus, S. Pipiraitė-Januškienė.
- Konferencija „Klimato kaita Lietuvoje: globalūs ir nacionaliniai iššūkiai, stebėseną ir politikos gairės“. Vilnius, 2020 m. gegužės 22 d. *Stendinis pranešimas* „Atsitiktinių medžių (random forest) klasifikatoriaus taikymas sniego nustatymui iš palydovinių ATMS duomenų“ J. Kilpys, H. Meng, Y. You, J. Dong, R. Ferraro.

## 1. LITERATŪROS APŽVALGA

Šiame skyriuje apžvelgiami moksliniai tyrimai, skirti palydovinių duomenų panaudojimui, sniego dangos rodiklių nustatymui ir stebėsenai. Apžvalga yra suskirstyta į penkias dalis. Pirmoje dalyje apžvelgiama palydovinių jutiklių įvairovė ir jų taikymo sniego dangos stebėsenai privalumai ir trūkumai. Antroje, trečioje ir ketvirtoje dalyje nagrinėjama kaip, naudojant palydovinius jutiklius, galima nustatyti šiuos sniego dangos rodiklius: snygį, sniego dangą ant Žemės paviršiaus bei vandens atsargas sniege. Šiuose poskyriuose apžvelgiami pagrindiniai palydovinių duomenų apdorojimo metodai bei mokslinių tyrimų ir taikymo raidos tendencijos. Paskutinė, penktoji, dalis skirta supažindinti su sniego dangos tyrimais rytų Baltijos regione, čia stebimais sniego rodiklių erdvinio pasiskirstymo ypatumais ir pokyčiais dėl klimato kaitos.

### 1.1. Palydovinių jutiklių tipai ir jų panaudojimas Žemės paviršiaus ir sniego dangos stebėsenai

Civilinių palydovinių Žemės paviršiaus stebėjimų pradžia laikomi 1960 m., kai į kosmosą buvo paleistas pirmasis meteorologinis palydovas *TIROS-1* (Lillesand ir kt., 2015). Šis palydovas pirmiausia buvo skirtas meteorologiniams ir klimato stebėjimams, tačiau kartu padėjo ir Žemės paviršiaus stebėjimo iš palydovų pagrindus. 1964 m. pradėta meteorologinių palydovų *Nimbus* programa. Dirbtiniai Žemės palydovai *Nimbus* buvo tiriamieji meteorologiniai palydovai, skirti nuotoliniams atmosferos tyrimams. 1972 m. paleistas ERST (angl. *Earth Resources Technology Satellite*) – pirmasis dirbtinis palydovas, skirtas ne orų ir atmosferos, bet Žemės paviršiaus tyrimams. Šis palydovas vėliau pervadintas į *Landsat 1* (Kilpys ir kt., 2021). *Landsat* programa buvo ilgalaikė ir sėkminga – iki šių dienų jau paleisti 8 *Landsat* palydovai. Šių palydovų daugiaspektriai duomenys padėjo geriau suprasti Žemėje vykstančius globalius procesus, įvertinti Žemės paviršiaus ir miestų vystymosi tendencijas. Iki *Landsat* misijos palydovinės nuotraukos buvo analizuojamos spausdintos ar kaip skaidruolės, o *Landsat* duomenys buvo pateikiami ir skaitmeniniu formatu. Tai atvėrė daug platesnes palydovinių duomenų analizės ir pritaikymo galimybes (Lillesand ir kt., 2015).



Anksčiau paminėtos pirmosios palydovinės atmosferos ir Žemės paviršiaus misijos puikiai buvo naudojamos ir sniego dangos nustatymui. Sniego dangą buvo galima nustatyti jau pirmojo orų palydovo TIROS-1 nuotraukose (1960 m.). Dėl aukštos sniego albedo reikšmės, sniego danga regimajame spektre sudaro ryškų kontrastą kitiems natūraliems paviršiams ir objektams (Kilpys ir kt., 2021). Regimajame spektre sniegas atspindi didžiąją dalį spinduliuotės, o artimojo infraraudonojo spektro (NIR) dalyje – didžiąją dalį spinduliuotės sugeria (Tedesco, 2015). Tačiau kiekvienu konkrečiu atveju sniego dangos spektrinis signalas priklauso nuo įvairių sniego dangos savybių: tankio, sniego dalelių dydžio, vandens atsargų sniege, įvairių priemaišų (pvz.: dulkių, suodžių, dumblių). Dažniausiai, kuo senesnė sniego danga, tuo prastesnės jos atspindžio savybės (mažėja albedas). Iš dalies taip yra dėl sniego kristalų metamorfozės ir, iš dalies, dėl didesnės priemaišų koncentracijos (Nolin, 2011; Tedesco, 2015).

Nuotolinis sniego dangos stebėjimas didelėse teritorijose dažniausiai atliekamas naudojant vidutinės skiriamosios gebos regimojo spektro jutiklius (AVHRR, MODIS, VIIRS ir kt.), tačiau specifiniams tyrimams taikomi ir didesnės skiriamosios gebos prietaisai. Didžiausios paklaidos susidaro nustatant sniego dangą miškingose vietovėse ir esant sudėtingam reljefui, o atvirose lyguminėse vietovėse palydoviniai duomenys yra tikslesni (Dietz ir kt., 2012; Kilpys ir kt., 2021; Tedesco, 2015).

Naudojant regimojo spektro jutiklius sniego dangos nustatymui pagrindinė problema yra debesų danga, kuri neleidžia stebėti Žemės paviršiaus. Debesų sukeliama stebėjimo trūkio galima išvengti naudojant pasyviuosius arba aktyviuosius mikrobangų jutiklius (Lillesand ir kt., 2015). Pasyvieji mikrobangų jutikliai gali atlikti stebėjimus bet koku oru, tačiau jie pasižymi maža skiriamąja geba (15–25 km) (Nolin, 2011). Naudojant pasyviuosius mikrobangų jutiklius galima nustatyti ne tik sniego dangą, bet ir VAS. Pirmieji VAS duomenų rinkiniai, paremti pasyviųjų mikrobangų jutiklių informacija, pradėti teikti XX a. 8-ojo dešimtmečio pabaigoje (Chang ir kt., 1987; Chang ir kt., 1982). VAS nustatymas remiasi mikrobangų spinduliuotės intensyvumo pokyčių matavimai, kurie priklauso nuo sniego dangos tankio ir skysto vandens kiekio.

Sniego dangos paplitimą, sniego storį bei tankį galima nustatyti ir naudojant aktyviuosius mikrobangų jutiklius – radarus. Radarų signalo sąveika su sniegu yra sudėtingesnė nei regimosios ar infraraudonosios spinduliuotės. Sintetinės apertūros radarų (SAR) siunčiamo signalo atgalinė sklaida, nuo sniegu padengtos teritorijos, priklauso nuo signalo išsklaidymo ties paklotiniu paviršiumi, išsklaidymo sniego dangos storumėje ir atspindėjimo/išsklaidymo nuo dirvos paviršiaus (Nagler ir kt., 2016;

Tedesco, 2015). Sklaidos intensyvumas priklauso nuo sniego dangos ir paklotinio paviršiaus savybių bei SAR stebėjimo kampo. Didelę įtaką radaro signalo atgalinei sklaidai turi sniego dangos ir jos skirtingų sluoksnių dielektrinės skvarbos rodikliai. Dielektrinė konstanta sniege keičiasi priklausomai nuo jo tankio ir skysto vandens kiekio. Sniego dangoje signalas susilpnėja dėl: 1) sniego kristalų išsklaidomos spinduliuotės; 2) išsklaidymo ties sniego ir dirvožemio riba; 3) išsklaidymo skirtingo tankio sniego sluoksniuose (Tedesco, 2015; Tsai ir kt. 2019a).

Be jau minėtų regimojo, infraraudonojo ir mikrobangų spektro jutiklių sniego dangos charakteristikų nustatymui taip pat naudojami lidarai (angl. *light detection and ranging*) (Kirchner ir kt., 2014; Nolin, 2011) ir nuotoliniai Žemės gravitacinio lauko matavimai (Niu ir kt., 2007; Tedesco, 2015). Naudojant lidarų galima apskaičiuoti sniego storį. Tam naudojami du palydovinio lidaro matavimai: dienos be sniego ir su sniegu. Turint du geografiškai sutampančius lidaro vaizdus apskaičiuojamas išmatuoto paviršiaus aukščio skirtumas, kuris ir laikomas sniego dangos storium (Nolin, 2011). Skirtumas gali būti skaičiuojamas naudojant pirminius skenavimo taškus, arba interpoliuotus erdvinis duomenis, arba naudojant abu minėtus metodus.

Žemės gravitacinio lauko matavimus atlieka GRACE (angl. *Gravity Recovery and Climate Experiment*) palydovai (Forman ir kt., 2012; Niu ir kt., 2007). GRACE matuoja gravitacinio lauko anomalijas erdvėje ir laike, o tai leidžia nustatyti Žemės masės pokyčius. Šie pokyčiai daugeliu atveju yra susiję su vandens išteklių svyravimais. GRACE išmatuoti masės pokyčiai nebūtinai yra susiję su sniegu ir VAS, todėl apdorojant duomenis būtina atskirti sniego dangos poveikį nuo kitų galimų Žemės masės svyravimo priežasčių. Tyrimai parodė, kad VAS apskaičiuotos naudojant GRACE duomenis, yra tikslios aukštose platumose, kur susikaupia daug sniego (Niu ir kt., 2007).

Palydoviniai sniego dangos matavimai pasižymi didele įvairove ir jutiklių gausa, tačiau šiame darbe ir literatūros apžvalgoje bus koncentruojamos į šias temas: snygio nustatymas zonduojančiais mikrobangų radiometrais (angl. *passive microwave sounders*), sniego dangos aptikimas regimojo spektro ir SAR jutikliais, vandens atsargų sniege nustatymas pasyviais mikrobangų radiometrais bei šių duomenų palyginimas su antžeminiais sniego dangos matavimais.

## 1.2. Snygio nustatymas

Snygio nustatymas naudojant palydovinius jutiklius yra sudėtingas dėl atmosferos procesų, veikiančių kritulių fazinę sudėtį, kompleksiško ir galimybių tiesiogiai išmatuoti šiuos procesus trūkumo. Norint sudaryti tikslių snygio nustatymo algoritmą reiktų tokių fizinių rodiklių, kaip ledo dalelių forma ir tankis, tačiau tokia informacija paprastai nėra prieinama. Tai lemia, kad naudojant palydovinius jutiklius, snygį įvertinti yra sunkiau nei skystus kritulius (Kongoli, Meng, Dong, & Ferraro, 2018; Meng ir kt., 2017).

Kritulių ir snygio nustatymui iš kosmoso dažniausiai naudojami pasyvieji zonduojantys mikrobangų jutikliai. Mikrobangos gali prasiskverbti į debesis, o šios spinduliuotės intensyvumo pokyčiai tiesiogiai susiję su sniego bei ledo dalelių skaičiumi ir dydžiu (Kongoli ir kt., 2003; Skofronick-Jackson ir kt., 2004).

Aukštų dažnių mikrobangos, pavyzdžiui, 160 GHz kanalas esantis ties atmosferos skaidrumo langu arba 183 GHz kanalas, kuris jautrus vandens garams, yra ypač jautrus ledo dalelėms (Kongoli ir kt., 2003). Ledo kristalai išsklaido šio dažnio spinduliuotę ir palydovo jutiklis fiksuoja mažesnę spinduliuotės intensyvumą. Iš esmės visi pasyviųjų mikrobangų jutiklių kritulių (skystų ir kietų) nustatymo algoritmai virš sausumos remiasi ledo kristalų atmosferoje signalo pokyčio nustatymu (Meng ir kt., 2017).

G. M. Skofronick-Jackson ir kt. (2004) sukūrė snygio nustatymo algoritmą, kuriame panaudoti aukšto dažnio mikrobangų duomenys iš AMSU-B radiometro (angl. *Advanced Microwave Sounding Unit-B*). Šis algoritmas rėmėsi debesų modelio duomenų transformacija (angl. *data inversion*) į AMSU-B ryškio temperatūrą. Ryškio temperatūra – tai kūno arba paviršiaus šiluminės energijos spinduliuotės intensyvumo matas. Jis išreikštas kaip temperatūra, nes spinduliuotės intensyvumas yra tiesiogiai susijęs su spinduliuojančio kūno paviršiaus temperatūra (Kilpys ir kt., 2021).

Vertikalūs sniego, temperatūros ir santykinės drėgmės profiliai ir jų poveikis stebimam atmosferos spinduliavimui buvo apskaičiuoti naudojant spinduliuotės pernašos modelį (angl. *radiative transfer model*) ir išreikšti per ryškio temperatūrą, atitinkančią penkis AMSU-B stebėjimo dažnius (89–183 GHz) (Skofronick-Jackson ir kt., 2004). Atliekant spinduliuotės pernašos modeliavimą buvo laikoma, kad sniego dalelės – tai identiškų ledo sferų koncentracija. Siekiant sudaryti skirtingus kietųjų kritulių debesų profilius, buvo keičiami sniego dalelių masės, paviršiaus spinduliuotės ir santykinės drėgmės parametrai. Sniego dalelių rodikliai ir debesų profiliai geriausiai atitinkantys AMSU-B ryškio temperatūrą buvo laikomi teisingais. G. M. Skofronick-Jackson ir kt. (2004) tyrimas parodė, kad naudojant aukšto

dažnio mikrobangų intensyvumo matavimus galima gauti informacijos apie snygį virš sausumos, tačiau jo nustatymas mikrobangų spektre labai priklauso nuo mikrofizinių debesų ir kritulių dalelių parametrų.

M.-J. Kim ir kt. (2008) patobulino aukščiau aprašytą AMSU-B duomenų algoritmą (Skofronick-Jackson ir kt., 2004). Pagrindiniai patobulinimai buvo susiję su tuo, kad į modelį buvo įtraukta galimybė panaudoti nesferines ledo daleles ir apskaičiuotos jų mikrobangų sklaidos savybės. Taip pat buvo pritaikyti duomenų skirstiniai būdingi antžeminiams sniego dalelių dydžio stebėjimams, o rezultatų transformacija buvo optimizuota panaudojant Bajeso metodą. Atnaujintas algoritmas buvo pritaikytas tiems patiems sniego atvejams kaip ir pradiniam tyrime (Skofronick-Jackson ir kt., 2004), o gauti rezultatai labiau atitiko meteorologinio radaro stebėjimus nei originalus algoritmas.

Kita dalis mokslininkų bandė nustatyti snygio atvejus remdamiesi statistiniais ryšiais tarp pasyviųjų mikrobangų radiometrų užfiksuotos ryškio temperatūros ir atmosferos sąlygų. G. Liu ir E.-K. Seo (2013) remdamiesi dviejų mikrobangų jutiklių, AMSU-B ir MHS (angl. *Microwave Humidity Sensor*), duomenimis sudarė statistinę snygio tikimybės reikšmių lentelę (angl. *look-up table*). Lentelė sudaryta atsižvelgiant į tris pagrindines komponentes, gautas apskaičiuotus pasyviųjų mikrobangų jutiklių spektro juostų (> 89 GHz) empirines ortogonaliasias funkcijas, ir susiejant šias komponentes su snygio intensyvumu, gautu iš CloudSat duomenų. CloudSat – eksperimentinis NASA palydovas paleistas 2006 m. Jis naudoja radarą kritulių ir debesų stebėjimui ir vertikaliai atmosferos zondavimui (Stephens ir kt., 2008). CloudSat palydovo duomenys laikomi labai tiksliais ir yra naudojami kitų palydovinių duomenų validacijai (Behrangi ir kt., 2014).

Yra sukurti logaritminės regresijos ir hibridiniai algoritmai, kurie naudoja AMSU, MHS, arba ATMS (angl. *Advanced Technology Microwave Sounder*) jutiklių ryškio temperatūrą bei papildomus filtrus iš skaitmeninių orų modelių (Kongoli ir kt., 2018; Meng ir kt., 2017). H. Meng ir kt. (2017) snygio intensyvumo nustatymui iš pasyviųjų mikrobangų radiometrų duomenų panaudojo 1DVAR (angl. *one-dimensional variational*) algoritmą. Šiame algoritme naudojami poliariinės orbitos palydovų mikrobangų jutikliai, galintys fiksuoti aukšto dažnio mikrobangų signalą. Pagrindiniai algoritmo žingsniai: debesų savybių nustatymas, ledo dalelių kritimo greičio apskaičiavimas, rezultatų koregavimas atsižvelgiant į ledo dalelių masę atmosferoje (angl. *ice water content*) ir galiausiai – snygio intensyvumo nustatymas. Dalis 1DVAR modelyje naudojamų rodiklių yra nustatyti remiantis statistiniais ryšiais tarp palydovinių matavimų ir atmosferos parametrų, kita dalis yra GFS skaitmeninio orų modelio išeities duomenys.

H. Meng ir kt. (2017) pasiūlytas snygio intensyvumo nustatymo algoritmas yra šiuo metu naudojamas NOAA operatyvinėje veikloje.

C. Kongoli ir kt. (2018) pasiūlė hibridinį sniego aptikimo algoritmą, kuris apjungia pasyviųjų mikrobangų jutiklių matavimus su statistiniu modeliu, kuris buvo sudarytas panaudojant MS duomenis ir GFS skaitmeninių orų modelio išvesties duomenis. Palydoviniai duomenys naudojami apskaičiuoti snygio tikimybę prie Žemės paviršiaus. Tam naudojami AMSU / MHS ir ATMS jutiklių spektro juostų duomenys (>89 GHz) ir iš jų išvestos pagrindinės komponentės. Pagrindinės komponentės yra įvedamos į logistinės regresijos modelį, kuris leidžia nustatyti kritulių tipą. Atskirai nagrinėjant GFS skaitmeninių orų modelio duomenis buvo nustatyta, kad snygio tikimybę galima apskaičiuoti naudojant debesų storio ir santykinės oro drėgmės duomenis 1–3 km aukštyje. Pritaikius logistinės regresijos modelį GFS duomenims gauta, kad snygis tiksliausiai klasifikuojamas, kai naudojamas debesų storis, santykinis oro drėgnumas ir vertikalių oro srautų greitis. Galutiniame žingsnyje buvo apjungti palydovinių jutiklių bei GFS modelio logistinės regresijos modelių išvesties rezultatai ir apskaičiuota galutinė snygio tikimybė, remiantis svoriniais koeficientais (Kongoli ir kt., 2018). Gautų rezultatų palyginimas su orų radaro duomenimis JAV parodė, kad toks hibridinis modelis yra tikslesnis nei naudojant vien tik pasyviųjų mikrobangų radiometrų duomenis.

Anksčiau aptarti snygio nustatymo algoritmai remiasi tiesiniais arba fizikiniais modeliais, tačiau pastaruoju metu meteorologijoje ir palydovinių duomenų analizei vis plačiau naudojami mašininio mokymosi algoritmai (angl. *machine learning*). Įvairūs mašininio mokymosi algoritmai yra taikomi kritulių nustatymui iš palydovinių duomenų (Bhuiyan ir kt., 2019; Chen ir kt., 2020; Tao ir kt., 2016) bei sniego dangos aptikimui ant žemės paviršiaus (Hou ir kt., 2019; Nijhawan ir kt., 2019; Tsai ir kt., 2019b). A. Adhikari ir kt. (2020) mašininio mokymosi algoritmus pabandė pritaikyti ir snygio nustatymui panaudojant MHS jutiklio stebėjimo duomenis. Snygio nustatymui jie naudojo keturis mašininio mokymosi algoritmus: K-artimiausių kaimynų (KNN) (angl. *K-nearest neighbor*), naivaus Bajeso (angl. *naive Bayes*), sprendimų medžio (angl. *decision tree*) ir atsitiktinių miškų (RF) (angl. *random forest*). Palyginus mašininio mokymosi algoritmų rezultatus su CloudSat snygio duomenimis buvo gauta, kad tiksliausiai kritulių tipas buvo nustatytas naudojant RF modelį. RF modeliai yra laikomi efektyviu metodu didelių duomenų klasifikacijai. Svarbus jų privalumas yra tai, kad RF nėra jautrus per dideliame modelio pritaikymui prie pradinių duomenų (angl. *overfitting*) (Belgiu, Drągu, 2016). RF modelis snygio nustatymui naudotas ir šiame darbe.

### 1.3. Sniego dangos nustatymas

Sniego dangos stebėjimui iš kosmoso gerai tinka regimojo ir infraraudonojo spektro jutikliai, tačiau jie ne visada gali fiksuoti Žemės paviršių dėl debesuotumo. Debesys palydovo jutiklio žvalgos juostoje gali lemti sniego dangos nustatymo klaidas arba dideles erdvinės duomenų spragas bei ilgus duomenų trūkius laike (Dietz ir kt., 2012). Regimajame spektre debesys gali būti klaidingai palaikyti sniegu, nes debesų ir sniego spektrinis signalas yra panašūs (Nolin, 2011). Palydovinių duomenų panaudojimą sniego dangos nustatymui taip pat apsunkina tanki augmenija, bei staigūs reljefo pokyčiai kalnuotose vietovėse (Hall, Riggs, 2007; Hüsler ir kt., 2014).

Vienas iš dažniausiai sniego dangai aptikti naudojamų regimosios ir artimosios infraraudonosios spinduliuotės jutiklių yra MODIS (angl. *Moderate Resolution Imaging Spectroradiometer*), kuris skrieja „Terra“ ir „Aqua“ palydovuose. „Terra“ palydovas buvo paleistas 1999 m., o „Aqua“ 2002 m. Šie abu palydovai skrieja poliarine orbita 705 km aukštyje, tačiau skirtingomis kryptimis: „Terra“ skrenda besileidžiančia trajektorija (iš šiaurės į pietus), o „Aqua“ – kylančia trajektorija (iš pietų į šiaurę). Pusiaują abu palydovai kerta maždaug 3 val. skirtumu vienas nuo kito („Terra“ – 10.30 val., „Aqua“ – 13.30 val. UTC) (Frazier, 2018). MODIS prietaisas turi 36 spektrines juostas, kurių bangos ilgiai svyruoja nuo 0,4 iki 14,4  $\mu\text{m}$ . Priklausomai nuo spektrinės juostos duomenų erdvinė skiriamoji geba siekia 250-1000 m (Salomonson ir kt., 1989).

Kadangi „Terra“ ir „Aqua“ palydovai kasdien savo stebėjimais padengia visą Žemės rutulį, MODIS sniego dangos duomenų rinkinys taip pat sudaromas kiekvieną dieną ir, atsižvelgiant į naudojamą spektrines juostas, yra vidutinės erdvinės skiriamosios gebos (500 x 500 m) (Hall, Riggs, 2007; Hall ir kt., 2002). Sudarant MODIS sniego dangos duomenų rinkinį taip pat įvedamos korekcijos dėl miškų ir kitos tankios augalijos, kuri gali sumažinti sniego dangos atspindžio reikšmes (Hall ir kt., 2002). Sudaryti MODIS sniego dangos duomenų rinkiniai naudojami hidrologiniuose, klimato ir orų modeliuose (Foppa, Seiz, 2012; Tekeli ir kt., 2005; Wang ir kt., 2015; Zhang ir kt., 2014).

Pagrindinis MODIS jutiklio trūkumas yra tai, kad jei vietovę dengia debesys, jis negauna jokios informacijos apie Žemės paviršiaus būklę ir sniego danga negali būti nustatyta. Tyrimuose Austrijoje, JAV, Kinijoje ir Vokietijoje nustatyta, kad žiemos metu, priklausomai nuo regiono, Žemės paviršius MODIS vaizduose 39–80 % laiko gali būti uždengtas debesimis (Dong, Menzel, 2016; López-Burgos ir kt., 2013; Parajka, Blöschl, 2008; Xie ir kt., 2009). Siekiant užpildyti duomenų spragas, atsirandančias dėl

debesuotumo, yra naudojami įvairūs būdai. Dažniausiai pasitaikantys metodai:

- 1) erdviniai ir laiko filtrai (Gafurov, Bárdossy, 2009; Parajka ir kt., 2010);
- 2) sujungiami kelių dienų nedebebuotų vaizdų duomenys (Wang, Xie, 2009; Xie ir kt., 2009);
- 3) naudojami duomenys iš panašių palydovinių jutiklių (Hall, Riggs, Foster, Kumar, 2010; Parajka, Blöschl, 2008; Wang ir kt., 2008);
- 4) naudojama minėtų metodų kombinacija bei papildomi oro temperatūros, kritulių, sniego dangos ribų, vietovės aukščio kriterijai (Dong, Menzel, 2016; López-Burgos ir kt., 2013; Molotch ir kt., 2004; Parajka ir kt., 2010).

Visi minėti duomenų trūkių dėl debesuotumo užpildymo metodai buvo išbandyti skirtingo reljefo ir klimato regionuose. Tyrimų, vietovių ir duomenų trūkių dėl debesuotumo užpildymo metodų santrauka pateikta 1.1 lentelėje. Pasirinkus bet kurį debesimis uždengtų pikselių užpildymo metodą, galima sudaryti ilgalaikes kasdieninių palydovinių sniego duomenų sekas, kurios tinka klimatologiniams sniego dangos tyrimams regioniniu, žemyno ar pusrutulio lygiu (Dong, Menzel, 2016; Hall ir kt., 2010; Hüsler ir kt., 2014; Zhao, Fernandes, 2009).

Pasaulyje yra kelios tarptautinės institucijos ir projektai, kurie ruošia ir teikia sniego dangos palydovinių duomenų rinkinius, paremtus regimojo ir artimojo infraraudonojo spektro jutikliais:

1. JAV Nacionalinis sniego ir ledo duomenų centras (NSIDC) (angl. *National Snow and Ice Data Center*) (Hall ir kt., 2002).
2. Europos kosmoso agentūros (ESA) (angl. *European Space Agency*) „GlobSnow“ projektas (Metsämäki ir kt., 2015).
3. Copernicus globali žemės paviršiaus tarnyba (angl. *Global Land Cover Service*) (Schwaizer, Ripper, 2017).
4. ESA „SnowPEX“ projektas (Metsämäki ir kt., 2017).
5. Vokietijos aviacijos ir kosmoso centro (DLR) „Global SnowPack“ projektas (Dietz ir kt., 2015).

Minėtų projektų ir institucijų sniego dangos duomenų rinkiniai yra išplėtoti ir patikrinti skirtingomis sąlygomis, tačiau daugelis jų remiasi regimojo spektro duomenis, todėl esant dideliame debesuotumui arba poliarinės nakties metu jie negali suteikti informacijos apie sniego dangą. Šių apribojimų neturi sintetinės apertūros radarai (SAR) (angl. *Synthetic Aperture Radar*). SAR jutikliai nepriklauso nuo saulės apšvietimo sąlygų ir gali būti naudojami sniegui ar ledui stebėti bet kokiomis oro sąlygomis (Nagler ir kt., 2016; Tsai ir kt., 2019b). Be to, naudojant SAR nekyla

problemų dėl sniego ir debesų atskyrimo, o tai yra dažna problema naudojant daugiaspektrinius jutiklius (Stillinger ir kt. 2019). Papildomas SAR jutiklių privalumas yra tai, kad jie gali naudoti horizontalią ir vertikalią radaro signalo poliarizaciją, o tai leidžia nustatyti stebimo paviršiaus fizines savybes, sudėtį, formą ar stebimo objekto judėjimo greitį (Tsai ir kt., 2019a).

**1.1 lentelė.** MODIS sniego dangos duomenų rinkinio, apimančio debesimis uždengtų pikselių užpildymo būdus ir tirtas vietas santrauka.

Tyrimas	Regionas	Klimato sąlygos	Debesuotumas	Duomenų trūkių užpildymo metodika
Parajka, Blöschl (2008)	Austrija	Vidutinio klimato zonos kalnuotas regionas	63 % (dar didesnis žiemos mėnesiais)	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius</li> <li>• Filtravimas laike (pirmyn)</li> </ul>
Gafurov, Bårdossy (2009)	Afganistanas, Kokcha upės baseinas	Sausringos vasaros ir šaltos žiemos	25–99 %	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Filtravimas laike (pirmyn ir atgal)</li> <li>• Sniego linijos nustatymas</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius ir vietovės aukštį</li> <li>• Sniego dangos susidarymo ir nutirpimo kritinės datos</li> </ul>
Paudel, Andersen (2011)	Transhimalajų kalnai (Tibetas)	Kalnuotas, sausringas regionas	20–50 %	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Filtravimas laike (pirmyn ir atgal)</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius</li> <li>• Sniego linijos nustatymas</li> <li>• Filtravimas pagal iš anksto apibrėžtas sniego susidarymo ir nutirpimo zonas</li> </ul>
Foppa, Seiz (2012)	Šveicarijos Alpės	Kalnuotas vidutinių platumų regionas	39–51 %	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius</li> <li>• Filtravimas laike (pirmyn ir atgal)</li> </ul>



Tyrimas	Regionas	Klimato sąlygos	Debesuotumas	Duomenų trūkių užpildymo metodika
López-Burgos ir kt. (2013)	Arizona (JAV), Salt River baseinas	Sausringas kalnuotas regionas	39 %	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Filtravimas laike (pirmyn ir atgal)</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius</li> <li>• Sniego tikimybės nustatymas panaudojant logistinę regresiją su svoriniais koeficientais</li> </ul>
Yu ir kt. (2016)	Tibetas	Kalnuotas regionas su sausomis žiemomis ir vėsiomis vasaromis	46–55 %	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Duomenų apjungimas su IMS sniego rodikliais (IMS remiasi optinių ir mikrobangų jutiklių stebėjimų apjungimu)</li> </ul>
Dong, Menzel (2016)	Pietvakarių Vokietija	Pereinamasis klimatas iš vidutinių platumų jūrinio į žemyninį	Neaprašytas	<ul style="list-style-type: none"> <li>• „Aqua“ ir „Terra“ duomenų apjungimas</li> <li>• Filtravimas laike (pirmyn ir atgal)</li> <li>• Erdvinis filtravimas pagal artimiausius kaimyninius pikselius</li> <li>• Santykinės sniego tikimybės apskaičiavimas remiantis antžeminiais matavimais</li> <li>• Sniego duomenų korekcija atsižvelgiant į meteorologines sąlygas</li> </ul>

Kriosferos tyrimuose plačiai naudojamas C juostos (4–8 GHz) SAR jutiklis. XX a. pabaigoje atlikti tyrimai daugiausia rėmėsi ERS-1, ERS-2, Envisat bei RADARSAT palydovinių misijų C juostos SAR duomenimis (Lów ir kt., 2002; Nagler, Rott, 2000; Strozzi ir kt., 1999). Šiuo metu vis daugėja tyrimų, kurie sniego dangos ir sniego tirpsmo nustatymui naudoja Sentinel-1 SAR duomenis (Conde ir kt., 2019; Heilig ir kt., 2019; Nagler ir kt., 2016). Į kosmosą yra paleisti du identiški Sentinel-1 palydovai: 2014 m. paleistas Sentinel-1A, o 2016 m. paleistas Sentinel-1B. Panaudojus šių abiejų palydovų duomenis, informaciją apie sniego dangą ir jos būklę konkrečioje vietovėje galima gauti kas 5–7 dienas.

Vienas paprasčiausių ir dažniausiai naudojamų sniego kartografavimo būdų yra SAR atgalinės sklaidos santykio tarp šlapio sniego ir be sniego (arba sauso sniego) atvejų nustatymas (Malnes, Guneriusen, 2002; Nagler, Rott, 2000; Nagler ir kt., 2016). Metodas remiasi dviejų SAR vaizdų, gautų esant sniegui ir besniegėmis (arba sauso sniego) sąlygomis, palyginimu ir šių vaizdų atgalinės sklaidos santykio nustatymu. Apskaičiavus santykį, nustatoma kritinė jo reikšmė: už ją aukštesnės reikšmės priskiriamos besniegam (arba sauso sniego) atvejui, o esant žemesnėms reikšmėms – šlapiam sniegui. Šis metodas geriausiai tinka šlapiam sniegui nustatyti ir nėra veiksmingas esant sausam sniegui. SAR signalas yra ypač jautrus paviršiaus dielektrinėms savybėms ir, didėjant vandens kiekiui sniege, SAR atgalinės sklaidos koeficientas staigiai mažėja (Shi, Dozier, 1995; Strozzii ir kt., 1997). Sausame sniege C juostos SAR signalas gali prasiskverbti iki 20 m storio, o šlapiame sniege signalo prasiskverbimo storis gali sumažėti iki 3 cm. Taip nutinka, dėl to, kad sniege daugėjant vandens SAR signalo sąveika ima panašėti į SAR atspindį nuo skysto vandens (Tsai ir kt., 2019b). Kritinės santykio tarp sniego ir sniegu nepadengto paviršiaus atvejų ribos nustatymas yra pritaikytas įvairiuose regionuose bei naudojant skirtingus SAR jutiklius (Heilig ir kt., 2019; Nagler, Rott, 2000; Varade ir kt., 2019).

Be santykio metodo, sniego dangą taip pat galima nustatyti naudojant SAR interferometriją (InSAR) arba SAR poliarimetriją (PolSAR). InSAR privalumas yra tai, kad jis gali kartografuoti tiek šlapia, tiek sausą sniegą. Lyginant sniego ir besniegius atvejus SAR signalo koherencija yra didesnė sniegu nepadengtose teritorijose nei tose vietovėse, kuriose susiformavo sniego danga (Conde ir kt., 2019; Singh ir kt., 2008; Strozzii ir kt., 1999). PolSAR metodika remiasi skirtingais VV, VH, HV, HH SAR poliarizacijos sklaidos mechanizmais sausame ir šlapiame sniege bei sniegu nepadengtuose paviršiuose (Cloude, Pettier, 1996; Varade ir kt., 2020). Skirtingos poliarizacijos signalo sklaida tiesiogiai priklauso nuo fizinių sniego dangos parametrų. Pastaruoju metu daugėja tyrimų, kurie sniego dangos plotui, VAS ir kitų sniego dangos charakteristikų nustatymui iš SAR duomenų naudoja mašininio mokymosi algoritmus bei visų minėtų metodų (santykio, InSAR, PolSAR) derinius (Santi ir kt., 2020; Tsai ir kt., 2019b; Yang ir kt., 2020).

Daugelis tyrimų, kur naudojami SAR duomenys sniego dangai nustatyti, orientuojasi į kalnuotas teritorijas. Ypač plačiai nagrinėjamas SAR duomenų pritaikymas Himalajuose Azijoje ir Alpėse Europoje (Tsai ir kt., 2019a). Mokslinių tyrimų skaičius lygumose bei vietovėse su didele žemės dangos įvairove yra ribotas. Miškingi ir kitos tankios augalijos plotai SAR sniego dangos tyrimuose dažnai yra pašalinami iš duomenų analizės (He ir kt., 2017; Nagler, Rott, 2000; Thakur ir kt., 2013). Tyrimai, kuriuose SAR

naudojama sniego dangos stebėsenai miškuose, remiasi papildoma išmatuota arba sumodeliuota informacija apie medžių kamienų ir lajos tūrio poveikį radaro atgalinės sklaidos koeficientui (Luojus ir kt., 2007, 2009; Pulliainen ir kt., 2001). Taip pat buvo bandymų nustatyti skirtingas SAR atgalinės sklaidos koeficiento santykio reikšmes konkrečioms žemės dangos tipams (Löw ir kt., 2002; Schellenberger ir kt., 2012). Minėti tyrimai miškingose ir žemės ūkio paskirties teritorijose parodė, kad augmenija sumažina SAR sniego nustatymo algoritmų tikslumą. Tačiau (Tsai ir kt., 2019a) tyrimų apžvalgoje teigiama, kad miškinguose regionuose bei vietovėse su kintančiu žemės dangos tipu atlikta labai nedaug tyrimų. Todėl tokioms teritorijoms reiktų skirti daugiau dėmesio ir plėtoti SAR sniego aptikimo metodiką.

#### 1.4. Vandens atsargų sniege nustatymas

Duomenys apie VAS yra svarbūs hidrologijoje, ypač pavasario potvynių prognozavimui ir potvynių kontrolei (Shi ir kt., 2016). Tradiciškai VAS apskaičiuojamas atliekant sniego nuotraukas, tačiau tai laikui imlus darbas, o matavimai atspindi sniego dangos sąlygas nedidelėje teritorijoje. Modeliuojant arba naudojant palydovinius stebėjimus galima gauti erdvinius duomenis net ir sunkiai prieinamose vietovėse, be to jie yra dažnesni nei sniego nuotraukų matavimai (Shi ir kt., 2016). VAS galima nustatyti naudojant pasyviuosius mikrobangų radiometrus.

Žemės paviršiaus natūraliai skleidžiama mikrobangų spinduliuotė kinta priklausomai nuo sniego storio, VAS, sniego temperatūros, drėgnumo lygio ir dirvožemio būklės po sniego danga. Susiformavus sniego dangai mikrobangų signalas susilpnėja. Pasyvieji mikrobangų jutikliai fiksuoja ryškio temperatūrą, kurios kaita atspindi visų minėtų sniego dangos savybių svyravimus (Armstrong ir kt. 1993). Pasyvieji mikrobangų radiometrai paprastai turi labai mažą erdvinę skiriamąją gebą (15–25 km), todėl šių jutiklių duomenys tinka globaliems ar pusrutulio tyrimams, tačiau pritaikyti juos regioniniu ar vietiniu lygiu sudėtinga (Foster ir kt., 2005). Skiriamoji geba yra nulemta techninių apribojimų, nes norint ją padidinti reikia didinti antenos dydį, tačiau tai konstruojant ir iškeliant palydovus į kosmosą nėra įmanoma (Martin, 2013). Tačiau pasyviųjų mikrobangų radiometrų privalumas yra tai, kad jie gali stebėti žemės paviršių nepriklausomai nuo debesuotumo ir Saulės apšviestumo.

Mikrobangų išsklidymas sniege ir lede labai priklauso nuo mikrobangų dažnio, todėl naudojant kelis skirtingų dažnių ruožus galima gauti informaciją apie vandens atsargas sniege. VAS nustatyti dažniausiai

naudojami pasyviųjų mikrobangų jutiklių dažniai ties 19 GHz ir 37 GHz (Nolin, 2011). Šių dažnių spinduliuotės intensyvumo skirtumas pirmiausia padeda identifikuoti vietoves su sniego danga, tačiau taip pat yra naudojamas ir VAS bei sniego dangos storio nustatymo algoritmuose (Saberis ir kt., 2020; Takala ir kt., 2011). VAS nustatymo algoritmai dažniausiai remiasi empiriniu modeliavimu, susiejant ryškio temperatūrą su antžeminių matavimų rezultatais arba spinduliuotės perdavimo (angl. *radiative transfer*) sniego terpėje modeliavimu – modelis radiometrų užfiksuotą ryškio temperatūrą paverčia sniego dangos rodikliais (Nolin, 2011). Modelio duomenų transformacijai į ryškio temperatūrą taip pat naudojami ir mašininio mokymosi algoritmai (Saberis ir kt., 2020).

VAS nustatymas, remiantis pasyviųjų mikrobangų jutiklių užfiksuota ryškio temperatūra, nėra vienareikšmiškas, ypač, kai signalas surenkamas iš teritorijos su nevienalyte sniego danga, kurios sniego tankis, storis, kristalų dydis ir stratigrafija kinta erdvėje. VAS nustatymą taip pat apsunkina augmenija bei į pikselį patenkantys vandens telkiniai (Dong ir kt., 2005; Foster ir kt., 2005). Tyrimai parodė, kad dalis palydovinių VAS duomenų paklaidų atsiranda dėl VAS algoritmuose naudojamos parametrizacijos. Pavyzdžiui, kai naudojamas pastovus sniego tankis ar nekintanti sniego dangos stratigrafija (Saberis ir kt., 2020). Dažniausiai laikoma, kad pasyviaisiais mikrobangų jutikliais užfiksuotas signalas ateina iš homogeniškos sniego dangos, nors realiai sniego dangą dažnai sudaro keli skirtingo tankio sluoksniai. Šviežias sausas sniegas pasyviaisiais mikrobangų radiometrais nėra užfiksuojamas, nes jo įtaka mikrobangų spinduliavimo gebai yra labai maža (Tedesco, 2015). Vykstant metamorfozei ir didėjant sauso sniego kristalams, mikrobangų signalas silpnėja dėl sniego dangos tūryje vykstančio išsklaidymo. Signalas silpnėjimas stebimas ir didėjant bangos dažniui. Naudojant 10 GHz dažnį dominuoja signalas, ateinantis iš dirvožemio, ir jautrumas sniego dangos storiui yra mažas. Ties 37 GHz dažniu atvirkščiai – stora sniego danga labai susilpnina signalą (Kilpys ir kt., 2021; Nolin, 2011).

Spinduliavimo gebos mažėjimo priklausomybė nuo sniego dangos storio nėra tiesinė – egzistuoja prisotinimo lygis, kurį pasiekus spinduliavimo geba nebekinta, nors sniego dangą ir storėja. Taip yra todėl, kad esant gana storai (arba labai tankiai) sniego dangai mikrobangos nebeprasiskverbia pro sniegą ir pasyvusis mikrobangų jutiklis nebefiksuoja jokio pokyčio (Tedesco, 2015). Prisotinimo lygis yra atvirkščiai proporcingas dažniui bei priklauso nuo sniego dangos savybių (dalelių dydžio, tankio ir pan.). Nustatyta, kad pasyviųjų mikrobangų jutiklių duomenimis paremti algoritmai nėra veiksmingi, kai VAS vertės viršija 120–150 mm (Mätzler, 1994; Nolin,

2011; Takala ir kt., 2011). Taip yra dėl to, kad esant tokiai storai (arba labai tankiai) sniego dangai, pradeda dominuoti ne Žemės skleidžiamų mikrobangų išsklaidymas sniege, bet pačio sniego generuojama spinduliuotė, ir 36 GHz dažnyje ryškio temperatūra nebekinta, nors VAS ir didėja (Saberis ir kt., 2020).

Norint iš pasyviųjų mikrobangų radiometrų gauti detalias sniego dangos charakteristikas, galima naudoti pradinių duomenų skiriamosios gebos padidinimo (angl. *downscaling*) metodus (Huang ir kt., 2016; Li ir kt., 2015; Zhu ir kt., 2021). Dauguma palydovinių duomenų erdvinės skiriamosios gebos didinimo būdų yra tokie pat kaip ir klimato kaitos tyrimuose ir juos galima suskirstyti į dinaminis ir statistinius (Miro, Famiglietti, 2018). Statistiniai metodai grindžiami prielaida, kad pradiniai ir galutiniai duomenys yra susiję dinaminiais ryšiais ir šie ryšiai išlieka pastovūs, nepriklausomai nuo mastelio ir stebėjimo laikotarpio (Wilby ir kt., 2004). Dinaminiai metodai remiasi procesų ir ryšių modeliavimu, kai į fizikinį modelį įvedami smulkaus mastelio duomenys, o gaunami išvesties duomenys yra stambaus mastelio.

Vienas iš statistinių duomenų raiškos didinimo būdų yra dirbtiniai neuroniniai tinklai (DNT) (angl. *artificial neural networks*) (Zhu ir kt., 2021). DNT gerai tinka nustatyti ryšius tarp įvesties ir išvesties duomenų, kai aiškiai nėra žinomas fizinis kintamųjų tarpusavio ryšys ar jų sąveika. Daugeliu atveju DNT prilygsta bet kokiai tiesinei funkcijai ir lengvai gali ją pakeisti (Cybenko, 1989). DNT dažniausiai susideda iš kelių sluoksnių ir neuronų rinkinio, o jo struktūra panaši į žmogaus nervų sistemas. Ieškant sprendinio konkretaus neurono svorinis koeficientas ir paklaida priklauso nuo ankstesnių sluoksnių neuronų sąveikos. Neurono išvesties duomenys yra paremti įvesties duomenų svorinių koeficientų bei paklaidų, atsirandančių neuronų aktyvacijos funkcijos sprendimo metu, suma. Daugiasluoksnis DNT turi įvesties ir išvesties sluoksnius bei vieną ar kelis paslėptus sluoksnius (Rumelhart ir kt., 1985). Neuronų skaičius įvesties sluoksnyje yra lygus pateiktų kintamųjų skaičiui, o išvesties sluoksnyje – norimų rezultatų skaičiui. Šie rodikliai pateikiami DNT apmokymo metu ir sudarius modelį nėra keičiami. Norint įvesti naujus parametrus DNT turi būti apmokomas iš naujo.

Dirbtiniai neuroniniai tinklai pasižymi tuo, kad gali apdoroti įvairių tipų duomenis ir efektyviai išmokyti ir nustatyti sudėtingus įvesties ir išvesties duomenų ryšius (Alemohammad ir kt., 2018; Miro, Famiglietti, 2018). DNT gebėjimas išmokyti sudėtingus ryšius ir lengvas modelio taikymas po DNT apmokymo yra viena iš priežasčių, kodėl jie vis dažniau naudojami geomoksluose. DNT yra naudojami kuriant aukštos skiriamosios gebos

dirvožemio drėgmės, kritulių palydovinių duomenų rinkinius bei gruntinio vandens paieškos algoritmus (Alemohammad ir kt., 2018; Alexakis, Tsanis, 2016; Miro, Famiglietti, 2018; Sharifi ir kt., 2019).

### 1.5. Sniego dangos tyrimai Baltijos valstybėse

Baltijos valstybės užima maždaug 175 000 km<sup>2</sup> plotą. Tai lygumų regionas su žemomis kalvomis – aukščiausias taškas yra tik 318 m virš jūros lygio. Pagal W. Köppeno klimato klasifikaciją beveik visas regionas priklauso Dfb klimato tipui, kuris apibūdinamas kaip drėgnas žemyninis klimatas su šiltomis (kartais karštomis) vasaromis ir šaltomis (kartais labai šaltomis) žiemomis. Tik kai kurios pajūrio dalys priklauso klimato tipui Cfb, kuris apibūdinamas kaip vidutinių platumų jūrinis klimatas (Chen, Chen, 2013).

Žiemos sezonu Rytinį Baltijos jūros regioną dažniausiai dengia sniegas, tačiau pastaraisiais dešimtmečiais stebimos sniego dangos ploto ir trukmės mažėjimo tendencijos (Rasmus ir kt., 2015). Tai atitinka ir ilgalaikes sniego dangos ploto ir trukmės mažėjimo tendencijas Šiaurės pusrutulyje, kurios daugiausia siejamos su klimato kaita ir vidutinės oro temperatūros augimu (Bulygina ir kt., 2009; Rasmus ir kt., 2015; Vaughan ir kt., 2013). Tyrimai rodo, kad vidutinė oro temperatūra Baltijos šalyse sparčiausiai auga žiemą ir pavasarį (Jaagus ir kt., 2014; Lizuma ir kt., 2007). Vidutinės temperatūros augimas ir vakarų pernašos intensyvėjimas taip pat lemia didesnę žiemos kritulių kiekį (Jaagus ir kt., 2016; The BACC II Author Team, 2015). Nustatyta, kad Baltijos valstybėse ryškus kritulių, sniego dangos ir upių nuotėkio režimo pokytis, susijęs su pasauline klimato kaita, įvyko maždaug 1988-1989 m. (Jaagus ir kt., 2016; Jaagus, Sepp, 2016).

Baltijos valstybėse atliktuose tyrimuose daug dėmesio skiriama sniego dangos režimo ir didelio masto atmosferos cirkuliacijos ryšiams (Keršytė, Rimkus, 2014; Serreze ir kt., 1997). Stipri vakarų cirkuliacija iš Šiaurės Atlanto į Baltijos jūros regioną atneša palyginti šiltą orą ir lemia trumpalaikę sniego dangą. Silpna vakarinė pernaša atvirkščiai – indikuoja sąlygas palankias šalto žemyninio oro prietakai ir stabilios sniego dangos formavimuisi. Regionines sniego dangos variacijas daugiausia lemia atmosferos cirkuliacija (Draveniece, 2009; Klavins, Rodinov, 2010), o jos svyravimus neblogai apibūdina Šiaurės Atlanto osciliacija (NAO) (Jaagus ir kt., 2017; Kim ir kt., 2013; Rimkus ir kt., 2014; Szwed ir kt., 2017; Ye, Lau, 2016) ir Arkties osciliacija (Cohen ir kt., 2014; Jaagus ir kt., 2014, 2017). Tyrimai rodo, kad teigiamas/neigiamas NAO fazes atitinka sniego dangos parametrų sumažėjimas/padidėjimas (Jaagus ir kt., 2017; Kim ir kt., 2013;

Rimkus ir kt., 2014; Szwed ir kt., 2017; Ye, Lau, 2016). Teigiamos NAO fazės metu padidėja slėgio skirtumas tarp Islandijos depresijos ir Azorų anticiklono, todėl Šiaurės Atlante sustiprėja zoninė oro masės pernaša. Esant neigiamai NAO fazei, priešingai – vakarų zoninė pernaša tampa silpnesnė.

Atmosferos cirkuliacijos, temperatūros ir kritulių pokyčiai lemia besikeičiančias sniego dangos erdvines ir trukmės charakteristikas. Baltijos valstybėse XXI amžiuje stebimas vėlesnis sniego dangos susidarymas ir ankstesnis sniego nutirpimas, dėl to mažėja metinis dienų su sniego danga skaičius (Draveniece ir kt., 2007; Galvonaitė ir kt., 2013; Tooming, Kadaja, 2006). Per dešimtmetį regione sniego dangos trukmė sumažėja maždaug 3-4 dienomis, o pokyčių greitis labai gerai atspindi vidutinės žiemos oro temperatūros augimo tempus (Rimkus ir kt., 2014). Be to, vis dažniau žiemomis pasitaiko atlydžiai ir didėja sniego dangos nepastovumas (Rasmus ir kt., 2015; Rimkus ir kt., 2014). Manoma, kad šie stebimi sniego fenologijos pokyčiai turės pasekmių vandens balansui ir upių nuotėkio maksimumui Rytų Baltijos regione (Jaagus ir kt., 2017; Stonevičius ir kt., 2017). Suomijoje atlikti tyrimai parodė, kad vykstantys klimato pokyčiai neigiamai veikia žiemos turizmą. Tikėtina, kad tai turės ir socialinio poveikį – lygumų slidinėjimo tradicijų nykimą ir neigiamą ekonominį poveikį žiemos turizmo regionuose (Landauer ir kt., 2015).

Ir nors Baltijos valstybėse stebimas sniego dangos trukmės mažėjimas, tačiau vidutinis maksimalus sniego storis keičiasi ne daug ir pokyčiai nėra vienodo ženklo (Rimkus ir kt., 2014; Zhong ir kt., 2018). Taip yra dėl to, kad maksimalų sniego storį šiame regione dažnai lemia ne sezoninio sniego akumuliacija, bet trumpi ir intensyvūs snygio atvejai. Ypač tokie krituliai didelę įtaką maksimaliam sniego storiui turi pajūryje, kur, dėl šildančios jūros įtakos žiemą, yra palankesnės sąlygos susidaryti intensyvesniems krituliams (Rimkus ir kt., 2014). Pastebėta, kad kai kur rytų Europoje ir Eurazijoje, dėl tokio jūros poveikio, šaltojo sezono pradžioje (lapkričio mėn.) ir pabaigoje (kovo mėn.) maksimalus sniego storis 1966–2009 m. laikotarpiu padidėjo (Zhong ir kt., 2018).

