AgroSens projekto rezultatai: skaitmeninių jutiklių integravimas dirvožemio savybių prognozavimui

LIETUVOS AGRARINIŲ IR MIŠKŲ MOKSLŲ CENTRAS

dr. Renaldas Žydelis, dokt. A. Kavaliauskas, dr. A. Kazlauskaitė-Jadzevičė, S. Pranaitienė

LMT Lietuvos mokslo taryba

Finansavimas: Šį tyrimą finansavo Lietuvos mokslo taryba (LMTLT), sutarties Nr. S-MIP-24-106

2026

Skaitmeninių jutiklių integravimas dirvožemio savybių prognozavimui Lietuvos agroklimatinėse zonose (AgroSens)

Projekto tikslas – integruoti skaitmeninius dirvožemio žemėlapius, bepiločių orlaivių (UAV) vaizdus ir dirvožemio jutiklių duomenis, taikant mašininio mokymosi (ML) metodus, siekiant tiksliau prognozuoti dirvožemio rodiklius, pavyzdžiui, organinės anglies kiekį ir anglies bei azoto (C/N) santykį.

Projekte derinami laboratorinių tyrimų rezultatai, bepiločių orlaivių (UAV) vaizdai ir kitų dirvožemio jutiklių duomenys.

Projekto vykdytojai: Renaldas Žydelis, Ardas Kavaliauskas, Asta Kazlauskaitė-Jadzevičė ir Simona Pranaitienė.

Vykdymo laikotarpis: 2024–2027 m.
Sutarties Nr.: S-MIP-24-106

LMT
Lietuvos mokslo taryba

Įvadas (1)

- ES dirvožemių stebėsenos duomenys parodė, kad 62 % dirvožemių yra pažeisti (EUSO, 2026), todėl siekiama iki 2050 m. užtikrinti sveiką dirvožemį (ES Dirvožemio direktyva).

- Lietuvoje vykdytos skirtingos dirvožemio stebėsenos programos, tačiau dėl nevienodų metodikų ir riboto duomenų prieinamumo informacija apie dirvožemio būklę išlieka fragmentuota. Todėl trūksta duomenų apie pažeistus Lietuvos dirvožemius.

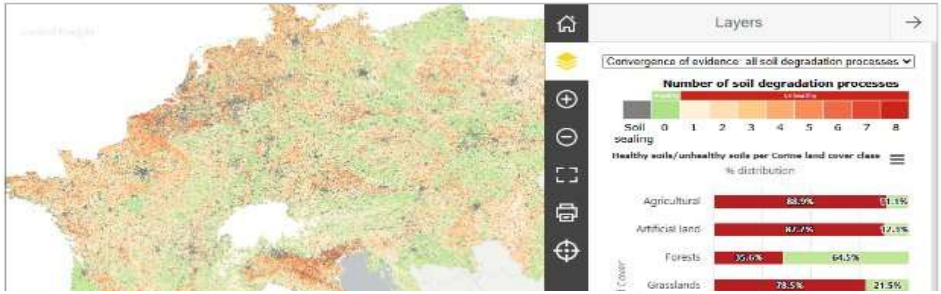
- Šiuo metu (2025–2027 m.) vykdomas nacionalinis dirvožemio stebėsenos projektas. Pagal Europos direktyvos reikalavimus kuriamas ir testuojamas reprezentatyvus Lietuvos stebėsenos tinklas. Projekto metu mėginiai renkami 1 387 taškuose visoje Lietuvoje, apimant skirtingus dirvožemio rajonus ir žemėnaudas. Gavus tyrimų rezultatus, bus galima išsamiau įvertinti Lietuvos dirvožemių būklę ir pažeidimus.

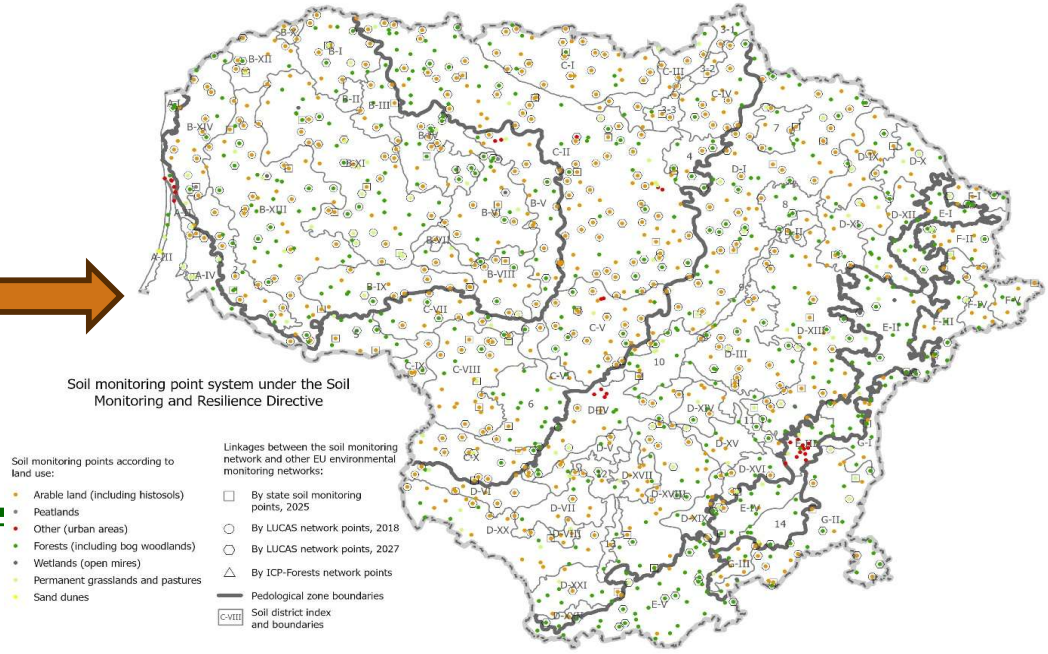


Soil Degradation in the EU

The **speedometer** indicates the proportion of land likely to be affected by one or more soil degradation processes or by soil sealing in the EU.

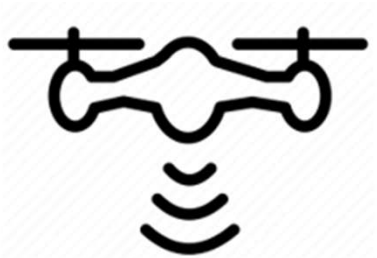
It is based on the **convergence of evidence map** below. This map shows where scientific evidence converges to indicate areas that are likely to be affected by soil degradation processes. As such, the map provides an indication of where unhealthy soils may be located in the EU.





Įvadas (2)





Šiuo metu sparčiai didėja nuotolinių metodų ir priemonių taikymo poreikis dirvožemio aktualių savybių (cheminių, fizikinių ir kt.) nustatymui ir jų pokyčio periodiniam stebėjimui.

Nuotoliniu būdu gauti dirvožemio duomenys naudingi tiksliajai žemdirbystei, dirvožemio žemėlapiams rengti.

