



**Vilniaus
universitetas**

Ataskaitinė informatikos krypties doktorantų konferencija 2025-10-02

Aivaras Bielskis (VU DMSTI doktorantas, Išmaniųjų technologijų tyrimų grupė)

Darbo tema.

Vertybinių popierių kainų prognozavimas ir investicinio portfelio formavimas naudojant mašininio mokymosi algoritmus.

Stock price forecasting and investment portfolio formation using machine learning algorithms.

Darbo vadovas.

prof. dr. Igoris Belovas.

Doktorantūros studijų laikotarpis.

2022 m. spalio mėn. 1 d. – 2026 m. rugsėjo mėn. 30 d.

Ataskaitinis laikotarpis.

2025 m. kovo mėn. 29 d. – 2025 m. spalio mėn. 2 d.

Visų studijų planas ir jo vykdymo suvestinė

Vilniaus
universitetas

Studijų metai	Egzaminai	
	Planas	Įvykdyta
I (2022/2023)	2	3
II (2023/2024)	1	1
III (2024/2025)	1	
IV (2025/2026)		
Iš viso:	4	4

Visų studijų planas ir jo vykdymo suvestinė

Vilniaus
universitetas

Studijų metai	Dalyvavimas konferencijose				Publikacijos					
	Tarptautinėse		Nacionalinėse		Su citav. rodikliu			Be citav. rodiklio		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būklė	Planas	Įvykdyta	Būklė
I (2022/2023)									1	Publikuota ¹
II (2023/2024)		1 ^{2,3}								
III (2024/2025)	1	1 ⁴			1	1	Pateikta ⁵			
IV (2025/2026)	1				1					
Iš Viso	2	1	0	0	2	1	0	0	1	1

¹ Bielskis A., Belovas, I. *Akcijų kainų ARIMA ir LSTM prognozavimo metodų lyginamoji analizė*. Lietuvos matematikos rinkinys. Serija B, 2022, 63, p. 21-27.

DOI: 10.15388/LMR.2022.29755

Visų studijų planas ir jo vykdymo suvestinė

Studijų metai	Dalyvavimas konferencijose				Publikacijos					
	Tarptautinėse		Nacionalinėse		Su citav. rodikliu			Be citav. rodiklio		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būklė	Planas	Įvykdyta	Būklė
I (2022/2023)									1	Publikuota ¹
II (2023/2024)		1 ^{2,3}								
III (2024/2025)	1	1 ⁴			1	1	Pateikta ⁵			
IV (2025/2026)	1				1					
Iš Viso	2	1	0	0	2	1	0	0	1	1

² Bielskis A. *Advanced Machine Learning Techniques for Investment Forecasting: An Integrated Approach*. ECML PKDD 2024, Vilnius. Poster session.

³ Bielskis A. *Advanced Machine Learning Techniques for Investment Forecasting: An Integrated Approach*. ECML PKDD 2024, Vilnius. MIDAS: The 9th Workshop on Mining Data for financial applications. Paper presentation.

Visų studijų planas ir jo vykdymo suvestinė

Studijų metai	Dalyvavimas konferencijose				Publikacijos					
	Tarptautinėse		Nacionalinėse		Su citav. rodikliu			Be citav. rodiklio		
	Planas	Įvykdyta	Planas	Įvykdyta	Planas	Įvykdyta	Būklė	Planas	Įvykdyta	Būklė
I (2022/2023)									1	Publikuota ¹
II (2023/2024)		1 ^{2,3}								
III (2024/2025)	1	1 ⁴			1	1	Pateikta ⁵			
IV (2025/2026)	1				1					
Iš viso	2	1	0	0	2	1	0	0	1	1

⁴ Bielskis A. Advanced Machine Learning Techniques For Investment Forecasting: An Integrated Approach. The International Conference on Optimization and Decision Science 2025, Milan, Italy.