Sniego dangos parametrams įtakos turi ne tik meteorologiniai veiksniai (krituliai, temperatūra, spinduliuotė, vėjas), bet ir geografiniai bei kraštovaizdžio elementai: atstumas nuo jūros, vietovės aukštis, augalijos pobūdis (Draveniece ir kt., 2007; Galvonaitė ir kt., 2007; Jaagus, 1997; Tong ir kt. 2009; Zhong ir kt., 2014; Zhong ir kt., 2018). Priklausomybę nuo kraštovaizdžio veiksnių pastebėta nagrinėjant tiek skystus, tiek kietus kritulius (Jaagus ir kt., 2009; Remm ir kt., 2011). Didžiausią įtaką kietų kritulių ir sniego dangos pasiskirstymui turi atstumas nuo Baltijos jūros bei vietovės aukštis.

Kitas svarbus aplinkos veiksnys veikiantis sniego dangos trukmę ir storį yra miškai. Miškuose dalis sniego yra sulaikoma medžių lajos, todėl sezono pradžioje sniego storis miškuose yra mažesnis. Tačiau medžių laja taip pat pakeičia Saulės spinduliuotės prietakos intensyvumą, ir tai sulėtina sniego tirpimą. Tai lemia, kad šaltojo sezono pabaigoje miškuose sniegas išsilaiko ilgiau ir yra storesnis nei atvirose vietovėse (Rimkus ir kt., 2014; Roth, Nolin, 2017). Šis ryšys tarp augalijos lajos ir sniego dangos formavimosi ir tirpimo priklauso nuo miško tipo, vietovės klimato ir reljefo (Roth, Nolin, 2017). Baltijos valstybėse atliktų tyrimų rezultatai sutampa su tyrimais kituose pasaulio regionuose, kur buvo nagrinėtas fizinių sniego dangos savybių ryšys su kraštovaizdžio elementais ir žemės dangos tipais (Andreadis ir kt., 2009; Kitaev ir kt., 2002; Roth, Nolin, 2017; Varhola ir kt., 2010).



## 2. PRADINIAI DUOMENYS

Šiame skyriuje pateikti disertacijoje naudotų sausumos MS ir palydovinių duomenų aprašymai:

- pirmoje dalyje aptariama, kodėl skirtingose disertacijos dalyse nagrinėjami skirtingi regionai bei laikotarpiai ir kaip tai susiję su palydoviniaisiais jutikliais ir jų duomenų prieinamumu.
- Antroje dalyje apžvelgiami naudoti antžeminių stočių sniego dangos duomenys, stebėjimų tvarka ir stebėjimų geografija.
- Trečioje dalyje pristatomi globalūs ATMS jutiklio, GFS modelio ir sausumos stočių duomenys naudoti snygio nustatymui.
- Ketvirtoje dalyje aptariamas MODIS sniego dangos duomenų rinkinys ir jo sudarymo principas.
- Penktoje dalyje apžvelgiamos Sentinel-1 SAR duomenų savybės bei CORINE žemės dangos tipų klasifikacija, kuri naudota kritinių SAR atgalinės sklaidos reikšmių nustatymui.
- Šešta dalis skirta HSAF VAS duomenų rinkinio pristatymui ir papildomų (Žemės dangos, vietovės aukščio, minimalios paros oro temperatūros) duomenų aprašymui.

### 2.1. Duomenų tipai ir tyrimo regionai

Darbe naudoti palydoviniai ir antžeminių stočių duomenys apima skirtingus laikotarpius ir regionus (2.1 lentelė). Tokių laikotarpių ir regionų įvairovę pirmiausia lėmė palydovinių jutiklių tipas, skiriamoji geba bei palydovo paleidimo metai. Regiono pasirinkimui įtakos taip pat turėjo nagrinėjamas sniego dangos rodiklis ir MS duomenų prieinamumas.

Palydoviniai jutikliai, kurie pasižymi aukšta skiriamąja geba (pvz.: Sentinel-1, Sentinel-2), turi siaurą žvalgos juostą (150–300 km). Todėl vieno stebėjimo metu šie jutikliai apima tik pakankamai nedidelę teritoriją. Sentinel palydovų duomenys šiame tyrime buvo naudoti sniego dangos parametrų Šventosios baseine tirti (2.1 lentelė). Be to, aukštos skiriamosios gebos palydovinių duomenų analizė reikalauja daug kompiuterinių išteklių ir tai taip pat apribojo galimybes panaudoti Sentinel-1 ir Sentinel-2 duomenis sniego dangos tyrimams visoje Lietuvos teritorijoje ar Baltijos valstybėse.

Vidutinės skiriamosios gebos MODIS duomenys padengia visą Žemės paviršių kiekvieną dieną, todėl jie tinka regioninio arba globalaus masto

sniego dangos tyrimams. Tačiau detalūs kiekvienos dienos sniego dangos storio matavimai MS buvo prieinami tik Lietuvoje, todėl ir MODIS duomenų analizė atlikta šiai teritorijai (2.1 lentelė).

**2.1 lentelė.** Tyrime naudotų duomenų, tyrimo regionų ir meteorologinių rodiklių apibendrinimas.

Duomenų tipas	Skiriamoji geba	Tyrimo regionas	Laikotarpis	Matuotas arba apskaičiuotas rodiklis
MS	Taškiniai duomenys	Pasaulis	2015–2018	<ul style="list-style-type: none"> <li>• Kritulių kiekis ir tipas</li> <li>• Oro temperatūra</li> <li>• Santykinė drėgmė</li> </ul>
		Baltijos valstybės	1961–2015	<ul style="list-style-type: none"> <li>• Sniego dangos storis</li> <li>• Padengimo sniegu balas</li> <li>• Oro temperatūra</li> <li>• Kritulių kiekis</li> </ul>
			2012–2017	<ul style="list-style-type: none"> <li>• VAS</li> </ul>
		Lietuva	2002–2018	<ul style="list-style-type: none"> <li>• Sniego dangos storis</li> <li>• Padengimo sniegu balas</li> </ul>
		Šventosios baseinas	2014–2019	<ul style="list-style-type: none"> <li>• Sniego dangos storis</li> <li>• Oro temperatūra</li> </ul>
ATMS	15 km	Pasaulis	2015–2018	<ul style="list-style-type: none"> <li>• Kritulių tipas</li> </ul>
MODIS	500 m	Lietuva	2002–2018	<ul style="list-style-type: none"> <li>• Sniego danga</li> <li>• Dienų su sniego danga skaičius</li> </ul>
Sentinel-1 SAR	20 m	Šventosios baseinas	2014–2019	<ul style="list-style-type: none"> <li>• Sniego danga</li> </ul>
Sentinel-2	20 m	Šventosios baseinas	2014–2019	<ul style="list-style-type: none"> <li>• Sniego danga</li> </ul>
HSAF VAS	0,25°	Baltijos valstybės	2012–2017	<ul style="list-style-type: none"> <li>• VAS</li> </ul>

Pasyviųjų mikrobangų radiometrų duomenys yra žemos skiriamosios gebos (15–30 km), tačiau turi plačią žvalgos juostą (1400–2600 km). Šių jutiklių duomenys gerai tinka tyrinėti pusrutulio ar globalaus masto

procesus. Šiame darbe ATMS duomenys naudoti snygio nustatymui visame pasaulyje (2.1 lentelė). HSAF VAS duomenų rinkinys, kuris sudarytas remiantis pasyviųjų mikrobangų radiometrų duomenimis, naudotas VAS tyrimui Baltijos valstybėse. Šio regiono pasirinkimą lėmė antžeminių VAS duomenų prieinamumas (2.1 lentelė).

Antžeminių meteorologinių stebėjimo tinklo duomenys buvo naudojami palydovinių duomenų verifikacijai bei mašininio mokymosi algoritmų sudarymui ir apmokymui. MS duomenų pasirinkimą ir regioną lėmė anksčiau aptartos palydovinių duomenų savybės bei stebimos teritorijos apimtis. Daugiausiai MS duomenų buvo naudojama iš Baltijos valstybių (2.1 lentelė) ir remiantis jais buvo aprašytos ilgalaikės sniego dangos kaitos tendencijos šiame regione. Darbe naudojami palydovinių, o kartu ir MS, duomenų laikotarpiai skiriasi, nes nagrinėjami palydoviniai jutikliai buvo paleisti skirtingu metu (Sentinel-1, Sentinel-2, MODIS) arba jų duomenų rinkiniai buvo prieinami tik nuo tam tikrų metų (ATMS, HSAF VAS).

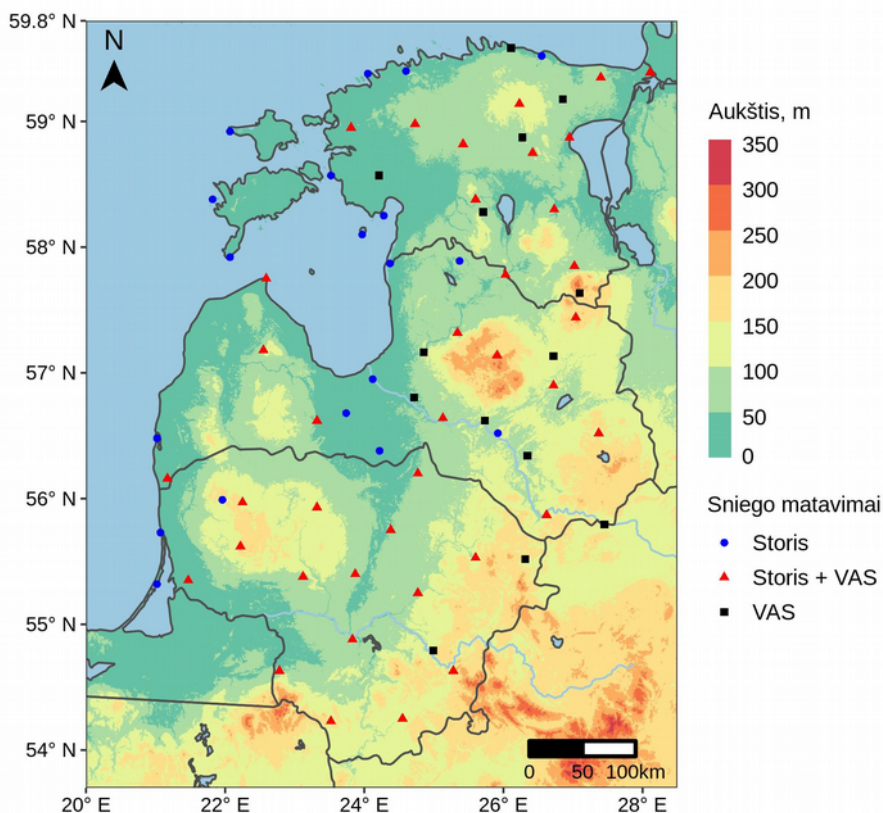
## 2.2. Sniego dangos stebėjimai meteorologijos stotyse

Sniego dangos analizė tradiciškai remiasi sniego dangos ir storio stebėjimais meteorologinėse stotyse (Draveniece ir kt., 2007; Galvonaitė ir kt., 2007; Rimkus ir kt., 2014; Tooming, Kadaja, 2006). Tačiau antžeminių matavimų tinklas yra gana negausus, ypač valstybių pasienio regionuose. Todėl stebėjimai iš kaimyninių šalių gali padėti užpildyti šias duomenų spragas ir tiksliau nustatyti sniego dangos rodiklių erdvinį pasiskirstymą.

Šiame tyrime analizuoti du pagrindiniai sniego dangos parametrai Baltijos valstybėse: dienų su sniego danga skaičius ir maksimalus storis. Šie rodikliai buvo apskaičiuoti 55 metų laikotarpiu (1961–2015 m.) naudojant šalčio laikotarpio (spalio–balandžio) mėnesių duomenis. Apskaičiuotas sezoninis ir atskirų mėnesių dienų su sniego danga skaičius bei maksimalus sniego storis buvo naudojami analizuojant erdvinį sniego dangos pasiskirstymą Baltijos šalyse ir daugiametę šių rodiklių kaitą.

Sniego dangos duomenys 1961–2015 m. laikotarpiui buvo gauti iš 57 meteorologijos stočių: 21 buvo Estijoje, 19 – Latvijoje ir 17 – Lietuvoje (2.1 pav.). Detalus stočių sąrašas pateiktas 1 priede. Meteorologinėse stotyse sniego dangos matavimai atliekami kiekvieną dieną 06:00 UTC. Vietovės padengimas sniegu įvertinamas naudojamas 10 balų sistemą, kur 0 reiškia, kad sniego nėra, o 10 reiškia, kad 100% matomos teritorijos yra padengta sniegu. Laikoma, kad diena yra su sniego danga, jei sniegas užima daugiau nei 50 % stotį supančios teritorijos (> 5 balai).

MS sniego duomenyse pasitaikė trūkių, tačiau jie sudarė tik apie 0,5% visų duomenų. Duomenų trūkiai buvo užpildyti pagal artimiausių meteorologijos stočių duomenis, naudojant svorinius koeficientus. Tyrime klimato norma buvo laikomas 1981–2010 m. laikotarpis. Šiam ataskaitiniam laikotarpiui buvo apskaičiuotos vidutinės sniego dangos rodiklių reikšmės Baltijos valstybėse ir jos buvo naudojamos skaičiuojant nuokrypius.



**2.1 pav.** Meteorologijos stotys Baltijos valstybėse, kurių sniego dangos stebėjimo duomenys buvo naudoti šiame darbe. Mėlynai ir raudonai pažymėtose stotyse sniego dangos storio matavimai 1961–2015 m. laikotarpiu buvo atliekami kasdien. Juodai pažymėtose stotyse nebuvo vykdomi kasdieniniai sniego dangos storio matavimai, tačiau kas 5–10 dienų buvo atliekami VAS matavimai (sniego nuotraukos).

Siekiant nustatyti sniego dangos rodiklių priklausomybę nuo meteorologinių sąlygų, analizuojamo laikotarpio (1961–2015) mėnesių vidutinė oro temperatūra ir kritulių kiekis buvo paimti iš CRU TS4.01 duomenų rinkinio, kurio erdvinė skiriamoji geba  $0,5 \times 0,5^\circ$  (Harris, Jones,

2017). Šiame tyrime buvo naudojamos vidutinės šio duomenų rinkinio gardelių vertės tiriamoje teritorijoje (53–60° š. pl.; 20–30° r. ilg.).

Duomenys apie vietovės aukštį gauti panaudojant JAV Nacionalinės aeronautikos ir kosmoso administracijos (NASA) SRTM (angl. *Shuttle Radar Topographic Mission*) skaitmeninio reljefo aukščio modelį (DEM – angl. *Digital Elevation Model*) (Jarvis ir kt., 2008).

Be sniego storio ir dienų su sniego danga šiame darbe taip pat buvo nagrinėtos ir vandens atsargos sniege. Vandens atsargos sniege meteorologinėse stotyse nėra matuojamos kasdien, jos nustatomos ekspedicinių matavimų metu, kurie vadinami „sniego nuotraukomis“ (angl. *snow survey*). Sniego nuotraukos žiemą atliekamos kas 10 dienų, o pavasarį, sniego dangos abliacijos laikotarpiu, kas 5 dienas. Matavimai atliekami tik tuomet, jei sniegas dengia daugiau nei 50 % regimo ploto aplink MS. Sniego nuotraukų maršruto ilgis atviroje vietovėje svyruoja nuo 1000 iki 2000 metrų, o miške dažniausiai būna 500 metrų. Atviraime lauke atliekama 100 matavimų (kas 10–20 m), o miške 50 matavimų (kas 10 m). Tos dienos VAS reikšmė gaunama išvedant visų sniego nuotraukos metų atliktų taškinių matavimų vidurkį. VAS matavimų duomenys pateikiami 1 mm tikslumu (LHMT, 2004). Tyrime naudoti 2012–2018 m. sniego nuotraukų VAS duomenys iš 52 meteorologijos stočių Baltijos šalyse (2.1 pav.) bei iš disertacijos metu atliktų lauko matavimų (2.2 pav.).



**2.2 pav.** Sniego nuotraukų maršrutai Neries regioniniame parke (Vilniaus raj.): 1) atviraime lauke (54.79092 °š. pl., 24.99717 °r. ilg.); 2) miške (54.78563 °š. pl., 24.96308 °r. ilg.).

2016–2019 m. buvo atliekamos papildomos sniego nuotraukos Vilniaus raj., Neries regioniniame parke, Elniakampio ežero apylinkėse. Jų metu buvo matuojamas sniego storis ir VAS atviroje pievoje bei miške (pušyne) 2 km ilgio maršrutuose (2.2 pav.). Centrinės matavimų poligonų koordinatės: 1) atvirame lauke – 54,79092 °š. pl., 24.99717 °r. ilg.; 2) miške – 54.78563 °š. pl., 24,96308 °r. ilg.

Atliekant sniego nuotraukas, sniego dangos storio ir VAS matavimai buvo vykdomi maždaug kas 100 metrų. Tiek atviroje vietovėje, tiek miške buvo atlikta po 20 matavimų. Sniego nuotraukų metu buvo vertinamas ir sniego kiekis esantis ant medžių lajos. Šie stebėjimai buvo vizualūs ir paremti balų sistema: 0 – sniego ant medžių lajos visai nėra, 1 – sniego yra nedaug arba susidaręs šerkšnas, 2 – sniego ant lajos yra gausiai.

**2.2 lentelė.** Doktorantūros metu, Neries regioniniame parke, atliktų papildomų sniego nuotraukų skaičius ir didžiausios išmatuotos reikšmės.

Šaltasis sezonas	Sniego nuotraukų skaičius	Sniego storio maksimumas, cm	VAS maksimumas, mm
2016/2017	7	16	26
2017/2018	5	30	57
2018/2019	5	32	61

Matavimai Neries regioniniame parke buvo atliekami 10–13 val. vietos laiku, siekiant, kada antžeminių stebėjimų laikas maždaug sutaptų su „Terra“ palydovo praskridimu virš Lietuvos (~11.15 val.). Iš viso 2016–2019 m. laikotarpiu atliktą 17 sniego nuotraukų (2.2 lentelė).

### 2.3. ATMS jutiklio, GFS modelio duomenys ir kritulių duomenys iš antžeminių stočių

ATMS pasyvusis zonduojantis mikrobangų radiometras yra įmontuotas „Suomi-NPP“ bei „NOAA-20“ palydovuose. Šie palydovai skrieja maždaug 824 km aukštyje virš Žemės paviršiaus, o jų orbitos yra poliarinės – Saulės sinchroninės (angl. *Sun-synchronous*) (Weng ir kt., 2011). Šiame tyrime naudoti „Suomi-NPP“ ATMS jutiklio duomenys.

ATMS jutiklio žvalgos juosta apima 2600 km. ATMS skenuoja Žemės paviršių 22-jose spektrinėse juostose statmenai palydovo skridimo trajektorijai. Spektrinių juostų dažniai kinta nuo 23,8 iki 185 GHz ir jų pagalba, nepriklausomai nuo debesuotumo, galima zonuoti skirtingus

atmosferos sluoksnius nuo paviršiaus iki atmosferos viršutinės ribos (Kim ir kt., 2014). Debesys ir vandens garai neslopina mikrobangų sklidimo, todėl ATMS gali matuoti vertikalius atmosferos temperatūros ir drėgmės profilius beveik bet koku oru. ATMS jutiklio fiksuojamą signalą gali iškreipti tik intensyvūs ištisiniai arba liūtiniai krituliai (Goldberg ir kt., 2013).

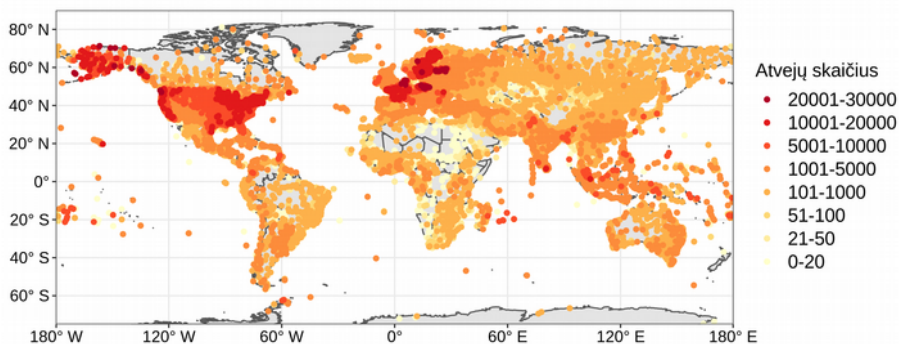
Priklausomai nuo dažnio, ATMS spektrinės juostos gali padėti nustatyti skirtingus atmosferos temperatūros ir drėgmės parametrus. Spektrinės juostos, kurių centrinis dažnis 23,8, 31,4 ir 88,2 GHz (juostų nr. 1, 2, 16), naudojamos nustatyti vandens kiekį debesyse, integruotą vandens kiekį atmosferoje (angl. *total precipitable water*) bei lietaus intensyvumą (Weng ir kt., 2003). 50,3–57,5 GHz dažnio skenavimo juostos (juostų nr. 3–15) pritaikytos nustatyti vertikalius atmosferos temperatūros profilius, nuo 0 iki 40 km aukščio. 165–185 GHz dažnius fiksuojančios ATMS spektrinės juostos (nr. 17–22) taikomos nustatyti vertikalų vandens garų kiekį nuo 0 iki 10 km aukščio (Goldberg ir kt., 2013). ATMS skiriamoji geba ties nadyru kinta nuo 15 iki 75 km ir priklauso nuo spektrinės juostos. Detali informacija apie ATMS jutiklio spektrines juostas pateikta 2 priede.

Snygio klasifikacijos algoritmui sudaryti buvo naudojami 2012–2018 m. globalūs ATMS duomenys, kurie gauti iš ESSIC (angl. *Earth System Science Interdisciplinary Center*) duomenų bazės. ATMS stebėjimo duomenų patikrai ir algoritmo apmokymui buvo naudoti sausumos stočių kritulių stebėjimai iš viso pasaulio, kurie gauti iš NOAA integruotos paviršiaus duomenų bazės (ISD) (angl. *Integrated Surface Database*) (2.3 pav.). MS duomenis sudarė trijų tipų šaltiniai:

1. JAV ASOS/AWOS tinklo informacija (automatinė paviršiaus stebėjimo sistema / automatinė oro stebėjimo sistema).
2. Automatinių meteorologinių stočių duomenys iš viso pasaulio.
3. Rankinių meteorologijos stočių iš viso pasaulio stebėjimai.

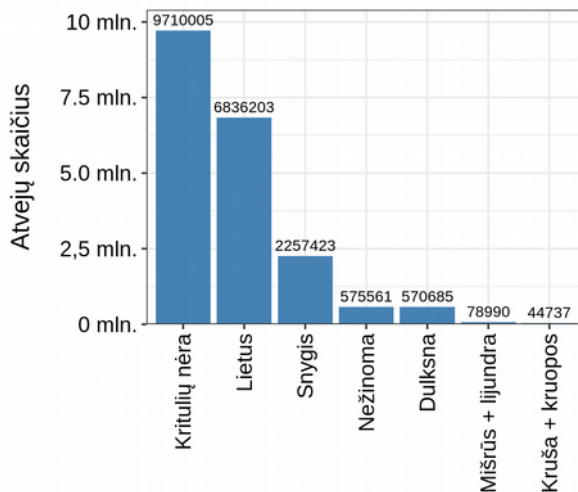
Kai kuriais atvejais informacija iš šių trijų duomenų šaltinių dubliavosi (pvz.: 00, 03, 06, 09, 12, 15, 18, 21 UTC laiku tie patys matavimai buvo pateikiami prie automatinių ir rankinių stočių). Tokiu atveju meteorologiniai stebėjimai buvo apjungti pagal šiuos prioritetus:

1. Rankiniai stebėjimai.
2. Automatiniai ASOS / AWOS jutikliai iš JAV.
3. Automatiniai jutikliai.
4. Kai tą pačią valandą toje pačioje vietoje buvo keli automatinių stočių pranešimai (pvz., kai duomenys pateikiami kas 3–6 minutes), buvo naudojami tie pranešimai, kuriuose buvo pateiktas atmosferos slėgis. Jei atmosferos slėgis nebuvo matuojamas, tuomet buvo naudojami duomenys artimiausi konkrečiai valandai (00–24 UTC).



**2.3 pav.** Meteorologijos stotys pasaulyje, kuriose nustatomas kritulių tipas, ir tokių pranešimų skaičius 2012–2018 m. laikotarpiu.

Antžeminių sausumos stočių matavimai, kurių metu buvo fiksuojami tik kritulių pėdsakai, analizėje naudojami nebuvo. Priklausomai nuo MS tipo ir pasaulio regiono yra naudojama iki 100 skirtingų kodų apibūdinančių orų sąlygas stebėjimų metu. Visi šie skirtingi stebėjimai buvo apibendrinti į 9 kategorijas: 1) kritulių nėra, 2) lietus, 3) sniegas, 4) mišrūs krituliai, 5) lijundra, 6) dulksna, 7) sniego/ledo kruopos, 8) kruša, 9) kritulių tipas nežinomas (2.4 pav.). Tačiau sudarant snygio nustatymo iš ATMS duomenų algoritmą buvo naudojami tik tie atvejai, kada MS buvo užfiksuotos šios trys kategorijos: „lietus“, „sniegas“ ir „kritulių nėra“.



**2.4 pav.** Skirtingų kritulių tipų atvejų skaičius meteorologijos stotyse pasaulyje 2012–2018 m. laikotarpiu.



Pirminiame MS duomenų rinkinyje nebuvo pateikta santykinė oro drėgmė (RH, %), tačiau ji buvo nustatyta pagal oro ir rasos taško temperatūrą. Skaičiavimams naudota Lawrence (2005) pasiūlyta formulė, kurią savo veikloje taiko JAV Nacionalinė orų tarnyba (NWS) (angl. *National Weather Service*). Taip pat buvo apskaičiuotas kiekvienos stoties atstumas iki jūros. Jūrų ir vandenynų kranto linija buvo gauta iš „Natural Earth“ duomenų bazės (Natural Earth, 2009). Naudoti 1:110000000 (1 cm = 1100 km) mastelio duomenys ir kiekvienai MS, pagal jos koordinates, rastas trumpiausias atstumas iki vandenyno pakrantės naudojant Haversine formulę (neatsižvelgiant į reljefą) (Sinnott, 1984).

### 2.3. lentelė. GFS modelio analizės išvesties rodiklių aprašymas.

Santrumpa	Matavimo vienetas	Paaikškinimas
HGT	gpm	Geopotencialus aukštis
TMP	K	Temperatūra
RH	%	Santykinė drėgmė
VVEL	Pa/s	Vertikalus greitis izobarinėse koordinatėse
CLWMR	kg/kg	Mišinio santykis debesyse
PRES	Pa	Slėgis
CWAT	kg/m <sup>2</sup>	Vandens kiekis debesyse
PWAT	kg/m <sup>2</sup>	Vandens kiekis, kuris gali iškristi kaip krituliai
UGRD_10m	m/s	Vėjo vektoriaus u-dedamoji 10 m aukštyje
VGRD_10m	m/s	Vėjo vektoriaus v-dedamoji 10 m aukštyje
WEASD	kg/m <sup>2</sup>	Vandens atsargos sniege

Kartu su ATMS ir antžeminiais duomenimis snygio nustatymo algoritmui sudaryti buvo naudojami ir NOAA GFS (angl. *Global Forecast System*) skaitmeninio orų modelio analizės duomenys. GFS analizės duomenys gauti iš NOAA NCEI (angl. *National Centers for Environmental Information*). Šio globalaus modelio analizės duomenys pateikiami 0.5° x 0.5° skiriamąja geba kiekvieną dieną kas 3 val. (00, 03, 06, 09, 12, 15, 18, 21 UTC). Modelis pateikia duomenis Žemės paviršiuje bei 20-tyje vertikalių atmosferos lygių nuo 200 iki 1000 hPa – iš viso 142 skirtingus rodiklius. Pagrindinių GFS modelio rodiklių trumpas aprašymas pateiktas 2.3 lentelėje.

Darbe naudoti GFS analizės duomenys – t. y. ne modelio prognozė, bet modelio asimiliuoti įvairių stebėjimų (MS, radiozondavimo, radarų ir t. t.) duomenys. Meteorologiniai stebėjimai paprastai yra netolygiai pasiskirstę erdvėje ir laike. Naudojant GFS modelio duomenų asimiliacijos sistemą, stebėjimų rezultatai yra pritaikomi prie reguliaraus geografinio tinklelio bei laiko žingsnio ir taip sudaromi vientisi atmosferos rodiklių sluoksniai.

#### 2.4. MODIS jutiklio duomenys

Šiame tyrime buvo naudojami kasdieniniai MODIS jutiklių užfiksuoti sniego dangos duomenys. Priklausomai nuo palydovo šie duomenys skirstomi į du rinkinius (Hall, Riggs, 2016): MOD10A1 – „Terra“ palydovo MODIS jutiklio duomenys ir MYD10A1 – „Aqua“ palydovo duomenys. „Terra“ ir „Aqua“ palydovai skrenda orbita artima poliarinei, trijų valandų skirtumu vienas nuo kito. MODIS matuoja Saulės spinduliuotės atspindį nuo paklotinio paviršiaus, naudodamas 36 spektrines juostas regimajame ir artimajame infraraudonajame spektruose (0,4–14,4  $\mu\text{m}$ ) (Frazier, 2018).

MOD10A1 ir MYD10A1 duomenų rinkiniai (6 versija) pateikiami 500x500 m gardelėse sinusoidinėje projekcijoje, o rinkinį sudaro skirtingi duomenų sluoksniai: sniego rodikliai, debesų ir duomenų kokybės klasifikatoriai. MOD10A1 ir MYD10A1 sniego dangos duomenų sluoksnis sudarytas naudojant normalizuotą sniego skirtumo indeksą (NDSI – angl. *Normalized Difference Snow Index*) bei papildomus ryškio temperatūros ir paviršiaus atspindžio duomenų filtrus (Hall, Riggs, 2016; Hall ir kt., 1995; Klein ir kt., 1998).

Sniegas regimajame spektre didžiąją dalį spinduliuotės atspindi, o artimojo infraraudonojo spektro bangas beveik visas sugeria. Tuo tarpu debesys atspindi bemaž visą šių abiejų spektrų spinduliuotę ir tai leidžia juos atskirti nuo sniego dangos. NDSI apskaičiuojamas naudojant MODIS 4 ir 6 spektrines juostas (jų centrinis bangos ilgis atitinkamai yra 0,55 ir 1,64  $\mu\text{m}$ ) (Hall ir kt., 2002):

$$NDSI = \frac{VIS_{0,55} - SWIR_{1,64}}{VIS_{0,55} + SWIR_{1,64}} \quad (2.1)$$

kur VIS – atspindžio reikšmės regimajame spektre, o SWIR– atspindžio reikšmės trumpabangės infraraudonosios spinduliuotės spektre. Skaičiai nurodo spektrinės juostos centrinį bangos ilgį ( $\mu\text{m}$ ).

Sniegas ir ledas regimajame spektre yra labai šviesūs paviršiai, o artimojo infraraudonojo spektro dalyje tamsūs. NDSI reikšmės svyruoja nuo -1 iki 1.

Jei NDSI > 0, laikoma, kad pikselyje yra sniego, jei NDSI ≤ 0, pikselis laikomas be sniego. Kuo indekso reikšmė aukštesnė, tuo užtikrinčiau galima teigti, kad visa vietovė pikselyje yra padengta sniegu.

MODIS pikselis laikomas padengtu sniegu, jei išlaikomos šios sąlygos (Hall, Riggs, 2016):

- 1) NDSI reikšmė yra didesnė nei 0,4;
- 2) atspindys artimajame infraraudonajame spektre ( $\lambda = 0,86 \mu\text{m}$ ) yra didesnis nei 0,10;
- 3) atspindys regimajame spektre ( $\lambda = 0,56 \mu\text{m}$ ) didesnis nei 0,11.

Šiame darbe buvo analizuoti 2002–2018 m. šaltojo laikotarpio (spalio–balandžio mėn.) MODIS sniego duomenys. Pirminiai MOD10A1 ir MYD10A1 duomenų rinkiniai pateikiami sinusoidinėje geografinėje projekcijoje, kuri buvo pakeista į WGS84-UTM geografinę projekciją naudojant „MODIS Reprojection Tool“ (Dwyer, Schmidt, 2006).

Iš MODIS sniego duomenų pašalinus debesų reikšmes (žr. 3.2 skyrelį), naujos pikselių klasifikacijos („sniegas“ / „nėra sniego“) patikrai naudoti oro temperatūros duomenys. Paros minimali oro temperatūra buvo gauta iš E-OBS (angl. *Europe-wide precipitation and temperature observations*) duomenų bazės (Cornes ir kt., 2018). E-OBS duomenys pateikiami  $0,25^\circ \times 0,25^\circ$  geografiniame tinklelyje, kuris apima visą Lietuvos teritoriją. Siekiant suvienodinti MODIS ir E-OBS duomenų erdvinę skiriamąją gebą, E-OBS duomenų tinklelis buvo padalintas į 25 mažesnes gardeles, kurių skiriamoji geba 500 x 500 m.

Palydovinių MODIS duomenų validacijai naudoti kasdieniniai sniego dangos stebėjimai iš 17-os Lietuvos meteorologijos stočių. Tyrime nebuvo naudojami Nidos MS duomenys, nes ji yra tarp dviejų didelių vandens telkinių (Baltijos jūros ir Kuršių marių) ir MODIS duomenų rinkinyje šios stoties koordinatės atitinkantis pikselis klasifikuojamas kaip vanduo.

## 2.5. Sentinel-1 SAR duomenys

Šiame tyrime buvo naudoti Copernicus programos palydovo Sentinel-1 SAR duomenys, kuriuos teikia Europos kosmoso agentūra (ESA). Sentinel-1 SAR yra C bangų juostoje veikiantis radaras, kurio signalo centrinis dažnis yra 5,4 GHz (Bourbigot ir kt., 2016). Tyrime naudoti aukštos skiriamosios gebos GRD (angl. *Ground Range Detected*) Sentinel-1A ir Sentinel-1B interferometrinio pločio žvalgos juostos IW (angl. *Interferometric Wide*) dvigubos poliarizacijos (VV/VH) duomenys. Sentinel-1 sistema veikia ScanSAR tipo režimu, kuris vadinamas „*Terrain Observation with*

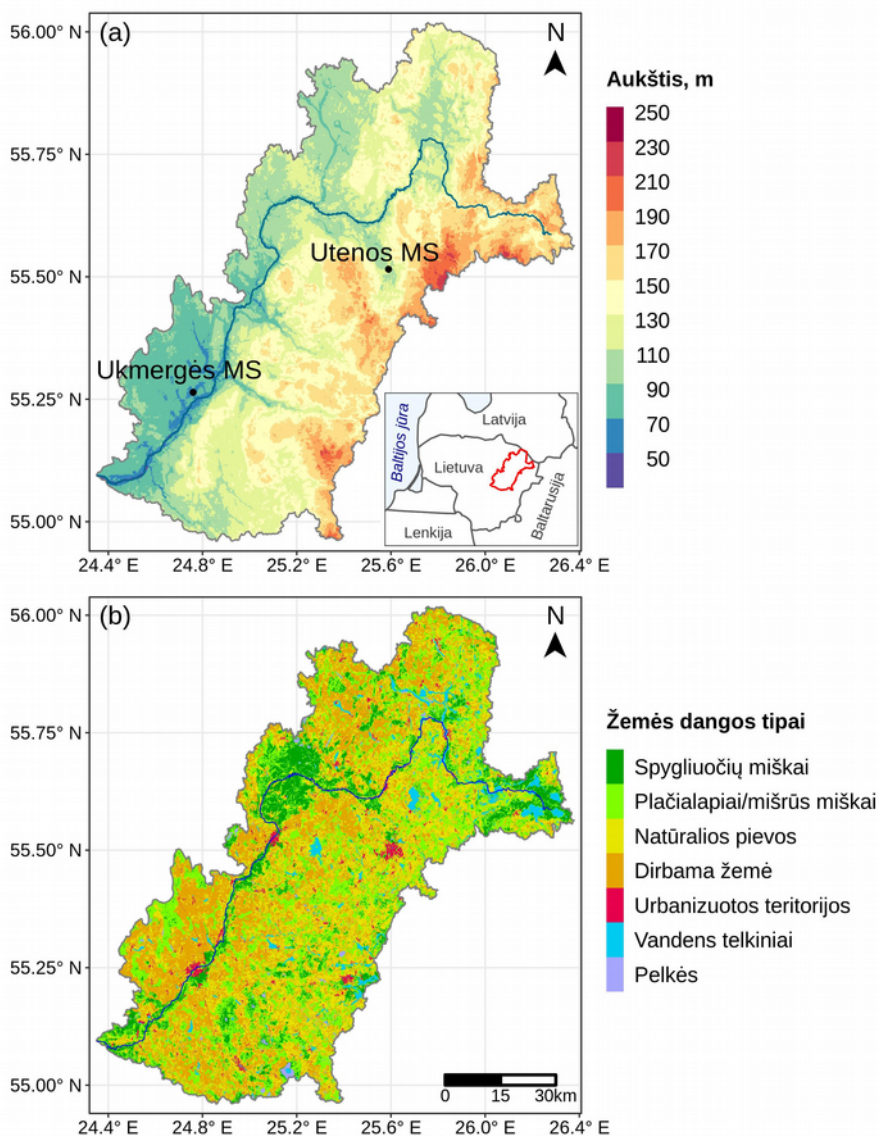
*Progressive Scan*“ (TOPS) (Torres ir kt., 2012). GRD duomenų rinkinys susideda iš SAR duomenų, kurie suprojektuoti ant žemės paviršiaus, naudojant Žemės elipsoido modelį (Bourbigot ir kt., 2016). Naudojant dviejų palydovų (Sentinel-1A ir Sentinel-1B) duomenis, informacija apie tą pačią vietovę gali būti gaunama kas šešias dienas.

Sentinel-1 žvalgos juostos plotis siekia 250 km, o duomenų erdvinė skiriamoji geba yra 20×22 m. Absoliutus SAR duomenų radiometrinis tikslumas yra 1 dB (Bourbigot ir kt., 2016). Šiame tyrime naudoti 2014–2019 m. šaltojo laikotarpio (spalio–balandžio mėn.) Sentinel-1A ir Sentinel-1B kylančios (angl. *ascending*) orbitos apvijos duomenys.

Sentinel-1 SAR duomenų reljefo korekcijai atlikti naudotas NASA SRTM skaitmeninis reljefo aukščio modelis (DEM) (Jarvis ir kt., 2008). SRTM 3Sec DEM duomenys yra globalūs, jų erdvinė skiriamoji geba siekia 90 m, o priklausomai nuo reljefo nuolydžio, jų vertikalusis tikslumas (RMSE) svyruoja nuo 4 iki 8 m (Athmania, Achour, 2014; Mouratidis, Ampatzidis, 2019).

SAR duomenų taikymo sniego dangos nustatymui tyrimas buvo atliktas Šventosios upės baseine, rytinėje Lietuvos dalyje (2.5 pav.). Tai didžiausias upės baseinas Lietuvos teritorijoje. Upės ilgis yra 242 km, o baseino plotas - 6789 km<sup>2</sup>. Šventosios upės baseinas driekiasi iš šiaurės rytų į pietvakarius ir yra asimetrinis. Siauresnė (dešinioji) baseino dalis yra Vidurio Lietuvos žemumoje, platesnė (kairė) – Baltijos aukštumose (2.5a pav.). Reljefo aukštis baseine svyruoja nuo 37 iki 241 m virš jūros lygio. 35% baseino ploto užima dirbama žemė, 26 % miškai, 7 % pievos, 3 % ežerai, o likusi dalis yra urbanizuotos teritorijos ir pelkės (2.5b pav.). Požeminis vanduo sudaro apie trečdalį viso upės nuotėkio, o kita dalis yra paviršinis nuotėkis susidarantis dėl sniego tirpsmo ir lietaus (Gailiušis ir kt., 2001).

Pirmasis sniegas Šventosios baseine paprastai iškrenta lapkričio antroje pusėje arba gruodžio pradžioje. Paprastai nuolatinė sezoninė sniego danga susiformuoja gruodžio pabaigoje, kartais – sausio mėnesį. 1981–2019 m. laikotarpiu vidutinis dienų skaičius su sniego danga buvo 75–85, o vidutinis maksimalus sniego dangos storis svyravo nuo 20 iki 25 cm. Pavasario sniego tirpsmas Šventosios baseine paprastai prasideda kovo viduryje. Tačiau pastaraisiais dešimtmečiais nuolatinė sezoninė sniego danga susidaro ne visada, dažnėja atlydžiai ir formuojasi trumpalaikė sniego danga (Rimkus ir kt., 2014).



**2.5 pav.** Šventosios upės baseinas: a) reljefas (SRTM DEM 4.0 versija) ir meteorologijos stotys, esančios baseino ribose; b) žemės dangos tipai remiantis CORINE 2018 duomenimis.

Kartu su SAR duomenimis naudoti žemės dangos tipai iš 2018 m. CORINE žemės dangos (CLC 2018) duomenų bazės (Büttner ir kt., 2017). CLC 2018 duomenys Šventosios baseinui parsisiūsti iš Copernicus Žemės dangos stebėjimo duomenų centro (angl. *Land Monitoring Service*). Smulčiausias CLC kartografavimo vienetas yra 25 hektarai, o minimalus

linijinių elementų plotis – 100 metrų. CLC 2018 pateikia penkis aukštos skiriamosios gebos (20 x 20 m) duomenų sluoksnius: urbanizuotos teritorijos, miškai, pievos, pelkės ir vandens telkiniai. Standartinę CLC nomenklatūrą sudaro 44 žemės dangos tipai (Büttner ir kt., 2017). Šventosios baseine nustatyti 22 CLC žemės dangos tipai, tačiau juos galima lengvai sugrupuoti naudojant 7 kategorijas: 1) spygliuočių miškai; 2) plačialapiai/mišrūs miškai; 3) dirbama žemė; 4) natūralios pievos; 5) urbanizuotos teritorijos; 6) pelkės; 7) vandens telkiniai (2.5b pav.). Pirmiausia buvo naudoti aukštos skiriamosios gebos (20 m) CLC sluoksniai, o ten, kur jų nebuvo, naudoti 100 m skiriamosios gebos duomenų sluoksniai (dirbama žemė, spygliuočių / plačialapių / mišrus miškas).

Šventosios baseinui sudaryti SAR sniego dangos žemėlapiai buvo palyginti su Sentinel-2 sniego dangos žemėlapiams, kur sniegas išskirtas pagal normalizuoto sniego dangos skirtumo indeksą (NDSI) (Drusch ir kt., 2012). Sentinel-2 antro lygio duomenų rinkinį 2A (angl. *level 2A*) sudaro ortorektifikuotas Žemės paviršiaus (BOA – angl. *Bottom of Atmosphere*) atspindys. Sentinel-2 jutiklio duomenų erdvinė skiriamoji geba priklauso nuo spektrinės juostos ir kinta nuo 10 iki 60 m (ESA, 2015). Kartu su atspindžio reikšmėmis, duomenų rinkinyje yra papildoma informacija apie sąlygas žvalgos juostoje (debesys, debesų šešėliai, augmenija, vanduo, sniegas ir kt.). Šie papildomi duomenys buvo naudoti Sentinel-2 debesimis uždengtų ir prastos kokybės pikselių filtravimui ir pašalinimui iš analizės.

Tiksli antžeminė informacija apie sniego storį ir oro temperatūrą gauta iš Ukmergės ir Utenos MS (2.5a pav.). Sniego storio duomenys iš šių stočių buvo naudojami klasifikuojant SAR vaizdus su plona (1–5 cm) ir stora sniego danga (> 5 cm). Oro temperatūros matavimai buvo naudojami siekiant nustatyti sniego dangos susidarymo ir tirpsmo pradžią bei išskirti šlapio ir sauso sniego atvejus (žr. 3.5 skyrelį).

## 2.6. HSAF vandens atsargų sniege duomenys

Šiame tyrime naudotas vandens atsargų sniege (VAS) duomenų rinkinys sudarytas Europos meteorologinių palydovų eksploatavimo organizacijos EUMETSAT (angl. *European Organisation for the Exploitation of Meteorological Satellites*) padalinio, skirto palydovinių duomenų taikymui operatyvinėje hidrologinėje ir vandentvarkos veikloje HSAF (angl. *Satellite Application Facility on Support to Operational Hydrology and Water Management*). HSAF VAS duomenų rinkinys sudarytas remiantis pasyviųjų mikrobangų jutikliu (AMSR-E, SSM/I ir SSMIS) išmatuotu Žemės

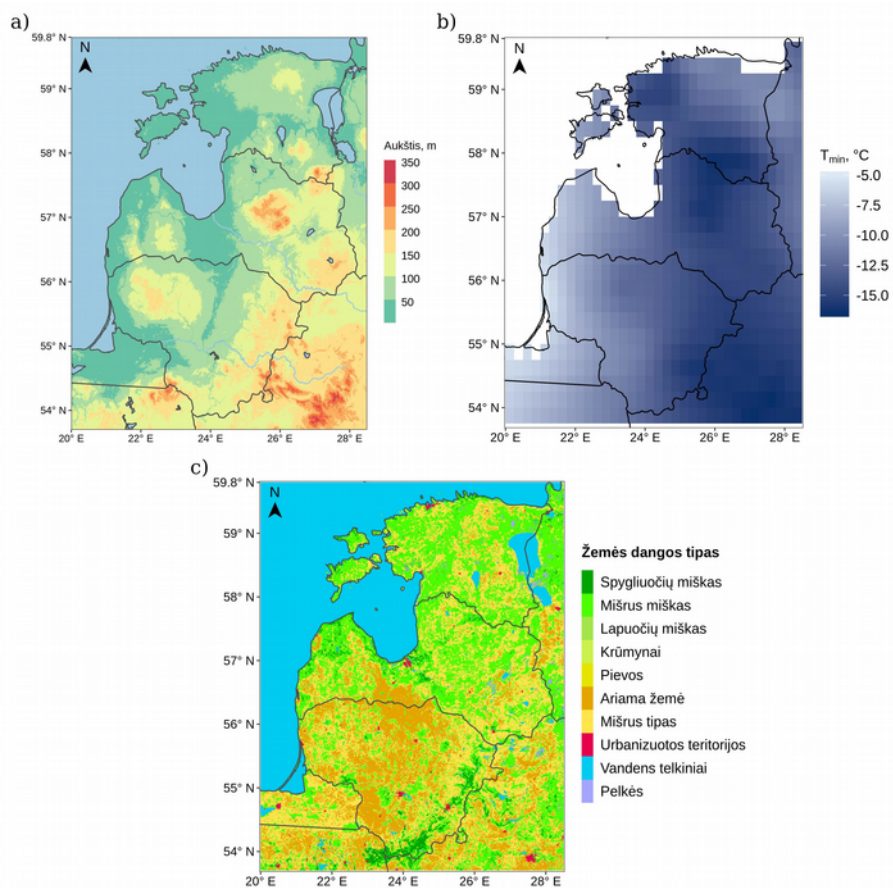
paviršiaus mikrobangų spinduliuotės intensyvumu (HSAF, 2018; Trigo ir kt., 2011). Šie jutikliai skrieja poliarinės orbitos palydovuose, jų stebėjimo kampas yra pastovus, o skiriamoji geba išlieka vienoda visoje žvalgos juostoje.

HSAF VAS nustatymo algoritmas remiasi palydovinių bei antžeminių duomenų asimiliacija. Naudojama pasyviaisiais mikrobangų radiometrais nustatyta ryškio temperatūra bei antžeminėse stotyse išmatuotas sniego dangos storis, vandens atsargos sniege ir sniego dalelių dydis (Pulliainen, 2006). Duomenys iš MS yra interpoliuojami ir sudaro pirminio spėjimo lauką, kuris perskaičiuojamas į mikrobangų radiometrų ryškio temperatūrą naudojant HUT (angl. *Helsinki University of Technology*) spinduliuotės pernašos matematinį modelį (Pulliainen ir kt., 1999). Modelis taip pat apima ir miškingas teritorijas ir atsižvelgia į augalijos poveikį mikrobangų spinduliuotei. Vėliau pirminio spėjimo laukas pritaikomas prie palydovinių jutiklių AMSR-E, SSM/I ir SSMIS užfiksuotos ryškio temperatūros (HSAF, 2018; Pulliainen ir kt., 1999). HSAF VAS duomenys pateikiami  $0,25^\circ \times 0,25^\circ$  geografiniame tinklelyje. Tyrime naudoti 2012–2018 m. laikotarpio VAS duomenys apėmė rytų Baltijos regioną ( $53\text{--}60^\circ\text{N}$ ,  $20\text{--}28^\circ\text{E}$ ).

Šiame tyrime buvo siekiama padidinti HSAF VAS duomenų rinkinio erdvinę skiriamąją gebą (žr. 3.4 skyrelį). Skiriamoji geba buvo padidinta iki  $0,05^\circ \times 0,05^\circ$  naudojant papildomą, aukštesnės skiriamosios gebos, informaciją apie kraštovaizdį ir meteorologines sąlygas:

1. 90 m skiriamosios gebos SRTM DEM. Vertikalusis šių duomenų tikslumas (RMSE) svyruoja nuo 4 iki 8 m (Jarvis ir kt., 2008; Mouratidis, Ampatzidis, 2019) (2.6a pav.).
2.  $0,25^\circ \times 0,25^\circ$  skiriamosios gebos E-OBS paros minimali temperatūra ( $T_{\min}$ ). Duomenys gauti iš E-OBS duomenų bazės (v17.0) ir pateikti  $0,25^\circ \times 0,25^\circ$  tinklelyje (Cornes ir kt., 2018) (2.6b pav.).
3.  $0,08^\circ \times 0,08^\circ$  skiriamosios gebos GLCF (angl. *Global Land Cover Facility*) žemės dangos duomenys. GLCF žemės dangos tipų klasifikacija yra sudaryta naudojant MODIS 2001–2012 m. duomenis (Friedl ir kt., 2009). Šiame duomenų rinkinyje yra išskiriama 16 žemės dangos tipų (2.6c pav.).

Visi aukščiau paminėti duomenų rinkiniai apima 2012–2018 m. šaltuosius sezonus (spalio-balandžio mėn.). HSAF VAS duomenys buvo palyginti su antžeminais VAS matavimais iš 52 meteorologijos stočių Baltijos šalyse, kuriose 2012–2018 m. buvo atliekamos sniego nuotraukos (2.1 pav.). Taip pat be palydovinių duomenų buvo naudoti ir lauko matavimai atlikti disertacijos tyrimo metu.



**2.6 pav.** Papildomi erdviniai duomenis naudojami didinant HSAF VAS duomenų rinkinio skiriamąją gebą (2017 m. vasario 10 d. pavyzdys): a) vietovės aukštis (SRTM DEM); b) minimali paros temperatūra iš E-OBS duomenų bazės; c) GLCF žemės dangos tipai.



### 3. DUOMENŲ APDOROJIMO METODIKA

Duomenų apdorojimo metodikos skyrius suskaidytas į penkias dalis, siekiant detalai aprašyti skirtingų palydovinių ir antžeminių duomenų apdorojimo ypatybes. Pirmame poskyryje aptariama kaip buvo vertinama Baltijos valstybėse MS atliktų sniego dangos stebėjimų kokybė, kaip buvo analizuojamas reljefo ir atstumo iki jūros poveikis sniego dangos rodikliams ir kaip atlikta žiemos sąlygų klasterizacija. Antrame poskyryje detalai paaiškinama pasiūlyta metodika, kaip iš regimojo spektro jutiklio MODIS duomenų pašalinti duomenų trūkius atsirandančius dėl debesuotumo. Trečias poskyris skirtas apibūdinti atsitiktinių miškų ir logistinės regresijos algoritmus, kurie buvo naudojami snygio atvejams nustatyti iš ATMS jutiklio duomenų. Ketvirtame poskyryje aprašytas HSAF VAS duomenų skiriamosios gebos didinimas panaudojant detalius duomenis apie aplinką (vietovės aukštį, Žemės dangos tipus, minimalią paros temperatūrą) bei mašininio mokymosi algoritmus. Penktas poskyris skirtas pristatyti SAR duomenų apdorojimo metodiką, kuri leidžia nustatyti kritines SAR atgalinės sklaidos santykio reikšmes, skirtas sniego dangos klasifikacijai skirtinguose Žemės dangos tipuose.