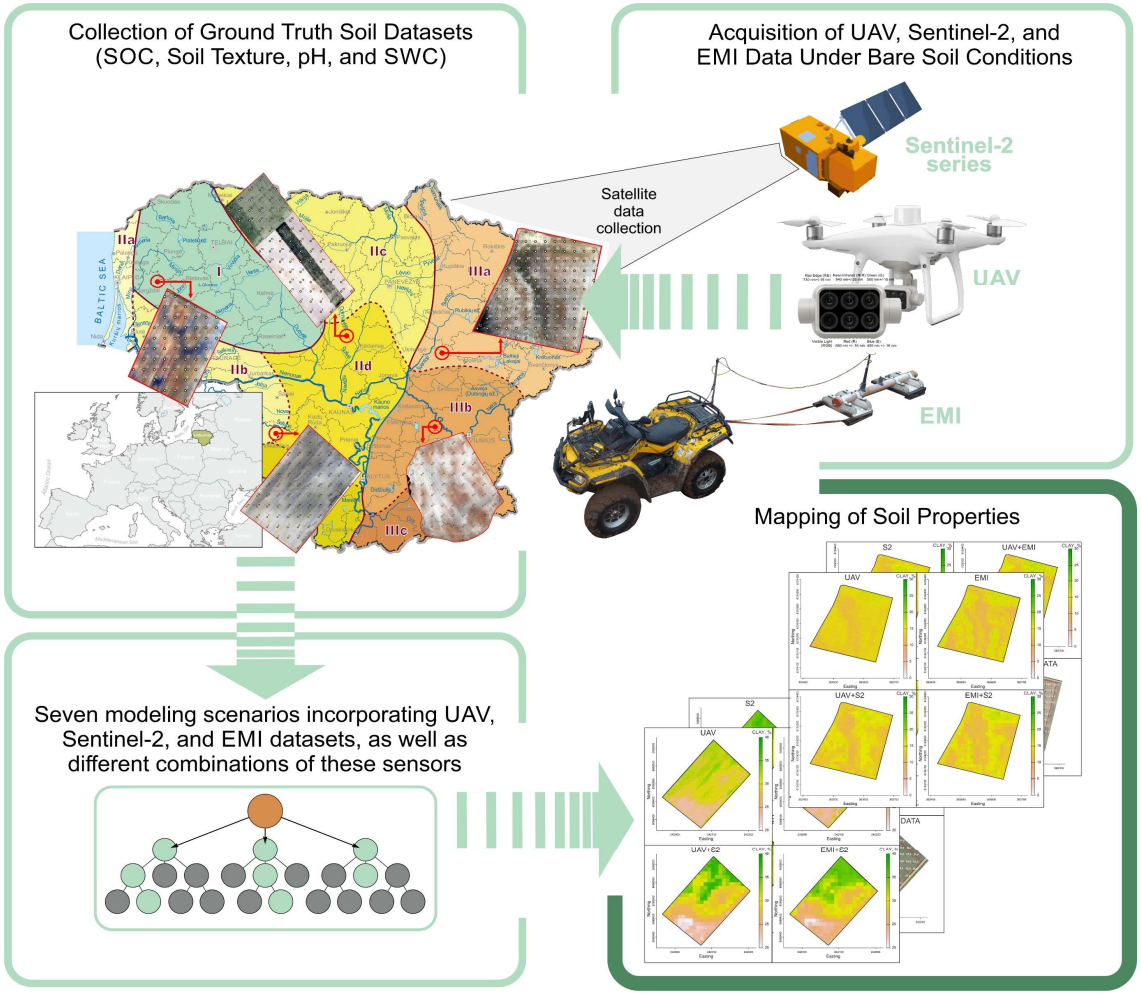
Nuotoliniu būdu gauti duomenys gali būti naudojami, prognozuojant dirvožemio savybių rodiklius, tačiau įvairios aplinkos sąlygos gali trikdyti prognozių tikslumą.

Tradiciniai dirvožemio tyrimo metodai yra brangūs, imlūs laikui ir ribotai atspindi erdvinį kintamumą, todėl jie turėtų būti derinami su nuotoliniais duomenimis.



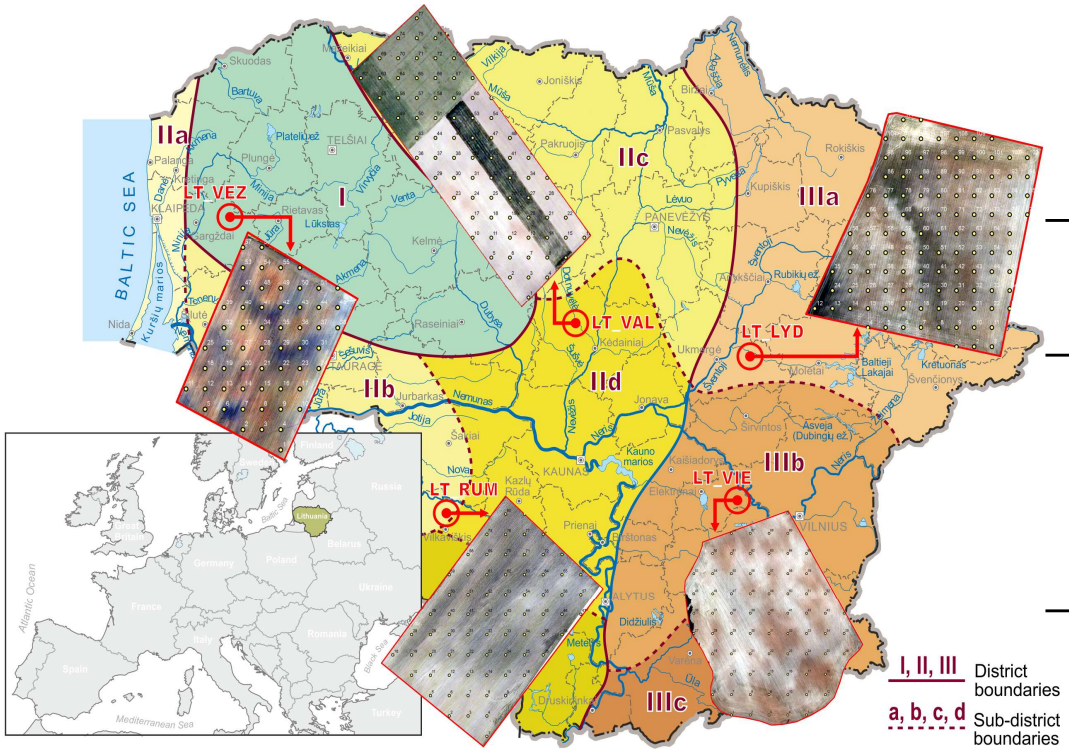
Tyrimo tikslas

Tyrimo tikslas: įvertinti skirtingų skaitmeninių jutiklių (bepiločių skraidyklių, palydovinių vaizdų ir dirvožemio EMI jutiklių) bei jų kombinacijų tikslumą prognozuojant dirvožemio savybes (granuliometrinę sudėtį – molio, smėlio ir dulkių daleles, dirvožemio organinę anglį, pH ir dirvožemio drėgmę), kartu analizuojant kaštų ir tikslumo santykį bei praktinį pritaikomumą lauko mastu.