⁵ Pateiktas straipsnis - Bielskis A. and Belovas I. Machine Learning Models and Ensemble Methods for Stock Index Return Forecasting. Romanian Journal of Information Science and Technology (ROMJIST)

Ataskaitinio pusmečio darbų planas ir jų vykdymo suvestinė

Egzaminai			
Planas	Įvykdyta	Būklė	
Dalyvavimas konferencijose			
Planas	Įvykdyta	Konferencijos tipas	
	Bielskis A. Advanced Machine Learning Techniques for Investment Forecasting: An Integrated Approach. The International Conference on Optimization and Decision Science 2025, Milan, Italy.	Tarptautinė	
Publikacijos			
Planas	Įvykdyta	Būklė	Publikacijos tipas
Romanian Journal of Information Science and Technology (ROMJIST)	Bielskis A. and Belovas I. Machine Learning Models and Ensemble Methods for Stock Index Return Forecasting. Romanian Journal of Information Science and Technology (ROMJIST)	Pateiktas	Žurnalas turi cituojamumo rodiklį, Q1.

Visų mokslinių tyrimų ir disertacijos rengimo etapai

Darbo pavadinimas		Atlikimo terminai	Pastabos
1.	Mokslinių tyrimų disertacijos tema apžvalga ir analizė: 1.1. Analitinės apžvalgos atlikimas. 1.2. Disertacijos tyrimo objekto detalizavimas.	2022 m. spalio mėn. – 2023 m. kovo mėn.	Įvykdyta
	1.3. Analitinės apžvalgos užbaigimas. 1.4. Mokslinių problemų susietų su tyrimo objektu identifikavimas ir tyrimo tikslo suformavimas	2023 m. balandžio mėn. – 2023 m. rugsėjo mėn.	Įvykdyta
2.	Mokslinio tyrimo vykdymas:		
	2.1. Tyrimo metodikos sudarymas: 2.1.1. Uždavinių, skirtų tyrimo tikslui pasiekti, suformulavimas. 2.1.2. Tyrimo metodikos išsikeltiems uždaviniams spręsti parinkimas. 2.1.3. Teorinio ir empirinio tyrimų suplanavimas pagal pasirinktą metodiką.	2023 m. spalio mėn. – 2024 m. kovo mėn.	Įvykdyta
	2.2. Teorinis tyrimas: 2.2.1. Mašininio mokymo metodų, planuojamų panaudoti tyrime parinkimas ir analizė. 2.2.2. Parinktų metodų adaptavimas ir modifikavimas, atsižvelgiant į problematikos specifiką.	2024 m. balandžio mėn. – 2024 m. rugsėjo mėn.	Įvykdyta

Visų mokslinių tyrimų ir disertacijos rengimo etapai

	2.3. Empirinis tyrimas: 2.3.1. Parinktų mašininio mokymo metodų įdiegimas, algoritmų konstravimas. 2.3.2. Įdiegtų algoritmų bei jų modifikacijų efektyvumo palyginamasis tyrimas.	2024 m. spalio mėn. – 2025 m. kovo mėn.	Įvykdyta
	2.3.3. Geriausių algoritmų adaptavimas ir jų taikymas sprendžiant konkrečius praktinius uždavinius.	2025 m. balandžio mėn. – 2025 m. rugsėjo mėn.	Įvykdyta
	2.4. Gautų rezultatų analizė ir apibendrinimas	2025 m. spalio mėn. - 2026 m. kovo mėn.	
1.	Atskirų daktaro disertacijos dalių (tyrimo metodikos, rezultatų, ginamų teiginių, išvadų ir kt.) parengimas: 3.1. Tikslų, uždavinių, tyrimo metodikos, ginamųjų teiginių patikslinimas. 3.2. Analitinės disertacijos dalies parengimas. 3.3. Teorinės disertacijos dalies parengimas. 3.4. Eksperimentinės disertacijos dalies parengimas. 3.5. Bendrųjų išvadų formulavimas.	2026 m. balandžio mėn. – 2026 m. rugsėjo mėn.	
2.	Daktaro disertacijos parengimas ir svarstymas padalinyje	2026 m. birželio mėn.	
3.	Daktaro disertacijos gynimas	2026 m. rugsėjo mėn.	