Antžeminių ir palydovinių duomenų apdorojimas ir statistinė analizė atlikta naudojant R programavimo kalbą bei specializuotų funkcijų paketus (angl. *R packages*). Sentinel-1 SAR pirminiam duomenų apdorojimui papildomai pasitelkta ESA SNAP programinė įranga. Visi šiame darbe pateikti žemėlapiai taip pat sudaryti naudojant R programavimo kalbą ir pateikiami WGS84 geografinėje koordinačių sistemoje.

#### 3.1. Antžeminių stočių duomenų homogeniškumo ir statistinių rodiklių vertinimas

Pirmiausia, prieš pradėdant sniego dangos rodiklių analizę, buvo atliktas sniego dangos matavimo Baltijos valstybėse duomenų homogeniškumo testas. Duomenų sekų homogeniškumas buvo patikrintas naudojant standartinį normalaus homogeniškumo testą SNHT (angl. *Standard Normal Homogeneity Test*) (Alexandersson, 1986). Taikant šį metodą apskaičiuojamas konkrečios stoties stebėjimo duomenų santykis su kitų stočių stebėjimų vidurkiu. Apskaičiuoti santykiai yra standartizuojami. Jei nagrinėjamos stoties duomenys išsiskiria lyginant su kitų stočių vidurkiu, laikoma, kad toje stotyje duomenys yra nehomogeniški. Jei pokytis

nustatomas visose stotyse vienu metu, tuomet tai laikoma klimato režimo pokyčiu arba sisteminiu matavimų pokyčiu (Alexandersson, 1986).

Šiame tyrime, naudojant SNHT testą, beveik visi statistiškai reikšmingi sniego dangos rodiklių pokyčiai Baltijos valstybėse buvo aptikti devintojo dešimtmečio pabaigoje. Šie pokyčiai nebuvo susiję su stočių perkėlimu ar matavimo metodikos pakeitimais ir šį laikotarpį Baltijos valstybėse galima laikyti sniego dangos režimo pasikeitimu, įvykusi dėl klimato kaitos.

Metų ir mėnesio dienų su sniego danga skaičius MS buvo apskaičiuotas susumuojant atvejus, kai stotyse buvo fiksuotas didesnis nei 5 balų vietovės padengtumasis sniego danga. Vidutinis dienų su sniego danga skaičius Baltijos valstybėms apskaičiuotas išvedant visų stočių duomenų aritmetinį vidurkį. Atskirų metų maksimalus sniego dangos storis Baltijos valstybėse, 1961–2015 m. laikotarpiu, buvo nustatytas randant storiausios sniego dangos reikšmę (cm) tarp visų nagrinėtų MS. Ryšys tarp dienų su sniego danga, maksimalaus sniego dangos storio, temperatūros ir kritulių buvo įvertintas naudojant Pearsono koreliacijos koeficientą.

Metai su skirtingais sniego dangos režimais buvo klasifikuojami pagal mėnesio dienų su sniego danga skaičiaus pasiskirstymą naudojant hierarchinės klasterizacijos modelį (Euklido atstumo matas, pilnoji jungtis). Pagal klasterizacijos rezultatus buvo išskirti penki žiemos tipai (žr. 4.1. skyrelį).

Dienų su sniego danga skaičius ir maksimalaus sniego storio kaitos tendencijos buvo įvertintos naudojant neparametrinį Sen nuolydžio metodą (angl. *Sen slope*) (Helsel ir kt., 2020). Pokyčių greitis buvo apskaičiuotas tiek atskiriems mėnesiams, tiek visam sezonui. Statistinis tendencijų reikšmingumas ( $p < 0,05$ ) buvo įvertintas naudojant neparametrinį Mann-Kendall testą, o nuosekloji t-testo analizė buvo naudojama norint įvertinti sniego režimo pokyčius, pvz. aptikti duomenų sekos režimo pokyčių taškus (Rodionov, 2004).

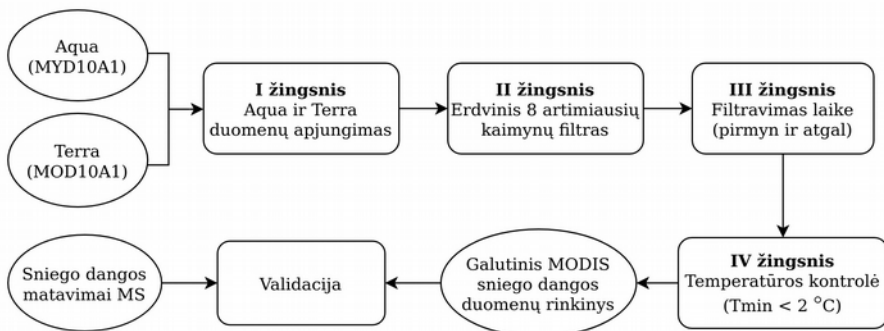
Geografinių kintamųjų (t. y. platumos, ilgumos, atstumo nuo jūros ir vietovės aukščio) poveikis sniego dangos parametrų erdviniam pasiskirstymui Baltijos šalyse buvo įvertintas naudojant tiesinės daugianarės regresijos modelį. Modelyje sniego dangos rodikliai buvo prediktantai, o geografiniai veiksniai – nepriklausomi kintamieji.

### 3.2. MODIS duomenų trūkių, atsirandančių dėl debesuotumo, panaikinimas

Regimojo spektro palydovinių jutiklių panaudojimą sniego dangos stebėsenai dažnai apsunkina duomenų spragos atsirandančios dėl debesuotumo. Šiame tyrime pateikta debesų spragų užpildymo metodika MODIS sniego duomenų rinkinyje panaudojant keturis žingsnius (3.1 pav.):

1. „Terra“ ir „Aqua“ palydovų MODIS duomenų apjungimas;
2. Debesimis uždengtų pikselių užpildymas naudojant nedebeisuotas vertes iš 8 kaimyninių pikselių;
3. Duomenų filtravimas laike: pirmyn – randama nedebeisuota reikšmė pasibaigus debesuotam laikotarpiui, atgal – randama nedebeisuota reikšmė prieš prasidedant ištisiniam debesuotumui;
4. Temperatūros kontrolė – sniego atvejų filtravimas atsižvelgiant į paros minimalią oro temperatūrą.

MODIS duomenų iš „Terra“ ir „Aqua“ palydovų apjungimas (I žingsnis) (3.1 pav.) yra įprasta praktika tyrinėjant sniego dangą (Da Ronco, De Michele, 2014; Dariane ir kt. 2017; Parajka, Blöschl, 2008). Palydovai „Terra“ ir „Aqua“ virš Lietuvos praskrenda skirtingu metu („Terra“ maždaug 9.15 val. UTC, „Aqua“ – 12.05 val. UTC). Todėl yra tikimybė, kad vienas iš MODIS vaizdų bus mažiau debesuotas, arba debesų zona bus pasislinkusi, ir naudojant skirtingų palydovų duomenys bus galima sumažinti debesimis uždengtų pikselių skaičių. Šiame tyrime pagrindiniu duomenų rinkiniu buvo laikomi „Terra“ palydovo MODIS duomenys (MOD10A1). S. Pipiraitės-Januškienės ir kt. (2018) tyrimas parodė, kad Lietuvoje antžeminėse stotyse stebėtas dienų su sniego danga skaičius geriau sutampa su „Terra“ nei su „Aqua“ MODIS matavimų rezultatais. Jei pikselis buvo padengtas debesimis MOD10A1 („Terra“) duomenų rinkinyje, tik tuomet buvo naudota informacija iš MYD10A1 („Aqua“).



3.1 pav. Pradinių MODIS sniego dangos duomenų apdorojimo schema.

Apjungus MOD10A1 ir MYD10A1 duomenų rinkinius, buvo panaudotas erdvinis debesimis padengtų pikselių filtravimas atsižvelgiant į artimiausių 8 kaimyninių pikselių reikšmes (II žingsnis) (3.1 pav.). Jei nagrinėjamą MODIS pikselį dengė debesys, buvo ieškoma nedebeisuotų kaimyninių pikselių. Jei tarp kaimynų buvo keli nedebeisuoti pikseliai, duomenų trūkiui užpildyti buvo naudojama dažniausiai pasitaikiusi nedebeisuotų pikselių reikšmė. Jei „sniego“ ir „be sniego“ kaimyninių pikselių skaičius buvo vienodas, laikyta, kad nagrinėjamas debesimis uždengtas pikselis yra su sniego danga.

Filtravimas laike (III žingsnis) buvo naudojamas užpildyti likusias debesų spragas MODIS duomenų rinkinyje (3.1 pav.). Kitų mokslininkų atlikti tyrimai parodė, kad debesų trūkių užpildymas naudojant interpoliavimą laike, pasiteisina įvairiomis klimato sąlygomis ir įvairiuose kraštovaizdžiuose (Foppa, Seiz, 2012; Parajka, Blöschl, 2008; Wang ir kt., 2015). Filtravimas laike buvo atliktas dviem būdais. Pirmasis būdas buvo užpildyti debeisuotą pikselį randant to paties pikselio reikšmę pasibaigus debeisuotumui (interpoliavimas „pirmyn“). Antrasis būdas buvo surasti pikselio vertę prieš prasidedant debeisuotiems orams (interpoliavimas „atgal“). Priklausomai nuo meteorologinės situacijos abu būdai gali lemti tiek didesnę, tiek mažesnę sniego dangos atvejų skaičių nei buvo realus. Tačiau naudojant šių abiejų būdų vidurkį galima gana tiksliai įvertinti sezoninį dienų su sniego danga skaičių, nes šių dviejų filtravimo metodų paklaidos yra priešingos (Foppa, Seiz, 2012).

Temperatūros kontrolė (IV žingsnis) buvo naudojama siekiant sumažinti pikselių skaičių, kurie buvo neteisingai identifikuoti kaip sniegas (3.1 pav.). Dėl nuolatinės debesų dangos MODIS duomenų pikselis po duomenų filtravimo laike (III žingsnio) ilgą laikotarpį gali būti laikomas padengtu sniegu. Tačiau esant šiltoms žiemomis bei sezono pradžioje ir pabaigoje galimi dažni atlydžiai, kai sniego danga visiškai ištirpsta. Siekiant nustatyti tinkamiausią kritinę temperatūrą, kuri padėtų sumažinti neteisingai nustatytų sniego dangos atvejų, buvo tirta minimali paros temperatūra nuo 0,5 iki 3,0 °C, taikant 0,5 °C temperatūros pokyčio intervalą. Naudojant pasirinktas temperatūros reikšmes buvo apskaičiuotas MODIS metinis dienų su sniego dangos skaičius ir palygintas su MS stebėjimų duomenimis. Minimali paros oro temperatūra, kurią pasirinkus gautas mažiausias skirtumas buvo laikoma kritine ir naudota MODIS duomenų filtravimui.

Pirminiuose MODIS duomenyse, užpildžius dėl debesų atsirandančius duomenų trūkius, gauto naujo duomenų rinkinio patikimumas buvo įvertintas naudojant antžeminius sniego dangos matavimus Lietuvoje. Buvo laikoma, kad vietovė yra padengta sniegu, kai daugiau nei 50 % matomo

ploto aplink MS buvo padengta sniegu (> 5 balai). Laikyta, kad palydovinių ir antžeminių matavimų laikas sutampa, nors „Aqua“ ir „Terra“ palydovų praskridimo laikas 3–6 val. skiriasi nuo sniego dangos stebėjimo laiko MS. Atlydžių arba pavasario tirpsmo metu, plona sniego danga gali greitai iširti, todėl laiko skirtumas tarp palydovo ir MS matavimų kartais gali lemti skirtingus rezultatus, tačiau šiame tyrime tai nebuvo detaliau tyrinėta. Remiantis MODIS ir MS sniego stebėjimo rezultatais buvo sudaryta nesutapimo matrica (angl. *confusion matrix*). Nesutapimo matricos klasės apibrėžtos 3.1 lentelėje.

**3.1 lentelė.** Nesutapimų matrica tarp MS ir MODIS duomenų: a – sniegas buvo nustatytas palydoviniuose ir antžeminiuose duomenyse; b – sniegas nustatytas palydoviniuose duomenyse, tačiau MS sniego nebuvo; c – palydoviniuose duomenyse sniegas nenustatytas, tačiau stebėtas MS; d – sniegas nenustatytas nei palydoviniuose, nei antžeminiuose duomenyse.

		MS	
		Sniegas	Nėra sniego
MODIS	Sniegas	<i>a</i>	<i>b</i>
	Nėra sniego	<i>c</i>	<i>d</i>

Naudojant nesutapimų matricos kategorijas (3.1 lentelė), buvo apskaičiuoti statistiniai validacijos rodikliai, padedantys įvertinti MODIS sniego dangos duomenų rinkinių tikslumą ir trūkumus lyginant su antžeminais stebėjimais (Wilks, 2011):

$$FBI = \frac{a+b}{a+c} \quad (3.1)$$

FBI yra dažnio paklaida (angl. *frequency bias*), jei FBI = 1 tuomet abu duomenų rinkiniai sutampa (jei FBI < 1, MODIS nustato sniegą rečiau nei jis stebimas MS; jei FBI > 1, MODIS nustato daugiau sniego atvejų nei MS).

$$POD = \frac{a}{a+c} \quad (3.2)$$

POD yra aptikimo tikimybė (arba pataikymo dažnis) (angl. *probability of detection*), ji svyruoja nuo 0 iki 1, kai palydovų jutikliai nustato visus sniego dangos atvejus, tuomet POD = 1.

$$POFD = \frac{b}{b+d} \quad (3.3)$$

POFD yra klaidingo aptikimo tikimybė (angl. *probability of false detection*), ji svyruoja nuo 0 iki 1, geriausias rezultatas kai POFD = 0.

$$FAR = \frac{b}{a+b} \quad (3.4)$$

FAR yra neteisingo identifikavimo santykis (angl. *false alarm ratio*), geriausias validacijos rezultatas kai  $FAR = 0$ . Šis indeksas turėtų būti naudojamas kartu su POD, nes atskirai jį sunku teisingai interpretuoti.

$$ACC = \frac{a+d}{a+b+c+d} \quad (3.5)$$

ACC yra tikslumas (angl. *accuracy*), jis svyruoja nuo 0 iki 1, geriausias rezultatas kai  $ACC = 1$ .

$$CSI = \frac{a}{a+b+c} \quad (3.6)$$

CSI yra kritinės sėkmės indeksas (angl. *critical success index*), jei jo reikšmė 0, tai reiškia, kad palydoviniai duomenys yra netikslūs, o geriausias rezultatas kai  $CSI = 1$ .

$$HSS = \frac{2(ad - bc)}{(a+c)(c+d) + (a+b)(b+d)} \quad (3.7)$$

HSS yra Heidke įvertis (angl. *Heidke skill score*), kuris parodo kiek palydoviniai duomenys yra tikslesni už atsitiktinį spėjimą. HSS reikšmės svyruoja nuo  $-\infty$  iki 1: neigiamos reikšmės parodo, kad duomenys yra mažiau tikslus nei atsitiktinis spėjimas, o geriausias rezultatas kai  $HSS = 1$ .

Naudojant MODIS duomenis su užpildytais debesuotais pikseliais, buvo apskaičiuotos mėnesio ir metų dienų su sniego danga skaičius. Metiniu dienų su sniego danga skaičiumi buvo laikoma dienų su sniegu suma nuo spalio 1 d. iki kitų metų balandžio 30 d. MODIS mėnesio ir metų dienų su sniego danga skaičiaus tikslumas taip pat buvo įvertintas naudojant klimatologinį vertės indeksą  $SS_{clim}$  (angl. *Climatological Skill Score*) (Wilks, 2011):

$$SS_{clim} = 1 - \frac{MSE}{MSE_{clim}} \quad (3.8)$$

kur MSE yra vidutinė kvadratinė paklaida tarp MODIS ir MS stebėjimų;  $MSE_{clim}$  – vidutinė kvadratinė paklaida tarp klimatologinio dienų su sniego danga skaičiaus vidurkio (2002–2018 m.) ir dienų skaičiaus MS konkrečiais metais. Jei  $SS_{clim}=1$ , tuomet MODIS ir antžeminiai stebėjimai sutampa, o 0 reiškia, kad MODIS dienų su sniego danga skaičius yra tokio pat tikslumo kaip ir klimatologinis vidurkis. Neigiama  $SS_{clim}$  vertė rodo, kad MODIS sniego duomenų rinkinys yra mažiau tikslus nei klimatologinis vidurkis.

### 3.3. Snygio nustatymas naudojant ATMS duomenis

Kritulių nustatymas naudojant zonduojančius mikrobangų radiometrų duomenis pagrįstas mikrobangų savybe prasiskverbti pro debesis. Priklausomai nuo kritulių fazės ir kritulių dalelių dydžio keičiasi ir mikrobangų signalas. ATMS jutiklio kanalai fiksuojantys aukštesnio nei 150 GHz dažnio spinduliuotę, (pvz.: 160 GHz ir 183 GHz) yra labiau jautrūs ledo kristalų poveikiui (Meng ir kt., 2017). Ledo dalelės debesyse ir krituliuose silpnina šių dažnių spinduliuotės intensyvumą ir ši savybė leidžia aptikti snygio atvejus.

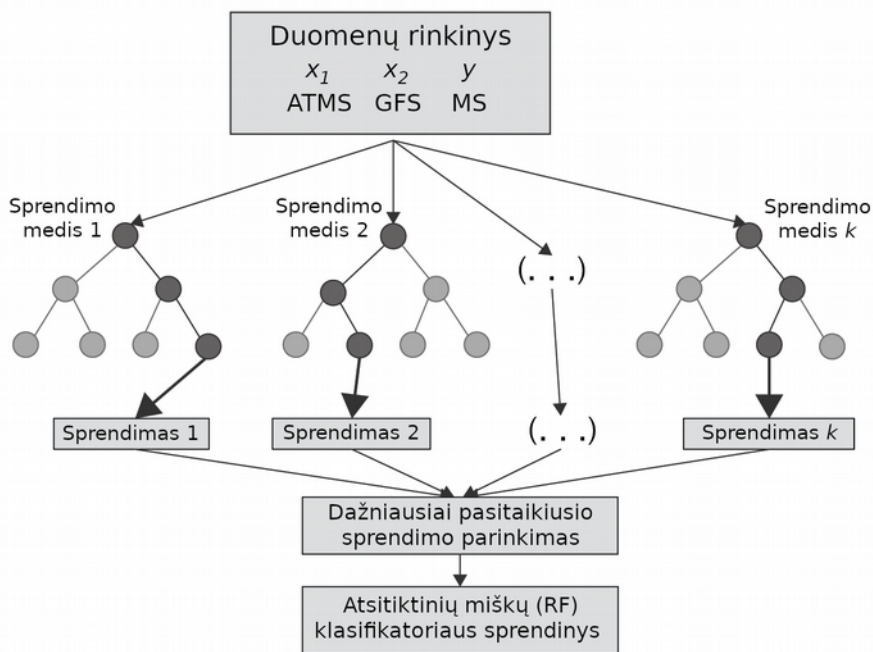
Šiame darbe, siekiant nustatyti snygio atvejus iš ATMS duomenų, buvo naudojamas atsitiktinių miškų RF (angl. *Random Forest*) klasifikatorius. RF apmokymui buvo naudoti meteorologinių stočių kritulių stebėjimai iš viso pasaulio. Naudoti tik tie kritulių atvejai, kurie buvo nustatyti 90 minučių intervale po ATMS praskridimo laiko ir esantys 50 km atstumu nuo ATMS signalo centrinių koordinačių. Tokie laiko apribojimai taikyti todėl, jog buvo pastebėta, kad ATMS kritulius aptinka anksčiau, negu jie pasiekia žemės paviršių ir yra apie 30–60 min kritulių intensyvumo vėlavimas lyginant ATMS ir MS matavimus (You ir kt., 2019).

Pagal aprašytus kriterijus sujungus ATMS ir MS duomenis jie taip pat buvo apjungti su NOAA GFS (angl. *Global Forecast System*) analizės duomenimis. Apjungiant duomenis buvo randama GFS duomenų gardelė, kurios centras būtų arčiausiai ATMS signalo koordinačių. Kiekvienai ATMS ir MS duomenų porai buvo priskirti GFS išvesties duomenys iš dviejų artimiausių laiko žingsnių (pvz., jei ATMS virš MS praskrido 07:43 UTC, tai šių duomenų porai buvo priskirti 06:00 ir 09:00 UTC GFS analizės duomenys. Vėliau GFS duomenys buvo interpoliuojami laike, siekiant kad jie kuo geriau atspindėtų atmosferos sąlygas tuo metu, kai buvo atliekami ATMS matavimai.

Apjungus duomenis buvo sudarytas duomenų rinkinys, kuris apibūdino troposferos ir pažemio meteorologines sąlygas kiekvieno ATMS praskridimo metu. Ši duomenų bazė buvo panaudota sudaryti atsitiktinių miškų snygio klasifikacijos modelį. Kritulių stebėjimai MS buvo naudojami kaip prediktantas, o ATMS spektro juostų duomenys ir GFS analizės rodikliai buvo naudojami kaip prediktoriai. RF modelis sudarytas naudojant R programos paketą „H2O“ ir jo RF funkciją.

RF algoritmas remdamasis įvesties duomenimis sudaro daugybę klasifikacinių medžių, kurių kiekvienoje atšakoje yra įvertinami prediktorių svoriai ir jų indėlis į klasifikavimo paklaidos mažėjimą (3.2 pav.). RF klasifikacijos tikslumas priklauso nuo sprendimų medžių skaičiaus, tačiau naudojant per didelį jų kiekį galima sudaryti modelį per daug pritaikytą prie pradinių duomenų (angl. *overfitting*) (Pal, 2005). Siekiant to išvengti

sudaryta duomenų bazė buvo padalinta į dvi dalis: 2012–2016 m. duomenys buvo naudojami RF apmokymui, o 2017–2018 m. duomenys – modelio testavimui ir validacijai. Taip pat kiekvienos apmokymo iteracijos metu buvo naudojamos atsitiktinai sugeneruotos ATMS/GFS/MS duomenų bazės eilutės (angl. *random seed*).



**3.2 pav.** Atsitiktinių miškų (RF) klasifikatoriaus sudarymo schema. RF apmokymui naudota sudaryta duomenų bazė, kurioje ATMS ir GFS duomenys buvo prediktoriai ( $x_1, \dots, x_n$ ), o MS kritulių duomenys – prediktantas ( $y$ ).

Pradinėje iteracijoje RF modelio sudarymui naudota ryškio temperatūra, užfiksuota visomis ATMS spektrinėmis juostomis, bei visi GFS modelio analizės rodikliai. Tačiau naudoti 142 prediktorius nėra efektyvu ir dalis jų yra tarpusavyje labai glaudžiai susiję, todėl buvo siekiama atrinkti rodiklius, kurie yra svarbiausi. Apibendrinus visus sudarytus klasifikacinius medžius atrenkami kintamieji, kurie dažnai buvo naudojami naujoms atšakoms sudaryti ir kurie turėjo didžiausią įtaką mažinant klasifikacijos paklaidą (Pal, 2005). Buvo atliekamos iteracijos ir naudojant R „H2O“ paketo funkciją *h2o.varimp* sudaroma santykinė prediktorių svarbos eilė (angl. *variable importance*). Remiantis santykinės prediktorių svarbos eile, kiekvienos



iteracijos metu buvo pašalinami kintamieji, neturintys daug reikšmės klasifikacijos tikslumui. Iš viso atlikta 20 iteracijų.

Naudojant po 20 RF iteracijų atrinktus rodiklius jie taip pat buvo panaudoti sudaryti logistinės regresijos modelį. Logistinės regresijos snygio klasifikavimo modelis buvo naudojamas palyginti RF modeliu gautus rezultatus. Abiejų, RF ir logistinės regresijos, modelių tikslumas buvo vertinamas pagal kritulių stebėjimus MS. Atliekant tikslumo vertinimą buvo apskaičiuoti statistiniai validacijos rodikliai paremti nesutapimo matricos kategorijomis (žr. 3.2 skyrelį ir 3.1 lentelę). Gauti validacijos rezultatai buvo palyginti su Kongoli ir kt. (2018) tyrimo rezultatais, siekiant nustatyti ar RF snygio klasifikacijos modelis yra tikslesnis nei šiuo metu NOAA naudojamas hibridinis logistinės regresijos algoritmas.

### 3.4. Sentinel-1 SAR duomenų apdorojimas

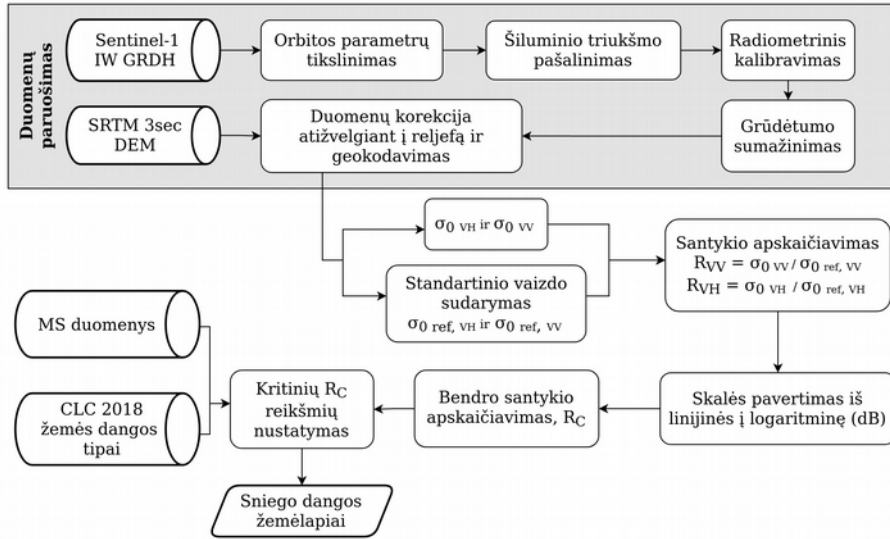
Siekiant nustatyti sniego dangą iš Sentinel-1 SAR stebėjimų, svarbu tinkamai paruošti pirminius SAR duomenis. SAR duomenų apdorojimas buvo atliekamas naudojant ESA „SNAP“ programinę įrangą, o pirminio duomenų paruošimo žingsniai buvo (3.3 pav.):

- 1) Sentinel-1 orbitos parametrų patikslinimas;
- 2) triukšmo, atsirandančio dėl prietaiso skleidžiamos šiluminės energijos, pašalinimas;
- 3) radiometrinis kalibravimas;
- 4) SAR vaizdo grūdėtumo sumažinimas;
- 5) duomenų korekcija atsižvelgiant į reljefą ir duomenų pateikimas WGS84 geografinėje koordinačių sistemoje.

Atlikus pirminį SAR duomenų paruošimą, buvo skaičiuojamas VV ir VH poliarizacijų SAR atgalinės sklaidos ( $\sigma_0$ ) santykis tarp vaizdų su sniegu ir standartinio vaizdo be sniego dangos. Standartinis vaizdas buvo sudarytas naudojant 2015–2019 m. spalio mėnesiais užfiksuotų SAR vaizdų  $\sigma_0$  reikšmių vidurkį. Standartinio vaizdo sudarymo metodika pagrįsta (Luojus ir kt., 2006) tyrimu, kuris parodė, kad skaičiuojant  $\sigma_0$  santykį galima naudoti ne tik konkrečių metų SAR vaizdą, bet ir kelių skirtingų metų vaizdų be sniego dangos vidurkį. Šiame tyrime SAR standartiniam vaizdui sudaryti buvo naudojami tik tie atvejai kai vidutinė paros oro temperatūra buvo teigiama ( $T_{\text{vid.}} > 0 \text{ } ^\circ\text{C}$ ) ir tą dieną nebuvo jokių kritulių. Šie meteorologiniai filtrai buvo naudojami siekiant išvengti atvejų su kietais krituliais ir trumpalaikė sniego danga. Rudenį susidariusi trumpalaikė sniego danga galėtų turėti

įtakos sudaromo standartinio vaizdo SAR  $\sigma_0$  dydžiui. Standartinis SAR vaizdas sudarytas iš 7 vaizdų:

- Sentinel-1A palydovo (2015 m. spalio 16 d., 2018 m. spalio 12 d., 2019 m. spalio 19 d.).
- Sentinel-1B palydovo (2016 m. spalio 16 d., 2017 m. spalio 23 d., 2018 m. spalio 18 d., 2019 m. spalio 25 d.).



**3.3 pav.** Sentinel-1 IW GRDH duomenų apdorojimo schema, siekiant sudaryti dvejetainius sniego dangos žemėlapius. Pilka sritis žymi pirminius SAR duomenų apdorojimo veiksmus, o baltoje srityje pažymėti žingsniai reikalingi išskirti sniego dangai.

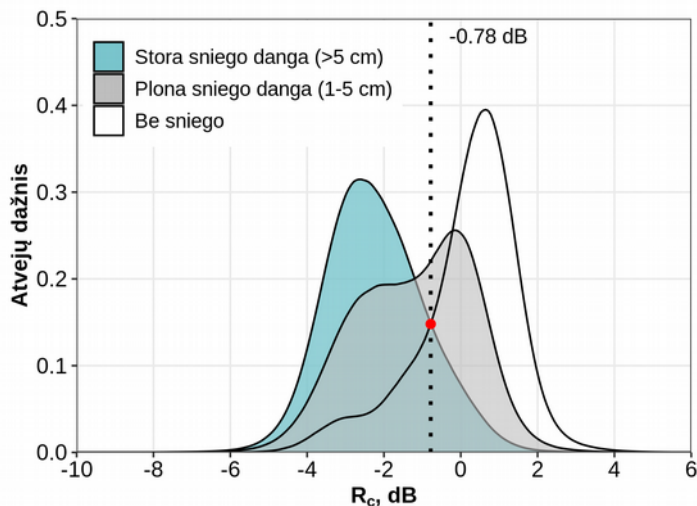
Kiekvienam 2014–2019 m. laikotarpiu žiemos SAR vaizdai buvo atskirai apskaičiuotas VV ir VH poliarizacijos duomenų  $\sigma_0$  santykis su standartiniu vaizdu ( $R_{VV}$  ir  $R_{VH}$ ) (3.3 pav.). Kitų mokslininkų atlikti tyrimai parodė, kad sauso ir drėgno sniego atgalinės sklaidos dydis priklauso net tik nuo dielektrinių sniego dangos savybių, bet ir nuo SAR signalo poliarizacijos, todėl naudojant kryžminę poliarizaciją (VV, VH) galima gauti tikslesnius duomenis – ypač esant mažiems SAR signalo kritimo kampams (Nagler ir kt., 2016; Strozzi ir kt., 1997). T. Nagler ir kt. (2016) pasiūlė VV ir VH  $\sigma_0$  santykio reikšmes apjungti naudojant svorinius koeficientus, kurie priklauso nuo SAR signalo kritimo kampo (angl. *local incidence angle*). Šiame tyrime panaudota tokia pati metodika – pagal T. Nagler ir kt. (2016) formulę buvo apskaičiuotas bendras  $R_{VV}$  ir  $R_{VH}$  santykis ( $R_c$ ), naudojant svorinį koeficientą:

$$R_C = WR_{VH} + (1 - W)R_{VV} \quad (3.12)$$

kur svorinis koeficientas ( $W$ ) priklauso nuo SAR signalo kritimo kampo ( $\theta$ ):

$$\begin{aligned} (\theta < 20^\circ) &\rightarrow W = 1 \\ (20^\circ \leq \theta \leq 45^\circ) &\rightarrow W = 0.5 \left( 1 + \frac{45 - \theta}{25} \right) \\ (\theta > 45^\circ) &\rightarrow W = 0.5 \end{aligned} \quad (3.13)$$

Pagal 3.11 formulę apskaičiuotos bendro santykio  $R_C$  reikšmės buvo naudojamos suklasifikuoti SAR pikselius su sniego danga ir be sniego. Klasifikacija buvo paremta kritinėmis  $R_C$  reikšmėmis, kurios buvo nustatytos kiekvienam žemės dangos tipui atskirai. Kritine  $R_C$  reikšme buvo laikomas pikselių su sniegu ir pikselių be sniego  $R_C$  dažnių skirstinių susikirtimo taškas (3.4 pav.). Skirstinių susikirtimo taškai buvo nustatyti septyniems dažniausiai pasitaikantiems CLC žemės dangos tipams Šventosios baseine: 1) spygliuočių miškams; 2) plačialapių / mišriems miškams; 3) ariamai žemei; 4) natūralioms pievoms; 5) urbanizuotoms teritorijoms; 6) pelkėms; 7) vandens telkiniams.



**3.4 pav.**  $R_C$  kritinės reikšmės, skiriančios atvejus su sniegu ir be sniego, nustatymas. Kritine reikšme laikytas „be sniego“ ir „storos sniego dangos“  $R_C$  skirstinių susikirtimo taškas (pažymėta punktyrine linija ir raudonu tašku).

Nustatant kritines  $R_C$  reikšmes buvo naudojamos dvi skirtingos sniego dangos storio kategorijos: plona sniego danga (1–5 cm) ir stora sniego danga (> 5 cm) (3.4 pav.). Sniego dangos storis buvo gautas iš Šventosios baseine

esančių Utenos ir Ukmergės MS. Oro temperatūra iš šių MS buvo naudojama nustatyti palankias sąlygas sniego tirpsmui ir šlapiai sniego dangai susidaryti. Šlapia sniego danga buvo laikomi tokie atvejai, kai minimali paros oro temperatūra ( $T_{\min}$ ) buvo teigiama. Intensyvaus tirpimo laikotarpiu buvo laikomi atvejai kai  $T_{\min} > 0$  °C, o sniego storis per 24 valandas sumažėjo 2 cm ar daugiau. Šie meteorologiniai duomenų filtrai buvo taikomi 20 km spinduliu aplink MS esantiems Sentinel-1 SAR pikseliams. Buvo laikomasi prielaidos, kad matavimai MS gerai atspindi sniego dangos sąlygas (sniego storį, VAS) 20 km buferinėje zonoje. Taškinių MS matavimų reikšmių prilyginimas toliau esančių vietovių sniego dangos rodikliams gali būti klaidingas dėl sniego dangos nevienalytiškumo ir sniego perskirstymo.

Dvejetainių sniego dangos žemėlapių, sudarytų remiantis SAR  $R_C$  kritinėmis reikšmėmis, tikslumas buvo įvertintas naudojant NDSI apskaičiuotą iš Sentinel-2 duomenų (L2A). Sentinel-2 MSI jutiklis veikia regimajame ir infraraudonajame spektre. NDSI buvo apskaičiuotas naudojant 0,56  $\mu\text{m}$  VIS (3 juosta) ir 1,61  $\mu\text{m}$  SWIR (11 juosta) duomenis, pagal 2.1 formulę.

Žiemą Lietuva, o kartu ir Šventosios baseinas, dažnai yra dengiami debesų, todėl rasti Sentinel-2 vaizdą užfiksuotą esant sniego dangai ir visiškai giedram dangui yra sudėtinga. Šiame darbe buvo naudoti Sentinel-2 vaizdai kuriuose debesys dengė iki 30 % viso ploto. SAR  $R_C$  sniego dangos žemėlapių validavimui buvo naudoti atvejai, kai Sentinel-1 ir Sentinel-2 palydovai virš Šventosios baseino praskrido tą pačią dieną. Dienų, kai šių dviejų palydovų trajektorijos sutampa, pasitaiko pakankamai retai. Remiantis aprašytais kriterijais buvo gauti tik du vaizdai tinkami SAR  $R_C$  ir Sentinel-2 NDSI palyginimui: 2018 m. vasario 26 d. ir 2018 m. kovo 28 d.

Sentinel-2 pikseliai buvo klasifikuoti kaip sniegas jei apskaičiuotas NDSI buvo didesnis nei 0,4. Pikseliai buvo priskirti debesų dangai kai Sentinel-2 duomenų rinkinyje nurodyta debesų tikimybė (angl. *cloud confidence mask*) buvo didesnė nei 98 %. Pagal Sentinel-2 NDSI ir debesuotumo reikšmes sudaryti sniego dangos žemėlapiai papildomai buvo nufiltruoti naudojant 11x11 pikselių erdvinį filtrą, siekiant pašalinti pavienius, tarp kaimynų savo reikšmėmis išsiskiriančius, pikselius.

SAR  $R_C$  sniego duomenų validacijos rodikliai apskaičiuoti remiantis nesutapimo matricos kategorijomis (žr. 3.1 lentelę) ir iš jos apskaičiuojamais statistiniais rodikliais, kurie detalai aprašyti 3.2 skyrelyje.

Tiek Sentinel-1, tiek Sentinel-2 pirminiai duomenys, bei galutiniai dvejetainiai sniego dangos žemėlapiai šiame darbe pateikti 20 x 20 m erdvine skiriamąja raiška.

### 3.5. Vandens atsargų sniege duomenų skiriamosios gebos didinimas naudojant dirbtinius neuroninius tinklus

Pasyvūs palydovų prietaisai, veikiantys mikrobangų spektre ir galintys užfiksuoti vandens atsargas sniege, pasižymi labai žema erdvine skiriamąja geba (15–25 km). Tokia skiriamoji geba nėra pakankama norint pritaikyti palydovinius VAS duomenis regioninei sniego dangos analizei bei mažų ir vidutinių upių hidrologiniam modeliavimui. Šiame tyrime buvo analizuojamos galimybės padidinti erdvinę EUMETSAT HSAF palydovinių VAS duomenų skiriamąją gebą nuo  $0,25^\circ \times 0,25^\circ$  (t. y. nuo maždaug 25 km) iki  $0,05^\circ \times 0,05^\circ$  (t. y. iki maždaug 5 km).

HSAF VAS duomenų rinkinio skiriamoji geba buvo padidinta laikantis prielaidos, kad ryšys tarp sniego dangos ir kitų aplinkos veiksnių (tokių kaip vietovės aukštis, žemės dangos tipas ir minimali oro temperatūra) išlieka nekintantis stambiame ir smulkiame mastelyje.

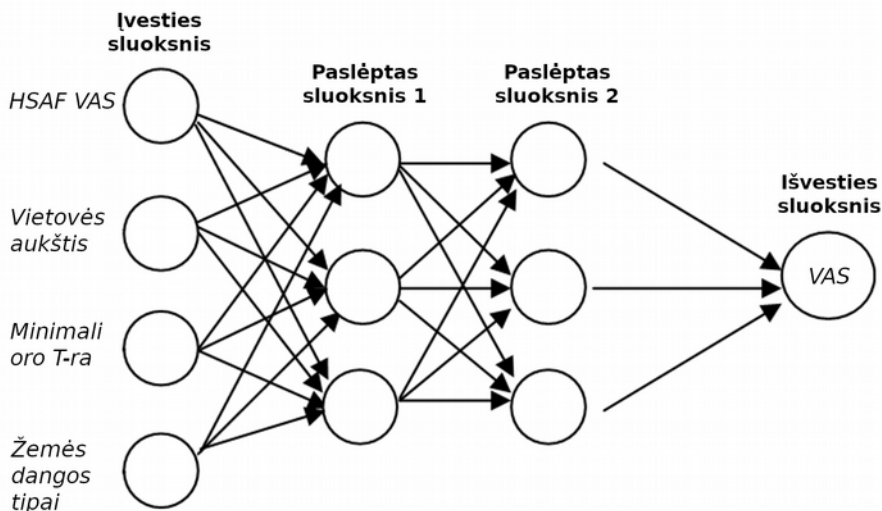
Palydovinių duomenų skiriamosios gebos didinimas buvo atliktas dviem metodais: naudojant tiesinę daugianarę regresiją DRM (angl. *Linear Regression Model*) ir dirbtinius neuroninius tinklus DNT (angl. *Artificial Neural Networks*). Šie būdai pasirinkti, nes į juos lengva įtraukti naujus prediktorius ir atnaujinti atsižvelgiant į papildomai surinktus naujus duomenis. Apmokant DNT ir DRM modelius ir vertinant jų tikslumą buvo naudojami VAS matavimai iš 52 meteorologijos stočių Baltijos valstybėse (žr. 2.1. pav.). Šiame tyrime naudoti HSAF VAS ir papildomi erdviniai duomenys apėmė penkis šaltuosius sezonus 2012–2018 m. laikotarpiu. Dalis atsitiktiniu būdu parinktų duomenų buvo palikta validacijai (13 %), o didžioji duomenų dalis buvo naudojami sudaryti DRM ir apmokyti DNT.

Pirmojo duomenų apdorojimo etapo metu GLCF žemės dangos ( $0,08^\circ \times 0,08^\circ$ ), SRTM DEM duomenys buvo perprojektuoti (angl. *resampled*) į  $0,25^\circ \times 0,25^\circ$  geografinį tinklą, kuris atitiko HSAF VAS ir  $T_{\min}$  duomenų tinklą. Tai leido sudaryti skiriamosios gebos atžvilgiu vienalytę duomenų bazę. Žemės dangos tipai buvo suskaidyti į skirtingus dvejetainius kintamuosius (0–1). Reljefo aukščio,  $T_{\min}$  ir HSAF VAS duomenys buvo normalizuoti naudojant jų minimumus ir maksimumus. Žemės dangos tipų suskaidymas ir duomenų normalizavimas atliktas todėl, kad DNT veikia geriau, kai visi kintamieji svyruoja nuo 0 iki 1.

Antrame etape buvo sudarytas DRM modelis susiejantis papildomus aplinkos rodiklius su HSAF VAS duomenimis. Sudarant daugianarės regresijos modelį, į galutinę jo versiją įtraukti tik tie prediktoriai, kurie buvo

reikšmingi, esant  $p < 0,05$  lygmeniui. Sudarytas DRM buvo naudotas padidinti HSAF VAS skiriamąją gebą iki  $0,05^\circ \times 0,05^\circ$ .

Trečiajame etape buvo sudarytas keturių sluoksnių „feed forward“ neuroninis tinklas. Jį sudarė įvesties sluoksnis, du paslėpti sluoksniai ir vienas išvesties sluoksnis (3.5 pav.). Dirbtinio neuroninio tinklo aktyvacijai pasirinkta sigmoidinė funkcija (angl. *sigmoid*). DNT mokymui panaudota 12160 HSAF VAS, vietovės aukščio, GLCF žemės dangos tipų ir  $T_{\min}$  duomenų porų. Svarbus DNT pranašumas prieš tiesinius modelius yra tai, kad jis nepriklauso nuo duomenų statistinio pasiskirstymo ir geba atrinkti netikslus ar nereikšmingus duomenis (Alexakis, Tsanis, 2016).



**3.5 pav.** Darbe naudoto dirbtinio neuroninio tinklo (DNT) schema.

Paskutiniame etape, DRM ir DNT metodais gauti aukštesnės skiriamosios gebos VAS duomenys buvo palyginti su sniego nuotraučių matavimais MS. Atliekant palyginimą buvo apskaičiuoti tokie statistiniai rodikliai:

1. Pearsono koreliacijos koeficientas.
2. Paklaida (ME):

$$ME = \frac{1}{N} \sum_{k=1}^N (\text{sat}_k - \text{insitu}_k) \quad (3.9)$$

3. Vidutinė absoliuti paklaida (MAE):

$$MAE = \frac{1}{N} \sum_{k=1}^N |\text{sat}_k - \text{insitu}_k| \quad (3.10)$$

4. Vidutinė kvadratinė paklaida (RMSE):

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N (\text{sat}_k - \text{insitu}_k)^2} \quad (3.11)$$

Šiose formulėse: *sat* – palydoviniai VAS duomenys; *insitu* – VAS matavimai MS; *N* – atvejų skaičius; *k* – atvejo eilė.

## 4. SNIEGO DANGOS CHARAKTERISTIKŲ NUSTATYMAS NAUDOJANT PALYDOVINIUS DUOMENIS

Šiame skyriuje pristatomi disertacijos darbo rezultatai, pateikiamas naudotas metodikos privalumų ir trūkumų vertinimas bei išvalgos susijusios su sniego dangos charakteristikų erdvine sklaida ir daugiamete kaita. Skyrių sudaro 5 dalys:

- Pirma dalis skirta pristatyti ilgalaikių sausumos MS sniego dangos stebėjimų Baltijos valstybėse rezultatus ir kaitos tendencijas. Daug dėmesio skiriama erdvinei ir sezoninei sniego dangos trukmės ir storio kaitai.
- Antroje dalyje aprašomi snygio nustatymo rezultatai naudojant ATMS duomenis bei mašininio mokymosi algoritmą. Validacija remiasi globaliais duomenimis, o detali atvejų analizė pateikta naudojant intensyvaus snygio atvejus JAV.
- Trečioje dalyje pateikiami MODIS sniego dangos duomenų palyginimo su MS stebėjimais Lietuvoje rezultatai bei įvertinami pasiūlytos duomenų trūkių užpildymo metodikos privalumai ir trūkumai.
- Ketvirta dalis skirta pristatyti SAR duomenimis paremtos sniego dangos klasifikacijos rezultatus Šventosios baseine. Nurodoma, kokiuose Žemės dangos tipuose duomenys yra tiksliausi ir kas lemia sniego dangos klasifikacijos klaidas.
- Penktoje dalyje aprašomi padidintos skiriamosios gebos HSAF VAS duomenų validacijos rezultatai, pateikiamas dirbtinių neuroninių tinklų ir tiesinių algoritmų vertinimas.

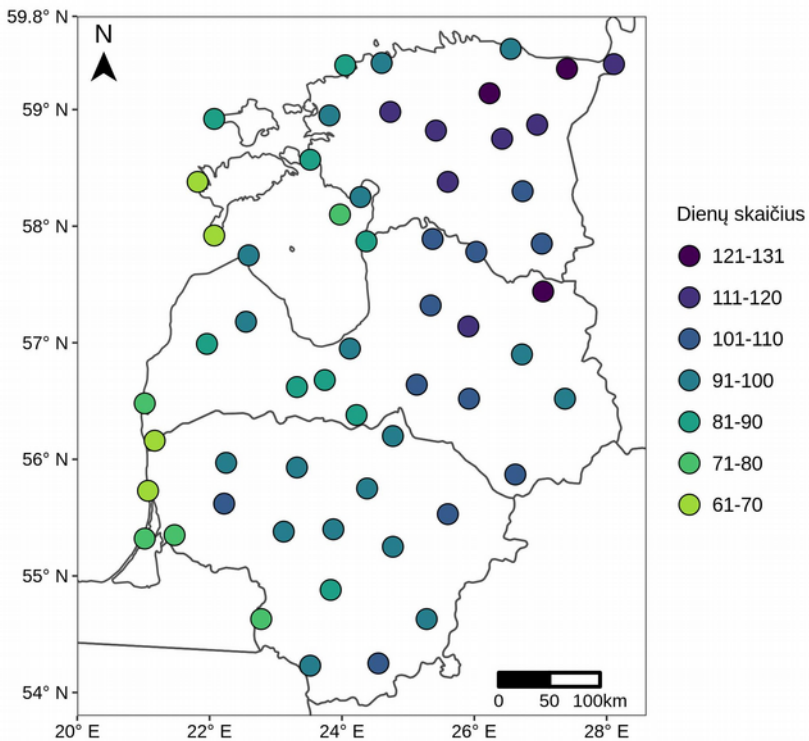
### 4.1. Sniego dangos charakteristikų kaita Baltijos valstybėse 1961–2015 m.

Šiame darbe vidutinės klimato sąlygos apibūdinamos remiantis 1981–2010 m. klimato norma, kuri buvo apskaičiuota visoms meteorologijos stotims Baltijos valstybėse. Naudojant šią klimato norma nustatyta, kad šalčiausi mėnesiai regione yra sausis ir vasaris, kai vidutinė temperatūra svyruoja nuo -6,1 iki -1,5 °C, o aukščiausia vidutinė oro temperatūra yra liepą, nuo 16,8 iki 18,8 °C. Vidutinis metinis kritulių kiekis kinta nuo 581 iki 872 mm. Didžiausias kritulių kiekis iškrenta vasaros mėnesiais (liepą ir



rugpjūtį) bei rudenį, o sausiausias laikotarpis Baltijos valstybėse yra žiema ir ankstyvas pavasaris.

Vidutiniškai pirmoji laikina sniego danga susidaro regiono šiaurės rytinėje dalyje lapkričio pradžioje, o pajūrio zonose – lapkričio mėnesio pabaigoje. Dažniausiai pastovi sniego danga pradeda formuotis po 3–4 savaitių, o sniegui kaupiantis jos storis palaipsniui didėja. Nustatyta, kad sniego danga maksimalų storį dažniausiai pasiekia vasario antroje pusėje arba kovo pradžioje. Kovo pradžioje prasideda sniego tirpimas, o pastovi sezoninė sniego danga visiškai ištirpsta kovo pabaigoje arba balandžio pradžioje. Tačiau tarpmetiniai sniego dangos trukmės ir tirpsmo datų svyravimai yra labai dideli. Kai kuriais tiriamo laikotarpio metais sniego danga išsilaikė iki balandžio vidurio, o trumpalaikiai sniego reiškiniai buvo stebimi ir gegužės pradžioje. Pastebėta, kad pastaraisiais dešimtmečiais didžiojoje Baltijos valstybių teritorijos dalyje vis dažniau nesusidaro pastovi sniego danga ir stebimi keli trumpalaikiai sniego dangos susiformavimo laikotarpiai kuriuos keičia atodėriai.