LAMMC

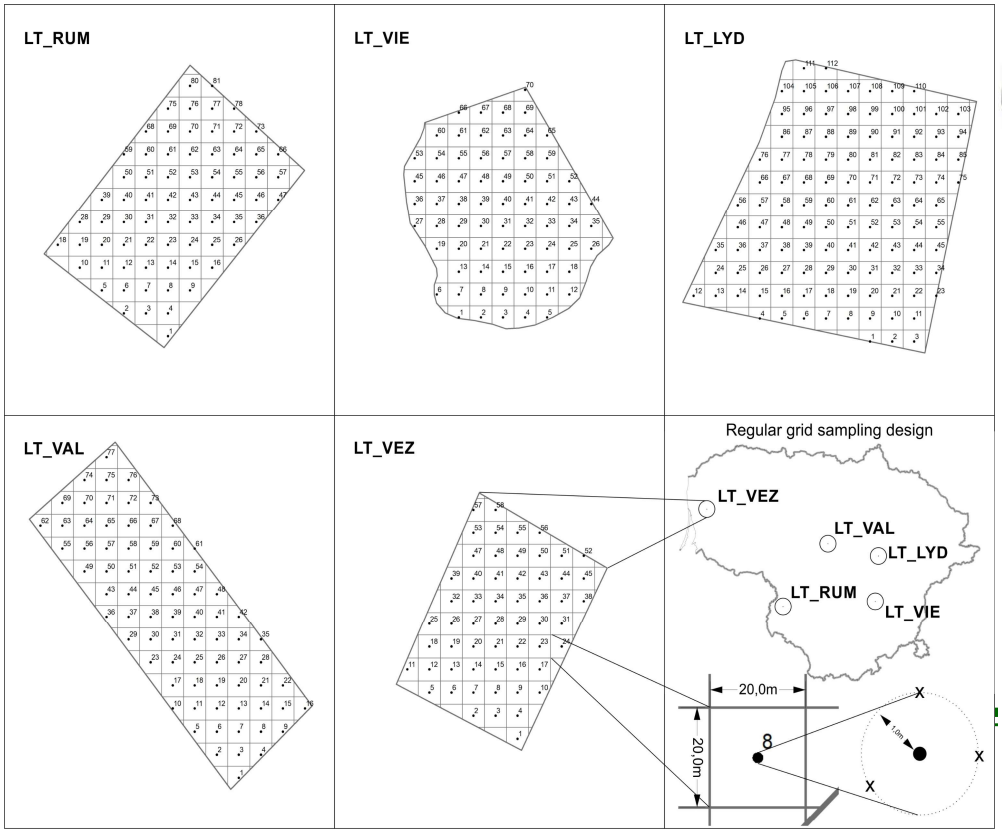
Tyrimų vietovė ir dirvožemio ėminiai

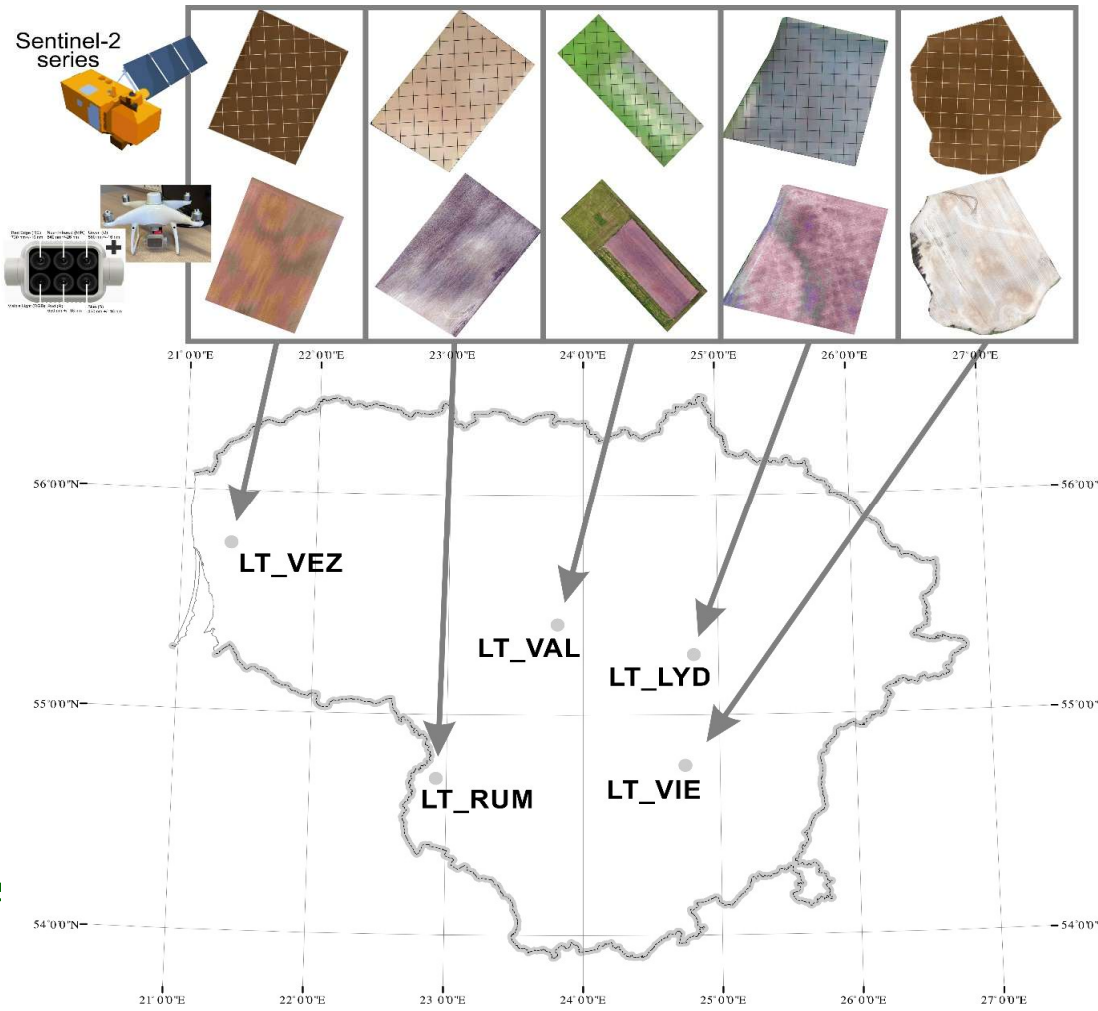


Laukas	Plotas (ha)	Ėminiai (*n*)	Ėminių surinkimo laikas	Bepilotės skraidyklės skrydžio laikas	Palydovinių vaizdų surinkimo laikas	EMI Surinkimo laikas
LT_RUM	2.8	72 (70)*	2021-05-10	2021-05-10	2021-05-12	2021-10-21
LT_VIE	2.7	70 (66)*	2021-05-10	2021-05-10	2021-05-11	2021-10-20
LT_VEZ	2.3	57(52)*	2021-05-14	2021-05-14	2021-05-12	2021-10-21
LT_LYD	4.7	112 (106)*	2021-08-10	2021-08-10	2021-08-09	2021-10-20
LT_VAL	3.0 (1.7)	77 (39)*	2021-09-10	2021-09-10	2021-09-08	2021-10-19