Tyrimo tema

- Akcijų kainų prognozavimas yra plačiai nagrinėjama tema tiek pasaulyje, tiek Lietuvoje. Egzistuojantys metodai yra nuolat tobulinami, yra ieškoma naujų kelių, vykdomi aktualių įvykių ir procesų tyrimai.
- Doktorantūroje pasirinkta tema „Vertybinių popierių kainų prognozavimas ir investicinio portfelio formavimas naudojant mašininio mokymosi algoritmus“ yra mano bakalauro baigiamojo darbo – „Investicinio portfelio optimizavimas“ ir magistro baigiamojo darbo – „Prognozavimo metodų analizė“ tęsinys.
- Pasirinkta tema yra svarbi, nes darbo rezultatai gali padėti investuotojams ir finansų analitikams, siekiantiems efektyviai valdyti investicinius portfelius ir priimti optimalius sprendimus.
- Mašininio mokymosi algoritmai yra aktualus įrankis prognozuojant vertybinių popierių kainų svyravimus sudarant investicinius portfelius.

Tyrimo objektas

- Tyrimo objektas yra viešai kotiruojamų įmonių akcijos, biržoje prekiaujami fondai, prekės (angl. commodities), obligacijos, valiutos, išvestinės priemonės ir kiti produktai, kuriais galima prekiauti rinkose.
- Tyrimu siekiama ištirti, kaip naudojant mašininio mokymosi algoritmus galima prognozuoti vertybinių popierių kainų kitimus ir kurti investicinius portfelius, kurie būtų optimaliai sudaryti atsižvelgiant į kainų kitimo tendencijas.
- Darbo metu planuojama tyrinėti tiek Lietuvos, tiek pasaulio vertybinius popierius.

Tyrimo tikslas

- Tyrimo tikslas yra pasiūlyti naujus (arba modifikuoti esamus) patobulintus algoritmus ir jų pagrindu sukurti programą, formuojančią optimalų investicinį portfelį.
- Programa turėtų naudojant mašininio mokymosi algoritmus efektyviai prognozuoti vertybinių popierių kainų (arba finansinių indeksų) svyravimus ir konstruoti portfelius, siekiant maksimizuoti pelną ir minimalizuoti riziką.

Mokslinės problemos

1. Didelių finansinių duomenų surinkimo ir filtravimo (parengimo) proceso automatizavimas
2. Egzistuojančių mašininio mokymosi algoritmų vertybinių popierių kainų prognozavimui bei investicinio portfelio valdymui modifikavimas (tobulinimas):
 - Prognozės tikslumo problema;
 - Rizikos valdymo problema;
 - Strategijos parinkimo problema;
 - Stabilumo problema;
 - Palyginimo ir verifikacijos problemos;
3. Nefinansinių veiksnių (pvz., globalių reiškinių: pandemijų, soc. krizių) poveikis investicinio portfelio valdymo procesui.

Tyrimo uždaviniai

1. Surinkti ir apdoroti finansinius duomenis, būtinus investicinių priemonių kainų prognozavimui ir portfelio formavimui. Išnagrinėti investicinių priemonių rinką, kad būtų galima įvertinti naujas investicines galimybes, kurias galima naudoti portfelio diversifikavimui ir rizikos minimizavimui.
2. Ištirti esančius mašininio mokymosi algoritmus, skirtus vertybinių popierių kainų prognozavimui ir investicinio portfelio formavimui. Ištirti esančius optimalaus investicinio portfelio formavimo metodus (algoritmus).
3. Palyginti mašininio mokymosi modelių prognozių tikslumą ir investicinių portfelių valdymo metodus, pasitelkiant istorinius bei sintetinius duomenis.