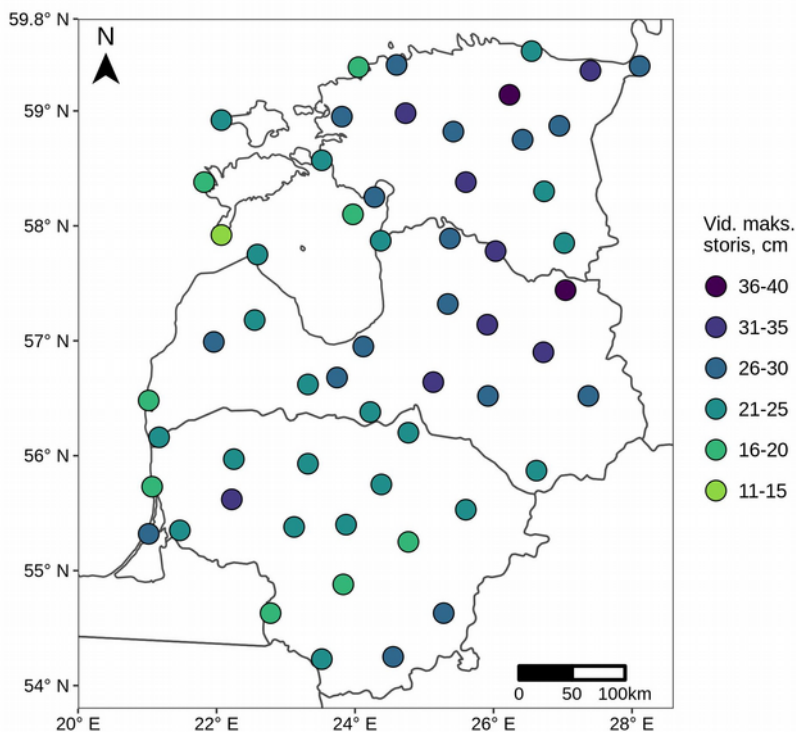


**4.1 pav.** Vidutinis dienų su sniego danga skaičius Baltijos valstybėse 1981–2010 m.

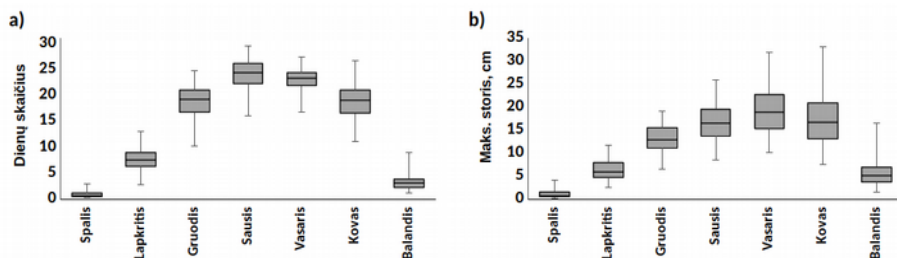
Pasirinktu klimato normos laikotarpiu (1981–2010 m.) buvo gauta, kad vidutiniškai Baltijos valstybėse būna 93 dienos su sniego danga (4.1 lentelė). Dienų su sniego danga skaičius svyravo nuo 56–70 dienų Baltijos jūros pajūryje iki daugiau nei 130 dienų šiaurės rytuose (4.1 pav.). Vidutinis maksimalus sniego storis kito nuo 15–20 cm pajūrio rajonuose ir Lietuvos pietvakariuose, iki daugiau nei 35 cm šiaurės rytinės Latvijos kalvose (4.2 pav.).

Vidutiniškai ilgiausiai sniego danga buvo fiksuojama sausio mėnesį, o maksimalus sniego storis – vasario mėnesį (4.3 pav.). Gruodis, sausis ir kovas pasižymėjo didžiausiais tarpmetiniais dienų su sniego danga skaičiaus svyravimais, o didžiausi tarpmetiniai sniego storio svyravimai buvo nustatyti vasarį ir kovą.

Dienų su sniego danga skaičius ir maksimalus sniego dangos storis yra glaudžiai susiję. Nustatyta, kad Pearsono koreliacijos koeficientas tarp šių rodiklių Baltijos valstybėse siekia 0,77 ( $p < 0,0001$ ). Glaudžiausias ryšys nustatytas spalio, kovo ir balandžio mėnesiais – t. y. tada, kai sniego danga nebuvo nuolatinė ir neapėmė visos teritorijos ( $r = 0,87–0,97$ ;  $p < 0,0001$ ).




**4.2 pav.** Vidutinis maksimalus sniego dangos storis Baltijos šalyse 1981–2010 m.



**4.3 pav.** Vidutinės mėnesio sniego dangos rodiklių reikšmės Baltijos šalyse 1981–2010 m.: a) dienų su sniego danga skaičius; b) maksimalus sniego dangos storis.

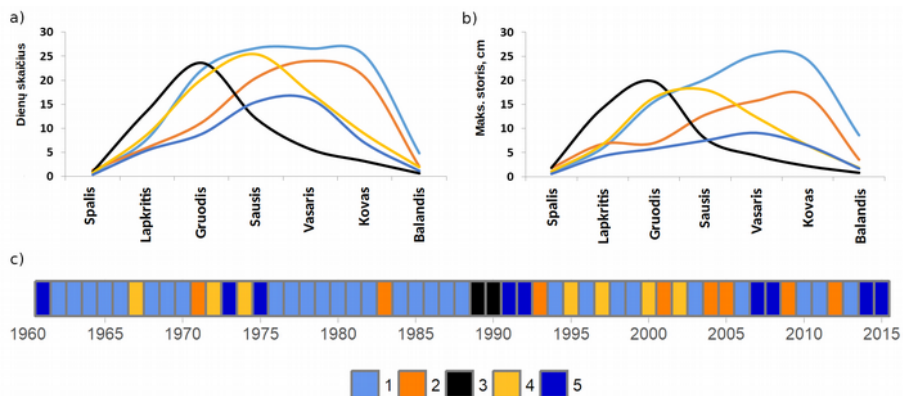
Anksčiau aptartos vidutinės sniego dangos rodiklių reikšmės rėmėsi 1981–2010 m. klimato normos laikotarpiu. Ilgalaikiai sniego dangos režimo pokyčiai Baltijos valstybėse buvo vertinti naudojant 1961–2015 m. duomenis. Nagrinėjant visą šį laikotarpį ir naudojant klasterinę analizę (plačiau žr. 3.1. skyrelį), žiemos buvo sugrupuotos į penkis tipus pagal joms būdingą sniego dangos režimą (4.4 pav.).



**4.4 pav.** Žiemų klasterinės analizės dendrolograma. Klasterizuota pagal mėnesio dienų su sniego danga skaičių bei maksimalų sniego storį. Punktyrinė linija žymi pasirinktą atstumą žiemų tipams apibūdinti.

Pirmajam tipui priklauso šaltos žiemos, kurių metu buvo užfiksuota daugiausia dienų su sniego danga ir buvo susiformavusi stora sniego danga (4.5 pav.). Tokiomis žiemomis sniego danga susiformuoja jau lapkritį arba gruodžio pradžioje ir išsilaiko iki kovo pabaigos ar balandžio pradžios. Antram tipui priskirtos žiemos, kai sniego danga susiformavo gana vėlai (daugiausia sausio pradžioje), tačiau buvo pastovi ir išsilaikė iki kovo

pabaigos. Trečio tipo žiemę nagrinėjamu laikotarpiu pasitaikė retai – tik 1989 ir 1990 m. Jos išsiskyrė labai anksti susiformavusia sniego danga, o jos maksimalus storis buvo užfiksuotas gruodžio mėnesį. Tačiau vėliau, po šios ankstyvos storos sniego dangos, sniegas ištirpo ir nuo sausio iki kovo susidarydavo tik trumpalaikė sniego danga. Ketvirtajam tipui priskirtos žiemos su vidutine sniego dangos trukme, tačiau su gana dideliu sniego storiu gruodžio ir sausio mėnesiais. Šios žiemos taip pat pasižymėjo tuo, kad antroje žiemos pusėje buvo fiksuoti atšilimai. Penkto tipo žiemos išsiskyrė labai plona bei nepastovia sniego danga (4.5 pav.) ir aukšta vidutine oro temperatūra.



**4.5 pav.** Sniego dangos režimo tipai Baltijos šalyse 1961–2015 m.: a) dienų su sniego danga skaičius; b) maksimalus sniego dangos storis; c) skirtingų sniego dangos režimo tipų pasiskirstymas laike. Žiemos tipai (1–5) pavaizduoti skirtingomis spalvomis.

1961–2015 m. laikotarpiu Baltijos valstybėse dienų su sniego danga skaičius mažėjo vidutiniškai 3,3 ( $p = 0,17$ ) dienos per dešimtmetį (4.6a pav.). Didžiausi pokyčiai užfiksuoti Latvijoje ir Lietuvoje, kur sniego dangos trukmė atitinkamai sumažėjo 4,2 ( $p = 0,09$ ) ir 4,0 ( $p = 0,09$ ) dienomis per dešimtmetį (4.1 lentelė). Nagrinėjant visą Baltijos valstybių teritoriją gauta, kad sniego dangos trukmės pokyčiai nebuvo statistškai reikšmingi. Tai yra daugiausiai susiję su dideliais tarpmetiniais dienų su sniego danga skaičiaus svyravimais ir nepastoviais pokyčiais. Ryškus sniego dangos trukmės sumažėjimas visame regione fiksuotas po 1989–1990 metų. Anksčiau, kitų autorių tyrime, nustatyta, kad tuo pačiu laikotarpiu Estijoje pasikeitė oro temperatūros, kritulių, sniego dangos ir nuotėkio režimas (Jaagus ir kt., 2017). Tyrimai Lenkijoje, taip pat parodė, kad 1988 ir 1989 m. buvo išskirtiniai, nes dienų su sniego dangos dienų skaičius buvo mažiausias per

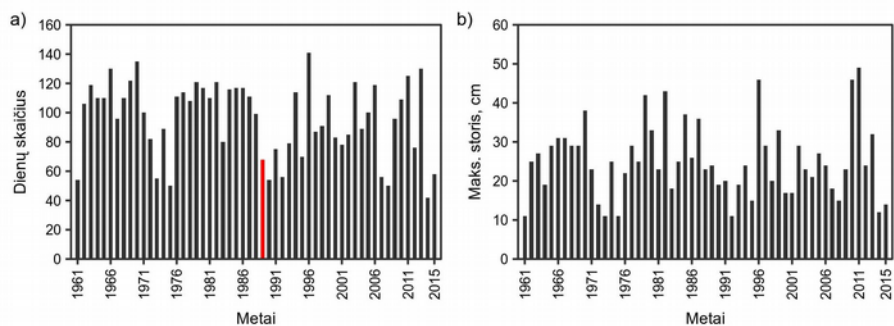
stebėjimo laikotarpį (Szwed ir kt., 2017). Pagal Rimkus ir kt. (2014) tyrimą šis laikotarpis buvo susijęs su labai aukštomis teigiamomis NAO indekso vertėmis ir Baltijos jūros regione galimai žymi žiemos sąlygų perėjimą iš žemyninio į jūrinį tipą (Hagen, Feistel, 2005). Laikoma, kad po 1989–1990 m., nustatyti sniego dangos ir kitų meteorologinių rodiklių pokyčiai yra labiau nulemti globalios klimato kaitos, o ne didelio masto atmosferos cirkuliacijos pokyčių.

**4.1 lentelė.** Dienų su sniego danga skaičiaus ir vidutinio maksimalaus sniego storio (cm) pokyčių tendencijos. Vidutinės rodiklių reikšmės pateiktos pagal 1981–2010 m. klimato normą, o tendencija (Sen nuolydis) apskaičiuota naudojant 1961–2015 m. laikotarpio duomenis. Skliausteliuose pateiktas trendo statistinis reikšmingumas pagal Mann-Kendal (p).

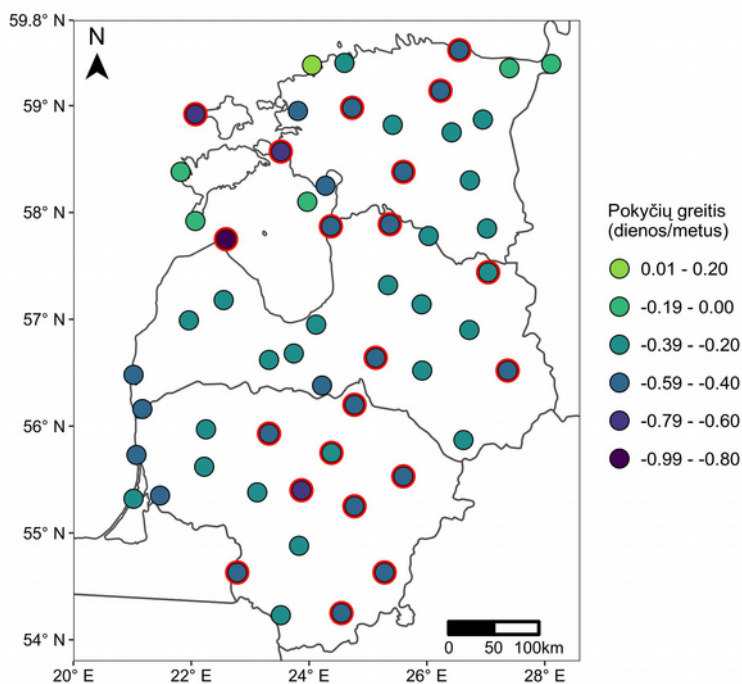
Teritorija	Dienų su sniego danga skaičius	Tendencija, dienos/per 10 metų	Vid. maks. sniego dangos storis, cm	Tendencija, cm/per 10 metų
Lietuva	87,7	-4,0 (p = 0,09)	23,3	-0,38 (p = 0,58)
Latvija	93,6	-4,2 (p = 0,09)	25,7	-0,61 (p = 0,53)
Estija	97,9	-2,7 (p = 0,19)	26,7	-0,32 (p = 0,68)
Baltijos valstybės	93,4	-3,3 (p = 0,17)	25,0	-0,55 (p = 0,48)

Ilgiausiai sniego danga Baltijos valstybėse išsilaiškė 1995–1996 m. žiemą (vidutiniškai 138 dienas), o mažiausia vidutinė sniego dangos trukmė (42 dienos) buvo užfiksuota 2013–2014 m. žiemą (4.6a pav.). Visose MS, išskyrus Pakri MS (Estija), buvo nustatytas dienų su sniego danga skaičiaus mažėjimas (4.7 pav.), tačiau šis pokytis buvo statistiškai reikšmingas tik 35 % matavimo vietų. Sparčiausiai dienų su sniego danga skaičius mažėja regiono pietryčiuose, aplink Rygos įlanką, bei kai kuriose Estijos vietovėse.

IPCC penktojoje ataskaitoje teigiama, kad sniego dangos trukmės ir ploto mažėjimas labiausiai pastebimas tuose regionuose, kur vidutinė oro temperatūra arti užšalimo taško, t. y. 0 °C (Vaughan ir kt., 2013). Tokiu atveju net ir nedideli oro temperatūros pokyčiai efektyviai sumažina sniego akumuliaciją, paspartina sniego tirpimą arba lemia abu procesus iš karto. Šiame darbe nustatyti dėsniniai atitinka šią globalią tendenciją – didžiausi pokyčiai nustatyti tose MS ir tais mėnesiais, kai oro temperatūra yra artima 0 °C.



**4.6 pav.** Tarpmetiniai sniego dangos parametrų svyravimai Baltijos valstybėse 1961–2015 m.: a) dienų su sniego danga skaičius; b) maksimalus sniego storis (cm). Metai, kuriais nustatytas sniego dangos trukmės režimo pasikeitimas pažymėti raudonai.

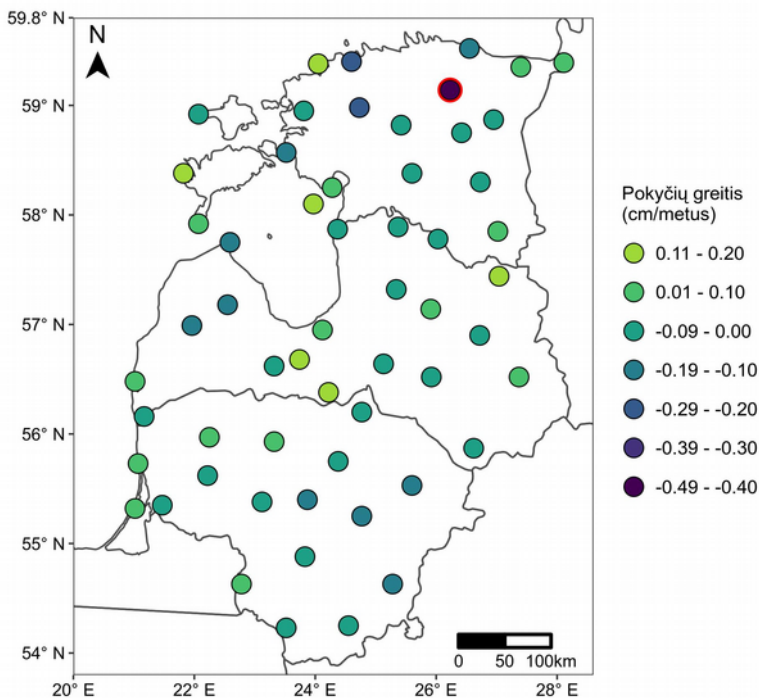


**4.7 pav.** Dienų su sniego danga skaičiaus pokyčiai Baltijos šalių meteorologijos stotyse 1961–2015 m. Stotys su statistiškai reikšmingais pokyčiais ( $p < 0,05$ ) apibrėžtos raudonai.

Nagrinėjamu laikotarpiu vidutinis maksimalus sniego storis Baltijos valstybėse beveik nepakito (4.1 lentelė). Tačiau antroje tirtu laikotarpio pusėje padidėjo jo tarpmetiniai svyravimai (4.6b pav.). Maksimalaus sniego storio kaitos tendencijos Baltijos šalių MS labai skyrėsi ir sunku išskirti


aiškias regiono zonas, kuriose vyrautų panašios tendencijos (4.8 pav.). Statistiškai reikšmingas ( $p < 0,05$ ) maksimalaus sniego dangos storio sumažėjimas nustatytas tik vienoje meteorologijos stotyje: Väike-Maarja, šiaurės Estijoje (-4,8 cm per dešimtmetį).

Nors šiame tyrime reikšmingų vidutinio maksimalaus sniego dangos storio pokyčių nenustatyta, daugelyje ankstesnių tyrimų kalbama apie sniego dangos storio mažėjimą. I. Gečaitė ir E. Rimkus (2010) nustatė, kad 1961–2010 m. laikotarpiu vidutinis maksimalus sniego storis Lietuvoje sumažėjo 3,5 cm. O. Bulygina ir kt. (2011) savo tyrime apskaičiavo, kad maksimalus sniego storis mažėja Europinėje Rusijos dalyje, o S. Rasmus ir kt. (2015) nustatė, kad maksimalus sniego storis sumažėjo Estijoje bei Lenkijoje. Tačiau visi šie tyrimai pabrėžia, kad Baltijos jūros regionui būdingi dideli tarpmetiniai sniego dangos storio svyravimai. Šis tyrimas apėmė 1961–2015 m. laikotarpį, o pačios didžiausios sniego storio reikšmės nustatytos 2011 m. Duomenys su nauju maksimumu galėjo lemti, kad apskaičiuoti trendai nėra statistiškai reikšmingi lyginant su kitais tyrimais, kurie naudojo kitų laikotarpių duomenis.



**4.8 pav.** Maksimalaus sniego dangos storio pokyčiai Baltijos šalių meteorologijos stotyse 1961–2015 m. Stotis su statistiškai reikšmingais pokyčiais ( $p < 0,05$ ) apibrėžta raudonai.

Nagrinėjant sniego dangos rodiklių pokyčius atskirais mėnesiais, nustatyta, kad labiausiai dienų su sniego danga skaičiaus sumažėjo gruodžio ir kovo mėnesiais. Tačiau statistiškai reikšmingas sumažėjimas buvo užfiksuotas tik balandžio mėnesį (4.9a pav.). Nagrinėjant vidutinį sniego dangos storį, nustatytas jo padidėjimas sausio mėnesį, o likusiais šaltojo sezono mėnesiais visi pokyčiai buvo neigiami (4.9b pav.). Nepaisant to, kad vasario ir kovo mėnesiais vidutinis maksimalus sniego storis sumažėjo, viso sezono vidutinis maksimumas beveik nepakito. Taip yra todėl, kad pastaraisiais dešimtmečiais maksimalus sniego storis dažniau fiksuotas gruodžio ir sausio mėnesiais. 1961–1988 m. laikotarpiu maksimalus sniego dangos storis gruodžio ir sausio mėnesiais buvo užfiksuotas tris kartus, o 1989–2015 m. laikotarpiu – dešimt kartų. 2012–2013 m. žiemą Baltijos valstybėse storiausia sniego danga buvo užfiksuota balandžio mėnesį, ir tai buvo vienintelis kartas per visą tyrimo laikotarpį.



**4.9 pav.** Mėnesio sniego dangos rodiklių pokyčiai Baltijos valstybėse 1961–2015 m.: a) dienų su sniego danga skaičius; b) maksimalus sniego dangos storis. Statistiškai reikšmingi pokyčiai ( $p < 0,05$ ) pažymėti juodu kontūru.

Tai, kad maksimalus sniego dangos storis Baltijos valstybėse keičiasi nežymiai, nors vidutinė žiemos temperatūra sparčiai kyla (Jaagus ir kt., 2014), galima paaiškinti ir tuo, kad vidutinis maksimalus sniego storis (25 cm) gali susiformuoti net ir vieno intensyvaus snygio metu. Maksimalus sniego storis nebūtinai yra sniego dangos akumuliacijos rezultatas – tai gali būti trumpalaikis reiškinys, labiau susijęs su intensyviais krituliais, nei su vidutinėmis žiemos sezono sąlygomis. Intensyvus snygis dažniau stebimas, kai oro temperatūra yra tik šiek tiek žemesnė arba aukštesnė nei  $0^{\circ}\text{C}$  (O’Gorman, 2014). Baltijos jūroje stebimas jūros ledo ploto ir trukmės mažėjimas (The BACC II Author Team, 2015), o tai lemia, kad daugiau šilumos iš vandens masės yra atiduodama atmosferai. Žiemą, vykstant šalto oro įsiveržimui ir esant sąlyginai šiltai, ledu nepadengtai, Baltijos jūrai, gali susidaryti palankios sąlygos labai intensyviame snygiui pajūrio teritorijose (Savijärvi, 2012). Tokių reiškinų metu gali susidaryti gili, tačiau



trumpalaikė sniego danga. J. Räisänen (2008) savo tyrime parodė, kad sniego dangos storio padidėjimas arba sumažėjimas XXI amžiuje priklausys nuo pusiausvyros tarp didėjančio šaltojo sezono kritulių kiekio ir kylančios oro temperatūros. Tai, kad šiame tyrime nenustatyta aiškių erdvinių ar statistiškai reikšmingų sniego dangos storio tendencijų, gali būti šio vykstančio balansavimo rezultatas.

Nagrinėjant 1961–2015 m. duomenis pastebėta, kad sniegingiausias laikotarpis pasislinko iš vasario į sausio mėn. Antroje šaltojo sezono pusėje vis dažniau stebimi atlydžiai ir laikotarpiai be sniego. Didžiausias sniego dangos rodiklių sumažėjimas užfiksuotas kovo mėnesį. Taip pat pasikeitė ir žiemos tipų, nustatytų naudojant klasterinę analizę (4.5 pav.), pasikartojimo dažnis. Pavyzdžiui, 1961–1988 m. 71 % visų žiemų atitiko pirmąjį sniego dangos režimo tipą, o 1989–2015 m. tokių žiemų sumažėjo iki 33 %, nors tai ir išliko vyraujantis tipas.

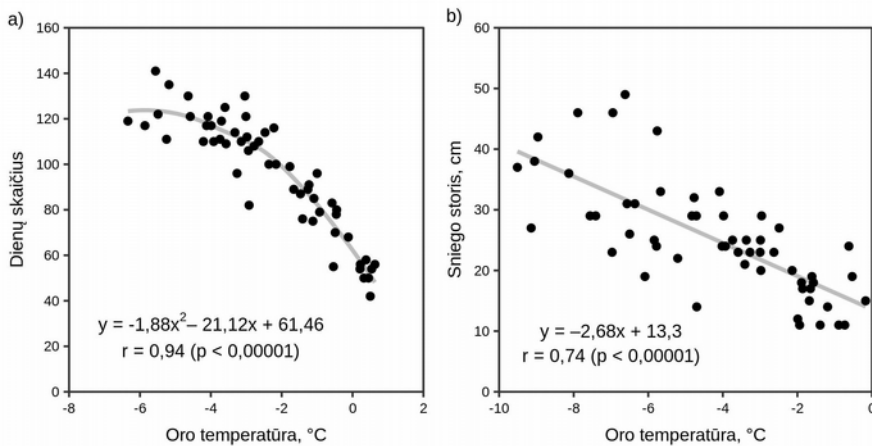
Panašios tendencijos pastebimos ir visame pasaulyje. IPCC penktojoje ataskaitoje pateikia duomenis, kad 1922–2012 m. laikotarpiu sniego dangos plotas didžiojoje dalyje Šiaurės pusrutulio vietų mažėjo, o ryškiausi pokyčiai, dėl padidėjusios oro temperatūros, nustatyti pavasarį ir rudenį (Vaughan ir kt., 2013). Dėl kylančios pavasario temperatūros Baltijos jūros baseine ir visoje šiaurinėje Eurazijoje pavasario sniego tirpsmas tampa trumpesnis ir intensyvesnis, o sniego dangos užimami plotai mažėja (Bulygina ir kt., 2011; Rasmus ir kt., 2015). Hidrologiniai tyrimai Estijoje (1951–2015 m.), Latvijoje (1951–2009 m.) ir Lietuvoje (1960–2009 m.) parodė, kad žiemos mėnesiais ir kovo mėnesį upių nuotėkis padidėjo dėl dažnesnio atlydžio, didėjančio skystų kritulių ir ankstesnio sniego tirpimo (Apsite ir kt., 2013; Jaagus ir kt., 2017; Stonevičius ir kt., 2014). Šias tendencijas patvirtina ir šio tyrimo rezultatai, kurie rodo kad ryškesni sniego dangos rodiklių pokyčiai Baltijos valstybėse įvyko žiemos pabaigoje ir pavasario pradžioje.

Siekiant įvertinti, kas turi didžiausią poveikį sniego dangos parametru kaitai Baltijos valstybėse, buvo tirtas jų ryšys su kitais meteorologiniais rodikliais ir geografiniais veiksniais. Nustatyta, kad sniego dangos trukmė labiausiai susijusi su vidutine oro temperatūra lapkričio-kovo mėn., o maksimalus sniego storis – sniego kaupimosi laikotarpiu (nuo gruodžio iki vasario mėn.). Visi 1961–2015 m. šaltieji sezonai, priklausomai nuo vidutinės temperatūros nuokrypio nuo klimato normos, buvo suskirstyti į tris lygias kategorijas. Naudojant šias kategorijas buvo įvertintas geografinių veiksnių poveikis erdviniam sniego dangos pasiskirstymui šaltomis ir šiltomis žiemomis.

Nustatyta, kad analizuojamoje teritorijoje vidutinis dienų su sniego danga skaičius glaudžiai koreliuoja su lapkričio–kovo mėnesio temperatūra ( $r = -0,94$ ;  $p < 0,00001$ ). Ryšys neigiamas ir netiesinis (4.10a pav.). Vidutinės oro temperatūros svyravimai itin šaltomis žiemomis turėjo labai mažai įtakos šiam parametrai (t. y. nesvarbu, kiek šalta buvo žiema – pasiekus maksimalų mėnesio dienų skaičių, sniego dangos trukmė didėti nebegali).

Atskirais šalčio laikotarpiu mėnesiais (lapkričio–kovo mėn.) koreliacijos koeficientai svyravo tarp  $-0,75$  ( $p < 0,00001$ ) ir  $-0,85$  ( $p < 0,00001$ ), o spalio ir balandžio mėnesiais jie atitinkamai sumažėjo iki  $-0,60$  ( $p < 0,00001$ ) ir  $-0,46$  ( $p = 0,0004$ ). Spalio ir balandžio mėnesiais vidutinė oro temperatūra buvo daug aukštesnė nei  $0\text{ }^{\circ}\text{C}$ , todėl šiems mėnesiams sniego danga nėra įprasta. Todėl šiais mėnesiais užfiksuotas platus oro temperatūros intervalas, kada nebuvo fiksuota sniego danga ir koreliacija yra gerokai mažesnė nei žiemos viduryje.

Vidutinis maksimalus sniego storis su vidutine oro temperatūra buvo labiausiai susijęs sniego kaupimosi laikotarpiu (gruodžio–vasario mėn.) ( $r = -0,74$ ;  $p < 0,00001$ ) (4.10b pav.). Nustatytas ryšys yra tiesinis, tačiau pastebėta, kad kai vidutinė gruodžio–vasario temperatūra nukrinta žemiau  $-4\text{ }^{\circ}\text{C}$ , padidėja duomenų sklaida.



**4.10 pav.** Ryšys tarp sniego dangos ir meteorologinių rodiklių Baltijos valstybėse 1961–2015 m.: a) ryšys tarp dienų su sniego danga skaičiaus ir vidutinės oro temperatūros lapkričio–kovo mėn.; b) ryšys tarp vidutinio maksimalaus sniego dangos storio ir oro temperatūros gruodžio–vasario mėn.

Teigiama, kad vidutinė žiemos temperatūra Baltijos jūros regione kyla sparčiau nei globali vidutinė temperatūra (Jaagus ir kt., 2014; The BACC II

Author Team, 2015). 1871–2011 m. laikotarpiu vidutinė metinė oro temperatūra šiame regione kilo 0,08 °C per dešimtmetį, o žiemos temperatūra – 0,10 °C per dešimtmetį (The BACC II Author Team, 2015). Turint omenyje glaudų neigiamą ryšį toks vidutinės oro temperatūros kilimas daro tiesioginę neigiamą įtaką sniego dangos trukmei Baltijos valstybėse. Šiame tyrime apskaičiuota, kad sezoninės sniego dangos trukmė vidutiniškai sumažėja 3,3 dienos per dešimtmetį (4.1 lentelė). Panašūs pokyčių greičiai nustatyti ir kituose tyrimuose: Estijoje gauta, kad per dešimtmetį dienų su sniego danga skaičius sumažėja 3–4 dienomis (Jaagus ir kt., 2017), o visame Baltijos jūros baseine vidutiniškai 2,6 dienomis per dešimtmetį (Rasmus ir kt., 2015). Visame šiaurės pusrutulyje, 1972–2008 m. laikotarpiu, sniego dangos trukmė mažėjo 5,3 dienomis per dešimtmetį, o didžiausi pokyčiai stebimi nuo XX a. devintojo dešimtmečio pabaigos (Choi ir kt., 2010).

Šiame darbe taip pat buvo nagrinėtas ir kritulių ryšys su sniego dangos rodikliais. Nustatyta, kad krituliai sniego dangos trukmei reikšmingos įtakos neturėjo. Silpna neigiama, statistiškai reikšminga koreliacija ( $r = -0,32$ ;  $p = 0,017$ ) buvo nustatyta tik vasario mėnesį. Tai galima paaiškinti tuo, kad didesnis kritulių kiekis fiksuojamas šiltesnėmis žiemomis ( $r = 0,50$ ;  $p = 0,0001$ ), krituliai dažniau iškrinta lietaus pavidalu, o tai prisideda prie sniego tirpimo.

Nagrinėjant kritulių įtaką sniego dangos storiui nustatyta, kad ryšys sniego dangos kaupimosi laikotarpiu yra nereikšmingas. Šiltomis žiemomis didelę kritulių dalį sudaro skysti krituliai, kurie labai paspartina sniego tirpsmą. Šaltomis žiemomis kritulių poveikis sniego storiui yra teigiamas, nes vyrauja kieti krituliai (sniegas). Atskirais mėnesiais koreliacija tarp maksimalaus sniego storio ir kritulių buvo labai silpna. Tik spalio ir gruodžio mėnesiais nustatyta statistiškai reikšminga teigiama koreliacija (atitinkamai  $r = 0,29$  ( $p = 0,033$ ) bei  $r = 0,32$  ( $p = 0,017$ )). Šaltomis žiemomis statistiškai reikšmingai teigiama koreliacija tarp kritulių kiekio ir maksimalaus sniego storio buvo nustatyta spalį ( $r = 0,45$ ;  $p = 0,0005$ ), gruodį ( $r = 0,54$ ;  $p < 0,0001$ ), sausį ( $r = 0,27$ ;  $p = 0,046$ ) ir vasarį ( $r = 0,55$ ;  $p < 0,0001$ ).

Žiemą erdviniam sniego dangos rodiklių pasiskirstymui didelę įtaką daro gana šilta Baltijos jūra. Centrinė jūros dalis yra orientuota pietų – šiaurės kryptimi, todėl meteorologijos stoties geografinė ilguma yra gera aproksimacija fiziniam atstumui iki centrinės Baltijos jūros dalies. Reali jūros pakrantės forma yra sudėtinga, todėl atstumas nuo meteorologijos stoties iki Baltijos jūros kranto nebuvo glaudžiai susijęs su stoties geografine ilguma ( $r = 0,41$ ;  $p = 0,0019$ ). Realus atstumas iki pakrantės sniego dangos rodikliams turėjo įtakos lapkričio-vasario mėn. (4.2 lentelė). Tačiau

koreliacija nebuvo stipri, nes rytinė Suomijos įlankos dalis ir Rygos įlanka žiemą dažnai užšąla, o dėl to labai sumažėja terminis kontrastas tarp jūros ir žemyno. Prie užšalančių pakrančių esančiose meteorologinėse stotyse sniego dangos trukmė ir sniego storis buvo palyginti dideli. Todėl šiame tyrime, vertinant galimą jūros poveikį sniego dangos rodikliams, vietoj fizinio atstumo iki Baltijos jūros pakrantės buvo naudojama stočių geografinė ilguma.

Koreliacijos koeficientas tarp MS geografinės ilgumos ir dienų su sniego danga skaičiaus siekė net 0,79 ( $p < 0,00001$ ). Šis ryšys stipriausias buvo gruodžio-vasario mėn. (4.2 lentelė), kai vidutinė oro temperatūra buvo žemiausia, o šiluminis kontrastas tarp jūros ir sausumos – didžiausias. Šiais mėnesiais aiškiai matomas sniego dangos trukmės meridianinis pasiskirstymas (t. y. dienų su sniego danga skaičius didėja einant iš vakarų į rytus).

**4.2 lentelė.** Dienų su sniego danga skaičiaus ir maksimalaus sniego storio koreliacija su geografiniais rodikliais Baltijos valstybėse 1961–2015 m. Pirmas skaičius – sniego dangos trukmė, antras – maksimalus sniego dangos storis. Statistiškai reikšmingi ( $p < 0,05$ ) koreliacijos koeficientai paryškinti.

Mėnuo	Platuma	Ilguma	Absoliutinis aukštis	Atstumas iki jūros
Spalis	<b>0.48/0.48</b>	<b>0.67/0.55</b>	<b>0.35/0.19</b>	0.04/-0.16
Lapkritis	0.25/ <b>0.61</b>	<b>0.60/0.59</b>	<b>0.54/0.17</b>	0.23/-0.16
Gruodis	0.14/ <b>0.38</b>	<b>0.79/0.54</b>	<b>0.48/0.31</b>	<b>0.47/0.00</b>
Sausis	0.16/ <b>0.33</b>	<b>0.80/0.50</b>	<b>0.63/0.40</b>	<b>0.50/0.06</b>
Vasaris	<b>0.39/0.40</b>	<b>0.81/0.66</b>	<b>0.52/0.47</b>	<b>0.33/0.15</b>
Kovas	<b>0.64/0.55</b>	<b>0.73/0.71</b>	<b>0.35/0.39</b>	0.07/0.09
Balandis	<b>0.63/0.65</b>	<b>0.51/0.58</b>	0.24/ <b>0.27</b>	-0.11/-0.07
Viso sezono	<b>0.40/0.35</b>	<b>0.79/0.54</b>	<b>0.52/0.41</b>	<b>0.32/0.07</b>

Ryšys tarp geografinės platumos ir sniego dangos rodiklių nustatytas spalio–lapkričio mėn. bei kovo–balandžio mėn. Šiais pereinamaisiais laikotarpiais regione susidaro didelis oro temperatūros gradientas tarp pietų ir šiaurės. Gruodžio ir sausio mėn. geografinės platumos poveikis sniego dangos trukmei buvo nereikšmingas – kaip minėta anksčiau, tuomet didžiausią poveikį turi atstumas iki centrinės Baltijos jūros dalies.

Kitas svarbus geografinis veiksnys, lemiantis sniego dangos trukmę, buvo vietovės aukštis virš jūros lygio ( $r = 0,52$ ;  $p = 0,00005$ ) (4.2 lentelė). Nors teritoriniai absoliutaus aukščio skirtumai nebuvo dideli (aukščiausias matavimo taškas buvo Alūksnėje, Latvijoje – 197 m), tačiau aukštesnėse vietovėse fiksuota žemesnės oro temperatūra ir sniego danga susidarė anksčiau ir ištirpo vėliau. Taip pat MS stebėjimai rodo, kad aukštesnėse sniego danga yra storesnė, o atlydžių pasitaiko rečiau.

Šaltojo sezono pradžioje maksimaliam sniego storiui didelę įtaką turėjo geografinė platumas ir ilgumas (4.2 lentelė). Gruodžio–vasario mėn. didėjo vietovės aukščio poveikis, o geografinės platumos įtaka šiek tiek sumažėjo. Geografinės platumos poveikis vėl sustiprėjo kovo ir balandžio mėnesiais. Realus atstumo iki Baltijos jūros kranto poveikis maksimaliam sniego storiui buvo nereikšmingas visą šaltąjį sezoną (4.2 lentelė).

Geografinės ilgumos ir reljefo įtaka sniego rodikliams buvo didesnė šiltomis žiemomis, kai sniego dangos rodiklių erdviniai skirtumai buvo didesni. Didėjant vietovės aukščiui ir atstumui nuo centrinės Baltijos jūros dalies sniego danga išsilaikydavo vis ilgiau nei pakrančių rajonuose. Sniego dangos rodiklių skirtumai tarp rytinės ir vakarinės regiono dalies buvo daug didesni šiltomis žiemomis. Šiltomis žiemomis dienų su sniego danga skaičius kai kuriose jūros pakrantės MS buvo 70 % mažesnis nei šiltomis žiemomis. Tuo tarpu kai kuriose žemyninėse stotyse šis skirtumas vos viršijo 20 %. Maksimalaus sniego storio skirtumai nebuvo tokie dideli. Šiltomis žiemomis maksimalus sniego storis buvo 30–40 % mažesnis žemyninėse stotyse ir 60–70 % mažesnis pajūrio stotyse. Šaltomis žiemomis išryškėjo geografinės platumos poveikis sniego dangos rodikliams.

Norint įvertinti suminių geografinių parametrų (platumos, ilgumos ir vietovės aukščio) poveikį sniego dangos rodiklių erdviniam pasiskirstymui Baltijos valstybėse, buvo sudaryti šie daugianarės regresijos modeliai:


$$DSS = -209,3 + 3,30x + 4,42y + 0,13z \quad (4.1)$$

$$MSS = -77,9 + 1,46x + 0,67y + 0,05z \quad (4.2)$$

kur DSS – dienų su sniego danga skaičius; MSS – maksimalus sniego storis, cm;  $x$  – geografinė platumas, WGS84 dešimtainiais laipsniais;  $y$  – geografinė ilgumas, WGS84 dešimtainiais laipsniais,  $z$  – vietovės aukštis, metrais virš jūros lygio.

Sudarius daugianarės regresijos modelius gauta, kad dienų su sniego danga modelio determinacijos koeficientas ( $R^2$ ) yra 0,77, o maksimalaus sniego storio – 0,47. Liekamosios standartinės paklaidos (angl. *residual standard errors*) buvo sąlyginai mažos: sniego dangos trukmei – 7,8 dienos, ir 4,0 cm sniego storio maksimumui.

Modelių paklaidos buvo naudojamos nustatyti atvejus ir procesus, kurių sudaryti regresiniai modeliai negalėjo tinkamai aprašyti. Didžiausios dienų su sniego danga skaičiaus modelio paklaidos buvo nustatytos kai kuriose pajūrio stotyse, kur fiksuojami didžiausi sniego dangos rodiklių gradientai (4.11 pav.). Modeliu gauta gerokai mažiau dienų su sniego danga nei išmatuota MS. Prie jūros esančiose MS, dienų su sniego danga skaičius gali būti gerokai mažesnis nei stotyse, esančioje keli kilometrai nuo pakrantės.

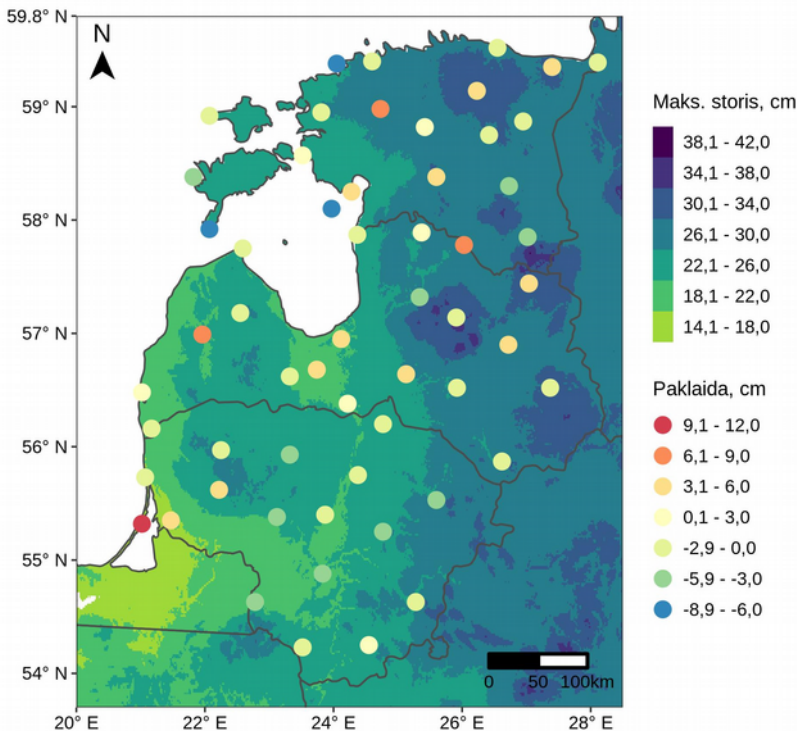


**4.11 pav.** Pagal daugianarės regresijos modelį apskaičiuotas vidutinis daugiametis dienų su sniego danga skaičius Baltijos valstybėse. Paklaidos rodo skirtumą (dienomis) tarp MS išmatuotų ir sumodeliuotų reikšmių.

Neigiamos paklaidos taip pat buvo užfiksuotos ir rytinėje, žemyninio klimato, regiono dalyje. Atstumas iki centrinės Baltijos jūros dalies, kurį gerai atspindi MS geografinė ilguma, yra svarbus veiksnys lemiantis erdvinį dienų su sniego danga pasiskirstymą, tačiau šis poveikis tolstant nuo jūros mažėja. Priklausomybė nėra tiesinė ir sudarytas daugianarės regresijos modelis nėra pajėgus tinkamai įvertinti šio ryšio. Tai lėmė, kad kai kuriose rytinėje dalyje esančiose MS buvo užfiksuotos neigiamos paklaidos (modeliu gauta 7–19 dienomis daugiau nei išmatuota MS) (4.11 pav.).

Didžiausios teigiamos paklaidos (12–13 dienų) buvo užfiksuotos dviejose Šiaurės Estijos stotyse (Kuusiku ir Väike-Maarja MS) (4.11 pav.). Tai rodo, kad sudarytas daugianarės regresijos modelis pilnai neįvertino geografinės platumos poveikio sniego dangos trukmei žemyninėse stotyse.

Nagrinėjant maksimalų sniego storį, gautą naudojant daugianarės regresijos modelį, erdvinis paklaidų pasiskirstymas buvo ne toks aiškus kaip sniego dangos trukmės atveju (4.12 pav.). Sniego storis labai priklauso nuo vietinių MS klimato sąlygų ir stoties aplinkos. Didžiausios teigiamos sniego storio modelio paklaidos nustatytos Nidos MS, kuri yra labiausiai į vakarus nutolusi stotis ir yra įkurta siaurame pusiasalyje (4.12 pav.). Nidos MS išmatuotas maksimalus sniego storis buvo daug didesnis nei gautas naudojant daugianarės regresijos modelį. Dėl specifinių pusiasalio sąlygų, šaltuoju sezonu Kuršių nerijoje kartais pasitaiko gausaus sniego atveju, kai susidaro gili, bet trumpalaikė sniego danga. Tai lemia šiltas Baltijos jūros ir Kuršių marių vanduo bei didelis vandens garų kiekis, kuris, vykstant šalto oro įsiveržimui, gali sukelti lokalaus masto intensyvų snygį.



**4.12 pav.** Pagal daugianarės regresijos modelį apskaičiuotas vidutinis maksimalus sniego dangos storis Baltijos valstybėse. Paklaidos rodo skirtumą tarp MS išmatuotų ir sumodeliuotų reikšmių.

Be aptartų geografinių rodiklių sniego dangos storiui ir trukmei įtakos turi ir kitos kraštovaizdžio savybės, kurios nebuvo įtrauktos į šį tyrimą (pvz.: miškingumas, kalvų šlaito nuolydis ir ekspozicija). Šie papildomi aplinkos parametrai galbūt galėtų padėti įvertinti vietines sniego dangos pokyčių tendencijas ir erdvinio pasiskirstymo dėsningumus.

Šis sniego rodiklių tyrimas parodė, kad 1961–2015 m. laikotarpiu Baltijos valstybėse sniego dangos trukmė vidutiniškai trumpėjo 3,3 dienos per dešimtmetį. Tačiau šių pokyčių intensyvumas regione nebuvo vienodas: statistškai reikšmingas ( $p < 0,05$ ) dienų su sniego danga skaičiaus sumažėjimas užfiksuotas tik 35 % stočių. Nagrinėjamu laikotarpiu vidutinis maksimalus sniego storis Baltijos valstybėse beveik nepakito, o statistškai reikšmingas sumažėjimas užfiksuotas tik vienoje stotyje Estijoje. Nustatyta, kad didžiausią įtaką erdviniam sniego dangos rodiklių pasiskirstymui turi vietovės aukštis ir geografinė ilguma (atstumas iki centrinės Baltijos jūros dalies). Mėnesio ir sezono sniego dangos trukmei daugiausiai įtakos turi vidutinė oro temperatūra, o kritulių kiekio poveikis nėra toks reikšmingas. Maksimalus sniego storis su vidutine oro temperatūra buvo glaudžiai susijęs sniego kaupimosi laikotarpiu (nuo gruodžio iki vasario mėn.), o vidutinis mėnesio kritulių kiekis reikšmingos įtakos sniego storio maksimumui neturėjo.

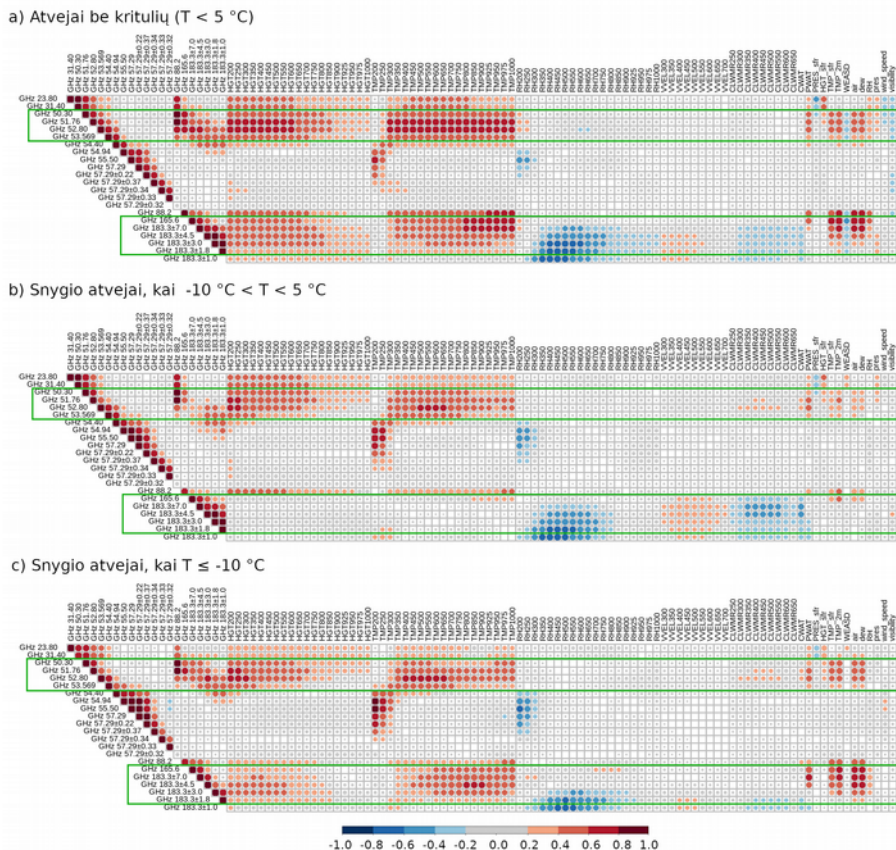
#### 4.2. Snygio duomenų, nustatytų naudojant ATMS, palyginimas su kritulių stebėjimais antžeminėse stotyse

Sniego dangos formavimasis prasideda nuo snygio. Tradiciškai snygis ir jo intensyvumas matuojami meteorologinėse stotyse, tačiau jį galima įvertinti ir naudojant palydovinius duomenis. Turint tikslius erdvinius palydovinius snygio duomenis galima būtų lengviau stebėti ir prognozuoti sniego dangos akumuliaciją.

Šiame darbe snygio nustatymui buvo naudoti ATMS jutiklio, esančio Suomi-NPP palydove duomenis. ATMS jutiklis turi 22 spektrines juostas ir, priklausomai nuo naudojamo mikrobangų dažnio, gali užfiksuoti skirtingas atmosferos ir žemės paviršiaus savybes. Siekiant nustatyti, kurios spektrinės juostos potencialiai yra tinkamos snygiui aptikti, buvo sudarytos koreliacijos matricos tarp palydovinio jutiklio teikiamos informacijos ir GFS globalaus orų modelio duomenų. Koreliacijos matricos sudarytos trims skirtingiems atmosferos būviams: 1) atvejams kai nebuvo jokių kritulių, o oro temperatūra buvo žemesnė nei +5 °C; 2) atvejams kai buvo fiksuotas snygis, o priežeminė oro temperatūra svyravo tarp +5 ir -10 °C; 3) atvejams kai



snigo, tačiau priežeminė oro temperatūra buvo žemesnė nei  $-10\text{ }^{\circ}\text{C}$  (4.13 pav.). Visi 4.13 pav. spalvomis pateikti koreliacijos koeficientai buvo reikšmingi esant  $p < 0,01$  statistinio reikšmingumo lygmeniui.



**4.13 pav.** ATMS ryškio temperatūros ir GFS modelio kintamųjų (žr. 2.3. lentelę) koreliacijos matricos ( $p < 0,01$ ): a) atvejai, kai nebuvo kritulių, o oro temperatūra ( $T$ ) prie žemės paviršiaus buvo žemesnė nei  $5\text{ }^{\circ}\text{C}$ ; b) snigio metu, kai oro temperatūra svyruoja tarp  $5\text{ }^{\circ}\text{C}$  ir  $-10\text{ }^{\circ}\text{C}$ ; c) snigio metu, kai temperatūra buvo žemesnė nei  $-10\text{ }^{\circ}\text{C}$ . Žaliai pažymėtos ATMS juostos, kurių koreliacijos reikšmės kinta keičiantis kritulių tipui.