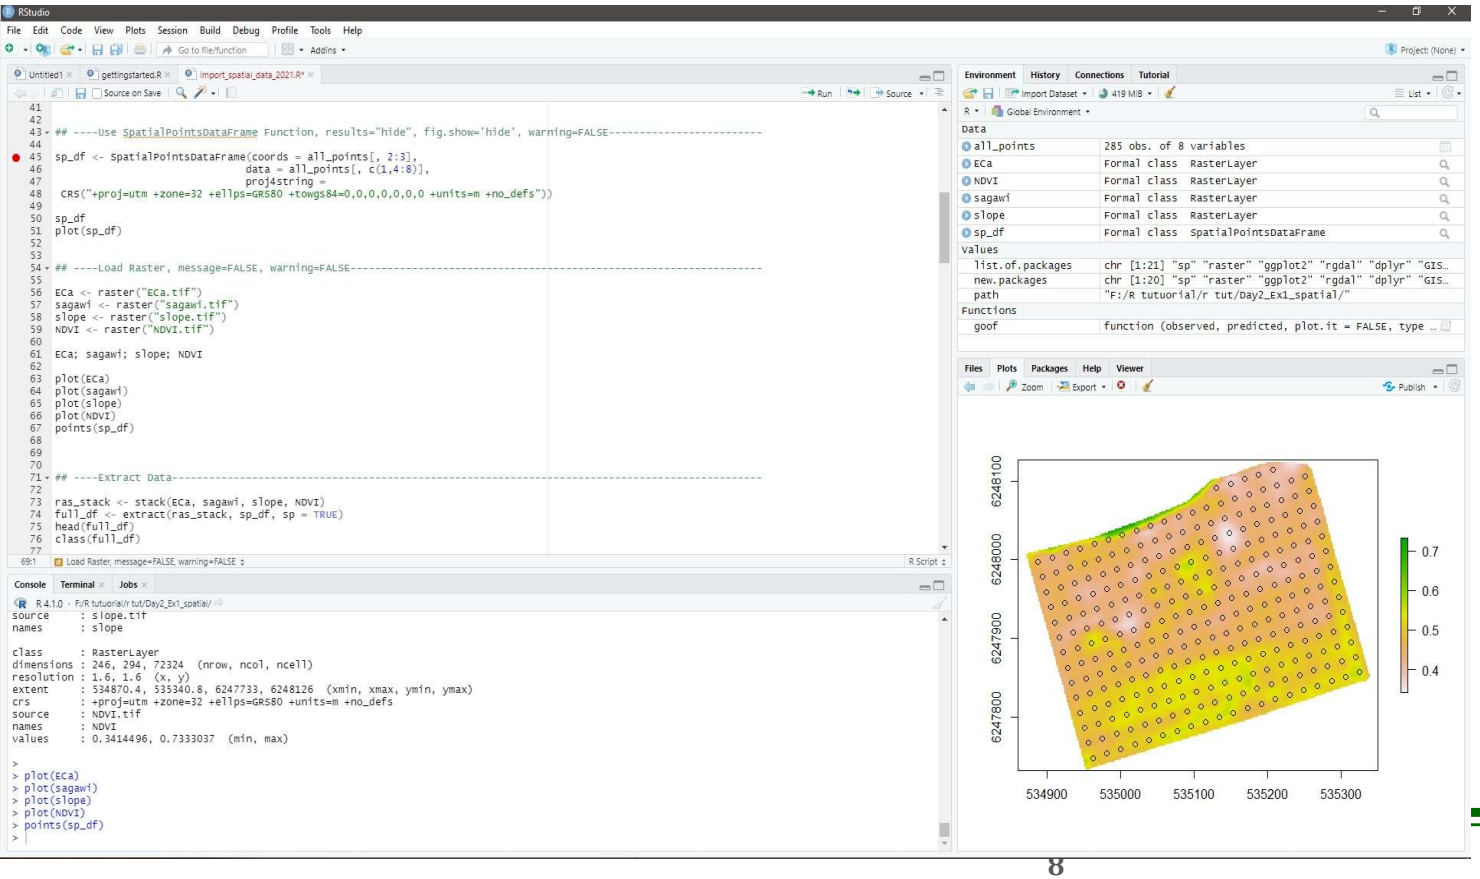
LAMMC

Ėminių surinkimo strategija





Modeliavimo metodas naudojant mašininį mokymąsi

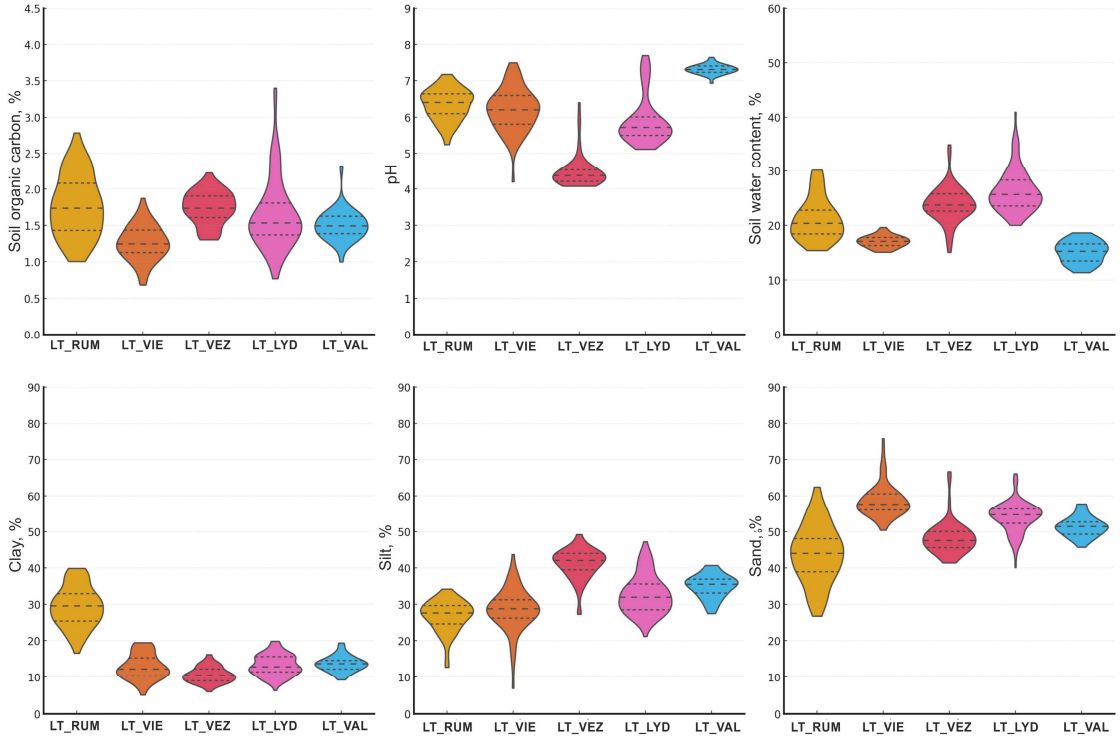


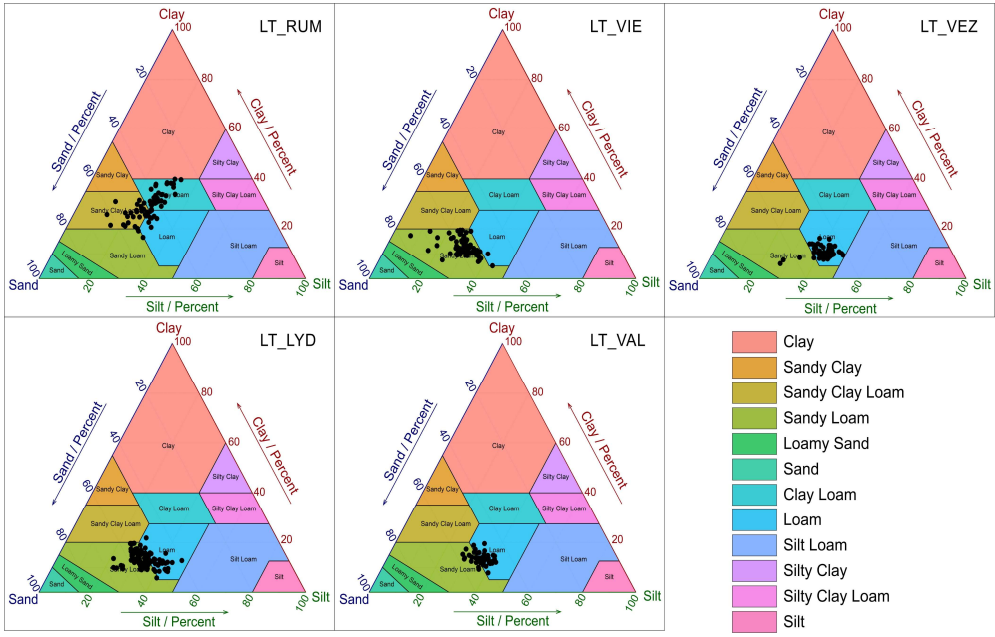
- Modeliai kurti kiekvienam laukui ir kiekvienam rodikliui atskirai (site-specific požiūris);
- Lauko duomenys padalyti: 70 % mokymui, 30 % validacijai (stratifikuota atranka);
- Naudotas Random Forest algoritmas (R, *caret*);
- Lauko duomenys sujungti su bepiločių skraidyklių, palydoviniais ir EMI duomenimis (7 modeliavimo scenarijai)