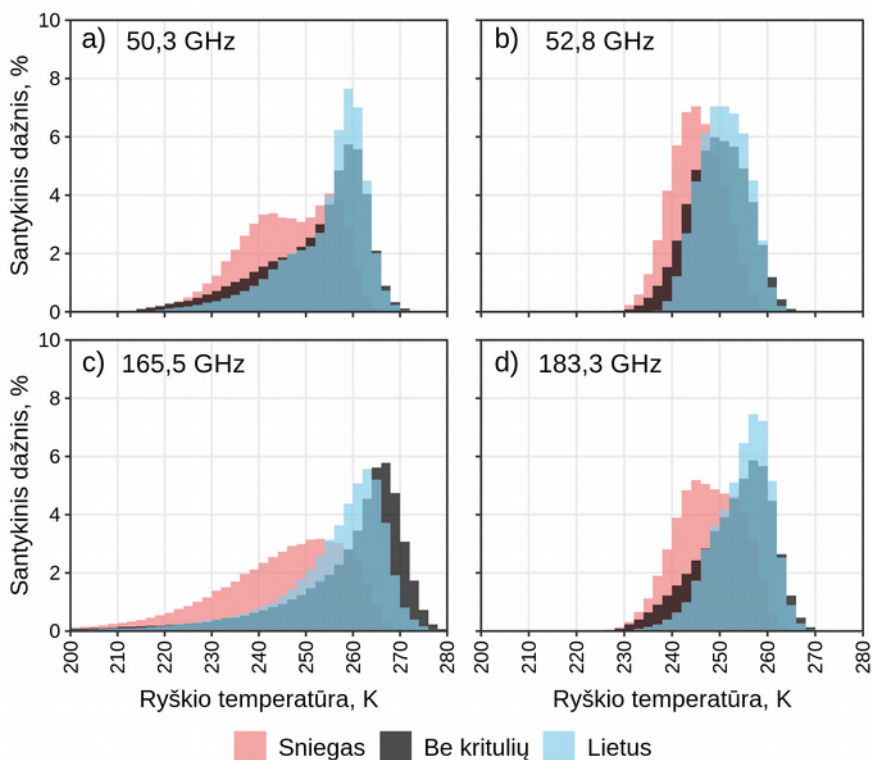
Nustatyta, kad spektrinėse juostose, kurios yra ties atmosferos skaidrumo langais (53,6 GHz ir 88,2 GHz) ATMS duomenys koreliuoja ne tik su atmosferos temperatūra (1000–300 hPa lygiuose), bet ir su Žemės paviršiaus rodikliais (oro temperatūra ir rasos tašku 2 m aukštyje, vandens atsargomis sniege – WEASD). Lyginant atvejus be kritulių su snigiu ( $-10\text{ }^{\circ}\text{C} < T < +5\text{ }^{\circ}\text{C}$ ) matyti, kad ATMS 165–183 GHz duomenys snigio atveju pasižymi aukšta koreliacija su GFS rodikliais, aprašančiais drėgmės kiekį atmosferoje

(CLWMR, CWAT) bei vertikalius atmosferos judesius (VVEL) vidurinėje ir viršutinėje troposferos dalyje (600–300 hPa lygiuose) (4.13b pav.). Tai parodo, kad snygio atveju ATMS jutiklis fiksuoja debesų parametrus ir kritulių formavimąsi atmosferoje, ypač procesus vykstančius vidurinėje troposferoje. Tačiau esant šaltiems orams ( $T \leq -10 \text{ }^\circ\text{C}$ ) ir labai šaltai atmosferai snygio atveju koreliacija tarp ATMS 165–183 GHz ryškio temperatūros ir CLWMR, CWAT, VVEL rodiklių tampa nereikšminga (4.13c pav.).

Labai šalto oro atveju rodiklių koreliacijos matrica skiriasi nuo snygio atvejų, esant  $-10 - +5 \text{ }^\circ\text{C}$  temperatūrai, ir yra panašesnė į matricą, būdingą atvejams be kritulių: pastebimas glaudesnis ryšys tarp ryškio temperatūros ir Žemės paviršiaus rodiklių (4.13a, c pav.). Šie rezultatai atitinka kitų autorių tyrimus, kuriuose teigiama, kad esant šaltam orui yra per mažai vandens garų, kad ATMS jutiklis būtų pajėgus užfiksuoti jų skleidžiamą mikrobangų spinduliuotę (Kongoli ir kt., 2015; Meng ir kt., 2017). Todėl, esant šaltam ir sąlyginai sausam orui, didesnė dalis ATMS jutiklio fiksuojamos spinduliuotės ateina nuo Žemės paviršiaus, bet ne iš atmosferos (net jei ir krinta kieti krituliai).

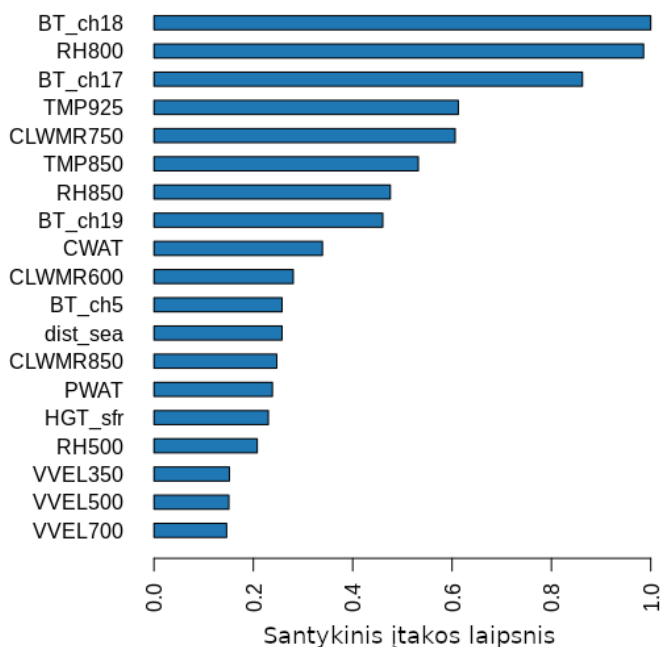
Naudojantis sudarytomis koreliacijos matricomis buvo atrinktos ATMS spektrinės juostos, kurios yra glaudžiai susijusios su troposferos temperatūra ir Žemės paviršiaus sąlygomis (50,3–53,6 GHz arba 3–6 juostos), drėgmės kiekiu atmosferoje ir vertikaliais judesiais (165,6–183 GHz arba 17–20 juostos) ir, kurių reikšmės skyrėsi lyginant atvejus be kritulių ir snygį. Tačiau šių ATMS juostų užfiksuotos ryškio temperatūros duomenų skirstiniai yra panašūs ir didele dalimi persidengia: lietaus ir snygio atveju persidengia 44–85 % duomenų, snygio ir atvejų be kritulių skirstiniai persidengia 31–67 % (4.14 pav.).

Kadangi ATMS ryškio temperatūros reikšmės skirtingų kritulių tipų atvejais yra gana panašios, vien tik šio jutiklio matavimų neužtenka tiksliai nustatyti kritulių tipui. Siekiant tiksliau nustatyti snygio tikimybę, sudarant RF algoritmą buvo naudojami ir GFS modelio rodikliai. Pirminių duomenų bazę sudarė 142 ATMS ir GFS kintamieji 2014–2018 m. laikotarpiu. Taip pat nuspręsta neįtraukti lietaus atvejų ir susikoncentruoti į snygio atskyrimą nuo atvejų be kritulių. Du trečdaliai sudaryto duomenų rinkinio (2012–2016 m.) panaudota apmokant RF kritulių klasifikacijos algoritmą, o trečdalis (2017–2018 m.) palikta algoritmo validacijai. Iš pradinių 142 parametrų, naudojant RF algoritmo kintamųjų santykinės svarbos rodiklį (angl. *variable importance*), buvo atrenkami patys svarbiausi (4.15 pav.). Santykinė svarba parodo kiek, panaudojus konkretų kintamąjį naujai RF klasifikacijos šakai, sumažėjo galutinio rezultato kvadratinė paklaida.



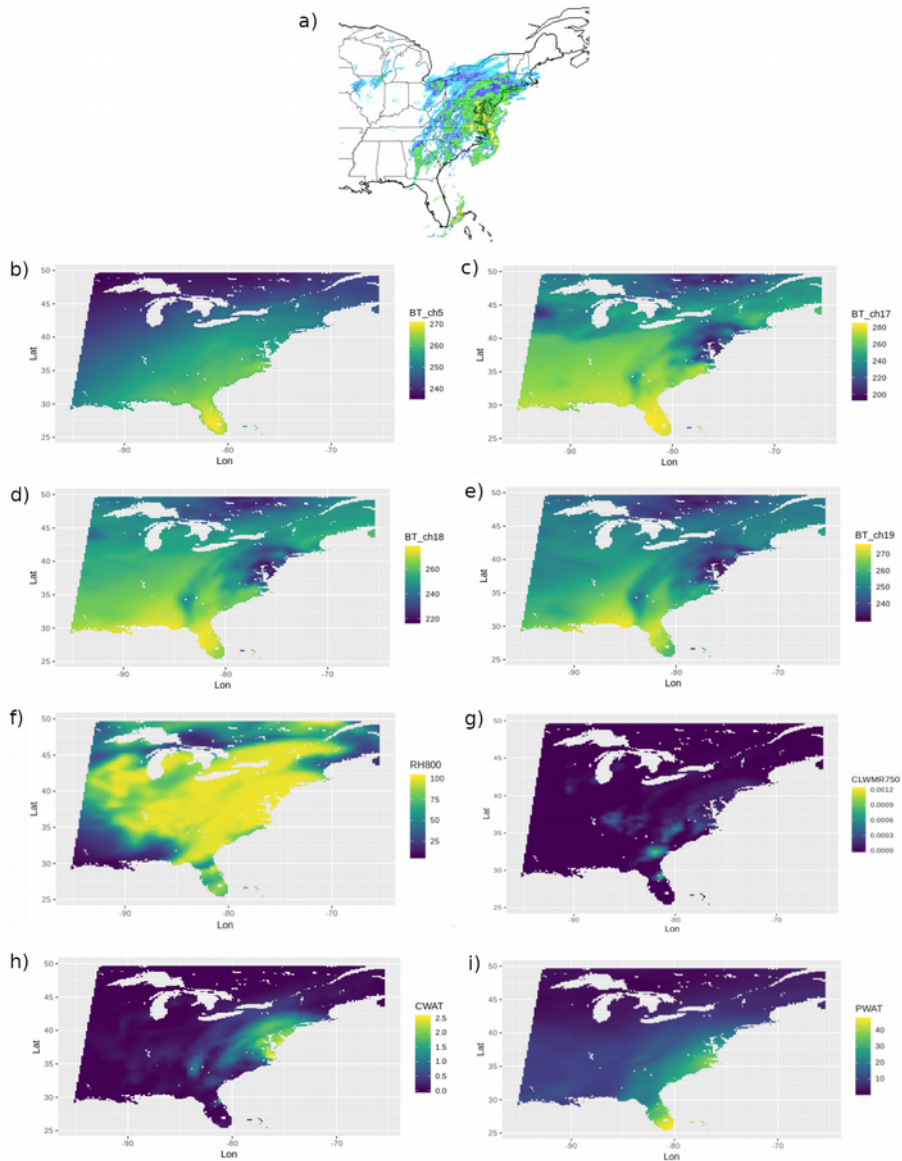
**4.14 pav.** ATMS ryškio temperatūros reikšmių pasiskirstymas lyjant, sningant ir atvejais be kritulių, naudojant skirtingas spektrines juostas su centriniais dažniais: a) 50,3 GHz; b) 52,8 GHz; c) 165,5 GHz; d) 183,3 GHz. Tamsesni mėlynos spalvos atspalviai parodo, kur lietaus atvejų skirstinys persidengia su atveju be kritulių ir snigio ryškio temperatūros skirstiniais.

Naudojant santykinės prediktorių svarbos rodiklį, buvo atlikta 20 RF algoritmo sudarymo iteracijų, kurių metų buvo pašalinama po 5–10 mažiausiai įtakos turinčių kintamųjų. Kiekvienos iteracijos metu, pašalinus dalį rodiklių, pasikeisdavo ir kitų rodiklių įtakos laipsnis, todėl jei būdavo pastebima, kad pašalinus kintamąjį labai pakisdavo svarbiausių rodiklių eilė, rodiklis buvo grąžinamas ir iteracija kartojama pašalinant kitus rodiklius. Galiausiai iš 142 ATMS ir GFS rodiklių, buvo atrinkti 8 svarbiausi snigio prediktoriai. Gauta, kad snigio ir atvejų be kritulių klasifikavimo RF algoritmui didžiausia įtaką turėjo ATMS 165,5–183,3 GHz ( $BT_{ch17-19}$ ) ir 52,8 GHz ( $BT_{ch5}$ ) spektro juostų ryškio temperatūra ir GFS modelio temperatūros santykinė drėgmė 800 hPa lygyje (RH800), mišinio santykis debesyse 750 hPa lygyje (CLWMR750), bendras vandens kiekis debesyse (CWAT) ir vandens kiekis, kuris gali iškristi kaip krituliai (PWAT).



**4.15 pav.** Snygio nustatymo atsitiktinių miškų (RF) algoritmo santykinės įtakos laipsnis, kuris parodo kokią santykinę svarbą klasifikacijos tikslumui turi konkretus ATMS ir GFS rodiklis. Paveiksle parodyta 20 kintamųjų su didžiausia santykinė svarba iš 142 naudotų.

ATMS 52,8 GHz ryškio temperatūra apibūdina vidutinę troposferos temperatūrą (4.16b pav.), panašiai kaip sinoptinėje meteorologijoje naudojami geopotencialaus aukščio skirtumai tarp skirtingų hPa lygių (pvz. 1000–500 hPa). ATMS 165,5–183,3 GHz ryškio temperatūra yra glaudžiai susijusi su vandens garų kiekiu atmosferos storumėje ir žema ryškio temperatūra parodo, kur vandens lašelių ir ledo kristalų debesyse yra daugiausiai (4.16c, d, e pav.). Tačiau panašios reikšmės gaunamos ir esant giedrai, kai ant paklotinio paviršiaus yra susiformavusi sniego danga. GFS modelio CWAT rodiklis apibūdina bendrą vandens kiekį debesų storumėje (4.16f pav.), o PWAT parodo, kur atmosferoje yra daugiausiai vandens, kurie potencialiai gali iškristi kaip krituliai (4.16g pav.). RH800 apibūdina drėgmės sąlygas apatinėje troposferoje (4.16h pav.), o CLWMR750 – skysto vandens masės santykį su oro mase 750 hPa lygyje – jis didžiausias ten, kur yra stori konvekciniai debesys (4.16i pav.).



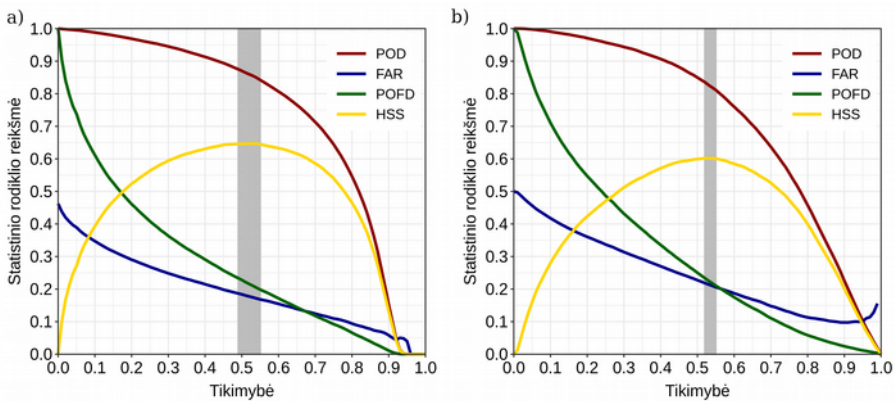
**4.16 pav.** ATMS ryškio temperatūros ir GFS modelio parametų reikšmės 2017 kovo 14 d. snigio metu JAV rytinėje dalyje: a) meteorologinio radaro atspindžio vaizdas, b) 52,8 GHz; c) 165,5 GHz; d)  $183,3 \pm 7,0$  GHz; d)  $183,3 \pm 4,5$  GHz; e)  $183,31 \pm 3,0$  GHz; f) RH800; g) CLWMR750; h) CWAT; i) PWAT.

Naudojant 8 pasirinktus rodiklius buvo sudarytas RF snigio nustatymo modelis bei logistinės regresijos modelis. Logistinės regresijos modelis sudarytas siekiant įvertinti, ar RF turi pranašumą lyginant su paprastesniais

tiesiniais modeliais. Gauta logistinės regresijos lygtis, kurios statistiniai validacijos rodikliai naudojant pirminius apmokymo duomenis buvo  $POD = 0,84$ ,  $POFD = 0,22$ ,  $HSS = 0,62$ :

$$\ln\left(\frac{P}{1-P}\right) = 28,17 + 0,0678 * BT_{ch5} + 0,0004 * BT_{ch17} - 0,1399 * BT_{ch18} - 0,0399 * BT_{ch19} + 0,0421 * RH800 + 1871,4 * CLWMR750 + 1,556 * CWAT - 0,2815 * PWAT \quad (4.3)$$

kur  $P$  – snygio tikimybė,  $BT_{ch5}$  – 52,8 GHz ryškio temperatūra (K),  $BT_{ch17}$  – 165,5 GHz ryškio temperatūra (K),  $BT_{ch18}$  – 183,3±7,0 GHz ryškio temperatūra (K),  $BT_{ch19}$  – 183,3±4.5 GHz ryškio temperatūra (K),  $RH800$  – santykinė drėgmė 800 hPa lygyje (%),  $CLWMR750$  – mišinio santykis debesyse 750 hPa lygyje (kg/kg),  $CWAT$  – vandens kiekis debesyse (kg/m<sup>2</sup>),  $PWAT$  – vandens kiekis atmosferoje, kuris potencialiai gali iškristi kaip krituliai (kg/m<sup>2</sup>).



**4.17 pav.** Validacijos rezultatai naudojant skirtingas snygio tikimybės reikšmes (0–100 %): a) RF algoritmas, b) logistinės regresijos algoritmas. Pilka sritis rodo, kur HSS yra didžiausias, ir šią tikimybės reikšmę galima laikyti kritine: a)  $\geq 49\%$ , b)  $\geq 52\%$ .

Naudojant tiek RF, tiek logistinės regresijos algoritmus gaunama snygio tikimybė. Pasirinkus tam tikrą kritinę tikimybės ribą (pvz.: 50 %) galima sudaryti binarinius snygio žemėlapius. Remiantis Heidke įverčiu (HSS) nustatyta, kokia algoritmais gauta snygio tikimybė jau yra patikima. RF atveju snygis patikimai nustatomas esant 49 % ( $HSS = 0,646$ ) ir aukštesnei tikimybei, o logistinės regresijos atveju – 52 % ( $HSS = 0,602$ ) (4.17 pav.). Taip pat kuo didesnis skirtumas tarp  $POD$  ir  $POFD$  reikšmių, prie pasirinktos tikimybės – tuo tikslesnis yra algoritmas. RF atveju ties pasirinkta ribine

tikimybe  $POD = 0,88$ , o  $POFD = 0,23$  (4.17a pav.), o logistinės regresijos atveju  $POD = 0,84$ , o  $POFD = 0,24$  (4.17b pav.). Visi validacijos rezultatai apibendrinti 4.3 lentelėje.

**4.3 lentelė.** Snygio aptikimo tikslumas naudojant ATMS jutiklio ryškio temperatūrą ir GFS modelio išvesties duomenis, taikant atsitiktinių miškų (RF) ir logistinės regresijos algoritmus. Italica šriftu pateikti rezultatai gauti esant šaltai atmosferai ( $T < -10$  °C). Validacijos rezultatai iš C. Kongoli ir kt. (2018) tyrimo pateikti palyginimui.

Metodas	Prediktoriai	ACC	POD	POFD	HSS
RF	<u>ATMS</u> : $BT_{ch5}$ , $BT_{ch17}$ , $BT_{ch18}$ , $BT_{ch19}$	0,83	0,88	0,23	0,65
	<u>GFS</u> : RH800, CLWMR750, CWAT, PWAT	<i>0,68</i>	<i>0,68</i>	<i>0,32</i>	<i>0,35</i>
Logistinė regresija	<u>ATMS</u> : $BT_{ch5}$ , $BT_{ch17}$ , $BT_{ch18}$ , $BT_{ch19}$	0,80	0,84	0,24	0,60
	<u>GFS</u> : RH800, CLWMR750, CWAT, PWAT	<i>0,68</i>	<i>0,61</i>	<i>0,26</i>	<i>0,35</i>
Hibridinis (Kongoli ir kt. 2018)	<u>ATMS</u> : $BT_{ch16}$ , $BT_{ch17}$ , $BT_{ch18}$ , $BT_{ch19}$ , $BT_{ch20}$ , $BT_{ch21}$ , $BT_{ch22}$ <u>GFS</u> : RH, TEMP, VVEL (1, 2, 3 km), debesų pado ir viršutinės ribos aukštis	0,79	0,72	0,17	0,55

Gauti statistinės validacijos rezultatai taip pat buvo palyginti su šiuo metu NOAA naudojamo ATMS snygio nustatymo algoritmo rezultatais, kurie pateikti C. Kongoli ir kt. (2018) tyrime. Šiame darbe gautos snygio aptikimo tikimybės tiek RF, tiek logistinės regresijos atveju buvo aukštesnės ( $POD = 0,80-0,83$ ) nei C. Kongoli ir kt. (2018) tyrime ( $POD = 0,72$ ) (4.3 lentelė). Tačiau klaidingo nustatymo tikimybė taip pat didesnė ( $POFD = 0,23-0,24$ ) ir tai rodo, kad šiame darbe sudaryti algoritmai linkę padidinti snygio tikimybę, ir dažniau nustato jį ten kur kritulių nėra. Taip pat nustatyta, kad esant šaltoms oro sąlygoms ( $T < -10$  °C) ATMS duomenys nėra tinkami nustatyti snygį, nes  $POD$  sumažėja iki  $0,61-0,68$ , o klaidos tikimybė ( $POFD$ ) išauga iki  $0,26-0,32$  (4.3 lentelė). Y. Wang ir kt. (2013) savo tyrime nustatė, kad snygio intensyvumo nustatymui, naudojant zonduojantį mikrobangų radiometrą AMSR-E, rezultatams įtakos turi ne tik snygio dalelių dydis, bet ir skysto (arba peršaldyto) vandens kiekis debesyse. Jie nustatė, kad prie žemės paviršiaus esant žemesnei nei  $-10$  °C oro temperatūrai, skysto vandens kiekis debesyse nebeatitinka logaritminio pasiskirstymo ir labai priklauso nuo debesies tipo. Todėl, tokiomis šaltomis sąlygomis skysto vandens debesyse poveikis snygio nustatymui yra įvertinamas netiksliai.

Šiame tyrime gauti rezultatai patvirtina šį teiginį, nes priežeminei oro temperatūrai krentant žemiau  $-10\text{ }^{\circ}\text{C}$  snygio nustatymo tikslumas ATMS jutikliu labai sumažėja.

Sudarytas RF snygio nustatymo algoritmo pritaikymas išbandytas naudojant kelis intensyvaus snygio atvejus JAV 2014–2018 m. (4.18 pav.). 2014 lapkričio mėnesį dėl susiformavusio omega formos blokuojančio gūbrio (angl. *omega block pattern*) susidarė palankios sąlygos šaltos arktinės oro masės įveržimui, kuri lėmė labai šaltus orus centrinėje JAV dalyje lapkričio 8–23 d. Šiuo laikotarpiu buvo registruojami minimalios oro temperatūros rekordai, o vietomis susidarė palankios sąlygos intensyviam snygiui. Naudojant RF algoritmą buvo sudarytas snygio tikimybės žemėlapis 2014 m. lapkričio 18 d. atvejui (4.18c pav.), kai snigo Ajovos ir Iliojaus valstijose (4.18a pav.). Lyginant RF algoritmo rezultatus su meteorologinio radaro ir NOAA ATMS snygio intensyvumo algoritmo rezultatais, matyti, kad RF algoritmu buvo nustatyta 80–100 % snygio tikimybė didesniame plote nei rodė meteorologinio radaro stebėjimai ar NOAA algoritmas.

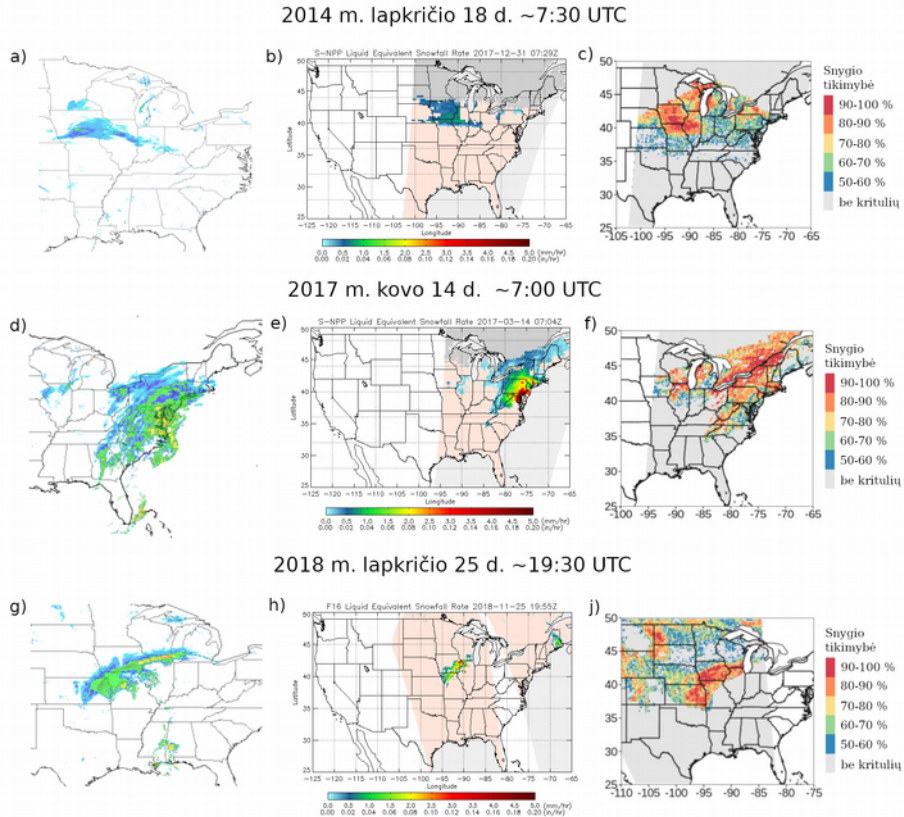
2017 m. kovo 14 d. vidutinių platumų ciklonas sukėlė labai intensyvių snygių ir pūgą JAV šiaurės rytuose (4.18d pav.). Kai kur per 24 val. iškrito iki 80 mm kritulių (sniego). RF algoritmu sudarytas snygio tikimybių žemėlapis atitinka atmosferos frontinių zonų konfigūraciją (4.18f pav.), tačiau lyginant su NOAA taikomu algoritmu (4.18e pav.) ir radaro duomenimis - kritulių zona per daug išplečia link Kanados ir Didžiųjų ežerų regiono.

2018 m. lapkričio 25 d. centrinėje JAV dalyje susiformavo gausių kritulių zona (4.18g pav.). Kanzaso ir Misūrio valstijose buvo fiksuojamos liūtys ir perkūnija, o šiauriau esančiose Ajovos, Viskonsino ir Iliojaus valstijose – intensyvus snygis (4.18h pav.). RF algoritmas pagrindiniam atmosferos frontui teisingai priskyrė 90–100 % kritulių tikimybę, tačiau, kaip buvo minėta anksčiau, pietvakarinėje jo dalyje iškrito lietus, o ne sniegas. Be to, RF algoritmas nustatė 50–70 % snygio tikimybę labai didelėje teritorijoje į šiaurės vakarus nuo pagrindinių ciklono frontų, nors ten kritulių visai nebuvo.

Pateikti pavyzdžiai rodo, kad sudarytas RF algoritmas teisingai identifikuoja teritorijas, kur buvo fiksuoti intensyvūs krituliai (priskiria joms 80–100 % snygio tikimybę), tačiau ne visais atvejais tai buvo sniegas. Visų analizuotų pūgų metu RF algoritmas 50–80 % snygio tikimybę nustatė ir tuose regionuose, kur kritulių apskritai nebuvo. Tai atitinka ir validacijos statistinius rodiklius (POFD = 0,23) bei parodo, kad RF algoritmas padidina snygio atvejų skaičių. Tai, greičiausiai, susiję su tuo, kad algoritmo sudarymui atrinkti ATMS jutiklio ir GFS modelio duomenys apibūdina vidutinės troposferos storumės sąlygas ir nėra tinkami tiksliau apibrėžti



kritulių zonos ribas. Tikėtina, kad RF snygio aptikimo algoritmą būtų galima patobulinti įtraukiant tokius rodiklius, kurie galėtų padėti apibrėžti lietaus (snygio) debesų ribas (pvz.: debesų storį, konvekcijos intensyvumą ir pan.).



**4.18 pav.** RF snygio klasifikacijos algoritmo pritaikymas intensyvių pūgų nustatymui JAV. Pirmas stulpelis (a, d, g) – meteorologinių radarų vaizdas (rodo kritulių pasiskirstymą ir intensyvumą); antras stulpelis (b, e, h) – šiuo metu NOAA naudojamo ATMS hibridinio snygio intensyvumo nustatymo modelio reikšmės (mm/val.); trečias stulpelis (c, f, j) – snygio tikimybė (%) naudojant ATMS duomenis ir RF klasifikacijos algoritmą.

Atlikta analizė rodo, kad ATMS jutikliu užfiksuotos ryškio temperatūros nepakanka norint tiksliai nustatyti snygio atvejus ir reikalinga papildoma informacija apie atmosferos būklę iš GFS skaitmeninio orų modelio. ATMS 165,5–183,3 GHz dažniuose užfiksuota ryškio temperatūra pasižymi aukšta koreliacija su drėgmės kiekiu troposferoje bei vertikaliais atmosferos judesiais. Tačiau esant šaltiems orams ( $T \leq -10$  °C) koreliacija tampa nereikšminga ir ATMS duomenys nėra pajėgūs tiksliai nustatyti snygio

atvejų. Snygio nustatymui sudaryti logistinės regresijos ir RF snygio klasifikavimo modeliai pasižymėjo panašia snygio aptikimo bei klaidos tikimybe, tačiau tais atvejais, kai snygio atvejai erdviškai ir laiko prasme yra reti – RF tikslumas yra didesnis (gautas aukštesnis Heidke įvertis). Esant šaltoms oro sąlygoms ( $T < -10$  °C) abiejų snygio nustatymo algoritmų tikslumas buvo mažesnis.

#### 4.3. Dienų su sniego dangą skaičiaus nustatymas Lietuvoje naudojant MODIS duomenis

Sniego danga pradeda formuotis iškritus sniegui ir laikantis vidutinei neigiamai oro temperatūrai, o sniego dangos trukmė yra laikoma tinkamu rodikliu apibūdinant žiemos sąlygas tiriamoje vietovėje. Sniego dangos susidarymą galima nustatyti naudojant regimojo spektro palydovinius duomenis, tačiau jų panaudojimą apsunkina debesuotumas. Vienas iš šio tyrimo uždavinių buvo apskaičiuoti metinį dienų su sniego dangą skaičių remiantis radiometro MODIS duomenimis, tačiau pirmiausia reikėjo užpildyti šių duomenų trūkius atsirandančius dėl debesuotumo.

Lietuvoje šaltuoju sezonu ištisinio debesuotumo sąlygos susidaro labai dažnai. Remiantis 2002–2018 m. MOD10A1 (palydovas „Terra“) ir MYD10A1 (palydovas „Aqua“) duomenimis, šaltuoju sezonu (spalio–balandžio mėn.) vidutiniškai 76–78 % laiko Lietuvos teritorija buvo padengta debesimis. Atvejai su debesimis sudarė nuo 70 % (2010–2011 m.) iki 84 % (2016–2017 m.) MODIS palydovinių duomenų. Siekiant užpildyti šiuos duomenų trūkius buvo naudojama 4 žingsnių metodika, detaliai aprašyta 3.2 skyrelyje.

Atlikus „Aqua“ ir „Terra“ MODIS duomenų apjungimą (I žingsnis) ir pikselių užpildymą pagal artimiausius 8 kaimyninius pikselius (II žingsnis) debesimis uždengtų pikselių skaičių pavyko sumažinti 11–13 % (4.4 lentelė). Apjungus „Aqua“ ir „Terra“ duomenis, vidutinis debesimis uždengtų pikselių skaičius sumažėjo iki 71%, o po II žingsnio sumažėjo iki 65 %. Pradiniame MYD10A1 duomenų rinkinyje ilgiausias nenutrūkstantis laikotarpis, kai tas pats pikselis buvo padengtas debesimis, siekė 89 dienas, o po erdvinio duomenų filtravimo (I ir II žingsniai) sumažėjo iki 35 dienų.

Atlikus erdvinį duomenų filtravimą, likę duomenų trūkiai, atsiradę dėl debesuotumo, buvo užpildyti naudojant filtravimą laike – randant pikselio reikšmę prieš arba po debesuoto laikotarpio (III žingsnis). Kadangi ištisinio debesuotumo laikotarpiai kai kuriais atvejais siekė 4 savaites ir daugiau, naudojant filtravimą laike gaunamos didelės paklaidos lyginant su

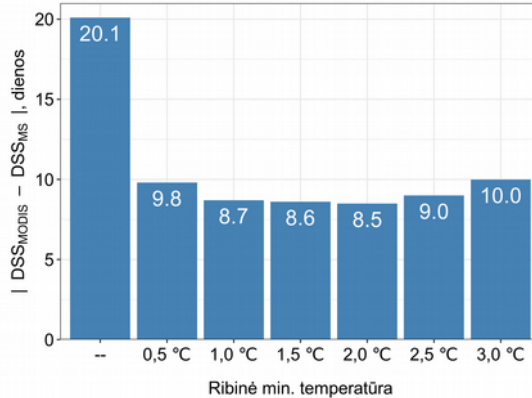
stebėjimais MS. Siekiant sumažinti neteisingos sniego dangos klasifikacijos atvejų skaičių buvo naudojamas papildomas paros minimalios oro temperatūros filtras (IV žingsnis).

**4.4 lentelė.** Debesimis padengtų pikselių kaita MODIS sniego duomenų rinkinyje skirtinguose duomenų apdorojimo žingsniuose. Skliausteliuose nurodytas šaltasis laikotarpis kai buvo užfiksuota minimali arba maksimali debesuotumo reikšmė.

Apdorojimo žingsnis	Vidutinis debesimis padengtų pikselių skaičius, %	Minimali sezono debesuotumo reikšmė, %	Maksimali sezono debesuotumo reikšmė, %	Ilgiausias nepertraukiamas laikotarpis su debesimis viename pikselyje, dienos
MYD10A1	78	74 (2006/2007)	84 (2016/2017)	89 (2010/2011)
MOD10A1	76	70 (2010/2011)	83 (2016/2017)	58 (2017/2018)
I žingsnis	71	64 (2010/2011)	78 (2016/2017)	45 (2009/2010)
II žingsnis	65	58 (2010/2011)	72 (2016/2017)	35 (2003/2004)

Laikyta, kad tomis dienomis, kai minimali oro temperatūra viršijo nustatytą ribą, sniego dangos negalėjo būti. Jei minimali paros temperatūra buvo aukštesnė už kritinę reikšmę pikselis buvo laikomas be sniego, net jei MODIS ir užfiksavo sniego dangą. Visais šalčio sezono mėnesiais buvo naudojama ta pati kritinė temperatūros reikšmė. Siekiant nustatyti minimalios oro temperatūros ribą, geriausiai tinkančią sniego dangos filtravimui Lietuvoje, buvo naudotos šešios skirtingos minimalios oro temperatūros ribinės reikšmės: 0,5 °C, 1 °C, 1,5 °C, 2 °C, 2,5 °C, 3 °C (4.19 pav.). Nenaudojant jokio temperatūros filtro gauta, kad metinis DSS apskaičiuotas remiantis MODIS duomenimis ( $DSS_{MODIS}$ ), nuo MS stebėjimų ( $DSS_{MS}$ ) vidutiniškai skyrėsi 20 dienų. Naudojant bet kurią pasirinkto intervalo (0,5–3,0 °C) minimalios oro temperatūros reikšmę metinio  $DSS_{MODIS}$  vidutinės absoliučios paklaidos sumažėjo perpus, iki 8,5-10 dienų (4.19 pav.). DSS palyginimas buvo atliekamas naudojant 17 MS duomenis 2002–2018 m. laikotarpiu. Gauta, kad 1 °C, 1,5 °C ir 2,5 °C minimalios temperatūros kritinės reikšmės buvo efektyviausios vienodame skaičiuje stočių. Tačiau vertinant visos Lietuvos vidurkį gautą, kad tinkamiausia ribinė minimali paros temperatūra yra 2,0 °C (4.19 pav.). Ši reikšmė ir buvo pasirinkta palydovinių sniego dangos duomenų temperatūros kontrolei (IV žingsnis). Atliktas metinio  $DSS_{MODIS}$  ir  $DSS_{MS}$  palyginimas rodo, kad bet kuri

oro temperatūros reikšmė 1–2 °C intervale yra tinkama norint nufiltruoti pikselius, kurie yra neteisingai klasifikuoti kaip padengti sniegu. Nustatyta kritinė minimali paros oro temperatūros reikšmė nėra universali ir turėtų būti pritaikoma konkrečiam tiriamam regionui.

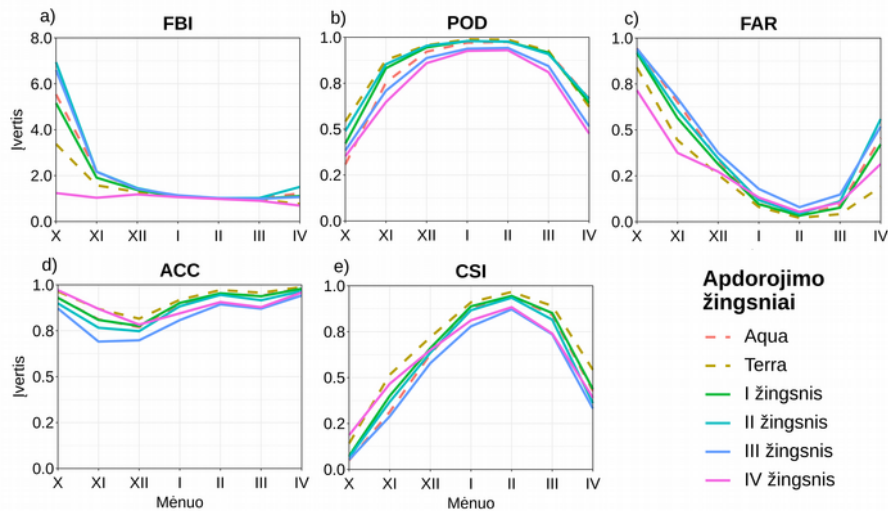


**4.19 pav.** Vidutinis absoliutus metinio dienų su sniegu dangą skaičiaus skirtumas tarp MODIS ( $DSS_{MODIS}$ ) ir MS stebėjimų ( $DSS_{MS}$ ) taikant skirtingus minimalios oro temperatūros filtrus.

MODIS duomenys su pašalintomis debesuotumo reikšmėmis buvo palyginti su stebėjimais MS bei apskaičiuoti validacijos rodikliai skirtingais duomenų apdorojimo etapais ir skirtingais mėnesiais. 4.20 pav. pateikti statistiniai rodikliai skirtingais mėnesiais ir skirtinguose duomenų apdorojimo žingsniuose (detalus statistinių rodiklių aprašymas pateiktas 3.2 skyrelyje). Nustatyta, kad pirminiai MODIS duomenys iš „Terra“ palydovo buvo tikslesni ( $POD = 0,96$ ;  $FAR = 0,12$ ) nei „Aqua“ palydovo ( $POD = 0,93$ ;  $FAR = 0,19$ ) (4.5 lentelė). Tikėtina, kad pagrindinė šių skirtumų priežastis yra tai, kad „Aqua“ palydove MODIS jutiklio 1,64  $\mu\text{m}$  spektrinė juosta veikia tik 70 % pajėgumu ir atspindžio reikšmės yra atkurtos naudojant kitų bangos ilgių duomenis (Riggs ir kt., 2016). Dalį skirtumų tarp MODIS duomenų taip pat lemia ir skirtingas palydovų praskridimo laikas.

Apjungus „Terra“ ir „Aqua“ palydovų MODIS duomenis (I žingsnis) ir atlikus erdvinį filtravimą pagal kaimyninius pikselius (II žingsnis),  $POD$  išliko panašus kaip ir originalių produktų ( $POD = 0,94$ ), tačiau  $FAR$  padidėjo ( $FAR = 0,22$ ). Tai indikuoja, kad naudojant erdvinį filtravimą sniego atvejų skaičius yra padidinamas, ypač rudens ir pavasario mėnesiais (4.20 pav.), kai sniego dangą yra trumpalaikė. Naudojant filtravimą laike (III žingsnis) užpildomi visi dėl debesuotumo atsirandantys Žemės paviršiaus

duomenų trūkiai, tačiau šis žingsnis gerokai padidina klaidos tikimybę, ir validacijos rodikliai sumažėja (pvz., POD = 0,89; FAR = 0,29) (4.5 lentelė).



**4.20 pav.** MODIS sniego duomenų rinkinio validacijos rezultatai skirtingais šalčio sezono mėnesiais ir skirtingais duomenų apdorojimo etapais: a) dažnio paklaida (FBI); b) aptikimo tikimybė (POD); c) klaidingas aptikimo dažnis (FAR); d) tikslumas (ACC); e) kritinės sėkmės indeksas (CSI).

Kritinės sėkmės indeksas (CSI) po III žingsnio nukrito iki 0,65, o tai rodo, kad tik 65 % sniego dangos atvejų nustatytų naudojant MODIS duomenis buvo teisingi. Kituose duomenų apdorojimo etapuose CSI reikšmės buvo 0,74–0,85. CSI yra atvirkščiai proporcingas FAR. Skaičiuojant CSI atsižvelgiama tik į tuos atvejus, kai sniego danga buvo nustatyta naudojant MODIS arba buvo stebėta MS. Šis rodiklis priklauso nuo įvykio (šiuo atveju sniego dangos) pasikartojimo dažnio. Jei stebimas reiškinys pasitaiko retai, CSI reikšmė bus maža. Tai akivaizdu spalio ir balandžio mėnesiais, kai sniego danga pasitaiko retai: vidutinė CSI reikšmė šiais mėnesiais buvo 0,05–0,35 (4.20 pav.). Tai rodo, kad tik 5–35% MODIS stebėtų sniego dangos atvejų buvo teisingi.

Temperatūros kontrolė (IV žingsnis) padeda sumažinti klaidingai klasifikuotų sniego atvejų skaičių, todėl lyginant su rezultatais gautais po III žingsnio, žymiai sumažėja FAR ir FBI rodikliai (4.5 lentelė). Bendras galutinio „MODIS“ duomenų rinkinio tikslumas buvo mažesnis (ACC = 0,89) nei originalių „Aqua“ ir „Terra“ produktų (ACC = 0,92 – 0,95). Tačiau, panaikinus duomenų trūkumus atsirandančius dėl debesuotumo, prieinamų Žemės paviršiaus stebėjimų skaičius padidėjo daugiau nei tris

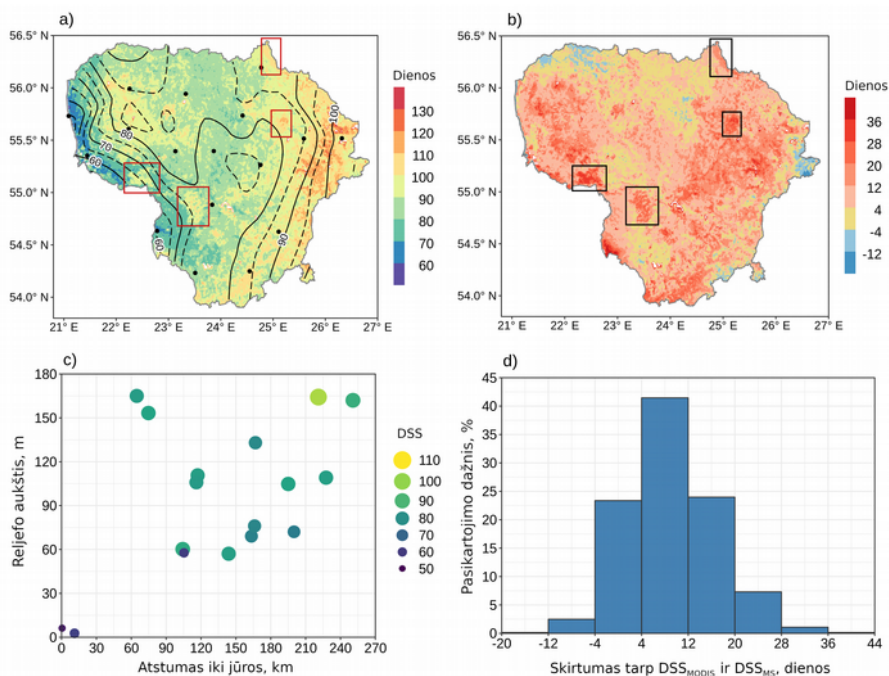
kartus. Galutinio MODIS duomenų rinkinio dažnio paklaida (FBI) buvo mažiausia (arčiausiai 1), o FAR vertė buvo geresnė nei naudojant pirminius „Aqua“ palydovo duomenis. Šie kasdieninių duomenų palyginimo rezultatai rodo, kad MODIS duomenų rinkinio, kuriame buvo užpildyti visi debesimis uždengti pikseliai, tikslumas yra panašus kaip ir pirminių duomenų. Galima teigti, kad atlikus papildomą MODIS duomenų apdorojimą, duomenų tikslumas nenukenčia, bet daugiau nei 4 kartus padidėja prieinamų Žemės dangos stebėjimo atvejų (4.5 lentelė) ir galima gauti kiekvienos dienos informaciją apie sniego dangą.

**4.5 lentelė.** Validacijos rezultatai skirtingais MODIS duomenų apdorojimo etapais. N – bendras atvejų skaičius; a, b, c, d – nesutapimų matricos kategorijos (žr. 3.1 lentelę). ACC – tikslumas (0–1), CSI – kritinės sėkmės indeksas (0–1), FAR – klaidingas aptikimo dažnis (0–1), FBI – dažnio paklaida (0 iki  $\infty$ ), POD – aptikimo tikimybė (0–1). Statistiniai rodikliai gauti naudojant 17 MS duomenis 2002–2018 m. spalio-balandžio mėn.

Etapas	N	a	b	c	d	ACC	CSI	FAR	FBI	POD
„Aqua“	12442	3147	221	715	8359	0,92	0,77	0,19	1,15	0,93
„Terra“	13656	4056	189	552	8859	0,95	0,85	0,12	1,09	0,96
I žingsnis	16917	4946	304	1058	10609	0,92	0,78	0,18	1,14	0,94
II žingsnis	19983	5963	369	1726	11925	0,90	0,74	0,22	1,21	0,94
III žingsnis	57732	19126	2473	7691	28442	0,82	0,65	0,29	1,24	0,89
IV žingsnis	57732	18639	2960	3580	32553	0,89	0,74	0,16	1,03	0,86

Naudojant kasdieninius MODIS sniego dangos duomenis buvo apskaičiuotas metinis ir mėnesinis DSS Lietuvoje. Metinis DSS apima laikotarpį nuo spalio pradžios iki balandžio pabaigos, kai sniegas Lietuvoje yra tikėtinas. 4.21 paveiksle pateiktas 2002–2018 m. DSS vidurkis ir DSS priklausomybė nuo duomenų ir geografinių rodiklių. Antžeminiams stebėjimais paremti DSS<sub>MS</sub> žemėlapiai buvo sudaryti naudojant kasdieninius sniego dangos stebėjimus 17 MS ir dvikubinio splaino (angl. *bicubic spline*) interpoliaciją. Pagal DSS<sub>MS</sub> ir DSS<sub>MODIS</sub> žemėlapius (4.21a pav.) matyti, kad vidutinė sniego dangos trukmė Lietuvoje didėja iš vakarų į rytus ir DSS glaudžiai susijęs su vietovės atstumu iki jūros bei vietovės aukščiu (4.21c

pav.).  $DSS_{MODIS}$  žemėlapyje matyti, kad sniego dangos trukmės reikšmių erdvinis pasiskirstymas gerai atspindi topografiją ir miškingus plotus Lietuvoje. Šis pastebėtas erdvinis  $DSS_{MODIS}$  pasiskirstymas atitinka ankstesnius tyrimus, kuriuose teigiama, kad sniego danga aukštumose ir miškuose išsilaiko ilgiau nei atvirose vietovėse (Galvonaitė ir kt., 2007; Rimkus ir kt., 2014).  $DSS_{MS}$  žemėlapyje reljefo ir miškų poveikis nėra pastebimas, nes interpoliuojant MS stebėjimų rezultatus neįmanoma užfiksuoti tokių lokalių ar regioninių sniego dangos trukmės skirtumų (4.21a pav.).



**4.21 pav.** Vidutinis metinis dienų su sniego danga skaičius ( $DSS$ ) 2002–2018 m.: a)  $DSS_{MODIS}$  – spalvų skalė,  $DSS_{MS}$  – izolinijos, taškai žymi MS, kurių duomenys naudoti tyrime, o stačiakampiais pažymėti dideli miškų masyvai vidurio Lietuvoje; b) skirtumų žemėlapis ( $DSS_{MODIS} - DSS_{MS}$ ); c)  $DSS_{MS}$  priklausomybė nuo vietovės aukščio ir atstumo iki Baltijos jūros; d) dažniausiai pasikartojančios  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumo reikšmės Lietuvoje.

Didžiausias vidutinis metinis  $DSS$  (100–120 dienų) stebimas aukštumose ir regionuose, esančiuose toliau nuo jūros. Mažiausiai dienų su sniego danga (50–70 dienų) buvo pajūryje ir pietvakarinėje Lietuvos dalyje. Didžiausi neigiami skirtumai tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  2002–2018 m. laikotarpiu nustatyti pačiame rytiniame šalies pakraštyje bei šiaurės vakaruose prie

Latvijos sienos. Aukštumose ir dideliuose miškų masyvuose remiantis MODIS duomenimis užfiksuota daugiau dienų su sniego danga nei gauta interpoliuojant MS duomenis (dideli teigiami DSS skirtumai) (4.21b pav.). Rytiniame Lietuvos pasienyje, remiantis interpoliuotais MS duomenimis DSS ir toliau didėjo einant į vakarus, o pagal MODIS – metinis DSS pačiame rytiniame pakraštyje šiek tiek sumažėjo (4.21b pav.). Šiame regione vietovės aukštis pradeda mažėti (baigiasi Baltijos aukštumos, prasideda Dysnos lyguma), o žemesnėse vietose sniego dangos trukmė būna trumpesnė. Reljefo įtaką galima pastebėti ir pasienyje pietvakariuose (prie Vištyčio ežero, kur prasideda Sūduvos aukštuma) – didėjant vietovės aukščiui  $DSS_{MODIS}$  pradeda didėti ir nustatyti dideli teigiami skirtumai lyginant su  $DSS_{MS}$  ( $> 40$  dienų) (4.21b pav.). Antžeminių sniego dangos stebėjimų tinklas Lietuvoje yra retas, todėl interpoliuojant MS duomenis, pasienio regionuose bei didelių miškų masyvuose susidaro dideli ( $> 10$  dienų) metinio DSS skaičiaus skirtumai tarp palydovinių ir antžeminių duomenų.

Nagrinėjant vidutinį metinį DSS, 23,3 % atvejų skirtumas tarp MODIS ir MS duomenų neviršijo  $\pm 4$  dienų, tačiau dažniausiai (74,0 % atvejų) vidutinis metinis  $DSS_{MODIS}$  buvo didesnis už  $DSS_{MS}$  daugiau nei +4 dienomis (4.21d pav.). Tik labai nedidelėje Lietuvos teritorijos dalyje (2,7%), daugiausia rytiniame ir šiaurės vakariniame pasienyje, buvo nustatyti neigiami skirtumai ( $< -4$  dienos), parodantys, kad naudojant palydovinius duomenis gauta mažiau dienų su sniego danga nei interpoliuojant MS duomenis.