7 modeliavimo scenarijai

Nr	Scenarijus		Kintamieji	Pikselio dydis
1	Bepilotė skraidyklė	UAV	Iš viso 5: *spectral bands (Blue, Green, Red, NIR, Red Edge*)	2.6 cm pikselis^{-1}
2	Dirvožemio EMI jutiklis	EMI	Iš viso 1: *ECa*	1.6 m pikselis $^{-1}$
3	Palydoviniai Sentinel-2a vaizdai	S2	Iš viso 10: *spectral bands (B2, B3, B4, B5, B6, B7, B8, B8A, B11, B12)*	10 m or 20 m pikselis $^{-1}$
4	Bepilotė skraidyklė + Dirvožemio EMI jutiklis	UAV+EMI	Iš viso 6: *5 spectral UAV bands (Blue, Green, Red, NIR, Red Edge) + ECa*	1.6 m pikselis $^{-1}$
5	Bepilotė skraidyklė + Palydoviniai Sentinel-2a vaizdai	UAV + S2	Iš viso 15: *5 spectral UAV bands (Blue, Green, Red, NIR, Red Edge) + 10 Sentinel-2 spectral bands (B2,B3,B4, B5, B6, B7,B8, B8A, B11, B12)*	10 m or 20 pikselis $^{-1}$
6	Dirvožemio EMI jutiklis + Palydoviniai Sentinel-2a vaizdai	EMI + S2	Iš viso11*: Eca + 10 Sentinel-2 spectral bands (B2,B3,B4, B5, B6, B7,B8, B8A, B11, B12)*	10 m or 20 m pikselis $^{-1}$
7	Bepilotė skraidyklė + Dirvožemio EMI jutiklis + Palydoviniai Sentinel-2a vaizdai	UAV +EMI + S2	Iš viso 16: *5 spectral UAV bands (Blue, Green, Red, NIR, Red Edge) + 10 Sentinel-2 spectral bands (B2,B3,B4, B5, B6, B7,B8, B8A, B11, B12) + ECa*	10 m or 20 m pikselis $^{-1}$

Dirvožemio rodiklių kintamumas skirtinguose laukuose





Sutrumpinimai:
LT_RUM – Rumokų laukas (Vilkaviškio rajonas)
LT_VIE – Vievinių laukas (Elektrėnų rajonas)
LT_VEZ – Vėžaičių laukas (Klaipėdos rajonas)
LT_LYD – Lyduokių laukas (Ukmergės rajonas)
LT_VAL – Valinavos laukas (Kėdainių rajonas)

LAMMC

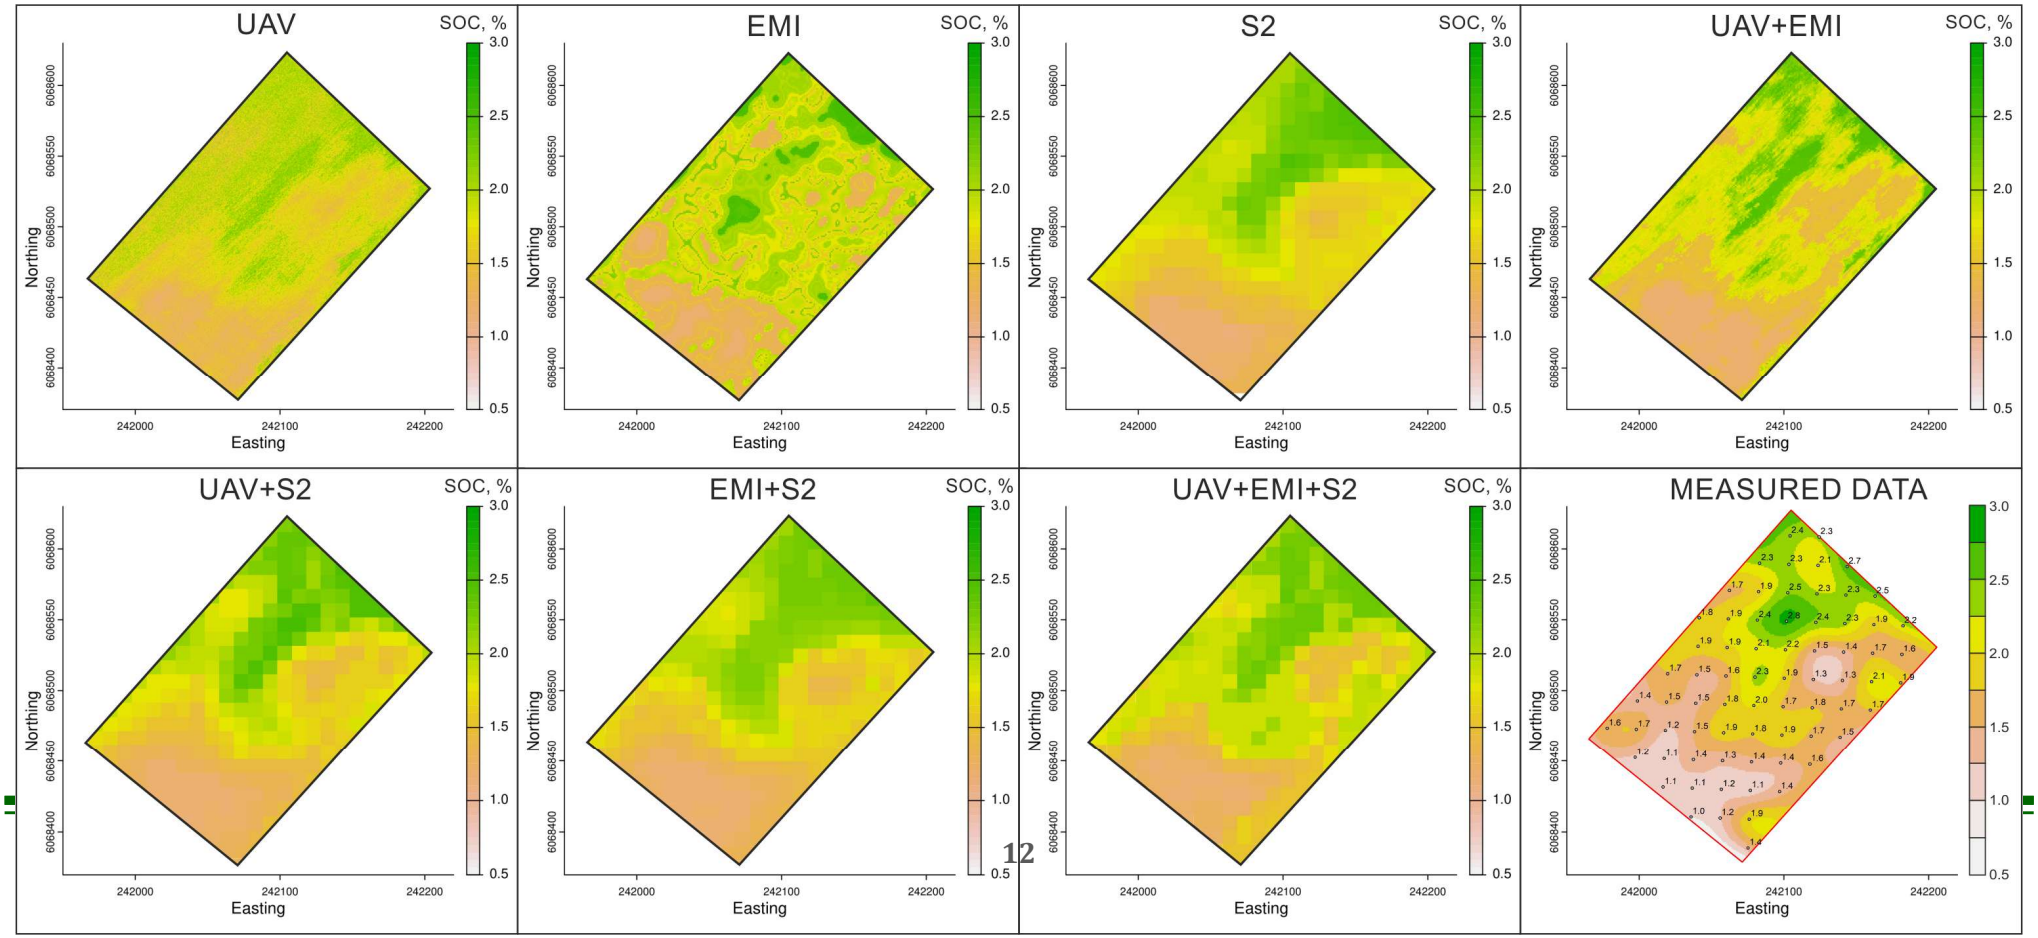
Dirvožemio savybių prognozavimo tikslumas : dirvožemio organinė anglis ≈ molis > smėlis ≈ dulkės ≈ dirvožemio drėgmė > pH.

Field	Data used (modelling Scenario)	SOC			SWC			pH		
		R^2	RMSE	NSE	R^2	RMSE	NSE	R^2	RMSE	NSE
LT_RUM	UAV	0.84	0.14	0.79	0.73	2.3	0.71	0.06	0.47	0.05
	EMI	0.37	0.35	0.24	0.38	2.89	0.37	0.08	0.4	0.08
	S2	**0.86**	0.15	0.86	0.62	2.8	0.6	0.1	0.39	0.07
	UAV + EMI	0.51	0.29	0.47	0.51	3.04	0.47	0.18	0.38	0.1
	UAV + S2	0.66	0.22	0.63	0.63	2.7	0.62	0.1	0.39	0.29
	EMI + S2	0.61	0.24	0.58	0.66	2.67	0.63	0.15	0.37	0.13
	UAV + EMI + S2	0.67	0.22	0.64	0.63	2.71	0.62	0.08	0.39	0.04
LT_VIE	UAV	**0.41**	0.21	0.26	0.2	1.43	0.16	0.04	0.68	0.09
	EMI	0.19	0.25	0.1	0.02	1.03	0.05	0.18	0.61	0.17
	S2	0.15	0.19	0.13	0.01	1.23	0.01	0.07	0.46	0.08
	UAV + EMI	0.27	0.21	0.24	0.11	0.87	0.02	0.23	0.6	0.22
	UAV + S2	0.25	0.21	0.17	0.01	1.24	0.02	0.12	0.44	0.02
	EMI + S2	0.23	0.18	0.22	0.02	1.22	0.01	0.15	0.43	0.06
	UAV + EMI + S2	0.21	0.21	0.14	0.01	1.23	0.01	0.22	0.4	0.19
LT_VEZ	UAV	0.54	0.15	0.53	0.08	3.74	0.04	0.05	0.28	0.11
	EMI	0.15	0.22	0.07	0.01	3.19	0.09	0.01	0.21	0.03
	S2	0.2	0.27	0.26	0.11	2.89	0.11	0.02	0.45	0.05
	UAV + EMI	0.6	0.14	0.59	0.43	2.75	0.23	0.02	0.2	0.08
	UAV + S2	**0.73**	0.19	0.39	0.19	2.77	0.18	0.02	0.45	0.03
	EMI + S2	0.02	0.28	0.14	0.19	2.83	0.14	0.03	0.41	0.04
	UAV + EMI + S2	0.18	0.22	0.13	0.18	2.79	0.17	0.03	0.41	0.06
LT_LYD	UAV	0.77	0.23	0.74	0.35	3.45	0.35	0.44	0.54	0.42
	EMI	0.1	0.69	0.08	0.01	3.99	0.02	0.1	0.71	0.05
	S2	0.46	0.37	0.34	0.07	3.29	0.03	0.36	0.49	0.32
	UAV + EMI	**0.81**	0.21	0.79	0.21	3.09	0.13	0.28	0.62	0.27
	UAV + S2	0.65	0.32	0.5	0.12	3.27	0.04	0.26	0.52	0.24
	EMI + S2	0.2	0.38	0.16	0.09	3.19	0.08	0.52	0.39	0.47
	UAV + EMI + S2	0.34	0.42	0.19	0.1	3.54	0.07	0.44	0.54	0.42
LT_VAL	UAV	0.19	0.14	0.17	0.16	1.89	0.15	0.03	0.15	0.12
	EMI	0.02	0.14	0.03	0.09	2.05	0.08	0.01	0.12	0.09
	S2	0.45	0.1	0.39	0.15	2.06	0.09	0.04	0.13	0.05
	UAV + EMI	0.02	0.14	0.06	0.12	1.87	0.1	0.31	0.16	0.16
	UAV + S2	0.22	0.12	0.14	0.14	1.98	0.11	0.07	0.14	0.05
	EMI + S2	**0.49**	0.1	0.4	0.14	2.07	0.1	0.04	0.13	0.27
	UAV + EMI + S2	0.42	0.1	0.28	0.13	2.05	0.08	0.01	0.13	0.24