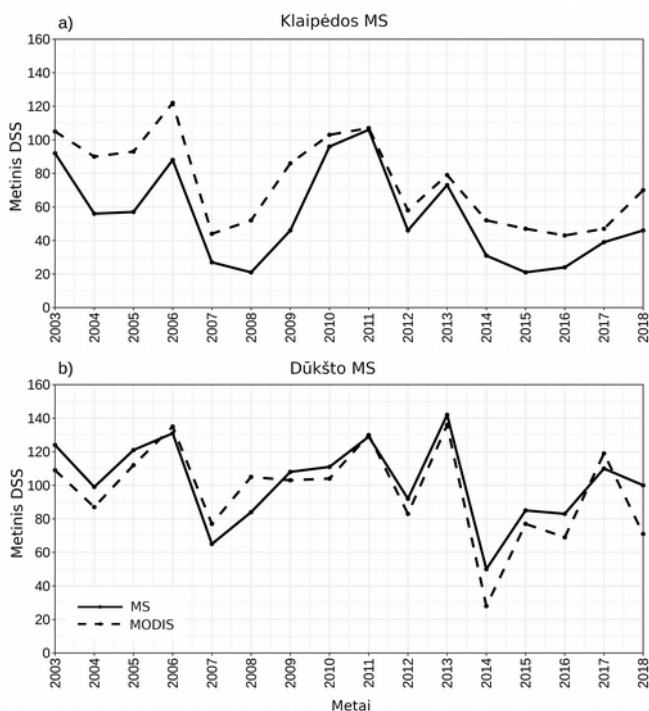
Metiniai MODIS duomenys buvo naudojami nustatyti ir tarpmetinius DSS svyravimus. Kaip minėta anksčiau metinis DSS priklauso nuo reljefo ir atstumo iki jūros. Tarpmetinius svyravimus ir regionų skirtumus Lietuvoje galima parodyti naudojant dvi stotis: Klaipėdos ir Dūkšto MS. Klaipėdos MS yra pajūrio stotis ir jos duomenys apibūdina jūrinį klimatą, o Dūkšto MS kuri įkurta Aukštaitijos aukštumoje gerai atspindi žemyninį klimatą.

Tyrimo laikotarpiu Dūkšto  $DSS_{MS}$  svyravo nuo 50 dienų 2013/2014 m. iki 142 dienų 2012/2013 m. žiemą (4.22 pav.). Klaipėdoje, Baltijos jūros pakrantėje, trumpiausiai sniego danga išsilaikė 2007–2008 m. ir 2014/2015 m. (21 diena), o ilgiausiai (106 dienas) – 2010/2011 žiemą (4.22 pav.). Įvairiais metais DSS Lietuvoje skyrėsi 3–5 kartus, o didžiausi tarpmetiniai DSS svyravimai stebėti Baltijos jūros pakrantėje. Tai, kad MODIS tiksliai užfiksavo šių kontrastingų žiemų DSS parodo, kad palydoviniai duomenys yra tinkami nagrinėti metinę sniego dangos trukmę ir jos kaitą.

Metinio  $DSS_{MODIS}$  palyginimo su metiniu  $DSS_{MS}$  Lietuvoje 2002–2018 m. laikotarpiu rezultatai apibendrinti 4.6 lentelėje. Vidutinis metinis  $DSS_{MS}$  Lietuvoje svyravo nuo 54 dienų Klaipėdos MS iki 102 dienų Dūkšto MS.



Vidutinis  $DSS_{MODIS}$  ir  $DSS_{MS}$  koreliacijos koeficientas Lietuvoje buvo 0,93 ir tai rodo, kad palydoviniai sniego dangos stebėjimai tiksliai atspindi tarpmetinius sniego dangos svyravimus. Vidutinis absoliutus skirtumas tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  buvo 8,5 dienos ir didžiojoje Lietuvos dalyje naudojant MODIS duomenis sniego dangos trukmė gauta ilgesnė. Tačiau skirtumai tarp palydovinių ir MS duomenų priklausė nuo metų bei vietovės. Klaipėdoje  $DSS_{MODIS}$  buvo vidutiniškai 20,6 dienos (53,8 %) didesnis nei  $DSS_{MS}$ . Didžiausias absoliutus skirtumas Klaipėdos MS užfiksuotas 2008–2009 m. žiemą ir siekė 40 dienų (87 %), o didžiausias santykinis skirtumas tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  nustatytas 2014–2015 m. ir siekė 124 % (4.22 pav.). Tačiau reikia pažymėti, kad didelis santykinis skirtumas Klaipėdos MS gautas dėl mažo  $DSS_{MS}$  (absoliutus skirtumas 2014–2015 m. buvo 26 dienos). Rytų Lietuvoje, Dūkšto MS,  $DSS_{MODIS}$  nuo  $DSS_{MS}$  vidutiniškai skyrėsi 11,4 dienos (13,2%). Priešingai nei pajūryje, kur  $DSS_{MODIS}$  visada buvo didesnis nei  $DSS_{MS}$ , Dūkšte 11 iš 16 metų  $DSS_{MODIS}$  buvo mažesnis nei nustatytas MS (4.23 pav.). Didžiausias absoliutus  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumas Dūkšto MS buvo 29 dienos (29 %) 2017/2018 m. žiemą.



**4.22 pav.** Metinio dienų su sniego danga skaičiaus (DSS) kaita 2002–2018 m.: a) Klaipėdoje; b) Dūkšte. Punktyrinė linija – MODIS duomenys, ištisinė – MS duomenys.

**4.6 lentelė.** Metinio  $DSS_{MODIS}$  ir  $DSS_{MS}$  palyginimas. Koreliacijos koef. – Spearmano koreliacijos koeficientas (visi koreliacijos koeficientai statistiškai reikšmingi,  $p < 0,05$ ); |Skirtumas| – vidutinis absoliutus skirtumas,  $DSS_{MODIS} - DSS_{MS}$ ; Skirtumas (%) – vidutinis santykinis skirtumas, lyginant su  $DSS_{MS}$ ; Debesuotumas (%) – vidutinis šaltojo sezono debesuotumas nustatytas naudojant apjungtą „Terra“ ir „Aqua“ MODIS duomenų rinkinį (po I žingsnio).


Rodiklis	Klaipėdos MS	Dūkšto MS	LT vidurkis
$DSS_{MS}$	54	102	79
Koreliacijos koef.	0,90	0,87	0,93
Skirtumas , dienos	20,6	11,4	8,5
Skirtumas, %	53,8	13,2	14,3
Debesuotumas,%	65,7	73,0	70,7

Metinio  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumai pajūryje buvo žymiai didesni nei likusioje Lietuvos dalyje. Tai galima susieti su tuo, kad vietovėse su jūriniu klimatu sniego danga nėra pastovi, dažnai fiksuojami atlydžiai. Prie didelių skirtumų Klaipėdoje gali prisidėti ir tai, kad Klaipėdos MS visai šalia Baltijos jūros (mažiau nei 400 m nuo kranto) ir stebėjimai joje atspindi jūros kranto zonos mikroklimatines sąlygas. Be to, Klaipėdos MS yra miesto teritorijoje, ir MODIS jutiklio signalą sudaro labai skirtingi atspindžiai nuo įvairių paklotinių paviršių. Tikėtina, kad šios išskirtinės kranto MS stebėjimų sąlygos yra pagrindinė priežastis, kodėl susidaro dideli  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumai Klaipėdos MS.

Panašūs rezultatai gauti ir nagrinėjant vidutines mėnesio DSS reikšmes. 4.7 lentelėje pateikti  $DSS_{MODIS}$  ir  $DSS_{MS}$  mėnesio reikšmių palyginimas. Nagrinėjant mėnesio DSS reikšmes naudotas papildomas klimatologinis vertės indeksas  $SS_{clim}$  (angl. *Climatological Skill Score*). Teigiamos  $SS_{clim}$  vertės rodo, kad naudojant MODIS duomenis su užpildytais duomenų trūkiais, gaunamas tikslesnis mėnesio DSS nei daugiametis tos stoties klimatologinis vidurkis. Neigiamos reikšmės rodo, kad vertinant mėnesio sniego dangos trukmę, daugiametis vidurkis buvo tikslesnis, nei DSS apskaičiuotas pagal to konkretaus mėnesio MODIS stebėjimus.

Didžiausi vidutiniai absoliutūs skirtumai tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  mėnesinių reikšmių užfiksuoti gruodį. Lietuvoje pastovi sezoninė sniego danga dažniausiai pradeda formuotis gruodžio mėnesį. Tačiau žiemos pradžioje dažnai pasitaiko atlydžiai ir vyrauja ištisinis debesuotumas (82 %

laiko teritorija yra padengta debesimis), todėl naudojant MODIS duomenis tikėtinos didelės paklaidos. Ši problema aktualiausia pajūryje. Remiantis MODIS duomenimis Klaipėdos MS sniego dangos tikimybė 2002–2018 m. laikotarpiu buvo du kartus didesnė nei remiantis MS stebėjimais (4.23 pav.). Dūkšto MS, kur klimatas yra žemyninis ir sniego danga yra pastovesnė,  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumai gruodžio mėnesį buvo mažesni. Sausio ir vasario mėnesiais  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumai visoje Lietuvos teritorijoje buvo mažesni, nes vidutinė oro temperatūra tampa neigiama ir susiformavusi sniego danga išlieka pastovi (išskyrus pajūrį). Kovo mėn. dėl pavasarinio sniego tirpsmo pradžios skirtumai tarp mėnesio  $DSS_{MODIS}$  ir  $DSS_{MS}$  vėl padidėja. Balandžio mėn. MODIS ir MS stebėjimai geriau dera tarpusavyje, nes vyrauja mažiau debesuoti orai (debesuotumas 57–60 %), o sniego danga dažnai jau būna ištirpusi. Šiame tyrime gauti rezultatai sutampa su kitais tyrimais atliktais Europoje – MODIS sniego dangos duomenų paklaidos didesnės rudenį ir mažesnės pavasarį (Parajka ir Blöschl, 2008; Foppa ir Seiz, 2012; Dong ir Menzel, 2016).



**4.23 pav.** Dienos su sniego danga tikimybė šaltuoju sezonu Dūkšto ir Klaipėdos MS. Punktyrinės linijos žymi dienas su sniego danga tikimybę, gautą naudojant MODIS duomenis su užpildytais duomenų trūkiais (po IV žingsnio), o ištisinės – remiantis matavimais MS.

Šaltuoju sezonu Lietuvoje vyrauja ištisinis debesuotumas ir jis didėja nuo spalio iki sausio mėn. Spalio mėn. vidutiniškai 66 % atvejų Žemės paviršių MODIS vaizduose dengia debesys, o lapkričio–sausio mėnesiais net 78–82 %. Dėl didelio debesuotumo ir pastaraisiais dešimtmečiais didėjančio sniego dangos nepastovumo ir dažnų atlydžių (Rimkus ir kt., 2014), šiame darbe naudojama MODIS duomenų užpildymo metodika nėra pajėgi užfiksuoti

tokios dažnos paklotinio paviršiaus sąlygų kaitos. Tai lemia, kad net ir įvedus oro temperatūros kontrolę (IV žingsnis), daugeliu atveju  $DSS_{MODIS}$  yra didesnis nei  $DSS_{MS}$  – ypač rudens ir žiemos mėnesiais.

**4.7 lentelė.**  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumai skirtingais mėnesiais.  $DSS_{MS}$  – dienų su sniego danga skaičius remiantis stebėjimais MS;  $|Skirtumas|$  – vidutinis absoliutus skirtumas,  $DSS_{MODIS} - DSS_{MS}$ ;  $SS_{clim}$  – klimatologinis vertės indeksas; Debesuotumas (%) – vidutinis mėnesio debesuotumas nustatytas naudojant apjungtą „Terra“ ir „Aqua“ MODIS duomenų rinkinį (po I žingsnio).

	10	11	12	01	02	03	04
<b>Klaipėdos MS</b>							
$DSS_{MS}$	0,2	3,0	8,8	16,6	16,5	8,4	0,8
$ Skirtumas $	0,63	4,31	9,06	6,25	3,44	1,88	0,88
$SS_{clim}$	-2,56	-3,11	-0,01	-0,52	0,67	0,92	-0,41
Debesuotumas, %	62,3	77,9	77,8	74,4	73,7	55,2	39,0
<b>Dūkšto MS</b>							
$DSS_{MS}$	1,4	7,7	18,5	26,6	25,7	19,1	3,2
$ Skirtumas $	1,19	3,06	3,25	2,69	1,63	3,56	1,56
$SS_{clim}$	-0,63	0,44	0,72	0,34	0,63	0,69	0,74
Debesuotumas, %	68,9	88,1	86,1	80,7	75,0	63,3	49,0
<b>LT vidurkis</b>							
$DSS_{MS}$	0,6	5,3	14,5	22,4	21,6	13,3	1,7
$ Skirtumas $	0,74	2,69	4,37	3,35	1,79	2,38	1,09
$SS_{clim}$	-0,15	0,24	0,59	0,45	0,85	0,88	0,63
Debesuotumas, %	66,1	82,4	82,3	78,5	75,4	62,9	47,5

Vasarį debesuotumas pradeda mažėti, o kovą ir balandį debesys pirminiuose MODIS vaizduose sudaro 47–63 % atvejų (4.7 lentelė). Kuo daugiau giedrų dienų tuo daugiau tiesioginių Žemės paviršiaus stebėjimų ir tuo patikimesnis mėnesio  $DSS_{MODIS}$ . Nagrinėjamu laikotarpiu pajūryje šaltuoju laikotarpiu buvo stebima mažiau debesų (Klaipėdos MS, 39–78 %) nei žemyninėje šalies dalyje (Dūkšto MS, 49–88 %).

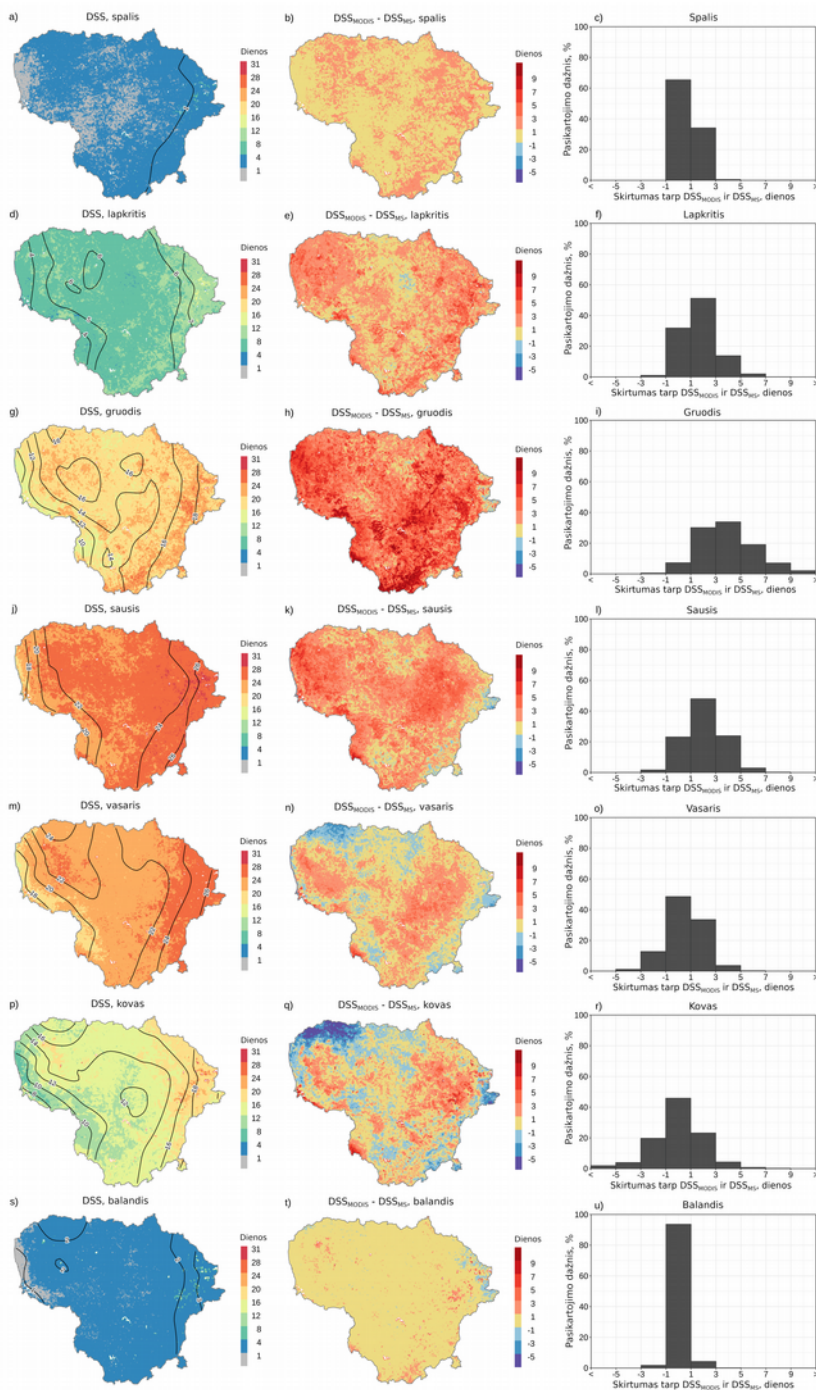
Spalio mėn.  $SS_{clim}$  Lietuvoje buvo neigiamas, o tai rodo, kad šaltojo sezono pradžioje vidutinis 2002–2018 m. dienų su sniego danga skaičius yra tikslesnis nei MODIS duomenys (4.7 lentelė). Kitais mėnesiais (lapkritį-balandį)  $SS_{clim}$  Lietuvoje buvo teigiamas ir palydoviniai duomenys buvo tikslesni už klimatologinį vidurkį. Vienintelė išimtis buvo pajūris: Klaipėdoje  $DSS_{MODIS}$  buvo tikslesnis už MS daugiamečių vidurkį tik vasario ir kovo mėn. (4.7 lentelė). Dideli absoliutūs  $DSS$  skirtumai ir neigiamas  $SS_{clim}$

Klaipėdos MS nustatyti didžiąją dalį šaltojo sezono. Tai indikuoja, kad sudarytas MODIS sniego duomenų rinkinys nėra labai tikslus pajūryje, kur sniego danga pasižymi nepastovumu.

Erdvinis mėnesio DSS pasiskirstymas ir skirtumai tarp  $DSS_{MODIS}$  bei  $DSS_{MS}$  pateikti 4.24 paveiksle. Visais mėnesiais DSS yra mažiausias pajūryje. Mažesnis DSS taip pat pastebimas pietvakarinėje Vidurio lygumos dalyje (4.24 pav., pirmas stulpelis). Sniego kaupimosi (lapkričio–gruodžio mėn.) ir tirpimo (vasario–kovo mėn.) laikotarpiais  $DSS_{MODIS}$  žemėlapiuose matyti, kad erdvinis pasiskirstymas glaudžiai susijęs su reljefu ir dideliais miškų plotais (4.24d, g, m, p pav.). Aukštesnėse ir miškuose sniego danga yra pastovesnė ir išsilaiko ilgiau.  $DSS_{MODIS}$  ir  $DSS_{MS}$  skirtumų žemėlapiai rodo, kad didžiojoje Lietuvos dalyje spalį skirtumas tarp MS ir MODIS buvo  $\pm 1$  diena (4.24c pav.). Lapkritį ir gruodį  $DSS_{MODIS}$  buvo 1–5 dienomis didesnis nei  $DSS_{MS}$ , o didžiausi skirtumai pastebėti gruodį, ypač miškinguose regionuose (4.24h, i pav.).

Sausio mėn. sniego danga Lietuvoje gana pastovi, todėl skirtumai tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  nėra labai dideli ir erdvinis pasiskirstymas yra panašus (4.24k, l pav.). Vasario mėnesį padidėja neigiamų ( $DSS_{MODIS} - DSS_{MS}$ ) skirtumų (4.24n pav.) – tai parodo, kad padaugėja atveju kai daugiau dienų su sniegu buvo nustatyta MS. Kovo mėnesį Lietuvos teritorijos dalis, kur skirtumas buvo teigiamas ir neigiamas buvo panaši, o skirtumų reikšmės buvo pasiskirsčiusios proporcingai (4.24r pav.). Vietovės, kur kovo mėn.  $DSS_{MODIS}$  buvo didesnis nei  $DSS_{MS}$ , gerai atitiko pagrindinių miškų plotų ir aukštesnų pasiskirstymą (4.24q pav.). Pavasarį sniegas pirmiausia pradeda tirpti atvirose vietose, pievose ir ariamos žemės laukuose, sniego danga greitai tampa neištisinė, o miškuose ji išsilaiko ilgiau. Esant neištisinei sniego dangai MODIS pikselis gali būti klasifikuojamas kaip nepadengtas sniegu, o MS diena su sniegu dangą fiksuojama jei daugiau nei 50 % apylinkių yra padengta sniegu. Tikėtina, kad dėl to kovo mėn. užfiksuota daugiau atvejų su neigiamu  $DSS_{MODIS} - DSS_{MS}$  skirtumu. Balandį vidutinis skirtumas tarp  $DSS_{MODIS}$  ir  $DSS_{MS}$  buvo nedidelis ( $\pm 1$  diena) (4.24t pav.).

Nuo gruodžio iki balandžio rytiniame Lietuvos pakraštyje, Dysnos lygumoje,  $DSS_{MODIS}$  buvo mažesnis nei  $DSS_{MS}$  (4.24h, k, n, q, t pav.). Šie neigiami skirtumai susidaro dėl MS duomenų interpoliacijos į vietoves, kur matavimai nėra atliekami. Šiame Lietuvos pakraštyje vietovės aukštis pradeda mažėti, o mažėjant aukščiui trumpėja ir vidutinė sniego dangos trukmė (4.21c pav.). Šį dienų su sniegu dangą skaičiaus mažėjimą galima užfiksuoti naudojant MODIS duomenis. Tikėtina, kad Dysnos lygumoje,  $DSS_{MODIS}$  yra tikslesnis nei interpoliuoti  $DSS_{MS}$  duomenys.



**4.24 pav.** Dienų su sniegu danga sezoniniai rodikliai: kairysis stulpelis – vidutinis mėnesio DSS ( $DSS_{MODIS}$  – spalvų skalė;  $DSS_{MS}$  – izolinijos); vidurinis stulpelis – skirtumų žemėlapis ( $DSS_{MODIS} - DSS_{MS}$ ); dešinysis stulpelis – dažniausiai pasikartojančios skirtumų reikšmės.

Meteorologijos stočių, matuojančių sniego dangos parametrus Lietuvoje yra nedaug, ir jos paprastai įrengiamos atvirose, lygiose vietovėse. Interpoliuojant MS sniego dangos duomenis į regionus su skirtingais žemės dangos tipais ir reljefu, gautas DSS gali būti klaidingas ir neatspindėti vietos sąlygų.

Patys didžiausi skirtumai (12–24 dienos) buvo nustatyti keliose duomenų gardelėse, kurios sudarė mažiau nei 0,4 % atvejų. Visos šios gardelės buvo prie ežerų ar didžiųjų upių slėniuose. Šios klaidos galėjo atsirasti dėl „Terra“ ir „Aqua“ MODIS algoritmuose naudojamo žemės / vandens duomenų sluoksnio ir jame esančių vandens telkinių kranto linijų nustatymo netikslumų (Carroll ir kt., 2017). Dėl to, kai kurie vandens telkinių pikseliai, arba pikseliai dalinai dengiantys vandens telkinius, gali būti priskirti žemei (o vėliau ir „sniegui“), nors iš tiesų turėtų būti klasifikuojami kaip „vanduo“. Kita galima priežastis, kodėl aplink didelius vidaus vandens telkinius fiksuotas labai didelis  $DSS_{MODIS}$ , yra priekrantės ledas ir tai, kad MODIS algoritmas priskiria jį sniego dangai. Pavasarį sniegas tirpsta daug greičiau nei ledas, ir ledo danga ežero pakrantėse ir upių slėniuose gali būti klaidingai priskirta sniegui, net jei apylinkėse sniego danga ir visiškai ištirpo. MODIS jutiklis gali fiksuoti šią ledo dangą ir tai lemia labai dideles mėnesių bei metų sniego dangos trukmės paklaidas aplink vandens telkinius.

Kituose tyrimuose teigiama, kad dalis nesutapimų tarp MODIS duomenų ir stebėjimų MS yra nulemti dėl to, kad palydoviniai ir antžeminiai jutikliai matuoja skirtingus fizikinius sniego dangos parametrus (atspindžio reikšmės / sniego storis) bei skiriasi matavimo laikas ir stebimas plotas (Dong, Menzel, 2016; Meromy ir kt., 2013). Lietuvoje rudenį ir pavasarį laikina sniego danga gali greitai susidaryti ir greitai ištirpti. Todėl matavimo laiko skirtumas tarp MODIS ir MS stebėjimų gali turėti įtakos rezultatams. Taip pat svarbu turėti omeny, kad MODIS pikselis apima 500 x 500 m plotą ir jo atspindžio vertė apibūdina vidutinės paklotinio paviršiaus sąlygas visame šiame plote. N. Foppa ir G. Seiz (2012) savo darbe teigia, kad sniego dangos stebėjimai MS apibūdina tik nedidelę teritoriją, ir tais atvejais kai sniego danga yra neištisinė matavimai MS nebūtinai reprezentuoja sąlygas visame regione. Šiame tyrime laikyta, kad diena yra su sniego danga, kai daugiau nei 50 % aplink MS esančios teritorijos buvo padengta sniegu. Sniego padengimas balais stebėtojo yra įvertinamas vizualiai. Didžioji dalis MS Lietuvoje įsteigtos lygiose, atvirose vietose, todėl stebėtojai gali įvertinti paviršiaus sąlygas didesniu nei 500 m spinduliu. Atlikto tyrimo rezultatai rodo, kad kovo mėn., prasidėjus sniego tirpsmui, daugėja atveju kai MS fiksuojama daugiau DSS nei remiantis MODIS duomenimis. Tikėtina, kad skirtumai atsiranda dėl interpoliacijos, tačiau prie šių nesutapimų gali

prisidėti ir tai, kad stebėtojas įvertina sniego dangos sąlygas didesniame plote nei MODIS ir esant neištisinei sniego dangai gaunami skirtingi rezultatai (MS – „yra sniegas“, nes > 50% teritorijos vis dar su sniegu, o MODIS – „sniego nėra“).

Šio tyrimo rezultatai rodo, kad naudojant erdvinį filtravimą, filtravimą laike bei minimalios oro temperatūros kriterijų galima užpildyti MODIS duomenų trūkius atsirandančius dėl debesų. Tokie apdoroti MODIS duomenys gali būti naudojami tiek metų, tiek mėnesio dienų su sniego danga skaičiaus nustatymui. Lyginant su stebėjimais meteorologijos stotyse, MODIS privalumas yra tai, kad galima labai detalai nustatyti erdvinį sniego dangos pasiskirstymą. Metų ir mėnesio  $DSS_{MODIS}$  erdvinis pasiskirstymas atitinka Lietuvos reljefo ir miško masyvų pasiskirstymą bei atspindi pagrindinį dėsnį, kad sniego dangos trukmė didėja tolstant nuo jūros ir didėjant vietovės aukščiui. Lyginant absoliučias DSS reikšmes, naudojant MODIS daugeliu atvejų gaunama vidutiniškai 8,5 dienomis ilgesnė sniego dangos trukmė nei MS. Didžiausios nesutapimai stebimi pajūryje, kur sniego danga yra nepastovi. Tačiau palydoviniai duomenys tikslesni regionuose kur yra dideli miškų masyvai ir Lietuvos pasienyje – šiuose regionuose dėl antžeminių stebėjimų trūkumo ir interpoliuojant MS duomenis gaunamos didelės dienų su sniego danga paklaidos.

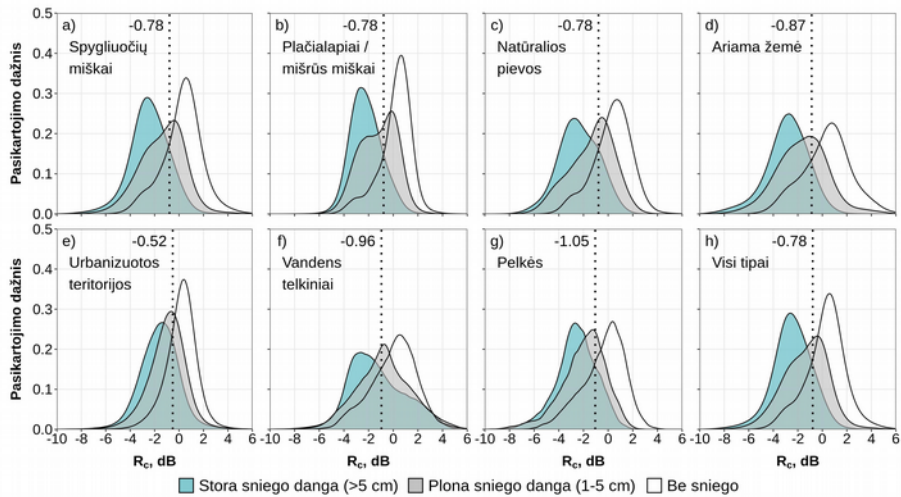
#### 4.4. Sniego dangos nustatymas Šventosios baseine naudojant SAR duomenis

Skirtingai nei regimojo spektro jutikliai SAR signalas gali prasiskverbti pro debesis ir, naudojant šio tipo jutiklius, Žemės paviršių galima stebėti nepriklausomai nuo oro sąlygų. Ant žemės paviršiaus susiformavus sniego dangai keičiasi SAR atgalinės sklaidos koeficientas, tačiau pokyčiai labai priklauso nuo sniego dalelių dydžio ir skysto vandens kiekio sniego dangoje. Šiame tyrime sniegui nustatyti naudota C juostos SAR jutiklio Sentinel-1 palydove teikiama informacija. Naudoti 2014–2019 m. Sentinel-1 duomenys virš Šventosios upės baseino.

Skirtingi žemės dangos tipai pasižymi skirtingais SAR atgalinės sklaidos koeficientais, todėl šiame tyrime kiekvienam žemės dangos tipui buvo nustatyta specifinė SAR atgalinės sklaidos santykio tarp vaizdų su sniegu ir standartinio vaizdo be sniego dangos ( $R_C$ ) reikšmė (4.25 pav.). Siekiant išsiaiškinti ar SAR jutiklis pajėgus užfiksuoti ploną sniego dangą visi sniego dangos atvejai buvo suskirstyti į dvi kategorijas pagal sniego storio matavimus Utenos ir Ukmergės MS: 1) plona sniego danga (1–5 cm) ir 2)



stora sniego danga ( $> 5$  cm). Rezultatai parodė, kad visuose žemės dangos tipuose esant storai sniego dangai  $R_C$  reikšmės buvo mažesnės (neigiamos) lyginant su atvejais be sniego. Tačiau tais atvejais, kai sniego danga buvo plona,  $R_C$  reikšmės persidengė tiek su atvejais, kai sniego nebuvo, ir atvejais, kai buvo stora sniego danga (4.25 pav.). 4.25 pav. pateikti  $R_C$  reikšmių skirstiniai remiasi 16 atvejų analize 2014–2019 m. laikotarpiu. Kritinės  $R_C$  reikšmės, skiriančios atvejus su sniegu ir be sniego, nustatytos remiantis storos sniego dangos  $R_C$  skirstinio sankirta su atvejų be sniego skirstiniu (4.25 pav.).



**4.25 pav.**  $R_C$  reikšmių pasiskirstymas skirtinguose žemės dangos tipuose priklausomai nuo sniego dangos: mėlyna spalva – atvejai su stora sniego danga ( $> 5$  cm), pilka – plonas sniegas (1–5 cm), balta – atvejai be sniego. Punktyrinė linija žymi kritinę  $R_C$  reikšmę, kuri parodo storos sniego dangos ir atvejų be sniego skirstinių susikirtimą.

Gauta, kad priklausomai nuo žemės dangos tipo, kritinės  $R_C$  reikšmės, skiriančios atvejus su sniegu, svyruoja nuo  $-0,52$  dB iki  $-1,05$  dB (4.8 lentelė). Mažiausias santykis ( $-0,52$  dB) nustatytas urbanizuotose teritorijose, o didžiausias ( $-1,05$  dB) pelkėse. Kituose žemės dangos tipuose kritinė  $R_C$  riba buvo nuo  $-0,78$  dB iki  $-0,96$  dB. Taip pat buvo analizuoti visi atvejai kartu, neskaidant pagal žemės dangos tipus – tokiu atveju gauta, kad kritinė  $R_C$  reikšmė yra  $-0,78$  dB (4.25h pav.). Šiame tyrime nustatytos kritinės  $R_C$  reikšmės yra mažesnės lyginant su kituose pasaulio regionuose atliktais tyrimais. Daugelyje tyrimu gauta, kad sniego klasifikacijai tinkamiausia SAR signalo santykio reikšmė yra  $-2$  arba  $-3$  dB (Lów ir kt., 2002; Malnes, Guneriusen, 2002; Nagler ir kt., 2016). Tačiau minėtuose tyrimuose, SAR

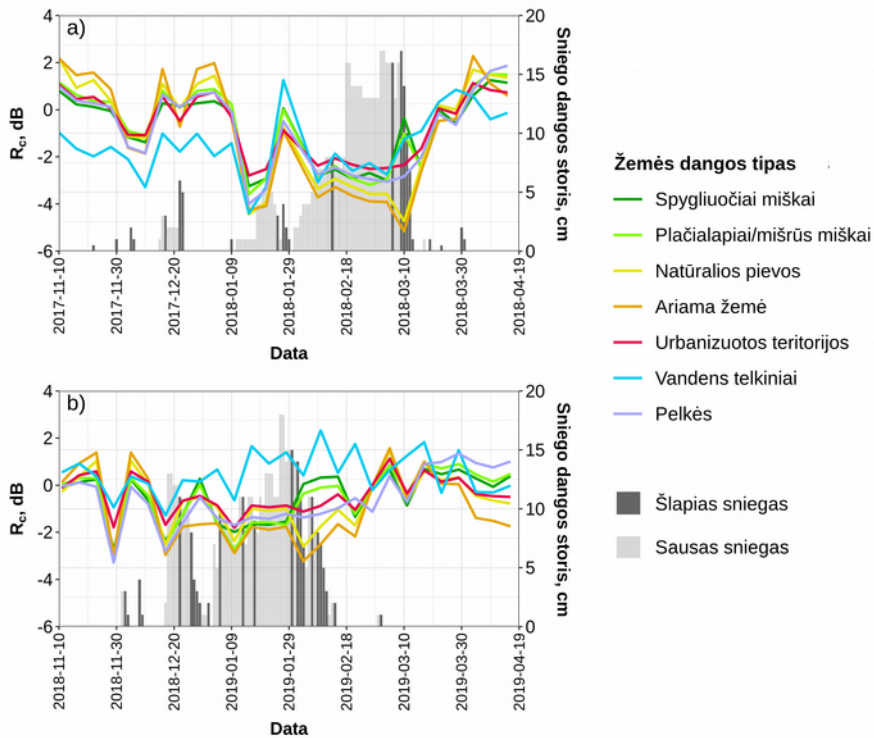
atgalinės sklaidos santykis naudotas atskirti šlapią sniegą nuo atvejų be sniego bei sauso sniego.

Didžiausias storos sniego dangos ir atvejų be sniego  $R_C$  reikšmių persidengimas tiriamoje teritorijoje nustatytas vandens telkiniuose (50,2 %), o mažiausias – plačialapiuose/mišriuose miškuose (20,7 %) (4.8 lentelė). Kuo didesnis  $R_C$  skirstinių persidengimas tuo didesnė tikimybė, kad SAR pikselis be sniego gali būti suklasifikuotas kaip sniegas, ir atvirkščiai – kuo mažiau persidengia  $R_C$  skirstiniai, tuo tiksliau galima nustatyti kada SAR pikselis yra padengtas sniegu.

**4.8 lentelė.** Kritinės  $R_C$  santykio reikšmės, skiriančios sniegą nuo atvejų be sniego skirtingo tipo žemės dangos vietovėse, bei gilaus sniego (> 5 cm) ir atvejų be sniego  $R_C$  skirstinių persidengimas procentais.

Žemės dangos tipas	Kritinė reikšmė, dB	Gilaus sniego ir atvejų be sniego $R_C$ skirstinių persidengimas
Plačialapiai/mišrūs miškai	-0,78	20,7 %
Spygliuočiai miškai	-0,96	21,8 %
Urbanizuotos teritorijos	-0,52	33,0 %
Natūralios pievos	-0,78	25,1 %
Vandens telkiniai	-0,96	50,2 %
Pelkės	-1,05	33,0 %
Ariama žemė	-0,87	23,3 %
<i>Visi tipai kartu</i>	-0,78	24,1 %

Šaltojo sezono eigoje  $R_C$  keitėsi sinchroniškai visuose žemės dangos tipuose – reikšmės kito tuo pačiu metu ir panašiu intensyvumu (4.26 pav.). Tačiau pastebėta, kad pavasario sniego tirpimo metu  $R_C$  reikšmių pokyčiai skirtinguose žemės dangos tipuose pradeda skirtis. Tirpstant sniego dangai ariamoje žemėje ir pievose  $R_C$  sumažėja ir pasiekia pačias žemiausias reikšmes (<-2 dB), o tuo pačiu metu plačialapiuose ir spygliuočių miškuose  $R_C$  reikšmės kyla ir artėja prie 0 dB. Tai gali būti susiję su tuo, kad ištirpus visam sniegui, susikaupusiam ant medžių lajos, pradeda dominuoti SAR signalas nuo medžių ir atgalinės sklaidos koeficientas ( $\sigma_0$ ) tampa panašus į ataskaitinį Sentinel-1 vaizdą. Tuo tarpu atvirose vietovėse (pievose ir ariamoje žemėje) dėl tirpimo didėja skysto vandens kiekis sniego dangoje ir  $\sigma_0$  mažėja.



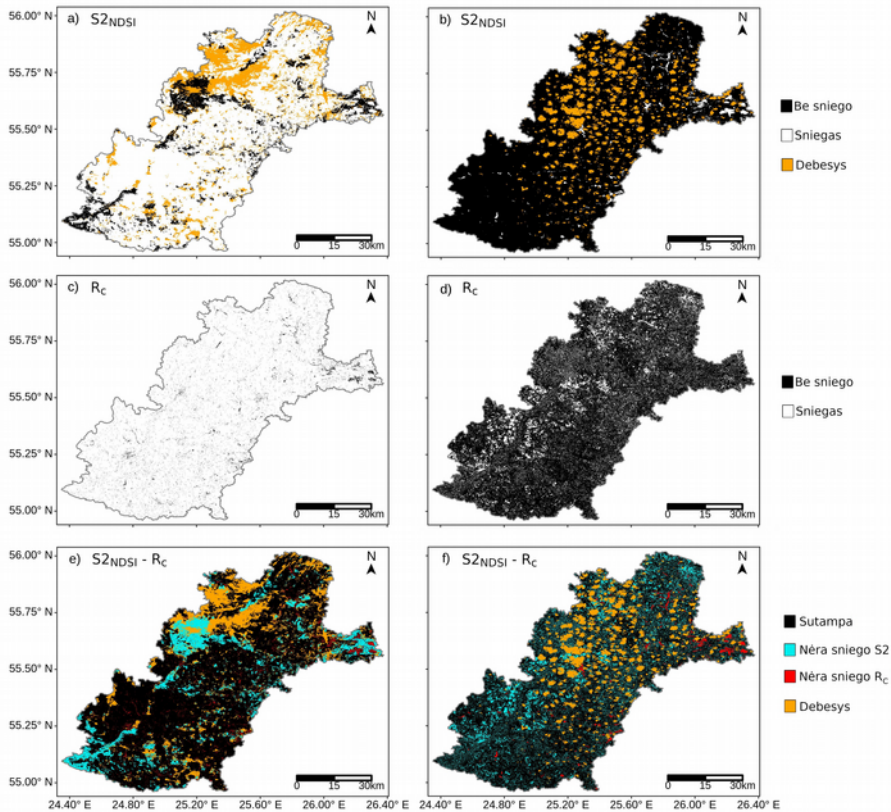
**4.26 pav.**  $R_C$  reikšmių kaita skirtingose žemės dangos tipuose 20 km spinduliui aplink Utenos MS: a) 2017–2018 žiemą; b) 2018–2019 m. žiemą. Pilkai stulpeliai rodo sniego dangos storį Utenos MS, tamsiai pilki žymi šlapio sniego atvejus (kai sniego danga per parą sumažėjo  $> 2$  cm, o  $T_{\min} > 0$  °C).

Nustatyta, kad  $R_C$  visuose žemės dangos tipuose mažėja (didesnės neigiamos vertės) kai sniego dangos storis viršija 5 cm. Tačiau pavasario sniego tirpimo metu susidariusio šlapio sniego poveikis SAR signalui buvo ryškus tik natūraliose pievose ir ariamoje žemėje (4.26a pav., 2018 m. kovo 7–13 d.; 4.26b pav., 2019 m. kovo 1–14 d.). Žiemos atlydžių metu, kai remiantis stebėjimais MS oro temperatūra buvo teigiama ir sniego danga plonėjo, ryškaus  $R_C$  sumažėjimo nei pievose, nei ariamuose laukuose nepastebėta (4.26a pav., 2018 m. sausio 25–30 d.; 4.26b pav., 2018 m. gruodžio 26 d. – 2019 m. sausio 2 d.). Tai gali būti susiję su tuo, kad Baltijos šalyse žiemos yra švelnios, o sniego danga retai būna sausa. Dėl vyraujančios šlapios sniego dangos, per atlydžius didėjantis vandens kiekis nesukelia ryškaus SAR  $\sigma_0$  pokyčio.

Iš visų analizuotų žemės dangos tipų mažiausias  $R_C$  jautrumas sniego storio pokyčiams ar sniego tirpimo pradžiai nustatytas vandens telkiniuose

(4.26 pav.). Tačiau to buvo tikėtasi, nes sniego danga ant vandens telkinių gali susidaryti tik jiems užšalus, o ledas taip pat pasižymi savitomis SAR signalo sklaidos savybėmis ir sunku atskirti ledo ir sniego poveikį SAR atgalinei sklaidai.  $R_C$  santykio skaičiavimas nėra tinkamiausias būdas nustatyti sniego dangą ant vandens telkinių ledo.

Pagal nustatytas  $R_C$  kritines reikšmes sudarytų Sentinel-1 sniego dangos žemėlapių tikslumas buvo vertinamas naudojant Sentinel-2 NDSI sniego dangos žemėlapius (Sentinel-2<sub>NDSI</sub>). Kadangi Sentinel-2 veikia regimajame spektre, Žemės paviršiaus stebėjimus riboja debesuotumas. 2014–2019 m. laikotarpiu buvo tik du atvejai, kai Sentinel-1 ir Sentinel-2 virš Rytų Lietuvos praskrido tą pačią dieną ir debesys dengė mažiau nei 30 % Šventosios baseino: 2018 m. vasario 26 d. ir 2018 m. kovo 28 d. (4.27 pav.).



**4.27 pav.** Šventosios upės baseino sniego dangos žemėlapiai: pirmas stulpelis – 2018 m. vasario 26 d. (a, c, e); antras stulpelis – 2018 m. kovo 28 d. (b, d, f). (a) ir (b) – Sentinel-2<sub>NDSI</sub> sniego žemėlapiai; c) ir d) –  $R_C$  sniego žemėlapiai; e) ir f) – skirtumų žemėlapiai (Sentinel-2<sub>NDSI</sub> –  $R_C$ ).

2018 m. vasario 26 d. Šventosios baseinas buvo padengtas ištisine sniego danga, o jos storis tiek Ukmergės, tiek Utenos MS buvo 13 cm. Sniego dangos žemėlapyje sudarytame remiantis SAR  $R_C$ , visa baseino teritorija yra padengta sniegu, išskyrus vandens telkinius ir urbanizuotas teritorijas (4.27c pav.). Didžiausi skirtumai tarp sniego dangos žemėlapių paremtų SAR  $R_C$  ir Sentinel-2<sub>NDSI</sub> nustatyti miškuose (ypač spygliuočių) (4.27e pav.). Remiantis sniego dangos stebėjimais MS, prieš tai buvo ilgas (> 10 dienų) laikotarpis su nuolatine sniego danga, kurios storis buvo didesnis nei 10 cm ir nuolat laikėsi neigiama oro temperatūra ( $T_{vid.} < -2,5$  °C). Todėl galima drąsiai daryti prielaidą, kad miškuose taip pat buvo susiformavusi ištisinė sniego danga. Tačiau Sentinel-2<sub>NDSI</sub> sniego dangos žemėlapyje miškuose sniego nėra (4.27a pav.) ir tai lemia, kad 2018 m. vasario 26 d. didžiausi nesutapimai tarp SAR  $R_C$  ir Sentinel-2<sub>NDSI</sub> buvo miškuose (4.27e pav.). Šiuo atveju tikėtina, kad skirtumų žemėlapis, parodo Sentinel-2<sub>NDSI</sub>, o ne  $R_C$  sniego klasifikavimo klaidas. Virš vandens telkinių sniego danga buvo nustatyta Sentinel-2<sub>NDSI</sub>, tačiau nebuvo užfiksuota  $R_C$  žemėlapiuose. Taip galėjo nutikti todėl, kad naudojant NDSI buvo tiksliai identifikuota ant ledo susidariusi sniego danga, o kadangi SAR neturi aiškaus signalo pokyčio dėl susidariusio ledo ar sniego ant ledo dangos (4.26 pav.), šie pikseliai buvo priskirti atvejams be sniego.

2018 m. kovo 28 d. naudojant Sentinel-2<sub>NDSI</sub> duomenis gauta, kad sniego buvo tik ant ežero ledo ir nedideliuose ploteliuose aukštumose rytinėje Šventosios upės baseino dalyje (4.27b pav.). Dūkšto ir Utenos meteorologijos stotyse sniego nebuvo. Naudojant Sentinel-1  $R_C$  duomenis sniego gauta daug daugiau (4.27d pav.). Sniego dangos klasifikacijos klaidas galėjo lemti didelis dirvožemio drėgmės kiekis, dėl kurio sumažėjo SAR atgalinės sklaidos koeficientas. Sentinel-2<sub>NDSI</sub> ir  $R_C$  skirtumų žemėlapyje (4.27f pav.) matyti, kad  $R_C$  nenustatė sniego dangos ant vandens telkinių, kai tuo tarpu Sentinel-2<sub>NDSI</sub> tai buvo pagrindinės vietos, kur buvo sniego. Tokia pati tendencija stebėta ir 2018 m. vasario 26 d. atveju. 2018 m. kovo 28 d. naudojant  $R_C$  kritines reikšmes sniegas nustatytas tiek atvirose, tiek miškingose vietovėse, tačiau remiantis Sentinel-2<sub>NDSI</sub> ir MS duomenimis sniego ten nebuvo.

Sentinel-1  $R_C$  sniego dangos duomenų statistinė validacija naudojant Sentinel-2<sub>NDSI</sub> kaip atskaitinius duomenis parodė, kad bendras tikslumas (ACC) yra 0,81, aptikimo tikimybė (POD) yra 0,95, o klaidingo nustatymo tikimybė (FAR) yra 0,29 (4.9 lentelė). Šie rodikliai rodo, kad naudojant SAR  $R_C$  metodą sniego dangos nustatymo tikslumas yra ribotas. Aukšta FAR reikšmė ir už 1 didesnė dažnio paklaida (FBI = 1,34) indikuoja, kad  $R_C$  metodas yra linkęs padidinti sniego dangos atvejų skaičių lyginant su Sentinel-2<sub>NDSI</sub>. Validacijos rodiklių įverčiai buvo geresni atvirose vietose

(pievose, ariamoje žemėje): ACC = 0,85–0,92, POD = 0,99, FAR = 0,13–0,22. Virš natūralių pievų  $R_C$  sniego dangos žemėlapiai taip pat turėjo aukščiausią Heidke įvertį (HSS = 0,83). Blogiausi  $R_C$  validacijos rodikliai gauti miškingose vietovėse. Spygliuočių miškuose  $R_C$  sniego dangos žemėlapio tikslumas (ACC) buvo 0,51, POD = 0,96, FAR = 0,86, HSS = 0,12. Labai aukšta dažnio paklaida (FBI = 6,7) parodė, kad Sentinel-1  $R_C$  pervertina sniego buvimą spygliuočių miškuose (4.9 lentelė).

**4.9 lentelė.**  $R_C$  algoritmo sniego dangos žemėlapių validacijos su Sentinel-2<sub>NDSI</sub> rezultatai. Sentinel-2<sub>NDSI</sub> buvo laikomi ataskaitiniais duomenimis (teisingai atspindinčiais sniego dangos pasiskirstymą ant žemės paviršiaus).

Žemės dangos tipas	ACC	POD	FAR	FBI	HSS
Plačialapiai/mišrūs miškai	0,78	0,98	0,39	1,61	0,58
Spygliuočiai miškai	0,51	0,96	0,86	6,72	0,12
Urbanizuotos teritorijos	0,80	0,89	0,23	1,16	0,61
Pievos	0,92	0,99	0,13	1,13	0,83
Vandens telkiniai	0,58	0,54	0,10	0,59	0,18
Pelkės	0,80	0,84	0,26	1,14	0,60
Dirbama žemė	0,85	0,99	0,22	1,26	0,71
<i>Visi tipai</i>	<i>0,81</i>	<i>0,95</i>	<i>0,29</i>	<i>1,34</i>	<i>0,63</i>

Daugelyje tyrimų miškų plotai nėra analizuojami ir iš analizės pašalinami, nes miškuose dalis SAR signalo yra išsklaidoma medžių lajoje, dalis nuo paviršiaus ir medžių kamienų gali atsispindėti du kartus (angl. *double bounce*) ir tik dalis signalo sugrįžta atsispindėjęs nuo paklotinio paviršiaus (He ir kt., 2017; Nagler, Rott, 2000; Nagler ir kt., 2016). Y. Duguay ir M. Bernier (2012) savo tyrime nustatė, kad atgalinės sklaidos koeficientas didėja didėjant augmenijos aukščiui. Teigiama, kad naudojant santykinius vaizdus ( $R_C$ ) augmenijos įtaką galima sumažinti, tačiau jos visiškai pašalinti neįmanoma. Suomijoje atliktame tyrime nustatyta, kad miškuose SAR atgalinės sklaidos skirtumai tarp šlapio sniego ir atvejų be sniegų buvo nedideli (Koskinen ir kt., 1997). Šiame tyrime gauta, kad  $R_C$  sniego dangos žemėlapiai, yra pakankamai tikslūs plačialapiuose/mišriuose miškuose (ACC = 0,78), tačiau jų tikslumas spygliuočių miškuose labai mažas (ACC = 0,51). Šie skirtumai gali būti nulemti to, kad plačialapiuose miškuose nukritus lapams, paklotinis paviršius nėra užstojamas ir SAR


signalas lengviau gali pasiekti žemės paviršių. Sniego dangos klasifikacijos rezultatams taip pat gali turėti įtakos susiformavęs sniegas ant medžių lajos. A. Muhuri ir kt. (2017) savo tyrime parodė, kad žiemą užšalusį miško lają (su sniegu ar ledu) padidina SAR signalo poliarizaciją, o ant paviršiaus susidariusi sniego danga atvirkščiai – poliarizaciją sumažina. Šiame darbe gauti rezultatai patvirtina kitų autorių tyrimus, kad SAR atgalinės sklaidos santykio metodo taikymas sniego dangos kartografavimui nėra tikslus vietovėse su aukšta augmenija (Duguay, Bernier, 2012; Löw ir kt., 2002; Schellenberger ir kt., 2012).

Buvo atliktas sniego dangos kartografavimas ir neskaidant  $R_C$  reikšmių pagal skirtingus žemės dangos tipus. Naudojant visus Sentinel-1 SAR duomenis kartu  $R_C$  kritinė reikšmė skirianti sniegą nuo neapsnigtų pikselių buvo  $-0,78$  dB. Naudojant šią reikšmę validacijos rezultatai buvo panašūs: ACC = 0,80, POD = 0,95, FAR = 0,32. Heidke įvertis buvo 0,61, o tai rodo, kad net ir naudojant vieną universalią  $R_C$  reikšmę visiems žemės dangos tipams sudarytų sniego dangos žemėlapių tikslumas yra panašus. Galima teigti, kad tais atvejais, kai kraštovaizdis yra pakankamai homogeniškas, galima naudoti vieną universalią  $R_C$  kritinę reikšmę ir taip supaprastinti sniego dangos kartografavimo algoritmą.

Aukščiau pateikti validacijos rezultatai buvo paremti tik dviem atvejais, kurie buvo užfiksuoti tais pačiais metais. Tai labai maža duomenų imtis, ir daugiau atvejų iš skirtingų metų leistų atlikti detalesnę SAR  $R_C$  tikslumo vertinimą. Tačiau tai būdinga ir kitiems tyrimams – dažnai SAR sniego dangos žemėlapių validacija remiasi vieno arba kelių atvejų palyginimu (Tsai ir kt., 2019a). Tai parodo, SAR sniego dangos nustatymo algoritmai, palyginti su regimojo spektro jutiklių algoritmais, nėra taip detalieji išbandyti ir pateikiami validacijos rodikliai turėtų būti vertinami labai atsargiai (Tsai ir kt., 2019a).

Be dviejų Sentinel-2<sub>NDSI</sub> vaizdų  $R_C$  sniego dangos duomenų tikslumas taip pat įvertintas naudojant antžeminius matavimus Ukmergės ir Utenos MS. Abi šios stotys yra atvirose vietose, kurios pagal CLC2018 žemės dangos klasifikacija priskirtos natūralioms pievoms. Duomenų palyginimui naudotos visos MS ir  $R_C$  duomenų poros 2014–2019 m. laikotarpiu. Iš viso gauta 123 tokie atvejai ir tomis dienomis sniego storis MS svyravo nuo 0 iki 18 cm, o  $R_C$  reikšmės kito nuo  $-4,04$  iki  $3,03$  dB (4.28 pav.). Sniego dangos atvejai MS, pagal maksimalią oro temperatūrą ir sniego storio pokytį, buvo suskirstyti į šlapio ir sauso sniego kategorijas.  $R_C$  ir MS sniego dangos atvejų palyginimas neparodė aiškaus ryšio tarp sniego storio (ar sniego drėgnumo) bei  $R_C$  reikšmių (4.28 pav.). Bendras  $R_C$  tikslumas (ACC) lyginant su antžeminiiais duomenimis buvo 0,48, FAR = 0,35, FBI = 0,36, POD = 0,24,

HSS = 0,05. Mažos POD ir Heidke įverčio reikšmės rodo labai žemą  $R_C$  sniego dangos klasifikavimo tikslumą, lyginant su taškiniais matavimais MS.



**4.28 pav.** Ryšys tarp  $R_C$  ir sniego storio Utenos ir Ukmergės MS. Mėlyna spalva pažymėti šlapio sniego atvejai, raudona – sauso sniego, juoda – atvejai be sniego.

SAR  $R_C$  sniego dangos klasifikavimo klaidas gali lemti keli veiksniai: sniego dangos slūgsojimo sąlygų ir sniego kristalų dydžio pasikeitimai bei skirtingų sniego dangos sluoksnių metamorfizmas (Dedieu ir kt., 2014; Paloscia ir kt., 2017). SAR  $R_C$  reikšmėms taip pat daug įtakos turi dirvožemio drėgmės kaita (Baghdadi ir kt., 1999). Sudarytų dvejetainių sniego dangos žemėlapių tikslumą gali sumažinti ir atsitiktinis SAR signalo triukšmas (Tsai ir kt., 2019a). Be minėtų veiksnių, dažnas sniego dangos klasifikacijos klaidas Šventosios baseine gali lemti plona sniego danga ir atlydžiai. Esant labai plonai sniego dangai, SAR atgalinę sklaidą labiausia lemia signalo sąveika su dirvožemio drėgme, o ne su sniego danga. Tais atvejais, kai dominuoja plona sniego danga, SAR signalo skirtumas lyginant su ataskaitiniu vaizdu yra nedidelis ir nieko nepasako apie paklotinio paviršiaus sąlygų pokyčius.

Atliktas tyrimas parodė, kad Sentinel-1  $R_C$  tinka kartografuoti sniego dangą atvirose teritorijose su vidutine ir stora sniego danga (> 5 cm), tačiau metodas nėra tikslus miškingose teritorijose bei esant plonai sniego dangai (1–5 cm). Sudaryta sniego dangos nustatymo metodika remiasi SAR atgalinės sklaidos pokyčių aptikimu skirtingos poliarizacijos vaizduose bei skirtinguose žemės dangos tipuose. Dažniausiai tokia metodika naudojama



kartografuojant šlapio sniego dangą. Tyrimai rodo, kad sauso sniego atveju pagrindinė SAR signalo sklaida vyksta sniego dangos tūryje, o atspindys – nuo dirvos paviršiaus (Tedesco, 2015). SAR signalo sklaida sniego dangos tūryje labai priklauso nuo sniego kristalų dydžio. Drėgno sniego sąlygomis dominuojantis procesas yra SAR signalo atspindys nuo skysto vandens esančio sniego dangoje ir didžioji dalis signalo grįžta nuo viršutinės sniego dangos ribos (Tsai ir kt., 2019a). Dėl didelės C juostos SAR signalo skvarbos ir mažo išsklaidymo sausame sniege, naudojant SAR signalo santykį ( $R_C$ ) yra sunku atskirti ploną sauso sniego dangą nuo atvejų be sniego (He ir kt., 2017). Šiame tyrime nebuvo nustatytas aiškus SAR  $R_C$  reikšmių skirtumas tarp šlapio ir sauso sniego atvejų. Gauta, kad  $R_C$  mažėja (didesnės neigiamos reikšmės), kai sniego danga yra storesnė nei 5 cm, nepriklausomai nuo jos drėgnumo. 2014–2019 m. žiemomis oro temperatūra Šventosios upės baseine dažnai buvo artima 0 °C, todėl sniego danga daugeliu atvejų gali būti laikoma drėgna. Jei sniego drėgnumo reikšmės nuolat išlieka panašios, tuomet sniego dangos storis tampa geru SAR atgalinės sklaidos prediktoriumi.

SAR  $R_C$  sniego dangos klasifikacijos palyginimas su Sentinel-2 regimojo spektro jutiklio stebėjimais parodė, kad sudaryti sniego dangos žemėlapiai pakankamai tikslūs atvirose vietovėse, tačiau virš miškų (ypač spygliuočių) sniego danga labai dažnai nustatoma klaidingai. Todėl ateityje, siekiant patobulinti SAR  $R_C$  sniego dangos kartografavimo tikslumą, galima bandyti įtraukti papildomus rodiklius susijusius su augmenija: lapų ploto indeksą (angl. *LAI – leaf area index*) ar NDVI (angl. *Normalized Difference Vegetation Index*). Pasiūlytos  $R_C$  metodikos tikslumas taip pat turėtų padidėti įtraukus informaciją apie dirvožemio sąlygas ir kritulius, nes dirvožemio drėgmė turi labai didelį poveikį SAR atgalinės sklaidos koeficientui.

#### 4.5. Palydovinių vandens atsargų sniege duomenų validacija Baltijos valstybėse

Kalbant apie sniego dangą svarbu ne tik jos užimama teritorija, bet ir jos storis ir tankis. Sniego dangos tankis yra labai glaudžiai susijęs su vandens atsargomis sniege (VAS), o jų kiekį galima nustatyti naudojant palydovinius pasyviuosius mikrobangų radiometrus. Tačiau pasyvieji mikrobangų radiometrai pasižymi žema skiriamąja geba (15–25 km). Tad vienas iš šio tyrimo tikslų buvo padidinti EUMETSAT HSAF vandens atsargų sniege duomenų skiriamąją gebą, naudojant papildomus erdvinius geografinius ir meteorologinius duomenis. Skiriamosios gebos didinimas buvo atliktas

naudojant tiesinę daugianarę regresiją (DRM) ir dirbtinius neuroninius tinklus (DNT). Skiriamoji geba nuo 25 x 25 km buvo padidinta iki 5 x 5 km.

HSAF VAS duomenų skiriamosios gebos didinimui buvo naudojamas SRTM 90 m. skiriamosios gebos skaitmeninis reljefo modelis (DEM), 0,08° x 0,08° žemės dangos tipai iš GLCF, bei 0,25° x 0,25° minimali paros temperatūra ( $T_{min}$ ) iš E-OBS duomenų bazės. Žemėnaudos tipai buvo išskaidyti į atskirus dvejetainius kintamuosius.

DRM ir DNT skiriamosios gebos didinimo modelių apmokymui naudoti 2012–2018 m. laikotarpio VAS matavimai iš 52 meteorologijos stočių. 2017–2018 m. sezono duomenys (apie 13 % visų duomenų) buvo palikti validacijai, o kiti panaudoti DRM ir DNT modelio sudarymui (iš viso 12160 duomenų porų). Modelių apmokymas vyko keliomis iteracijomis, kurių metų buvo nustatomi svarbiausi prediktoriai ir ieškoma optimalios modelių konfigūracijos.

Sudarant daugianarės regresijos modelį svarbiausiais VAS prediktoriais buvo laikomi tie rodikliai, kurių statistinio reikšmingumo lygmuo buvo  $p < 0,05$ . Naudojant šį kriterijų iš pirminių duomenų, skirtų modelio apmokymui, kaip nereikšmingi pašalinti vandens telkinių, pelkių, natūralių pievų ir mišrios žemės dangos tipai bei minimali paros oro temperatūra ( $T_{min}$ ). Vandens telkinių, pelkių ir natūralių pievų tipuose nebuvo atliekamos sniego nuotraukos, todėl natūralu, kad šie dangos tipai buvo pašalinti kaip nereikalingi. Svarbiausi DRM modelio prediktoriai ir jų statistinio reikšmingumo lygmuo ( $p$ ) pateikti 4.10 lentelėje.

Gauta DRM lygtis, kurios determinacijos koeficientas ( $R^2$ ) buvo 0,89:

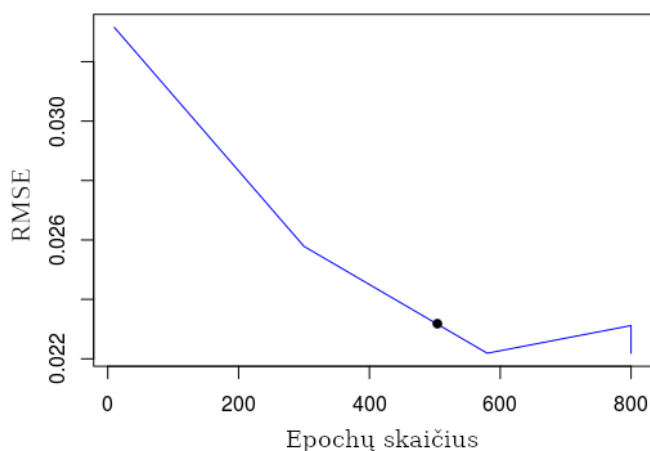
$$VAS_{LRM} = -0,0027 + 0,7169 * VAS_{HSAF} + 0,0089 * DEM - 0,0019 * Spygliuočiai - 0,0061 * Mišrūs - 0,0013 * Ariama žemė - 0,0025 * Urbanizuotos \quad (4.4)$$

kur  $VAS_{HSAF}$  – HSAF vandens atsargų sniege duomenų rinkinys, DEM – vietovės aukštis, pagal SRTM skaitmenį reljefo modelį (m), Spygliuočiai – spygliuočių miškai (0/1), Mišrūs – mišrūs miškai (0/1), Ariama žemė (0/1), Urbanizuotos – urbanizuotos teritorijos (0/1).

Dirbtinį neuroninį tinklą sudarė įvesties sluoksnis, du paslėpti sluoksniai bei išvesties sluoksnis. DNT apmokymui pasirinkta 500 epochų (4.29 pav.), kad būtų išvengta per didelio modelio pritaikymo testiniams duomenims. Viena epocha (arba iteracija) laikomas vienas pilnas apmokymo ciklas, kai panaudojami visi prediktoriai, apskaičiuojami jų svoriniai koeficientai ir tarpusavio ryšiai.

**4.10 lentelė.** Kintamieji, kurie buvo naudojami galutiniame DRM VAS skiriamosios gebos didinimo modelyje, bei jų santykinė svarba pagal statistinę p vertę.

Prediktorius	p vertė
HSAF VAS	$< 2e^{-16}$
Reljefo aukštis	$4,16e^{-15}$
Mišrus miškas	0,000741
Ariama žemė	0,003354
Urbanizuotos teritorijos	0,003738
Spygliuočiai miškai	0,031935




**4.29 pav.** Vidutinės kvadratinės paklaidos (RMSE) kaita apmokant dirbtinį neuroninį tinklą. Taškas žymi pasirinktą epochų skaičių (500).

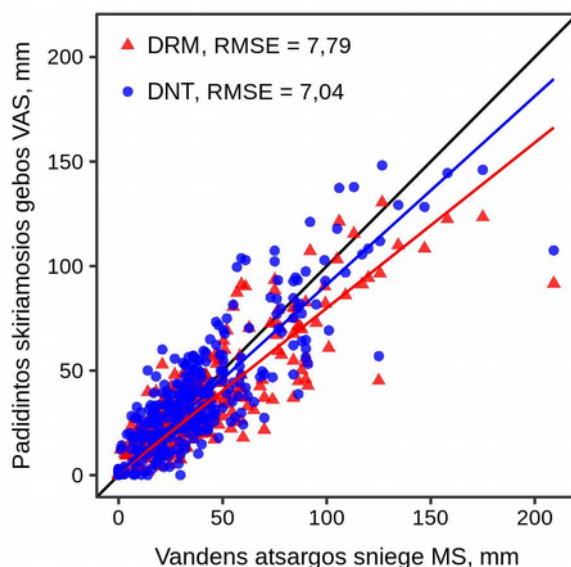
Naudojant DNT algoritmo kintamųjų santykinės svarbos rodiklį (angl. *variable importance*), buvo atrinkti patys svarbiausi prediktoriai, susiejantys VAS su aplinkos sąlygomis (4.30 pav.). Santykinė svarba parodo kaip panaudojus konkretų kintamąjį, sumažėjo galutinio DNT modelio kvadratinė paklaida. Iš DNT modelio sudarymo buvo pašalinti vandens telkinių, pelkių, bei natūralių pievų žemės dangos tipai, nes šiuose dangos tipuose nebuvo nė vieno antžeminio matavimo (sniego nuotraukos), kurio duomenis būtų buvę galima panaudoti DNT apmokymui.

Sudarius DNT ir DRM modelius, padidintos skiriamosios gebos HSAF VAS duomenys buvo palyginti su 2017–2018 m. sniego nuotraukų matavimais Baltijos valstybėse. Validacijos rezultatai parodė, kad rezultatai

gauti naudojant daugianarę regresiją ir dirbtinius neuroninius tinklus yra panašūs (4.31 pav.). Šiek tiek tikslesni buvo VAS duomenys gauti naudojant neuroninius tinklus (RMSE = 7,04; ME = 0,03), nei naudojant daugianarę regresiją (RMSE = 7,79; ME = -1,08) (4.11 lentelė). Koreliacija tarp padidintos skiriamosios gebos HSAF VAS duomenų ir matavimų MS buvo 0,94.



**4.30 pav.** Santykinę prediktorių svarbą DNT modelyje, skirtame padidinti HSAF VAS duomenų skiriamąją gebą.



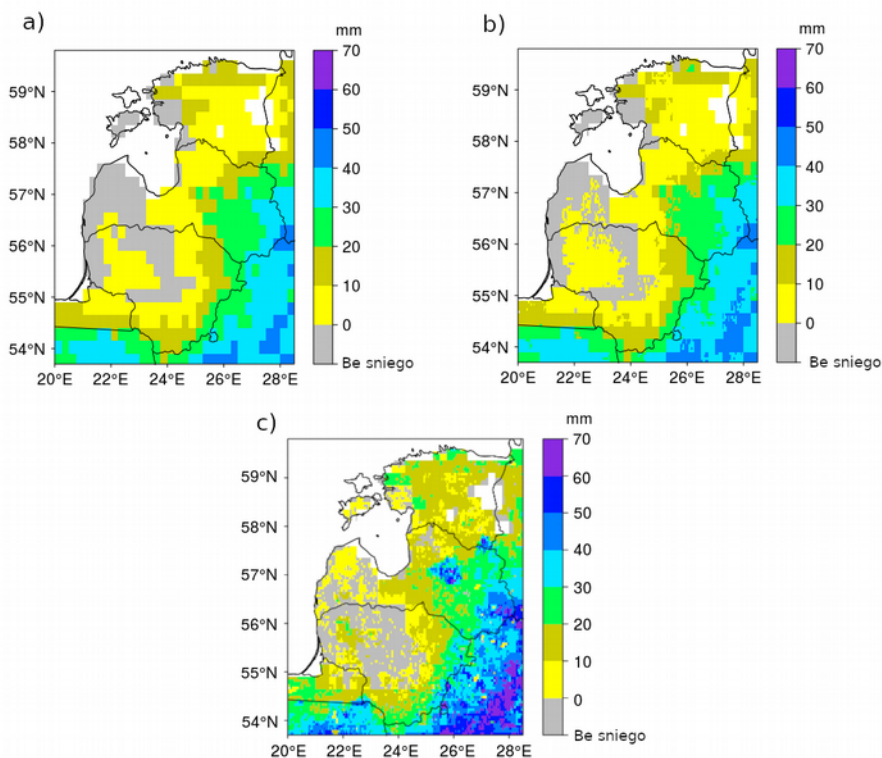
**4.31 pav.** Daugianarės regresijos (DRM) ir neuroninio tinklo (DNT) modeliais padidintos erdvinės skiriamosios gebos HSAF VAS ryšys su VAS matavimais sniego nuotraukų metu 2017–2018.

**4.11 lentelė.** HSAF padidintos skiriamosios gebos VAS duomenų palyginimas su sniego nuotraukų matavimais MS. HSAF – pirminis VAS duomenų rinkinys, DRM – aukštesnės skiriamosios gebos VAS duomenys, gauti naudojant daugianarės regresijos modelį, DNT – VAS gauti naudojant dirbtinį neuroninį tinklą.

Statistinis rodiklis	HSAF	DRM	DNT
Koreliacijos koef.	0,93	0,94	0,94
Vid. paklaida (ME), mm	-0,94	-1,08	0,03
Vid. absoliuti paklaida (MAE), mm	2,41	2,73	2,33
Vid. kvadratinė paklaida (RMSE), mm	7,81	7,79	7,04

Nors taškinės validacijos rezultatai indikuoja, kad DNT modeliu gauti VAS duomenys yra tikslesni, tačiau nagrinėjant erdvinį duomenų pasiskirstymą, pastebėta, kad DNT sukuria sniegą ( $VAS > 0$ ) ten, kur jo neturėtų būti (4.32c pav.). DNT tiksliai padidina HSAF VAS duomenų skiriamąją gebą tais atvejais, kai VAS reikšmės yra aukštos ( $> 20$  mm), tačiau kai VAS reikšmės yra mažos gaunami netikslūs rezultatai. Greičiausia, pagrindinė priežastis yra tai, kad DNT modelyje, didesnė santykinė svarba tenka žemės dangos tipams, o ne HSAF VAS duomenims (4.30 pav.). Todėl kai kuriais atvejais, kai pirminiuose HSAF VAS duomenyse nėra sniego, kitų rodiklių (vietovės aukščio, žemės dangos tipų,  $T_{min}$ ) įtaka lemia, kad DNT algoritmu gaunamos VAS reikšmės yra didesnės už 0 mm. Norint išvengti šių nepageidaujamų dirbtinio neuroninio tinklo rezultatų reiktų HSAF VAS suteikti didesnę svorį, taip pat šios problemos galbūt galima išvengti pasirinkus kitą DNT aktyvacijos funkciją (pvz.: ReLU – *Rectified Linear Unit* arba TLU – *Threshold logic unit*).

Erdvinis VAS reikšmių pasiskirstymas gautas naudojant daugianarės regresijos modelį (DRM) daug artimesnis pirminiam HSAF VAS reikšmių pasiskirstymui (4.32b pav.). Padidintos skiriamosios gebos VAS duomenų neapibrėžtumas tiek DNT, tiek DRM atveju gali būti susijęs su ribotais MS duomenimis, kurie buvo prieinami algoritmų apmokymui. Didžioji dalis MS duomenų buvo atvejai be sniego ir turint daugiau sniego nuotraukų duomenų būtų galima pasiekti geresnių rezultatų. Taip pat yra reikalingi VAS matavimai iš vietovių su skirtingo tipo žemės danga – šiame tyrime nebuvo nė vieno antžeminio matavimo iš natūralių pievų, pelkių ar krūmynų (pagal GLCF klasifikaciją).



**4.32 pav.** VAS Baltijos šalyse 2017 m. vasario 10 d.: a) originalus  $0,25 \times 0,25^\circ$  HSAF VAS duomenų rinkinys; b)  $0,05 \times 0,05^\circ$  skiriamosios gebos HSAF duomenų rinkinys, gautas naudojant DRM; c)  $0,05 \times 0,05^\circ$  skiriamosios gebos HSAF duomenų rinkinys, gautas naudojant DNT.

Gauti rezultatai indikuoja, kad DRM ar DNT modeliu gauti padidintos skiriamosios gebos VAS duomenys yra panašaus tikslumo kaip ir pirminiai HSAF VAS duomenis. Palydovinių sniego duomenų skiriamosios gebos didinimo metodų potencialas yra ribotas, nes yra glaudžiai susijęs su pirminių įvesties duomenų kokybe ir tikslumu (Li ir kt., 2015; Zhu ir kt., 2021). Siekiant gauti tikslesnius erdvinius rezultatus, apmokant statistinius modelius reiktų suteikti didesnę svorį palydoviniams VAS duomenims bei įvesti aukštos skiriamosios gebos rodiklius, kurie padėtų nustatyti sniego susidarymui ar tirpsmui palankias sąlygas. Vienas iš tokių papildomų rodiklių galėtų būti Saulės spinduliuotės intensyvumas (Li ir kt., 2015) arba regimojo spektro sniego dangos paplitimo informacija (Mhaweji ir kt., 2014). Tačiau tokių duomenų pritaikymą apsunkina didelis debesuotumas, būdingas šaltajam sezonui Baltijos valstybėse.

Šis tyrimas parodė, kad naudojant detalius aplinkos duomenis (vietovės aukštį, žemės dangos tipus, minimalią oro temperatūrą) galima padidinti palydovinių VAS duomenų skiriamąją gebą. Statistinė validacija parodė, kad naudojant dirbtinius neuroninius tinklus, gauti šiek tiek tikslesni VAS duomenys, tačiau nagrinėjant duomenų erdvinį pasiskirstymą, nustatyta, kad naudojant DNT algoritmą sniego reikšmės ( $VAS > 0$  mm) kartais gaunamos ten, kur jų nebuvo pirminiuose HSAF duomenyse. Pagrindinė priežastis yra tai, kad dirbtinio neuroninio tinklo modelyje, didesnis santykinis prediktorių svoris tenka žemės dangos tipams, o ne pirminiams HSAF VAS duomenims.

Nors pasiūlyti palydovinių VAS duomenų skiriamosios gebos didinimo metodai turi savo trūkumus, naudojami papildomi aplinkos ir meteorologiniai rodikliai yra lengvai prieinami ir globalūs, todėl šią metodiką galima lengvai pritaikyti bet kuriam regionui.

## IŠVADOS

1. Didžiausią įtaką erdviniam sniego dangos rodiklių pasiskirstymui Baltijos valstybėse turi vietovės aukštis ir geografinė ilguma, kuri yra atstumo iki centrinės Baltijos jūros dalies aproksimacija. Nagrinėjant meteorologinių rodiklių įtaką sniego dangos rodikliams Baltijos valstybėse gauta, kad sniego dangos trukmė labiausiai susijusi su vidutine oro temperatūra lapkričio-kovo mėnesiais, o maksimalus sniego storis – sniego kaupimosi laikotarpiu (nuo gruodžio iki vasario mėn.). Gauta, kad kritulių kiekio įtaka sniego dangos trukmei ir maksimaliam storiui nebuvo statistiškai reikšminga. 1961–2015 m. laikotarpiu Baltijos valstybėse dienų su sniego danga skaičius mažėjo vidutiniškai 3,3 dienos per dešimtmetį. Tuo tarpu vidutinis maksimalus sniego storis Baltijos valstybėse beveik nepakito.

2. Snygio metu palydovinio ATMS jutiklio 165,5–183,3 GHz dažniuose užfiksuota ryškio temperatūra pasižymi aukšta koreliacija su GFS skaitmeninio orų modelio atmosferos rodikliais, apibūdinančiais drėgmės kiekį bei vertikalius atmosferos judesius vidurinėje ir viršutinėje troposferos dalyje (600–300 hPa lygiuose). Išimtis – šalto oro sąlygos, kai  $T \leq -10$  °C – tuomet koreliacija tampa nereikšminga. Snygio klasifikavimui pagal ATMS ir GFS duomenis sudaryti logistinės regresijos ir atsitiktinių miškų (RF) algoritmai pasižymėjo panašia snygio aptikimo bei klaidos tikimybe (POD = 0,80–0,83; POFD = 0,23–0,24). Heidke įvertis buvo aukštesnis naudojant RF (HSS = 0,65) ir tai rodo, kad RF algoritmas pranašesnis tuose regionuose ir situacijose, kai snygio atvejai yra reti. Esant šaltoms oro sąlygoms ( $T < -10$  °C) abiejų snygio nustatymo algoritmų tikslumas buvo mažesnis ir padidėjo klaidos tikimybė.

3. Erdvinio filtravimo, filtravimo laike bei minimalios paros oro temperatūros ( $T_{\min}$ ) kontrolės taikymas yra efektyvi priemonė užpildant MODIS sniego dangos duomenų spragas atsirandančias dėl debesuotumo. Nustatyta, kad efektyviausiai atsirandančias sniego dangos nustatymo klaidas sumažina 2,0 °C kritinė  $T_{\min}$  reikšmė. Vidutinis koreliacijos koeficientas tarp metinio dienų su sniego danga skaičiaus Lietuvoje, nustatyto remiantis MODIS duomenimis, ir MS stebėjimų siekė 0,93, o vidutinis absoliutus skirtumas – 8,5 dienas. Daugeliu atvejų metinė sniego dangos trukmė, gauta naudojant palydovinius duomenis, buvo daugiau kaip 4 dienomis ilgesnė nei išmatuota MS. Tikėtina, kad MODIS sniego dangos duomenys virš miškų masyvų ir pasienio regionuose yra tikslesni nei gauti interpoliuojant MS duomenis. Didžiausios MODIS sniego dangos duomenų klaidos buvo nustatytos pajūryje, kur sniego danga yra nepastovi.



4. Nustatyta, kad Lietuvoje Sentinel-1 SAR jutiklio atgalinė sklaida keičiasi, kai sniego danga yra storesnė nei 5 cm. Ryšys tarp SAR signalo ir šlapios sniego dangos nustatytas tik atvirose vietovėse (pievose ir ariamoje žemėje) pavasarinio sniego tirpsmo metu. Priklausomai nuo žemės dangos tipo kritinės SAR santykio ( $R_C$ ) reikšmės, skiriančios sniegą (> 5 cm) nuo atvejų be sniego, kito nuo -0,52 dB iki -1,05 dB. Vidutinė kritinė  $R_C$  reikšmė, neskaidant pagal žemės dangos tipus, buvo -0,78 dB. SAR  $R_C$  sniego dangos klasifikacijos palyginimas su Sentinel-2 regimojo spektro jutiklio stebėjimais parodė, kad sudaryti sniego dangos žemėlapiai pakankamai tikslūs pievose ir ariamoje žemėje (POD = 0,99; FAR = 0,13–0,22). Tačiau virš miškų (ypač spygliuočių) sniego danga labai dažnai buvo nustatoma klaidingai (FAR = 0,86).

5. Naudojant detalius aplinkos duomenis (vietovės aukštį, žemės dangos tipus, minimalią oro temperatūrą) galima padidinti palydovinių HSAF vandens atsargų sniege (VAS) duomenų skiriamąją gebą nuo  $0,25^\circ$  iki  $0,05^\circ$ . Tikslesni padidintos skiriamosios gebos VAS duomenys gauti naudojant dirbtinius neuroninius tinklus (RMSE = 7,04) nei naudojant daugianarę regresiją (RMSE = 7,79). Padidintos skiriamosios gebos HSAF VAS duomenų erdvinė analizė parodė, kad naudojant dirbtinių neuroninių tinklų algoritmą, sniego danga (VAS > 0 mm) kartais gaunama ten, kur jos nebuvo pirminiuose duomenyse. Pagrindinė šių klaidų priežastis yra tai, kad dirbtinio neuroninio tinklo algoritme, didesnis santykinis prediktorių svoris tenka žemės dangos tipams, o ne pirminiams HSAF VAS duomenims.

## APIBENDRINIMAS

Vykstant antžeminio meteorologinio tinklo automatizavimui Baltijos valstybėse mažėja stočių su stebėtojais, todėl mažėja ir monitoringo programos apimtis. Sniego dangos padengimo laipsnis vietovėje bei vandens atsargos sniege – tai vieni pagrindinių rodiklių, kurių matavimo vietų skaičius sparčiai mažėja. Šių duomenų prieinamumas per 20 metų Lietuvoje sumažėjo 59–86%. Šiame darbe pristatyti rezultatai rodo, kad atsirandančią matavimų spragą gali užpildyti palydoviniai duomenys.

Naudojant palydovinius stebėjimus galima gauti informacijos apie sniego dangos formavimąsi (snygio intensyvumą), sniego dangos paplitimą bei vandens atsargas sniege. Regimojo spektro palydoviniai jutikliai suteikia detalios informacijos apie sniego dangos paplitimą, pasyviųjų mikrobangų jutiklių duomenys naudojami nustatyti snygį bei vandens atsargas sniege, o sintetinės apertūros radarai (SAR) – sniego dangos plotą, bei jo tankį ir storį.

Sniego danga pradeda formuotis iškritus pirmajam sniegui ir laikantis neigiamai temperatūrai. Sniego dangos paplitimą ir jos storio augimą šaltojo sezono metu galima pakankamai tiksliai nustatyti žinant kietųjų kritulių kiekį ir jų erdvinį pasiskirstymą. Šiame tyrime snygio nustatymui buvo naudojami ATMS zonduojančio radiometro duomenys. Pritaikius atsitiktinių miškų (RF) modelį buvo siekiama patobulinti jau egzistuojantį snygio intensyvumo algoritmą ir kuo tiksliau atskirti snygio atvejus nuo atvejų be kritulių. Sudarytas atsitiktinių miškų klasifikatorius leido pakankamai tiksliai nustatyti snygio atvejus, kai oro temperatūra 2 m aukštyje svyravo tarp +5 ir -10 °C, tačiau esant žemesnei oro temperatūrai snygio klasifikacijos tikslumas mažėjo. Snygio nustatymo algoritmai, kuriuose naudojami palydoviniai duomenys, sudaro galimybę gauti kasdieninę detalią informaciją apie kietųjų kritulių pasiskirstymą ir jų intensyvumą, o tai leidžia prognozuoti sniego dangos paplitimą ir storį, net ir neturint duomenų iš antžeminių meteorologijos stočių.

Regimojo spektro jutikliai (MODIS, Sentinel-2) pasižymi aukšta skiriamąją geba, tačiau jų pagrindinis trūkumas yra tai, kad signalas neprasiskverbia pro ištisinį debesų sluoksnį. Šaltuoju sezonu Lietuvoje debesis Žemės paviršių dengia daugiau nei 70 % laiko. Sniegos dangos stebėsenai galima naudoti MODIS duomenis, tačiau būtina užpildyti duomenų spragas atsirandančias dėl debesuotumo. Šiame darbe pasiūlyta metodika, kaip naudojant erdvinį duomenų apjungimą, filtravimą laike bei įvedant meteorologinius kriterijus galima užpildyti šias spragas. Metodika nėra tinkama operatyviam sniego dangos stebėjimui – norint ją pritaikyti

reikia sulaukti sezono pabaigos. Tačiau ši metodika gerai tinka sniego dangos klimato tyrimams ir gauti rezultatai sutampa su sniego dangos stebėjimais meteorologijos stotyse žemyninėje Lietuvos dalyje. Pajūryje, dėl greitai kintančių sniego dangos sąlygų, ši metodika nėra tokia efektyvi – vidutiniškai gaunama 54 % ilgesnė sniego dangos trukmė nei nustatyta MS. Lyginant su taškiniais MS stebėjimais, MODIS suteikia detalesnės informacijos apie erdvinį sniego dangos trukmės pasiskirstymą. Šis pranašumas ypač akivaizdus dideliuose miškų masyvuose, pasienio regionuose ir aukštumose.

Sniego danga taip pat gali būti nustatyta naudojant Sentinel-1 SAR jutiklį, kuris Žemės paviršių gali stebėti bet kokiomis oro sąlygomis (naktį, esant ištisiniam debesuotumui, lyjant ir t. t.). SAR atgalinės sklaidos koeficientas priklauso nuo daugelio veiksnių (paviršiaus sudėties, šiurkštumo, dielektrinių savybių), todėl nustatyti, kada koeficiento pasikeitimus lemia susidariusi sniego danga, o kada kitos priežastys, yra sudėtinga. Atvirose vietovėse sniego dangos įtaką SAR signalo pasikeitimui nustatyti lengviau nei miškuose, nes miškuose medžių laja (dėl fenologinių sezonų kaitos, dėl vėjo ar kritulių) nuolat kinta ir tai lemia SAR atgalinės sklaidos dydį. Šis lajos poveikis gali būti dominuojantis ir visiškai užgožti signalą, ateinantį nuo sniego dangos ant Žemės paviršiaus.

Daugelyje tyrimų teigiama, kad naudojant SAR atgalinės sklaidos santykį ( $R_c$ ) galima nustatyti tik šlapią sniego dangą, nes skystas vanduo sniege labai pakeičia SAR atgalinės sklaidos koeficientą. Tačiau šiame tyrime gauta, kad  $R_c$  pasikeičia, kai sniego danga storesnė nei 5 cm, nepriklausomai nuo to ar ji buvo drėgna ar ne. Taip gali būti todėl, kad Lietuvoje sniego danga dažnai yra drėgna dėl oro temperatūros artimos 0 °C ir tiriamu laikotarpiu (2014–2019 m.) nebuvo nustatyta ryškios  $R_c$  reikšmių atskirties tarp sauso ir šlapio sniego atvejų. Taip pat reiktų papildomo detalaus tyrimo, ar pasirinkti kriterijai apibūdinantys šlapią sniego dangą ( $T_{\min} > 0$  °C, sniego storio pokytis -2 cm/parą) yra tinkami visais atvejais. SAR duomenų pritaikymą sniego dangos stebėsenai šalies mastu apsunkina santykinai siaura jutiklio žvalgos juosta (250 km) – vienu praskridimu ji apima tik dalį Lietuvos teritorijos. Tačiau aukštos skiriamosios gebos Sentinel-1 SAR duomenys gali būti pritaikyti sniego dangos stebėsenai mažų upių baseinuose.

Sniego dangos plotas ir trukmė yra svarbūs rodikliai orų prognozių modeliuose ir klimato tyrimuose, tačiau sudarant pavasario potvynio prognozes labai svarbu detali informacija apie vandens atsargas sniege. EUMETSAT HSAF organizacija teikia kasdienius vandens atsargų sniege (VAS) duomenis, tačiau jie pasižymi labai žema skiriamąja geba (0,25° x

0,25°). Šiame tyrime HSAF VAS duomenų skiriamoji geba naudojant dirbtinių neuroninių tinklų ir daugianarės regresijos modelius buvo padidinta iki 0,05° x 0,05°. Dirbtinių neuroninių tinklų modeliu padidintos skiriamosios gebos VAS validacijos rodikliai buvo geresni, tačiau erdvinio pasiskirstymo analizė parodė, kad sniego danga (VAS > 0 mm) buvo gauta ten kur jos neturėjo būti. Klaidingo nustatymo galima būtų išvengti modeliuose suteikiant didesnę svorį pirminiems palydoviniams VAS duomenims.

Visi sudaryti palydovinių duomenų rinkiniai buvo lyginami su sniego dangos matavimais meteorologijos stotyse (MS). Siekiant kuo tiksliau įvertinti sniego dangos erdvinį pasiskirstymą ir ilgalaikę kaitą, Baltijos valstybėse buvo apskaičiuoti sniego dangos rodiklių pokyčiai ir svyravimai 1961–2015 m. laikotarpiu remiantis vien sausumos stočių stebėjimais. Erdviniai sniego dangos ir sezoninės eigos dėsningumai, nustatyti remiantis MS duomenimis, leido lengviau vertinti sniego dangos dėsningumus, nustatytus naudojant palydovinius jutiklius.

Dėl mažėjančio sniego dangos rodiklių matavimų apimčių detali informacija apie sniego dangą gali būti gaunama iš palydovinių duomenų. Tačiau norint tai pasiekti pirmiausia reikia plėtoti metodologiją, kuri leistų apjungti ir išnaudoti skirtingų palydovinių jutiklių privalumus. Pavyzdžiui, regimojo spektro jutiklių duomenų spragas, atsirandančias dėl debesuotumo, galima užpildyti panaudojant pasyviųjų mikrobangų jutiklių ar SAR duomenis. SAR ir pasyvieji mikrobangų jutikliai gali suteikti informacijos ne tik apie sniego dangos paplitimą, bet ir apie jos tankį ir vandens atsargas sniege. Zonduojantys mikrobangų radiometrai leidžia nustatyti kietuosius kritulius ir ši informacija naudinga prognozuojant sniego akumuliaciją. Šių skirtingų palydovinių jutiklių informacijos sintezė leistų gauti išsamią informaciją apie sniego dangos formavimąsi, paplitimą ir abliaciją. Šis darbas parodo, kad palydovinių duomenų trūkumus galima pašalinti (arba sumažinti) pritaikius tinkamus palydovinių duomenų apdorojimo metodus ir atskleidžia palydovinių duomenų potencialą nuolatiniam sniego dangos stebėjimui lyguminėse teritorijose.

## LITERATŪROS SĄRAŠAS

- Adhikari, A., Ehsani, M. R., Song, Y., Behrangi, A. (2020). Comparative Assessment of Snowfall Retrieval From Microwave Humidity Sounders Using Machine Learning Methods. *Earth and Space Science*, 7(11), e2020EA001357. <https://doi.org/10.1029/2020EA001357>
- Alemohammad, H. S., Kolassa, J., Prigent, C., Aires, F., Gentine, P. (2018). Global downscaling of remotely sensed soil moisture using neural networks. *Hydrology and Earth System Sciences*, 22(10), 5341–5356. <https://doi.org/10.5194/hess-22-5341-2018>
- Alexakis, D. D., Tsanis, I. K. (2016). Comparison of multiple linear regression and artificial neural network models for downscaling TRMM precipitation products using MODIS data. *Environmental Earth Sciences*, 75(14), 1077. <https://doi.org/10.1007/s12665-016-5883-z>
- Alexandersson, H. (1986). A homogeneity test applied to precipitation data. *Journal of Climatology*, 6(6), 661–675. <https://doi.org/10.1002/joc.3370060607>
- Andreadis, K. M., Storck, P., Lettenmaier, D. P. (2009). Modeling snow accumulation and ablation processes in forested environments. *Water Resources Research*, 45(5). <https://doi.org/10.1029/2008WR007042>
- Apsite, E., Rudlapa, I., Latkovska, I., Elferts, D. (2013). Changes in Latvian river discharge regime at the turn of the century. *Hydrology Research*, 44(3), 554–569. <https://doi.org/10.2166/nh.2012.007>
- Armstrong, R. L., Brun, E. (eds.) (2008). *Snow and climate : physical processes, surface energy exchange and modeling*. Cambridge: Cambridge University Press.
- Armstrong, R. L., Chang, A., Rango, A., Josberger, E. (1993). Snow depths and grain-size relationships with relevance for passive microwave studies. *Annals of Glaciology*, 17, 171–176. <https://doi.org/10.3189/S0260305500012799>
- Athmania, D., Achour, H. (2014). External Validation of the ASTER GDEM2, GMTED2010 and CGIAR-CSI- SRTM v4.1 Free Access Digital Elevation Models (DEMs) in Tunisia and Algeria. *Remote Sensing*, 6(5), 4600–4620. <https://doi.org/10.3390/rs6054600>
- Baghdadi, N., Fortin, J. P., Bernier, M. (1999). Accuracy of wet snow mapping using simulated radarsat backscattering coefficients from observed

- snow cover characteristics. *International Journal of Remote Sensing*, 20(10), 2049–2068. <https://doi.org/10.1080/014311699212344>
- Behrangi, A., Tian, Y., Lambrigtsen, B. H., Stephens, G. L. (2014). What does CloudSat reveal about global land precipitation detection by other spaceborne sensors? *Water Resources Research*, 50(6), 4893–4905. <https://doi.org/10.1002/2013WR014566>
- Belgiu, M., Drăgu, L. (2016, April 1). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, Vol. 114, pp. 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Beniston, M., Farinotti, D., Stoffel, M., Andreassen, L. M., Coppola, E., Eckert, N., Fantini, A., Giacona, F., Hauck, C., Huss, M., Huwald, H., Lehning, M., López-Moreno, J., Magnusson, J., Marty, C., Morán-Tejedá, E., Morin, S., Naaim, M., Provenzale, A., Rabatel, A., Six, D., Stötter, J., Strasser, U., Terzago, S. Vincent, C. (2018). The European mountain cryosphere: a review of its current state, trends, and future challenges. *The Cryosphere*, 12, 759–794. <https://doi.org/10.5194/tc-12-759-2018>
- Bhuiyan, M. A. E., Nikolopoulos, E. I., Anagnostou, E. N. (2019). Machine learning-based blending of satellite and reanalysis precipitation datasets: A multiregional tropical complex terrain evaluation. *Journal of Hydro-meteorology*, 20(11), 2147–2161. <https://doi.org/10.1175/JHM-D-19-0073.1>
- Bourbigot, M., Johnsen, H., Piantanida, R., Hajduch, G., Poullaouec, J. (2016). Sentinel-1 Product Definition. <https://sentinel.esa.int/documents/247904/0/Sentinel-1-Product-Definition/6049ee42-6dc7-4e76-9886-f7a72f5631f3>
- Bulygina, O N, Razuvaev, V. N., Korshunova, N. N. (2009). Changes in snow cover over Northern Eurasia in the last few decades. *Environmental Research Letters*, 4, 45026. <https://doi.org/10.1088/1748-9326/4/4/045026>
- Bulygina, Olga N, Groisman, P. Y., Razuvaev, V. N., Korshunova, N. N. (2011). Changes in snow cover characteristics over Northern Eurasia since 1966. *Environmental Research Letters*, 6, 45204. <https://doi.org/10.1088/1748-9326/6/4/045204>
- Büttner, G., Kosztra, B., Soukup, T., Sousa, A., Langanke, T. (2017). CLC2018 Technical Guidelines. [https://land.copernicus.eu/user-corner/technical-library/clc2018technicalguidelines\\_final.pdf](https://land.copernicus.eu/user-corner/technical-library/clc2018technicalguidelines_final.pdf)

- Carroll, M. L., DiMiceli, C. M., Townshend, J. R. G., Sohlberg, R. A., Elders, A. I., Devadiga, S., Sayer, A. M., Levy, R. C. (2017). Development of an operational land water mask for MODIS Collection 6, and influence on downstream data products. *International Journal of Digital Earth*, 10(2), 207–218. <https://doi.org/10.1080/17538947.2016.1232756>
- Chang, A. T. C., Foster, J. L., Hall, D. K. (1987). Nimbus-7 SMMR Derived Monthly Global Snow Cover and Snow Depth. *Annals of Glaciology*, 39–44.
- Chang, A. T. C., Foster, J. L., Hall, D. K., Rango, A., Hartline, B. K. (1982). Snow water equivalent estimation by microwave radiometry. *Cold Regions Science and Technology*, 5(3), 259–267. [https://doi.org/10.1016/0165-232X\(82\)90019-2](https://doi.org/10.1016/0165-232X(82)90019-2)
- Chen, D., Chen, H. W. (2013). Using the Köppen classification to quantify climate variation and change: An example for 1901–2010. *Environmental Development*, 6, 69–79. <https://doi.org/10.1016/J.ENVDEV.2013.03.007>
- Chen, H., Chandrasekar, V., Cifelli, R., Xie, P. (2020). A Machine Learning System for Precipitation Estimation Using Satellite and Ground Radar Network Observations. *IEEE Transactions on Geoscience and Remote Sensing*, 58(2), 982–994. <https://doi.org/10.1109/TGRS.2019.2942280>
- Choi, G., Robinson, D. A., Kang, S. (2010). Changing northern hemisphere snow seasons. *Journal of Climate*, 23(19), 5305–5310. <https://doi.org/10.1175/2010JCLI3644.1>
- Cloude, S. R., Pettier, E. (1996). A review of target decomposition theorems in radar polarimetry. *IEEE Transactions on Geoscience and Remote Sensing*, 34(2), 498–518. <https://doi.org/10.1109/36.485127>
- Cohen, J., Furtado, J. C., Jones, J., Barlow, M., Whittleston, D., Entekhabi, D. (2014). Linking Siberian Snow Cover to Precursors of Stratospheric Variability. *Journal of Climate*, 27(14), 5422–5432. <https://doi.org/10.1175/JCLI-D-13-00779.1>
- Conde, V., Nico, G., Mateus, P., Catalão, J., Kontu, A., Gritsevich, M. (2019). On the estimation of temporal changes of snow water equivalent by spaceborne sar interferometry: a new application for the sentinel-1 mission. *Journal of Hydrology and Hydromechanics*, 67(1), 93–100. <https://doi.org/10.2478/johh-2018-0003>
- Cornes, R. C., van der Schrier, G., van den Besselaar, E. J. M., Jones, P. D. (2018). An Ensemble Version of the E-OBS Temperature and Precipi-

- tation Data Sets. *Journal of Geophysical Research: Atmospheres*, 123(17), 9391–9409. <https://doi.org/10.1029/2017JD028200>
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems*, 2(4), 303–314. <https://doi.org/10.1007/BF02551274>
- Da Ronco, P., De Michele, C. (2014). Cloud obstruction and snow cover in Alpine areas from MODIS products. *Hydrology and Earth System Sciences*, 18(11), 4579–4600. <https://doi.org/10.5194/hess-18-4579-2014>
- Darlane, A. B., Khoramian, A., Santi, E. (2017). Investigating spatiotemporal snow cover variability via cloud-free MODIS snow cover product in Central Alborz Region. *Remote Sensing of Environment*, (202), 152–165. <https://doi.org/10.1016/j.rse.2017.05.042>
- Dedieu, J. P., Besic, N., Vasile, G., Mathieu, J., Durand, Y., Gottardi, F. (2014). Dry snow analysis in alpine regions using RADARSAT-2 full polarimetry data. Comparison with in situ measurements. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3658–3661. <https://doi.org/10.1109/IGARSS.2014.6947276>
- Déry, S. J., Brown, R. D. (2007). Recent Northern Hemisphere snow cover extent trends and implications for the snow-albedo feedback. *Geophysical Research Letters*, 34(L22504). <https://doi.org/10.1029/2007GL031474>
- Dietz, A. J., Kuenzer, C., Dech, S. (2015). Global SnowPack: a new set of snow cover parameters for studying status and dynamics of the planetary snow cover extent. *Remote Sensing Letters*, 6(11), 844–853. <https://doi.org/10.1080/2150704X.2015.1084551>
- Dietz, J. A., Kuenzer, C., Gessner, U., Dech, S. (2012). Remote sensing of snow – a review of available methods. *International Journal of Remote Sensing*, 33(13), 4094–4134. <https://doi.org/10.1080/01431161.2011.640964>
- Dong, C., Menzel, L. (2016). Producing cloud-free MODIS snow cover products with conditional probability interpolation and meteorological data. *Remote Sensing of Environment*, 186, 439–451. <https://doi.org/10.1016/j.rse.2016.09.019>
- Dong, J., Walker, J. P., Houser, P. R. (2005). Factors affecting remotely sensed snow water equivalent uncertainty. *Remote Sensing of Environment*, 97(1), 68–82. <https://doi.org/10.1016/j.rse.2005.04.010>



- Draveniece, A., Briede, A., Rodinovs, V., Kļaviņš, M. (2007). Long-term changes of snow cover in Latvia as indicator of climate change. In M. Kļaviņš (Ed.), *Climate Change in Latvia* (pp. 73–86). Riga: University of Latvia Press.
- Draveniece, A. (2009). Detecting changes in winter seasons in Latvia: the role of arctic air masses. *Boreal Environment Research*, 14, 89–99.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Duguay, Y., Bernier, M. (2012). The use of RADARSAT-2 and TerraSAR-X data for the evaluation of snow characteristics in subarctic regions. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3556–3559. <https://doi.org/10.1109/IGARSS.2012.6350650>
- Dwyer, J., Schmidt, G. (2006). The MODIS reprojection tool. *Earth Science Satellite Remote Sensing: Data, Computational Processing, and Tools*, 2, 162–177. [https://doi.org/10.1007/978-3-540-37294-3\\_9](https://doi.org/10.1007/978-3-540-37294-3_9)
- ESA. (2015). SENTINEL-2 User Handbook. Žiūrēta 2020 m. spalio 4 d. [https://sentinel.esa.int/documents/247904/685211/Sentinel-2\\_User\\_Handbook](https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook)
- Foppa, N., Seiz, G. (2012). Inter-annual variations of snow days over Switzerland from 2000-2010 derived from MODIS satellite data. *The Cryosphere*, 6, 331–342. <https://doi.org/10.5194/tc-6-331-2012>
- Forman, B. A., Reichle, R. H., Rodell, M. (2012). Assimilation of terrestrial water storage from GRACE in a snow-dominated basin. *Water Resources Research*, 48(1), 1507. <https://doi.org/10.1029/2011WR011239>
- Foster, J. L., Sun, C., Walker, J. P., Kelly, R., Chang, A., Dong, J., Powell, H. (2005). Quantifying the uncertainty in passive microwave snow water equivalent observations. *Remote Sensing of Environment*, 94(2), 187–203. <https://doi.org/10.1016/j.rse.2004.09.012>
- Frazier, S. (2018). MODIS. Žiūrēta 2019 m. balandžio 11 d. <https://modis.gsfc.nasa.gov/about/>
- Friedl, M. A., Sulla-Menashe, D., Schneider, A., Ramankutty, N., Sibley, A., Huang, X. (2009). MODIS Collection 5 global land cover: Algorithm re-

- finements and characterization of new datasets. *Remote Sensing of Environment*, 114, 168–182. <https://doi.org/10.1016/j.rse.2009.08.016>
- Gafurov, A., Bárdossy, A. (2009). Cloud removal methodology from MODIS snow cover product. *Hydrology and Earth System Sciences*, 13, 1361–1373.
- Gailiušis, B., Jablonskis, J., Kovalenkoviėnė, M. (2001). Lietuvos upė: hidrografija ir nuotėkis. Kaunas: Lietuvos Energetikos institutas.
- Galvonaitė, A., Misiūnienė, M., Valiukas, D., Buitkuvienė, M. S. (2007). Lietuvos klimatas. Vilnius: Lietuvos hidrometeorologijos tarnyba.
- Galvonaitė, A., Valiukas, D., Kilpys, J., Kitrienė, Z., Misiūnienė, M. (2013). Lietuvos klimato atlasas. Vilnius: Lietuvos hidrometeorologijos tarnyba.
- Gao, Y., Xie, H., Yao, T., Xue, C. (2010). Integrated assessment on multi-temporal and multi-sensor combinations for reducing cloud obscuration of MODIS snow cover products of the Pacific Northwest USA. *Remote Sensing of Environment*, 114, 1662–1675. <https://doi.org/10.1016/j.rse.2010.02.017>
- Gečaitė, I., Rimkus, E. (2010). Sniego dangos režimas Lietuvoje. *Geografija*, 46(1), 17–24.
- Goldberg, M. D., Kilcoyne, H., Cikanek, H., Mehta, A. (2013). Joint Polar Satellite System: The United States next generation civilian polar-orbiting environmental satellite system. *Journal of Geophysical Research: Atmospheres*, 118(24), 13,463–13,475. <https://doi.org/10.1002/2013JD020389>
- Hagen, E., Feistel, R. (2005). Climatic turning points and regime shifts in the Baltic Sea region: the Baltic winter index (WIBIX) 1659–2002. *Boreal Environment Research*, 10, 211–224.
- Hall, D. K., Riggs, G. A. (2016). MODIS/Terra Snow Cover Daily L3 Global 500m SIN Grid, Version 6. National Snow and Ice Data Center. <https://nsidc.org/data/MOD10A1/versions/6>
- Hall, D. K., Riggs, G. A. (2007). Accuracy assessment of the MODIS snow products. *Hydrological Processes*, 21(12), 1534–1547. <https://doi.org/10.1002/hyp.6715>
- Hall, D. K., Riggs, G. A., Foster, J. L., Kumar, S. V. (2010). Development and evaluation of a cloud-gap-filled MODIS daily snow-cover product. *Remote Sensing of Environment*, 114, 496–503. <https://doi.org/10.1016/j.rse.2009.10.007>

- Hall, D. K., Riggs, G. A., Salomonson, V. V. (1995). Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data. *Remote Sensing of Environment*, 54(2), 127–140. [https://doi.org/10.1016/0034-4257\(95\)00137-P](https://doi.org/10.1016/0034-4257(95)00137-P)
- Hall, D. K., Riggs, G. A., Salomonson, V. V., Digirolamo, N. E., Bayr, K. J. (2002). MODIS snow-cover products. *Remote Sensing of Environment*, 83, 181–194. [https://doi.org/10.1016/S0034-4257\(02\)00095-0](https://doi.org/10.1016/S0034-4257(02)00095-0)
- Harris, I. C., Jones, P. D. (2017). Dataset Record: CRU TS4.01: Climatic Research Unit (CRU) Time-Series (TS) version 4.01 of high-resolution gridded data of month-by-month variation in climate (Jan. 1901- Dec. 2016). <https://doi.org/http://dx.doi.org/10.5285/58a8802721c94c66ae45c3baa4d814d0>
- He, G., Feng, X., Xiao, P., Xia, Z., Wang, Z., Chen, H., Li H., Guo, J. (2017). Dry and wet snow cover mapping in mountain areas using SAR and optical remote sensing data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(6), 2575–2588. <https://doi.org/10.1109/JSTARS.2017.2673409>
- Heilig, A., Wendleder, A., Schmitt, A., Mayer, C. (2019). Discriminating Wet Snow and Firn for Alpine Glaciers Using Sentinel-1 Data: A Case Study at Rofental, Austria. *Geosciences*, 9(2), 69. <https://doi.org/10.3390/geosciences9020069>
- Helsel, D. R., Hirsch, R. M., Ryberg, K. R., Archfield, S. A., Gilroy, E. J. (2020). Statistical Methods in Water Resources. In *U.S. Geological Survey Techniques and Methods: Vol. Book 4*. <https://doi.org/10.3133/TM4A3>
- Hou, J., Huang, C., Zhang, Y., Guo, J., Gu, J. (2019). Gap-Filling of MODIS Fractional Snow Cover Products via Non-Local Spatio-Temporal Filtering Based on Machine Learning Techniques. *Remote Sensing*, 11(1), 90. <https://doi.org/10.3390/rs11010090>
- HSAF. (2018). Product User Manual (PUM) for product H13 – SN-OBS-4 Snow water equivalent by MW radiometry. Žiūrēta 2018 m. vasario 25 d. <http://hsaf.meteoam.it/Products/Detail?prod=H13>
- Huang, X., Deng, J., Ma, X., Wang, Y., Feng, Q., Hao, X., Liang, T. (2016). Spatiotemporal dynamics of snow cover based on multi-source remote sensing data in China. *The Cryosphere*, 10, 2453–2463. <https://doi.org/10.5194/tc-10-2453-2016>

- Hüsler, F., Jonas, T., Riffler, M., Musial, J. P., Wunderle, S. (2014). A satellite-based snow cover climatology (1985–2011) for the European Alps derived from AVHRR data. *The Cryosphere*, 8(1), 73–90. <https://doi.org/10.5194/tc-8-73-2014>
- IPCC. (2013). Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change (V. B. and P. M. M. Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, Ed.). Cambridge: Cambridge University Press.
- Jaagus, J. (1997). The impact of climate change on the snow cover pattern in Estonia. *Climatic Change*, 36(1–2), 65–77. <https://doi.org/10.1023/a:1005304720412>
- Jaagus, J., Briede, A., Rimkus, E., Remm, K. (2009). Precipitation pattern in the Baltic countries under the influence of large-scale atmospheric circulation and local landscape factors. *International Journal of Climatology*, 30, 705–720. <https://doi.org/10.1002/joc.1929>
- Jaagus, J., Briede, A., Rimkus, E., Remm, K. (2014). Variability and trends in daily minimum and maximum temperatures and in the diurnal temperature range in Lithuania, Latvia and Estonia in 1951–2010. *Theoretical and Applied Climatology*, 118(1–2), 57–68. <https://doi.org/10.1007/s00704-013-1041-7>
- Jaagus, J., Briede, A., Rimkus, E., Sepp, M. (2016). Changes in precipitation regime in the Baltic countries in 1966–2015. *Theoretical and Applied Climatology*, 1–11. <https://doi.org/10.1007/s00704-016-1990-8>
- Jaagus, J., Sepp, M. (2016). Regime shift in winter climatic conditions and river runoff in Estonia since the winter 1988/89. Proceedings of Baltic Earth Conference 2016, 143–144.
- Jaagus, J., Sepp, M., Tamm, T., Järvet, A., Mõisja, K. (2017). Trends and regime shifts in climatic conditions and river runoff in Estonia during 1951–2015. *Earth System Dynamics*, 8, 963–976. <https://doi.org/10.5194/esd-8-963-2017>
- Jarvis, A., Reuter, H. I., Nelson, A., Guevara, E. (2008). Hole-filled SRTM for the globe Version 4, available from the CGIAR-CSI SRTM 90m Database. Žiūrēta 2018 m. spalio 4 d. <http://srtm.csi.cgiar.org>
- Keršytė, D., Rimkus, E. (2014). Žiemų tipai Baltijos jūros regione ir Lietuvoje. *Geografija*, 50(1), 1–10.