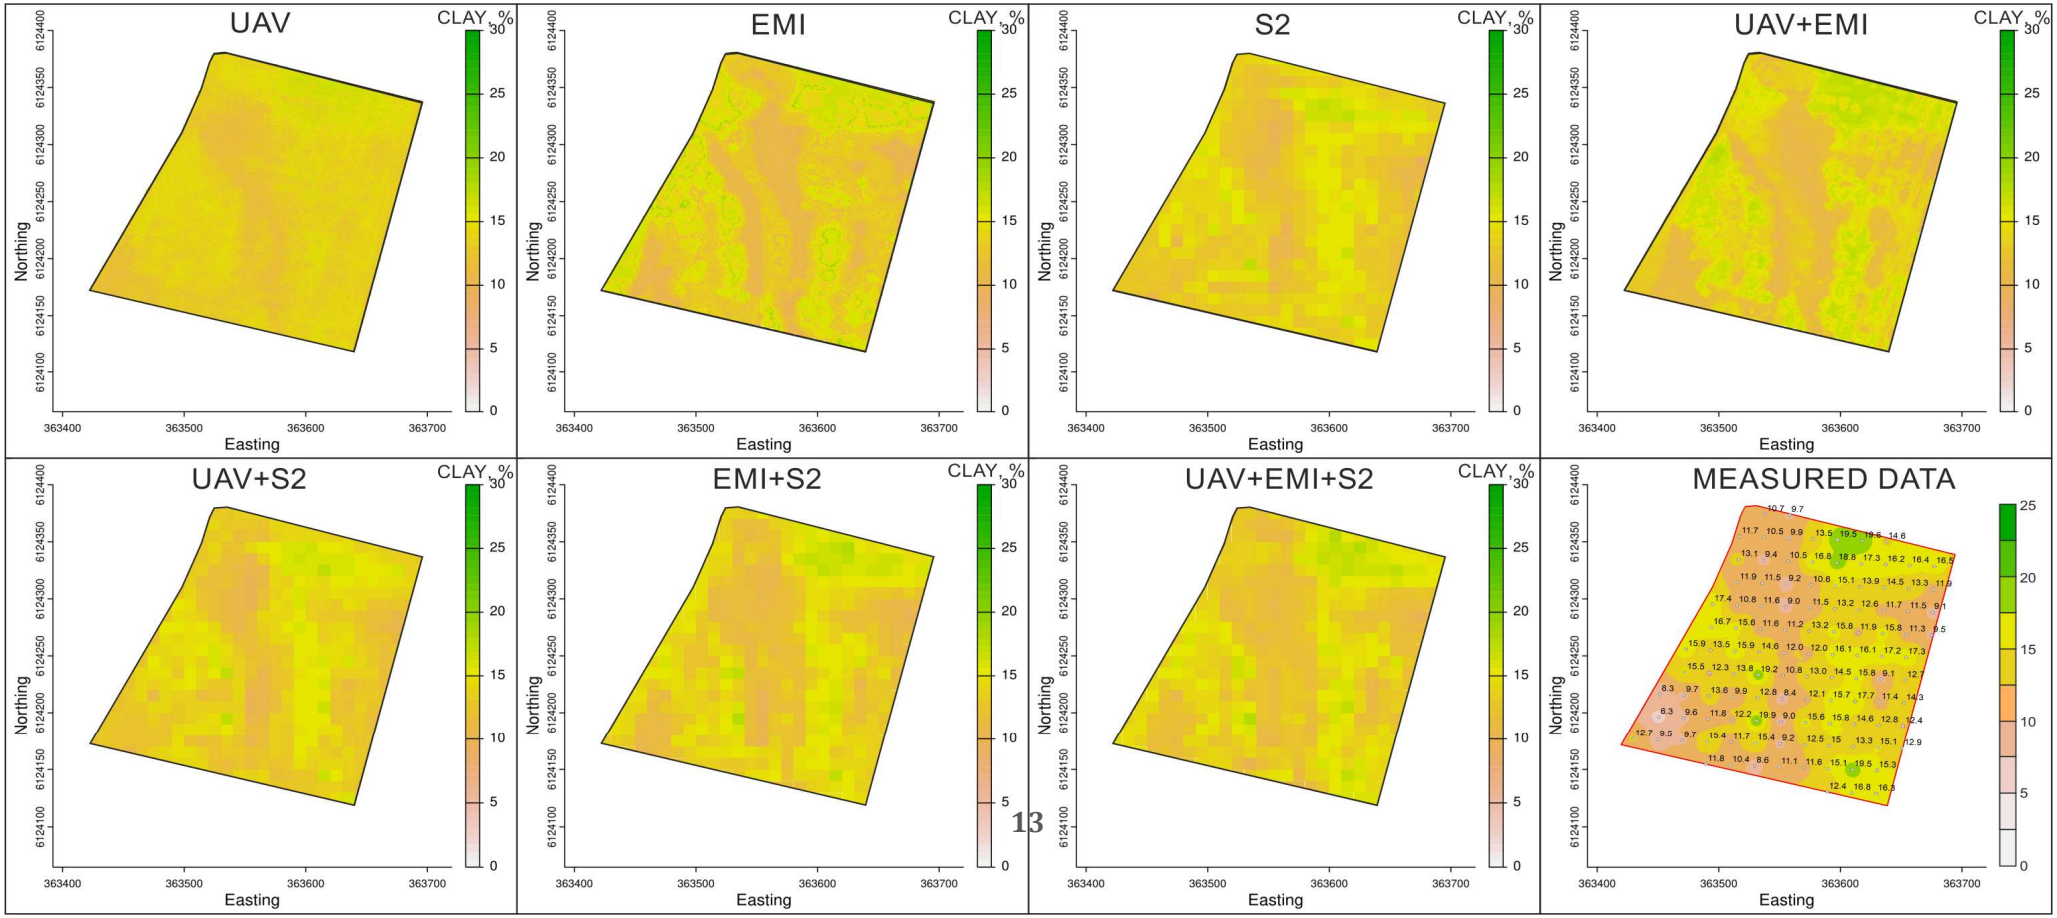
Field	Data used (modelling Scenario)	Clay			Silt			Sand		
		R^2	RMSE	NSE	R^2	RMSE	NSE	R^2	RMSE	NSE
LT_RUM	UAV	0.53	4.09	0.47	0.05	4.91	0.02	0.51	6.01	0.45
	EMI	0.54	4.29	0.47	0.03	4.01	0.03	0.32	5.93	0.27
	S2	0.64	3.95	0.58	0.35	2.99	0.26	0.51	5.52	0.51
	UAV + EMI	0.59	3.81	0.51	0.04	4.78	0.02	0.44	6.21	0.42
	UAV + S2	0.55	4.24	0.52	0.28	3.27	0.11	0.47	5.75	0.46
	EMI + S2	0.59	3.65	0.58	0.34	2.94	0.29	0.49	5.65	0.48
	UAV + EMI + S2	0.58	4.06	0.56	0.34	3.09	0.21	0.46	5.75	0.46
LT_VIE	UAV	0.45	3.17	0.43	0.1	5.33	0.16	0.02	3.99	0.03
	EMI	0.57	2.19	0.56	0.01	6.11	0.05	0.02	7.13	0.02
	S2	0.41	3.21	0.34	0.06	5.79	0.06	0.02	3.54	0.06
	UAV + EMI	0.45	2.7	0.44	0.02	5.55	0.02	0.16	6.05	0.06
	UAV + S2	0.56	3.1	0.29	0.05	5.24	0.05	0.08	3.34	0.03
	EMI + S2	0.43	3.24	0.49	0.12	6.49	0.06	0.05	3.76	0.05
	UAV + EMI + S2	0.54	3.04	0.46	0.12	5.79	0.16	0.06	3.47	0.03
LT_VEZ	UAV	0.48	1.83	0.45	0.15	3.47	0.13	0.23	2.52	0.11
	EMI	0.66	1.5	0.59	0.42	3.97	0.41	0.46	2.21	0.43
	S2	0.3	2.6	0.31	0.11	2.84	0.09	0.07	2.43	0.04
	UAV + EMI	0.79	1.26	0.71	0.54	3.71	0.49	0.46	3.14	0.45
	UAV + S2	0.37	2.02	0.31	0.4	2.44	0.33	0.08	2.58	0.17
	EMI + S2	0.45	1.82	0.46	0.18	2.86	0.12	0.06	2.44	0.05
	UAV + EMI + S2	0.46	1.85	0.34	0.31	2.63	0.23	0.05	2.65	0.03
LT_LYD	UAV	0.36	2.41	0.32	0.47	4.17	0.43	0.37	3.47	0.34
	EMI	0.34	3.04	0.34	0.12	5.57	0.12	0.03	5.14	0.04
	S2	0.46	2.37	0.41	0.43	3.76	0.41	0.11	3.45	0.06
	UAV + EMI	0.42	2.39	0.41	0.55	3.97	0.49	0.43	3.46	0.37
	UAV + S2	0.56	2.29	0.45	0.49	3.61	0.45	0.23	3.16	0.22
	EMI + S2	0.38	2.31	0.37	0.4	4.09	0.35	0.14	4.08	0.14
	UAV + EMI + S2	0.43	2.41	0.4	0.5	4.19	0.43	0.15	3.89	0.14
LT_VAL	UAV	0.19	2.67	0.39	0.01	3.58	0.08	0.12	3	0.27
	EMI	0.1	2.15	0.14	0.02	3.84	0.03	0.21	2.95	0.12
	S2	0.01	1.9	0.03	0.08	3.74	0.17	0.11	3.01	0.09
	UAV + EMI	0.17	1.79	0.15	0.17	3.22	0.13	0.57	2.73	0.45
	UAV + S2	0.02	1.82	0.04	0.02	3.64	0.11	0.06	3.15	0.01
	EMI + S2	0.13	1.84	0.17	0.02	3.7	0.15	0.1	3.06	0.06
	UAV + EMI + S2	0.11	1.8	0.12	0.03	3.58	0.07	0.04	3.21	0.04

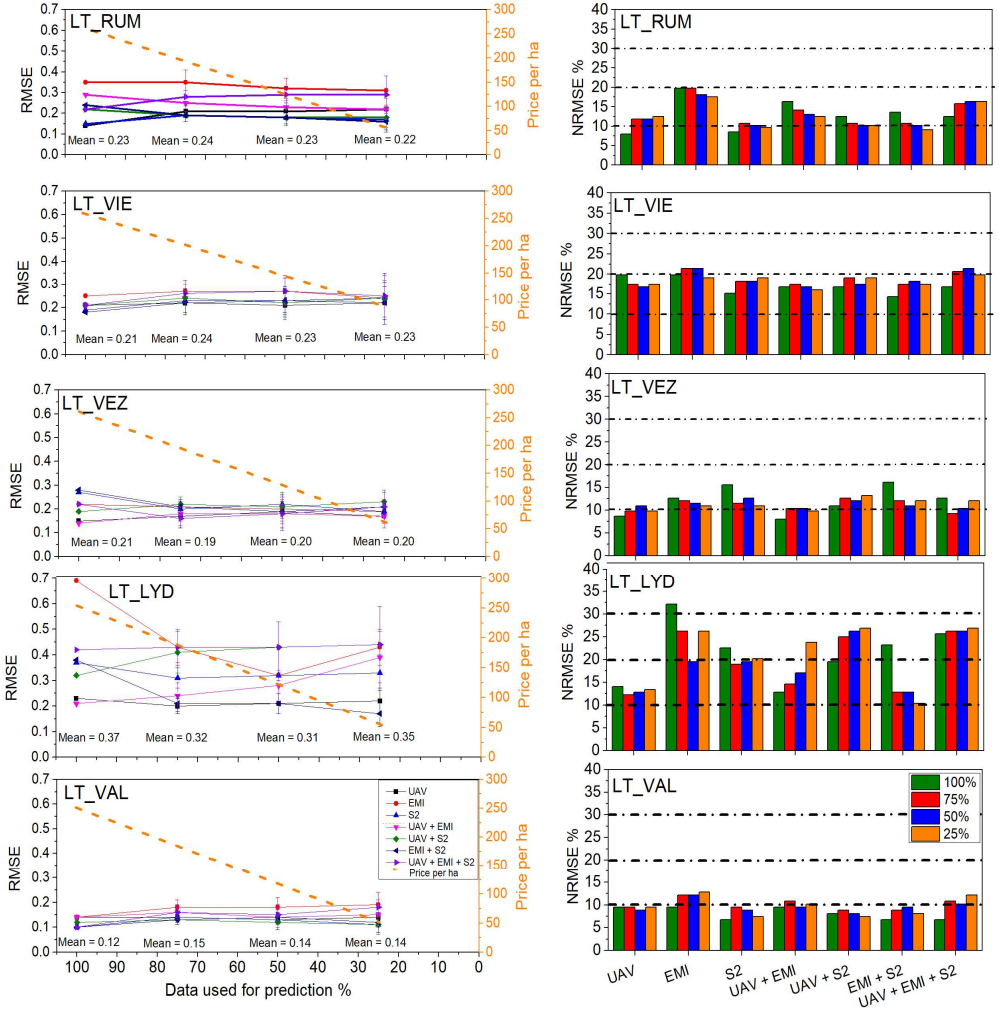
LAMMC

Dirvožemio organinės anglies žemėlapis, naudojant skirtingus modeliavimo scenarijus Rumokų lauke



Molio dalelių žemėlapis, naudojant skirtingus modeliavimo scenarijus Lyduokių lauke





Ėminių skaičiaus mažinimas: poveikis tikslumui ir išlaidoms

Modeliuojant ir mažinant lauko ėminių kiekį (nuo 25 iki 75 %) tik nežymiai mažėjo dirvožemio organinės anglies ir molio prognozių tikslumas;

Mažėjant ėminių kiekiui ženkliai mažėjo cheminių analizių sąnaudos (nuo ~240–270 iki ~60–68 €/ha)

Sąnaudos hektarui išlieka gana didelės, siekiant itin detalių žemėlapių (2.6 cm)

Teoriškai sąnaudas būtų galima dar mažinti, tačiau tam reikalingi didesni tyrimų laukai, kad būtų užtikrintas pakankamas ėminių kiekis modeliavimui (geostatistiniu požiūriu rekomenduojama apie 100 taškų, tačiau ir su 20–50 taškų galima pasiekti gana gerų rezultatų).

Apibendrinimas

Aukščiausias prognozių tikslumas pasiektas dirvožemio organinei angliai ir moliui, smėlio, dulkių ir dirvožemio drėgmės rezultatai buvo vidutiniai, o pH prognozės – silpniausios, nes pH nėra tiesiogiai susijęs su spektriniais signalais, todėl prognozės grindžiamos tik netiesioginiais ryšiais su kitais rodikliais.

Bepiločių skraidyklių ir palydovinių Sentinel-2 vaizdų duomenys geriausiai tinka dirvožemio organinės anglies prognozėms, o dirvožemio EMI jutiklių duomenys tinka molio prognozėms.

Jutiklių kombinacijos ne visada pagerino tikslumą (galimas „overfitting“ ir vietos specifiškumas).

Erdvinė raiška ir vietos sąlygos (dirvožemis, klimatas, reljefas) reikšmingai veikia modelių rezultatus.

Modeliai yra vietai specifiniai, todėl jų pritaikomumas kituose laukuose yra ribotas, ypač esant skirtingoms agroklimatinėms sąlygoms, ūkininkavimo praktikoms ir dirvožemio tipams.

Computers and Electronics in Agriculture 244 (2026) 111543

Contents lists available at ScienceDirect

Computers and Electronics in Agriculture

journal homepage: www.elsevier.com/locate/compag

Original papers

Comparison of soil property predictions in Lithuanian croplands using UAV, satellite, EMI data and machine learning

R. Žydelis [a,*], L. Weihermüller [b], L.C. Gomes [c], A.B. Møller [c], F. Castaldi [d], J. Volungevičius [a], A. Kavaliauskas [a], T. Koganti [c], J. Wetterlind [e], İ. Cinkaya [f], L. Borůvka [g], F. van Egmond [h], S. Higgins [i], F. Liebisch [j], V. Povilaitis [a], A. Kazlauskaitė-Jadzevičė [a], K. Amalevičiūtė-Volungė [k], S. Pranaitienė [a], E. Vaudour [l]

[a] Institute of Agriculture, Lithuanian Research Centre for Agriculture and Forestry, Lithuania
[b] Agrosphere Institute (IBG-3), Forschungszentrum Jülich GmbH, Germany
[c] Department of Agroecology, Aarhus University, Blichers Allé 20, 8830 Tjele, Denmark
[d] Institute of BioEconomy, National Research Council of Italy (CNR), Via Giovanni Caproni 8, 50145 Firenze, Italy
[e] Swedish University of Agricultural Sciences, Department of Soil and Environment, Skara, Sweden
[f] Ministry of Agriculture and Forestry/General Directorate of Agricultural Research and Policies, Turkey
[g] Czech University of Life Sciences Prague (CZU), Department of Soil Science and Soil Protection, Kamýcká 129, 165 00 Prague-Suchdol, Czech Republic
[h] Wageningen Environmental Research, P.O. Box 47, 6700 AA Wageningen, the Netherlands
[i] Agri-Food and Biosciences Institute, Belfast, Northern Ireland, UK
[j] Agroecology and Environment, Agroscope, Zürich, Switzerland
[k] Lithuanian Agricultural Advisory Service, Akademija, Lithuania
[l] Université Paris-Saclay, INRAE, AgroParisTech, UMR EcoSys, 91120 Palaiseau, France

ARTICLE INFO

Keywords:
Clay
Electrical conductivity
Proximal sensing
Remote sensing
SOC

ABSTRACT

Combining remote and proximal sensing provides a cost-effective solution for mapping soil properties in croplands. This study assessed the potential of remote sensing based on high resolution multispectral UAV imagery (2.6 cm), satellite (Sentinel-2), and in-field measured electromagnetic induction (EMI) data for predicting six soil properties – soil organic carbon content (SOC), clay, sand, silt contents, pH, and soil water content (SWC) – across five Lithuanian agroclimatic zones. Seven modelling scenarios, using individual and combined sources of sensor data, employing a random forest model, were evaluated. To assess real-world applicability, sampling-reduction simulation were additionally performed. SOC and clay predictions achieved the highest accuracy, while silt, sand, and SWC showed acceptable accuracy only in a few sites or specific modelling scenarios. Soil pH predictions were poor across all scenarios. Prediction accuracy varied across study sites, likely influenced by climate, soil parent material, topography, and agricultural management. Sensor data resolutions (2.6 cm, 1.6 m, 10 m per pixel) significantly affected prediction accuracy. For SOC predictions, UAV and Sentinel-2 data performed best, while EMI alone was less effective. In contrast, for clay predictions, EMI data yielded the highest accuracy, emphasizing its role for soil texture assessment. Multi-sensor fusion improved model performance during training but did not consistently enhance validation accuracy across sites, highlighting important cost–accuracy trade-offs and the need for realistic performance evaluation. Overall, the results demonstrate that the benefits of multi-sensor soil mapping are property-specific and site-dependent, providing guidance for scalable and economically viable field-scale soil mapping strategies.

1. Introduction

The vitality of life on Earth depends on soil health, as soils provide 95% of the world's food (EU, 2021). Soils also play a key role in nutrient cycling, carbon storage, and partitioning of surface runoff and water infiltration, which can help mitigate climate change and reduce flooding risks (Adhikari and Hartemink, 2016). Soil health relies on complex interactions between chemical, biological, and physical processes (Vogel

10.1016/j.compag.2026.111543

Tel. +370 698 84 417
El. paštas renaldas.zydelis@lammc.lt

LAMMC

Ačiū už dėmesį!