- Kilpys, J., Jukna, L., Stonevičius, E., Šimanauskienė, R., Bevainis, L. (2021). Žemės stebėjimas iš kosmoso. Vilnius: Vilniaus universiteto leidykla. <https://doi.org/10.15388/vup-book-0007>
- Kim, E., Lyu, C.-H. J., Anderson, K., Vincent Leslie, R., Blackwell, W. J. (2014). S-NPP ATMS instrument prelaunch and on-orbit performance evaluation. *Journal of Geophysical Research: Atmospheres*, 119(9), 5653–5670. <https://doi.org/10.1002/2013JD020483>
- Kim, M.-J., Weinman, J. A., Olson, W. S., Chang, D.-E., Skofronick-Jackson, G., Wang, J. R. (2008). A physical model to estimate snowfall over land using AMSU-B observations. *Journal of Geophysical Research*, 113(D9), D09201. <https://doi.org/10.1029/2007JD008589>
- Kim, Y., Kim, K.-Y., Kim, B.-M. (2013). Physical mechanisms of European winter snow cover variability and its relationship to the NAO. *Climate Dynamics*, 40(7–8), 1657–1669. <https://doi.org/10.1007/s00382-012-1365-5>
- Kirchner, P. B., Bales, R. C., Molotch, N. P., Flanagan, J., Guo, Q. (2014). LiDAR measurement of seasonal snow accumulation along an elevation gradient in the southern Sierra Nevada, California. *Hydrology and Earth System Sciences*, 18(10), 4261–4275. <https://doi.org/10.5194/hess-18-4261-2014>
- Kitaev, L., Kislov, A., Krenke, A., Razuvaev, V., Martuganov, R., Konstantinov, I. (2002). The snow cover characteristics of northern Eurasia and their relationship to climatic parameters. *Boreal Environment Research*, 7, 437–445.
- Klavins, M., Rodinov, V. (2010). Influence of large-scale atmospheric circulation on climate in Latvia. *Boreal Environment Research*, 15, 533–543.
- Klein, A. G., Hall, D. K., Riggs, G. A. (1998). Improving snow cover mapping in forests through the use of a canopy reflectance model. *Hydrological Processes*, 12(10–11), 1723–1744. [https://doi.org/10.1002/\(SICI\)1099-1085\(199808/09\)12:10/11<1723::AID-HYP691>3.0.CO;2-2](https://doi.org/10.1002/(SICI)1099-1085(199808/09)12:10/11<1723::AID-HYP691>3.0.CO;2-2)
- Kongoli, C., Meng, H., Dong, J., Ferraro, R. (2015). A snowfall detection algorithm over land utilizing high-frequency passive microwave measurements-Application to ATMS. *Journal of Geophysical Research: Atmospheres*, 120(5), 1918–1932. <https://doi.org/10.1002/2014JD022427>

- Kongoli, C., Meng, H., Dong, J., Ferraro, R. (2018). A hybrid snowfall detection method from satellite passive microwave measurements and global forecast weather models. *Quarterly Journal of the Royal Meteorological Society*, 144(S1), 120–132. <https://doi.org/10.1002/qj.3270>
- Kongoli, C., Pellegrino, P., Ferraro, R. R., Grody, N. C., Meng, H. (2003). A new snowfall detection algorithm over land using measurements from the Advanced Microwave Sounding Unit (AMSU). *Geophysical Research Letters*, 30(14). <https://doi.org/10.1029/2003GL017177>
- König, M., Winther, J.-G., Isaksson, E. (2001). Measuring snow and glacier ice properties from satellite. *Reviews of Geophysics*, 39(1), 1–27. <https://doi.org/10.1029/1999RG000076>
- Koskinen, J. T., Pulliainen, J. T., Hallikainen, M. T. (1997). The use of ers-1 sar data in snow melt monitoring. *IEEE Transactions on Geoscience and Remote Sensing*, 35(3), 601–610. <https://doi.org/10.1109/36.581975>
- Landauer, M., Sievänen, T., Neuvonen, M. (2015). Indicators of climate change vulnerability for winter recreation activities: a case of cross-country skiing in Finland. *Leisure/Loisir*, 39(3–4), 403–440. <https://doi.org/10.1080/14927713.2015.1122283>
- Lawrence, M. G. (2005). The relationship between relative humidity and the dewpoint temperature in moist air: A simple conversion and applications. *Bulletin of the American Meteorological Society*, 86(2), 225–233. <https://doi.org/10.1175/BAMS-86-2-225>
- LHMT. (2004). Meteorologinių stebėjimų nuostatai. Vilnius: Lietuvos hidrometeorologijos tarnyba.
- Li, H., He, Y., Hao, X., Che, T., Wang, J., Huang, X. (2015). Downscaling Snow Cover Fraction Data in Mountainous Regions Based on Simulated Inhomogeneous Snow Ablation. *Remote Sensing*, 7(7), 8995–9019. <https://doi.org/10.3390/rs70708995>
- Li, X., Shen, H., Zhang, L., Li, H. (2015). Sparse-based reconstruction of missing information in remote sensing images from spectral/temporal complementary information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 1–15. <https://doi.org/10.1016/J.ISPRSJPRS.2015.03.009>
- Lillesand, T., Kiefer, R. W., Chipman, J. (2015). Remote Sensing and Image Interpretation. 7th Edition. Hoboken, USA: Wiley.
- Liu, G., Seo, E.-K. (2013). Detecting snowfall over land by satellite high-frequency microwave observations: The lack of scattering signature and a

- statistical approach. *Journal of Geophysical Research: Atmospheres*, 118(3), 1376–1387. <https://doi.org/10.1002/jgrd.50172>
- Lizuma, L., Kļaviņš, M., Briede, A., Rodinovs, V. (2007). Long-term changes of air temperature in Latvia. In Kļaviņš Māris (Ed.), *Climate Change in Latvia*. Riga: UL Publishing House.
- López-Burgos, V., Gupta, H. V, Clark, M. (2013). Reducing cloud obscuration of MODIS snow cover area products by combining spatio-temporal techniques with a probability of snow approach. *Hydrology and Earth System Sciences*, 17, 1809–1823. <https://doi.org/10.5194/hess-17-1809-2013>
- Löw, A., Ludwig, R., Mauser, W. (2002). Land use dependent snow cover retrieval using multitemporal, multisensoral SAR-images to drive operational flood forecasting models. Proceedings of the EARSeL-LISSIG-Workshop Observing Our Cryosphere from Space.
- Luojus, K. P., Pulliainen, J. T., Metsämäki, S. J., Hallikainen, M. T. (2006). Accuracy assessment of SAR data-based snow-covered area estimation method. *IEEE Transactions on Geoscience and Remote Sensing*, 44(2), 277–286. <https://doi.org/10.1109/TGRS.2005.861414>
- Luojus, K. P., Pulliainen, J. T., Metsämäki, S. J., Hallikainen, M. T. (2007). Snow-covered area estimation using satellite radar wide-swath images. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4), 978–988. <https://doi.org/10.1109/TGRS.2006.888864>
- Luojus, K. P., Pulliainen, J. T., Metsämäki, S. J., Hallikainen, M. T. (2009). Enhanced SAR-based snow-covered area estimation method for boreal forest zone. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 922–935. <https://doi.org/10.1109/TGRS.2008.2006047>
- Malnes, E., Guneriussen, T. (2002). Mapping of snow covered area with Radarsat in Norway. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1, 683–685. <https://doi.org/10.1109/igarss.2002.1025145>
- Mankin, J. S., Viviroli, D., Singh, D., Hoekstra, A. Y., Diffenbaugh, N. S. (2015). The potential for snow to supply human water demand in the present and future. *Environmental Research Letters*, 10(11), 114016. <https://doi.org/10.1088/1748-9326/10/11/114016>
- Martin, S. (2013). An introduction to ocean remote sensing. In *An Introduction to Ocean Remote Sensing* (Vol. 9781107019386). <https://doi.org/10.1017/CBO9781139094368>

- Mätzler, C. (1994). Passive microwave signatures of landscapes in winter. *Meteorology and Atmospheric Physics*, 54(1–4), 241–260. <https://doi.org/10.1007/BF01030063>
- Meng, H., Dong, J., Ferraro, R., Yan, B., Zhao, L., Kongoli, C., ... Zavadsky, B. (2017). A 1DVAR-based snowfall rate retrieval algorithm for passive microwave radiometers. *Journal of Geophysical Research: Atmospheres*, 122(12), 6520–6540. <https://doi.org/10.1002/2016JD026325>
- Meromy, L., Molotch, N. P., Link, T. E., Fassnacht, S. R., Rice, R. (2013). Subgrid variability of snow water equivalent at operational snow stations in the western USA. *Hydrological Processes*, 27(17), 2383–2400. <https://doi.org/10.1002/hyp.9355>
- Metsämäki, S., Mattila, O.-P., Pulliainen, J., Niemi, K., Luojus, K., Böttcher, K. (2012). An optical reflectance model-based method for fractional snow cover mapping applicable to continental scale. *Remote Sensing of Environment*, 123, 508–521. <https://doi.org/10.1016/j.rse.2012.04.010>
- Metsämäki, S., Pulliainen, J., Salminen, M., Luojus, K., Wiesmann, A., Solberg, R., Böttcher, K., Hiltunen, M., Ripper, E. (2015). Introduction to GlobSnow Snow Extent products with considerations for accuracy assessment. *Remote Sensing of Environment*, 156, 96–108. <https://doi.org/10.1016/j.rse.2014.09.018>
- Metsämäki, S., Ripper, E., Mattila, O. P., Fernandes, R., Schwaizer, G., Luojus, K., Luojus, K., Nagler, T., Bojkov, B., Kern, M. (2017). Evaluation of Northern Hemisphere and regional snow extent products within ESA SnowPEX-project. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4246–4249. <https://doi.org/10.1109/IGARSS.2017.8127939>
- Mhawej, M., Faour, G., Fayad, A., Shaban, A. (2014). Towards an enhanced method to map snow cover areas and derive snow-water equivalent in Lebanon. *Journal of Hydrology*, 513, 274–282. <https://doi.org/10.1016/j.jhydrol.2014.03.058>
- Miro, M. E., Famiglietti, J. S. (2018). Downscaling GRACE Remote Sensing Datasets to High-Resolution Groundwater Storage Change Maps of California’s Central Valley. *Remote Sensing*, 10(1), 143. <https://doi.org/10.3390/rs10010143>
- Molotch, N. P., Fassnacht, S. R., Bales, R. C., Helfrich, S. R. (2004). Estimating the distribution of snow water equivalent and snow extent beneath



- cloud cover in the Salt–Verde River basin, Arizona. *Hydrological Processes*, 18(9), 1595–1611. <https://doi.org/10.1002/hyp.1408>
- Mouratidis, A., Ampatzidis, D. (2019). European Digital Elevation Model Validation against Extensive Global Navigation Satellite Systems Data and Comparison with SRTM DEM and ASTER GDEM in Central Macedonia (Greece). *ISPRS International Journal of Geo-Information*, 8(3), 108. <https://doi.org/10.3390/ijgi8030108>
- Muhuri, A., Ratha, D., Bhattacharya, A. (2017). Seasonal Snow Cover Change Detection over the Indian Himalayas Using Polarimetric SAR Images. *IEEE Geoscience and Remote Sensing Letters*, 14(12), 2340–2344. <https://doi.org/10.1109/LGRS.2017.2764123>
- Nagler, T., Rott, H. (2000). Retrieval of wet snow by means of multitemporal SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 38(2 I), 754–765. <https://doi.org/10.1109/36.842004>
- Nagler, T., Rott, H., Ripper, E., Bippus, G., Hetzenecker, M. (2016). Advancements for Snowmelt Monitoring by Means of Sentinel-1 SAR. *Remote Sensing*, 8(4), 348. <https://doi.org/10.3390/rs8040348>
- Natural Earth. (2009). Natural Earth » 1:110m Physical Vectors. Žiūrēta 2020 m. balandžio 22 d. <https://www.naturalearthdata.com/downloads/110m-physical-vectors/>
- Nijhawan, R., Das, J., Raman, B. (2019). A hybrid of deep learning and hand-crafted features based approach for snow cover mapping. *International Journal of Remote Sensing*, 40(2), 759–773. <https://doi.org/10.1080/01431161.2018.1519277>
- Niu, G.-Y., Seo, K.-W., Yang, Z.-L., Wilson, C., Su, H., Chen, J., Rodell, M. (2007). Retrieving snow mass from GRACE terrestrial water storage change with a land surface model. *Geophysical Research Letters*, 34(15), 15704. <https://doi.org/10.1029/2007GL030413>
- Nolin, A. W. (2011). Recent advances in remote sensing of seasonal snow. *Journal of Glaciology*, 56(200), 1141–1150. <https://doi.org/10.3189/002214311796406077>
- O’Gorman, P. A. (2014). Contrasting responses of mean and extreme snowfall to climate change. *Nature*, 512(7515), 416–418. <https://doi.org/10.1038/nature13625>

- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217–222. <https://doi.org/10.1080/01431160412331269698>
- Paloscia, S., Pettinato, S., Santi, E., Valt, M. (2017). COSMO-SkyMed Image Investigation of Snow Features in Alpine Environment. *Sensors*, 17(1), 84. <https://doi.org/10.3390/s17010084>
- Parajka, J., Blöschl, G. (2008). Spatio-temporal combination of MODIS images - potential for snow cover mapping. *Water Resources Research*, 44(3). <https://doi.org/10.1029/2007WR006204>
- Parajka, J., Pepe, M., Rampini, A., Rossi, S., Blöschl, G. (2010). A regional snow-line method for estimating snow cover from MODIS during cloud cover. *Journal of Hydrology*, 381, 203–212. <https://doi.org/10.1016/j.jhydrol.2009.11.042>
- Pipiraitė-Januškienė, S., Kilpys, J., Rimkus, E. (2018). Palydovinės informacijos apie sniego dangą trūkių užpildymo metodų vertinimas. *Geologija. Geografija*, 4(3). <https://doi.org/10.6001/geol-geogr.v4i3.3831>
- Pulliainen, J., Koskinen, J., Hallikainen, M. (2001). Compensation of forest canopy effects in the estimation of Snow Covered Area from SAR data. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2, 813–815. <https://doi.org/10.1109/igarss.2001.976645>
- Pulliainen, J. T., Grandell, J., Hallikainen, M. T. (1999). HUT snow emission model and its applicability to snow water equivalent retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 37(3), 1378–1390. <https://doi.org/10.1109/36.763302>
- Pulliainen, Jouni. (2006). Mapping of snow water equivalent and snow depth in boreal and sub-arctic zones by assimilating space-borne microwave radiometer data and ground-based observations. *Remote Sensing of Environment*, 101(2), 257–269. <https://doi.org/10.1016/j.rse.2006.01.002>
- Räisänen, J. (2008). Warmer climate: less or more snow? *Climate Dynamics*, 30(2–3), 307–319. <https://doi.org/10.1007/s00382-007-0289-y>
- Rasmus, S., Boelhouwers, J., Briede, A., Brown, I. A., Falarz, M., Ingvander, S., Jaagus, J., Kitaev, L., Mercer, A., Rimkus, E. (2015). Recent Change—Terrestrial Cryosphere. In *Second Assessment of Climate Change for the Baltic Sea Basin* (pp. 117–129). [https://doi.org/10.1007/978-3-319-16006-1\\_6](https://doi.org/10.1007/978-3-319-16006-1_6)

- Remm, K., Jaagus, J., Briede, A., Rimkus, E., Kelviste, T. (2011). Interpolative mapping of mean precipitation in the Baltic countries by using landscape characteristics. *Estonian Journal of Earth Sciences*, 60(3), 172–190. <https://doi.org/10.3176/earth.2011.3.05>
- Riggs, G. A., Hall, D. K., Román, M. O. (2016). *MODIS Snow Products Collection 6 User Guide*. [https://modis-snow-ice.gsfc.nasa.gov/uploads/C6\\_MODIS\\_Snow\\_User\\_Guide.pdf](https://modis-snow-ice.gsfc.nasa.gov/uploads/C6_MODIS_Snow_User_Guide.pdf)
- Rimkus, E., Kažys, J., Butkutė, S., Gečaitė, I. (2014). Snow cover variability in Lithuania over the last 50 years and its relationship with large-scale atmospheric circulation. *Boreal Environment Research*, 19, 337–351.
- Rodionov, S. N. (2004). A sequential algorithm for testing climate regime shifts. *Geophysical Research Letters*, 31, L09204. <https://doi.org/10.1029/2004GL019448>
- Roth, T. R., Nolin, A. W. (2017). Forest impacts on snow accumulation and ablation across an elevation gradient in a temperate montane environment. *Hydrology and Earth System Sciences*, 21, 5427–5442. <https://doi.org/10.5194/hess-21-5427-2017>
- Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1985). Learning Internal Representations by Error Propagation. In *Cognitive Science*. <https://apps.dtic.mil/dtic/tr/fulltext/u2/a164453.pdf>
- Saberi, N., Kelly, R., Flemming, M., Li, Q. (2020). Review of snow water equivalent retrieval methods using spaceborne passive microwave radiometry. *International Journal of Remote Sensing*, 41(3), 996–1018. <https://doi.org/10.1080/01431161.2019.1654144>
- Salomonson, V. V., Barnes, W. L., Maymon, P. W., Montgomery, H. E., Ostrow, H. (1989). MODIS: Advanced Facility Instrument for Studies of the Earth as a System. *IEEE Transactions on Geoscience and Remote Sensing*, 27(2), 145–153. <https://doi.org/10.1109/36.20292>
- Santi, E., Paloscia, S., Pettinato, S., De Gregorio, L., Cuzzo, G., Jacob, A., Notarnicola, C., Cigna, F., Tapete, D. (2020). SWE retrieval in Alpine areas with high-resolution COSMO-SkyMed X-band SAR data using Artificial Neural Networks and Support Vector Regression techniques. *33rd General Assembly and Scientific Symposium of the International Union of Radio Science, URSI GASS 2020*. <https://doi.org/10.23919/URSIGASS49373.2020.9232247>

- Savijärvi, H. I. (2012). Cold air outbreaks over high-latitude sea gulfs. *Tellus A: Dynamic Meteorology and Oceanography*, 64(1), 12244. <https://doi.org/10.3402/tellusa.v64i0.12244>
- Schellenberger, T., Ventura, B., Zebisch, M., Notarnicola, C. (2012). Wet snow cover mapping algorithm based on multitemporal COSMO-skyMed X-band SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(3), 1045–1053. <https://doi.org/10.1109/JSTARS.2012.2190720>
- Schwaizer, G., Ripper, E. (2017). Product User Manual. Snow Cover Extent Collection 500 M Continental Europe. [https://land.copernicus.eu/global/sites/cgls.vito.be/files/products/CGLOPS2\\_PUM\\_SCE500-CEURO-500m\\_V1\\_I1.02.pdf](https://land.copernicus.eu/global/sites/cgls.vito.be/files/products/CGLOPS2_PUM_SCE500-CEURO-500m_V1_I1.02.pdf)
- Serreze, M. C., Carse, F., Barry, R. G., Rogers, J. C. (1997). Icelandic low cyclone activity: Climatological features, linkages with the NAO, and relationships with recent changes in the Northern Hemisphere circulation. *Journal of Climate*, 10(3), 453–464. [https://doi.org/10.1175/1520-0442\(1997\)010<0453:ILCACF>2.0.CO;2](https://doi.org/10.1175/1520-0442(1997)010<0453:ILCACF>2.0.CO;2)
- Sharifi, E., Saghafian, B., Steinacker, R. (2019). Downscaling Satellite Precipitation Estimates With Multiple Linear Regression, Artificial Neural Networks, and Spline Interpolation Techniques. *Journal of Geophysical Research: Atmospheres*, 124(2), 789–805. <https://doi.org/10.1029/2018JD028795>
- Shi, Jiancheng, Dozier, J. (1995). Inferring Snow Wetness Using C-Band Data from SIR-C's Polarimetric Synthetic Aperture Radar. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 905–914. <https://doi.org/10.1109/36.406676>
- Shi, JianCheng, Xiong, C., Jiang, L. (2016). Review of snow water equivalent microwave remote sensing. *Science China Earth Sciences*, 59(4), 731–745. <https://doi.org/10.1007/s11430-015-5225-0>
- Singh, G., Venkataraman, G., Rao, Y. S., Kumar, V., Snehmani. (2008). In-sar coherence measurement techniques for snow cover mapping in himalayan region. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 4(1). <https://doi.org/10.1109/IGARSS.2008.4779913>
- Sinnott, R. W. (1984). Virtues of the Haversine. *Sky and Telescope*, 68(2), 158.

- Skofronick-Jackson, G. M., Weinman, J. A., Kim, M. J., Chang, D. E. (2004). A physical model to determine snowfall over land by microwave radiometry. *IEEE Transactions on Geoscience and Remote Sensing*, 42(5), 1047–1058. <https://doi.org/10.1109/TGRS.2004.825585>
- Stephens, G. L., Vane, D. G., Tanelli, S., Im, E., Durden, S., Rokey, M., Reinke, D., Partain, P., Mace, G. G., Austin, R., L'Ecuyer, T., Haynes, J., Lebsock, M., Lebsock, M., Waliser, D., Wu, D., Kay, J., Gettelman, A., Wang, Z., Marchand, R. (2008). CloudSat mission: Performance and early science after the first year of operation. *Journal of Geophysical Research*, 113(8), D00A18. <https://doi.org/10.1029/2008JD009982>
- Stillinger, T., Roberts, D. A., Collar, N. M., Dozier, J. (2019). Cloud Masking for Landsat 8 and MODIS Terra Over Snow-Covered Terrain: Error Analysis and Spectral Similarity Between Snow and Cloud. *Water Resources Research*, 55(7), 6169–6184. <https://doi.org/10.1029/2019WR024932>
- Stonevičius, E., Valiuškevičius, G., Rimkus, E., Kažys, J. (2014). Climate induced changes of Lithuanian rivers runoff in 1960–2009. *Water Resources*, 41(5), 592–603. <https://doi.org/10.1134/S0097807814050133>
- Stonevičius, Edvinas, Rimkus, E., Štaras, A., Kažys, J., Valiuškevičius, G. (2017). Climate change impact on the Nemunas River basin hydrology in the 21st century. *Boreal Environment Research*, 22, 49–65.
- Strozzi, T., Wegmuller, U., Matzler, C. (1999). Mapping wet snowcovers with SAR interferometry. *International Journal of Remote Sensing*, 20(12), 2395–2403. <https://doi.org/10.1080/014311699212083>
- Strozzi, T., Wiesmann, A., Mätzler, C. (1997). Active microwave signatures of snow covers at 5.3 and 35 GHz. *Radio Science*, 32(2), 479–495. <https://doi.org/10.1029/96RS03777>
- Szwed, M., Pińskwar, I., Kundzewicz, Z. W., Graczyk, D., Mezghani, A. (2017). Changes of snow cover in Poland. *Acta Geophysica*, 65(1), 65–76. <https://doi.org/10.1007/s11600-017-0007-z>
- Takala, M., Luojus, K., Pulliainen, J., Derksen, C., Lemmetyinen, J., Kärnä, J.-P., Koskinen, J., Bojkov, B. (2011). Estimating northern hemisphere snow water equivalent for climate research through assimilation of spaceborne radiometer data and ground-based measurements. *Remote Sensing of Environment*, 115(12), 3517–3529. <https://doi.org/10.1016/j.rse.2011.08.014>

- Tao, Y., Gao, X., Hsu, K., Sorooshian, S., Ihler, A. (2016). A deep neural network modeling framework to reduce bias in satellite precipitation products. *Journal of Hydrometeorology*, 17(3), 931–945. <https://doi.org/10.1175/JHM-D-15-0075.1>
- Tedesco, M. (ed.) (2015). *Remote Sensing of the Cryosphere*. Chichester, UK: Wiley Balckwell. <https://doi.org/10.1002/9781118368909>
- Tekeli, A. E., Akyürek, Z., Arda Orman, A., Ensoy, A., Nal Orman, A. (2005). Using MODIS snow cover maps in modeling snowmelt runoff process in the eastern part of Turkey. *Remote Sensing of Environment*, 97, 216–230. <https://doi.org/10.1016/j.rse.2005.03.013>
- Thakur, P. K., Garg, P. K., Aggarwal, S. P., Garg, R. D., Mani, S. (2013). Snow Cover Area Mapping Using Synthetic Aperture Radar in Manali Watershed of Beas River in the Northwest Himalayas. *Journal of the Indian Society of Remote Sensing*, 41(4), 933–945. <https://doi.org/10.1007/S12524-012-0236-1>
- The BACC II Author Team (eds). (2015). *Second Assessment of Climate Change for the Baltic Sea Basin*. Heidelberg: Springer. <https://doi.org/10.1007/978-3-319-16006-1>
- Tong, J., Déry, S. J., Jackson, P. L. (2009). Topographic control of snow distribution in an alpine watershed of western Canada inferred from spatially-filtered MODIS snow products. *Hydrology and Earth System Sciences*, 13(3), 319–326. <https://doi.org/10.5194/hess-13-319-2009>
- Tooming, H., Kadaja, J. (2006). *Handbook of Estonian Snow Cover* (A. Kallis, Ed.). Tallin: Estonian Meteorological and Hydrological Institute.
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B. Ö., Floury, N., Brown, M., Traver, I. N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., Rostan, F. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- Trigo, I. F., Dacamara, C. C., Viterbo, P., Roujean, J.-L., Olesen, F., Barroso, C., Camacho-de-Coca, F., Carrer, D., Freitas, S. C., García-Haro, J., Geiger, B., Gellens-Meulenberghs, F., Ghilain, N., Meliá, J., Pessanha, L., Siljamo, N., Arboleda, A. (2011). The Satellite Application Facility for Land Surface Analysis. *International Journal of Remote Sensing*, 32(10), 2725–2744. <https://doi.org/10.1080/01431161003743199>

- Tsai, Y. L. S., Dietz, A., Oppelt, N., Kuenzer, C. (2019a). Remote sensing of snow cover using spaceborne SAR: A review. *Remote Sensing*, 11(12), 1456. <https://doi.org/10.3390/rs11121456>
- Tsai, Y. L. S., Dietz, A., Oppelt, N., Kuenzer, C. (2019b). Wet and dry snow detection using sentinel-1 SAR data for mountainous areas with a machine learning technique. *Remote Sensing*, 11(8). <https://doi.org/10.3390/rs11080988>
- Varade, D., Dikshit, O., Manickam, S. (2019). Dry/wet snow mapping based on the synergistic use of dual polarimetric SAR and multispectral data. *Journal of Mountain Science*, 16(6), 1435–1451. <https://doi.org/10.1007/s11629-019-5373-3>
- Varade, D., Singh, G., Dikshit, O., Manickam, S. (2020). Identification of Snow Using Fully Polarimetric SAR Data Based On Entropy and Anisotropy. *Water Resources Research*, 56(2). <https://doi.org/10.1029/2019WR025449>
- Varhola, A., Coops, N. C., Weiler, M., Moore, R. D. (2010). Forest canopy effects on snow accumulation and ablation: An integrative review of empirical results. *Journal of Hydrology*, 392(3–4), 219–233. <https://doi.org/10.1016/j.jhydrol.2010.08.009>
- Vaughan, D. G., Comiso, J. C., Allison, I., Carrasco, J., Kaser, G., Kwok, R., Mote, P., Murray, T., Paul, F., Ren, J., Rignot, E., Solomina, O., Steffen, K., Zhang, T., Stocker, T., Qin, D., Plattner, G.-K., Tignor, M., Allen, S. K., Boschung, J. Nauels, A., Xia, Y., Bex, V., Midgley, P. M. (2013). Observations: Cryosphere. In *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press.
- Wang, W., Huang, X., Deng, J., Xie, H., Liang, T. (2015). Spatio-temporal change of snow cover and its response to climate over the Tibetan Plateau based on an improved daily cloud-free snow cover product. *Remote Sensing*, 7(1), 169–194. <https://doi.org/10.3390/rs70100169>
- Wang, X., Xie, H. (2009). New methods for studying the spatiotemporal variation of snow cover based on combination products of MODIS Terra and Aqua. *Journal of Hydrology*, 371, 192–200. <https://doi.org/10.1016/j.jhydrol.2009.03.028>
- Wang, X., Xie, H., Liang, T. (2008). Evaluation of MODIS snow cover and cloud mask and its application in Northern Xinjiang, China. *Remote*

- Sensing of Environment*, 112, 1497–1513. <https://doi.org/10.1016/j.rse.2007.05.016>
- Wang, Y., Liu, G., Seo, E. K., Fu, Y. (2013). Liquid water in snowing clouds: Implications for satellite remote sensing of snowfall. *Atmospheric Research*. <https://doi.org/10.1016/j.atmosres.2012.06.008>
- Wegmann, M., Orsolini, Y., Dutra, E., Bulygina, O., Sterin, A., Brönnimann, S. (2017). Eurasian snow depth in long-term climate reanalyses. *The Cryosphere*, 11, 923–935. <https://doi.org/10.5194/tc-11-923-2017>
- Weng, F., Sun, N., Qiu, S., NOAA JPSS Program Office (2011). NOAA JPSS Advanced Technology Microwave Sounder (ATMS) Sensor Data Record (SDR) from IDPS. NOAA National Centers for Environmental Information. <https://doi.org/10.7289/V5BR8Q7N>
- Weng, F., Zhao, L., Ferraro, R. R., Poe, G., Li, X., Grody, N. C. (2003). Advanced microwave sounding unit cloud and precipitation algorithms. *Radio Science*, 38(4), 1–13. <https://doi.org/10.1029/2002RS002679>
- Wilby, R. L., Charles, S. P., Zorita, E., Timbal, B., Whetton, P., Mearns, L. O. (2004). Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods Document history. [http://www.ipcc-data.org/guidelines/dgm\\_no2\\_v1\\_09\\_2004.pdf](http://www.ipcc-data.org/guidelines/dgm_no2_v1_09_2004.pdf)
- Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences*. Elsevier/Academic Press.
- WMO. (2016). The Global Observing System for Climate: Implementation Needs GCOS-200. [http://unfccc.int/files/science/workstreams/systematic\\_observation/application/pdf/gcos\\_ip\\_10oct2016.pdf](http://unfccc.int/files/science/workstreams/systematic_observation/application/pdf/gcos_ip_10oct2016.pdf)
- Xie, H., Wang, X., Liang, T. (2009). Development and assessment of combined Terra and Aqua snow cover products in Colorado Plateau, USA and northern Xinjiang, China. *Journal of Applied Remote Sensing*, 3(1), 033559. <https://doi.org/10.1117/1.3265996>
- Yang, J., Li, C., Li, L., Ding, J., Zhang, R., Han, T., Liu, Y. (2020). Automatic detection of regional snow avalanches with scattering and interference of C-band SAR data. *Remote Sensing*, 12(17), 2781. <https://doi.org/10.3390/RS12172781>
- Ye, K., Lau, N.-C. (2016). Influences of surface air temperature and atmospheric circulation on winter snow cover variability over Europe. *International Journal of Climatology*, 37, 2606–2619. <https://doi.org/10.1002/joc.4868>



- You, Y., Meng, H., Dong, J., Rudlosky, S. (2019). Time-Lag Correlation Between Passive Microwave Measurements and Surface Precipitation and Its Impact on Precipitation Retrieval Evaluation. *Geophysical Research Letters*, 46(14), 8415–8423. <https://doi.org/10.1029/2019gl083426>
- Zhang, Y.-F., Hoar, T. J., Yang, Z.-L., Anderson, J. L., Toure, A. M., Rodell, M. (2014). Assimilation of MODIS snow cover through the Data Assimilation Research Testbed and the Community Land Model version 4. *Journal of Geophysical Research: Atmospheres*, 119(12), 7091–7103. <https://doi.org/10.1002/2013JD021329>
- Zhao, H., Fernandes, R. (2009). Daily snow cover estimation from Advanced Very High Resolution Radiometer Polar Pathfinder data over Northern Hemisphere land surfaces during 1982–2004. *Journal of Geophysical Research*, 114(D5), D05113. <https://doi.org/10.1029/2008JD011272>
- Zhong, X., Zhang, T., Wang, K. (2014). Snow density climatology across the former USSR. *The Cryosphere*, 8(2), 785–799. <https://doi.org/10.5194/tc-8-785-2014>
- Zhong, Xinyue, Zhang, T., Kang, S., Wang, K., Zheng, L., Hu, Y., Wang, H. (2018). Spatiotemporal variability of snow depth across the Eurasian continent from 1966 to 2012. *The Cryosphere*, 12(1), 227–245. <https://doi.org/10.5194/tc-12-227-2018>
- Zhu, L., Zhang, Y., Wang, J., Tian, W., Liu, Q., Ma, G., Kan, X., Chu, Y. (2021). Downscaling Snow Depth Mapping by Fusion of Microwave and Optical Remote-Sensing Data Based on Deep Learning. *Remote Sensing*, 13(4), 584. <https://doi.org/10.3390/rs13040584>

## PRIEDAI

**1 priedas.** Tyrime naudotų meteorologinių stočių Baltijos valstybėse sąrašas. Šiame sąrašė pateiktos tik tos stotys ir tie rodikliai, kurie buvo naudoti tyrime. Sąrašas neatspindi visos stočių matavimo programos.

Stotis	Valstybė	Platuma	Ilguma	Aukštis, m	Matavimai			
					Oro T-ra	Kritu- liai	Sniego storis	VAS
Ainazi	LV	57,87	24,37	6	+	+	+	
Altja	EE	59,58	26,11	5				+
Aluksne	LV	57,44	27,04	197	+	+	+	+
Bauska	LV	56,38	24,22	31	+	+	+	
Birštonas	LT	54,60	24,03	47				+
Biržai	LT	56,20	24,77	56	+	+	+	+
Daugavpils	LV	55,87	26,62	98	+	+	+	+
Dobele	LV	56,62	23,32	42	+	+	+	+
Dotnuva	LT	55,40	23,87	69	+	+	+	+
Dūkštas	LT	55,52	26,32	164				+
Griskani	LV	56,52	27,37	157	+	+	+	+
Gulbene	LV	57,13	26,72	141				+
Jelgava	LV	56,68	23,74	5	+	+	+	
Jogeva	EE	58,75	26,42	70	+	+	+	+
Johvi	EE	59,35	27,40	73	+	+	+	+
Kaunas	LV	54,88	23,83	73	+	+	+	+
Kybartai	LT	54,63	22,78	57	+	+	+	+
Kihnu	EE	58,10	23,97	3	+	+	+	
Klaipėda	LT	55,73	21,07	4	+	+	+	
Kolka	LV	57,75	22,59	4	+	+	+	+
Koodu	EE	58,57	24,21	21				+
Kuldiga	LV	56,99	21,96	11	+	+	+	
Kunda	EE	59,52	26,55	2	+	+	+	
Kuusiku	EE	58,98	24,73	53	+	+	+	+
Laane-Nigula	EE	58,95	23,81	24	+	+	+	+

Stotis	Valstybė	Platuma	Ilguma	Aukštis, m	Matavimai			
					Oro T-ra	Kritu- liai	Sniego storis	VAS
Laukuva	LT	55,62	22,22	167	+	+	+	+
Lazdijai	LT	54,23	23,52	125	+	+	+	+
Liepāja	LV	56,48	21,02	4	+	+	+	
Lielpeci	LV	56,80	24,72	45				+
Lubana	LV	56,90	26,72	95	+	+	+	+
Massumoisa	EE	58,28	25,71	99				+
Narva	EE	59,39	28,11	28	+	+	+	+
Nida	LT	55,32	21,02	17	+	+	+	
Pakri	EE	59,38	24,05	26	+	+	+	
Panevėžys	LT	55,75	24,38	55	+	+	+	+
Parnu	EE	58,25	24,28	14	+	+	+	
Piedruja	LV	55,80	27,45	113				+
Palvinas	LV	56,62	25,73	76				+
Priekuli	LV	57,32	25,34	122	+	+	+	+
Raseiniai	LT	55,38	23,12	103	+	+	+	+
Rīga	LV	56,95	24,12	6	+	+	+	
Ristna	EE	58,92	22,07	7	+	+	+	
Rucava	LV	56,16	21,17	68	+	+	+	+
Rujiena	EE	57,89	25,37	68	+	+	+	
Šiauliai	LT	55,93	23,32	108	+	+	+	+
Sigulda	LV	57,17	24,85	100				+
Sili	LV	56,34	26,35	99				+
Šilutė	LT	55,35	21,47	4	+	+	+	+
Skriveri	LV	56,64	25,13	80	+	+	+	+
Sorve	EE	57,92	22,07	2	+	+	+	
Stende	LT	57,18	22,55	80	+	+	+	+
Tallinn	EE	59,40	24,60	33	+	+	+	
Tartu	EE	58,30	26,73	62	+	+	+	+
Telšiai	LT	55,97	22,25	153	+	+	+	+
Tiirikoja	EE	58,87	26,95	32	+	+	+	+

Stotis	Valstybė	Platuma	Ilguma	Aukštis, m	Matavimai			
					Oro T-ra	Kritu- liai	Sniego storis	VAS
Tooma	EE	58,87	26,27	89				+
Tudu	EE	59,18	26,85	74				+
Tuulemae	EE	57,63	27,10	236				+
Turi	EE	58,82	25,42	60	+	+	+	+
Ukmerge	LT	55,25	24,77	72	+	+	+	+
Utena	LT	55,53	25,60	120	+	+	+	+
Vaike-Maarja	EE	59,14	26,23	121	+	+	+	+
Valga	EE	57,78	26,03	65	+	+	+	+
Varėna	LT	54,24	24,55	109	+	+	+	+
Viljandi	EE	58,38	25,60	86	+	+	+	+
Vilnius	LT	54,63	25,28	190	+	+	+	+
Vilsandi	EE	58,38	21,82	6	+	+	+	
Virtsu	EE	58,57	23,52	2	+	+	+	
Voru	EE	57,85	27,02	82	+	+	+	+
Zilani	LV	56,52	25,92	107	+	+	+	
Zoseni	LV	57,14	25,91	188	+	+	+	+
Elniakampis	LT	54,79	25,00	105				+

**2 priedas.** Detali informacija apie ATMS spektrines juostas ir jų pagrindinės taikymo sritys.

Nr.	Dažnis (GHz)	Ekvivalentinė triukšmo temperatūra (NEΔT), °K	Erdvinė skiriamoji geba ties nadyru (km)	Pagrindinė taikymo sritis
1	23,80	0,28	75	Atmosferos skaidrumo langas, tinkantis paviršiaus temperatūrai fiksuoti
2	31,40	0,35	75	
3	50,30	0,42	33	Dažniai, kur spinduliuotę aktyviai sugeria deguonis Tinka troposferos temperatūros profiliams nustatyti
4	51,76	0,31	33	
5	52,80	0,32	33	
6	53,596±0,115	0,35	33	
7	54,40	0,32	33	
8	54,94	0,32	33	
9	55,50	0,35	33	Tinka troposferos temperatūros profiliams nustatyti
10	$f_0 = 57,290334$	0,49	33	
11	$f_0 \pm 0,217$	0,67	33	
12	$f_0 \pm 0,3222 \pm 0,048$	0,70	33	
13	$f_0 \pm 0,3222 \pm 0,022$	1,06	33	
14	$f_0 \pm 0,3222 \pm 0,010$	1,45	33	Tinka stratosferos temperatūrai nustatyti
15	$f_0 \pm 0,3222 \pm 0,045$	2,40	33	
16	88,2	0,29	33	
17	165,6	0,44	15	Atmosferos skaidrumo langas
18	$183,31 \pm 7,0$	0,34	15	Tinka vandens garų profiliams nustatyti
19	$183,31 \pm 4,5$	0,39	15	
20	$183,31 \pm 3,0$	0,48	15	
21	$183,31 \pm 1,8$	0,49	15	
22	$183,31 \pm 1,0$	0,62	15	

## PADEKA

Pirmiausia norėčiau padėkoti savo disertacijos darbo vadovui, prof. dr. Egidijui Rimkui, už palaikymą renkantis doktorantūros darbo temą ir vykdant tyrimus. Esu dėkingas už visus pokalbius doktorantūros metu, kurie dažniausiai būdavo ne apie mokslą, tačiau jie padėjo palaikyti gerą ir draugišką atmosferą. Manau, kad gera darbo vadovo savybė yra humoro jausmas, ir man labai pasisekė, kad mano ir prof. E. Rimkaus humoro jausmas sutapo.

Taip pat labai norėčiau padėkoti savo žmonai Kristinai už palaikymą. Disertacijos tyrimai, projektų ir publikacijų rengimas dažnai reikšdavo neapibrėžtas darbo valandas ir maža indėlių į šeimos biudžetą. Ačiū Kristinai už parodytą meilę ir supratingumą, kad mokslas tai ne tik darbas – tai tam tikras gyvenimo būdas.

Doktorantūros metu atlikti moksliniai tyrimai būtų neįmanomi be duomenų, todėl esu dėkingas Lietuvos hidrometeorologijos tarnybai už suteiktus sniego dangos stebėjimų duomenis Lietuvoje. Svarbiu doktorantūros akcentu tapo stažuotė JAV Merilando universiteto Žemės sistemų palydovinių tyrimų institute (CISESS). Už šią galimybę esu labai dėkingas Baltijos-Amerikos laisvės fondui (angl. *Baltic-American Freedom Foundation*), kuris suteikė finansavimą ir visokeriopą pagalbą tiek ruošiantis, tiek grįžus iš stažuotės. Tai buvo neįkainojama patirtis.

Esu dėkingas doc. dr. Jūratei Sužiedelytei Visockienei (Vilnius Tech), dr. Juliiui Taminskui (Gamtos tyrimų centras) ir doc. dr. Gintautui Stankūnavičiui (VU Geomokslų institutas), kurie skyrė laiko ir perskaitė disertacijos juodraščių. Jų komentarai padėjo įvertinti silpnąsias ir stipriąsias disertacijos vietas, o pastabos leido pataisyti klaidas ir patobulinti galutinį tekstą. Taip pat noriu padėkoti VU Hidrologijos ir klimatologijos katedros darbuotojams už diskusijas, pokalbius ir visokeriopą paramą doktorantūros ir ankstesnių studijų metu: prof. dr. A. Bukančiui, doc. dr. J. Kažiui, S. Pipiraitei-Januškienei, doc. dr. D. Pupieniui, doc. dr. G. Stankūnavičiui, doc. dr. E. Stonevičiui, prof. dr. G. Valiuškevičiui ir L. Valiuškevičienei.

Ačiū visiems skaitantiems ir vartantiems šį darbą.

## PUBLIKACIJŲ SĄRAŠAS

### **Disertacijos tema parengtos publikacijos (Web of Science):**

- Kilpys J., Pipiraitė-Januškienė S., Rimkus E. (2020). Snow climatology in Lithuania based on the cloud-free moderate resolution imaging spectroradiometer snow cover product. *International Journal of Climatology*, 1–17. <https://doi.org/10.1002/joc.6483>
- Rimkus E., Briede A., Jaagus J., Stonevicius E., Kilpys J., Viru B. (2018). Snow-cover regime in Lithuania, Latvia and Estonia and its relationship to climatic and geographical factors in 1961–2015. *Boreal Environment Research*, 23, 193-208.

### **Kitos publikacijos:**

- Kilpys J., Jukna L., Stonevičius E., Šimanauskienė R., Bevainis L. (2021). *Žemės stebėjimas iš kosmoso*. Vilnius: Vilniaus universiteto leidykla, <https://doi.org/10.15388/vup-book-0007>
- Pipiraitė-Januškienė S., J. Kilpys, Rimkus E. (2018). Palydovinės informacijos apie sniego dangą trūkių užpildymo metodų vertinimas. *Geologija. Geografija*, 4(3), 103-112.
- Rimkus E., Stonevičius E., Kilpys J., Mačiulytė V., Valiukas D. (2017). Drought identification in the Eastern Baltic region using NDVI. *Earth System Dynamics*, 8(3), 627-637.

Vilniaus universiteto leidykla  
Saulėtekio al. 9, III rūmai, LT-10222 Vilnius  
El. p. [info@leidykla.vu.lt](mailto:info@leidykla.vu.lt), [www.leidykla.vu.lt](http://www.leidykla.vu.lt)  
Tiražas 20 egz.