Tyrimo uždaviniai

4. Pasiūlyti ir pritaikyti naujus mašininio mokymosi algoritmus, kurie geriau prognozuotų vertybinių popierių kainų kitimą ir leistų geriau optimizuoti investicinį portfelį. Pasiūlyti naujas strategijas, kaip naudoti mašininio mokymosi algoritmus investicinio portfelio valdyje ir kaip padidinti grąžą bei sumažinti riziką. Kombinuoti tradicinius finansų modelius su mašininio mokymosi algoritmais, kad būtų sukurti nauji investiciniai modeliai.
5. Palyginti sukurtų mašininio mokymosi modelių ir investicinių strategijų veiksmingumą su kitų autorių sukurtais strategijomis ir modeliais.

- Skaidyti tyrimą į dvi dalis: prognozavimo užduotis ir portfelio formavimo užduotis.
- Prognozavimo uždaviniui atlikti – jungti visus:
 - long short term memory (LSTM),
 - gated recurrent unit (GRU),
 - temporal fusion transformer (TFT),
 - extreme gradient boost (XGBoost),
 - deep multilayer perceptron (DMLP) metodus,
 - šių metodų mažesnę mišinį.
- Prognozavimo uždaviniui atlikti – patobulinti, arba apjungti su kitais metodais Random Forest (RF) metoda.

- Portfelio formavimo uždaviniui atlikti naudoti ir palyginti
 - Markowitz mean-variance (MV),
 - diversified mean-variance with forecasting (DMVF),
 - omega portfolio optimization models (Omega-CVaR),
 - stochastic dominance (SD),
 - generalized autoregressive conditional heteroskedasticity (GARCH),
 - independent factor analysis (IFA),
 - ordinary least squares (OLS) metodus.
- Prie tyrimo pridėti maximum-drawdown (MDD) metriką ir iš jos išplaukiančią calmar ratio (CR) metrikas vertinant rezultatus.

Teorinio ir empirinio tyrimo planas

1. Prognozavimo uždaviniui naudojamų metodų (LSTM, GRU, TFT, XGBoost bei DMLP) įgyvendinimas ir šių metodų jungimas.
2. Prognozių atlikimas naudojant įgyvendintus metodus. Atliktų prognozių rezultatų lyginimas.
3. Trūkumų šalinimas ir esant poreikiui metodų modifikavimas.
4. Gautų rezultatų analizė.
5. Portfelio formavimo uždaviniui naudojamų metodų (MV, DMVF, Omega-CVaR, SD, Garch, IFA, OLS) įgyvendinimas.
6. Prognozavimo ir portfelio formavimo sistemos sudarymas.
7. Sistemos testavimas, trūkumų šalinimas ir esant poreikiui metodų modifikavimas.
8. Galutinių rezultatų analizė.

1. **Ansamblinis prognozavimo metodas** - Šis tyrimas nagrinėja ansamblinio mokymosi metodų efektyvumą finansinių laiko eilučių prognozavimui. Užuoat rėmęsi pavieniais modeliais, tyrimas optimizuoja jų kombinaciją, užtikrindamas didesnę prognozių tikslumą ir patikimumą.
2. **Finansinei veiklai orientuotas vertinimas** - Skirtingai nuo įprastų tyrimų, kurie daugiausia vertina modelių tikslumą pagal statistinius paklaidų rodiklius, šis darbas integruoja finansinį efektyvumo vertinimą. Naudojant Maximum Drawdown, Total Return ir Calmar Ratio, tyrimas pateikia praktines išvalgas apie modelių pelningumą ir rizikos sureguliuotą efektyvumą realiomis rinkos sąlygomis.
3. **Pažangus ansamblinio svorių optimizavimas** - Siekiant pagerinti ansamblinio modelio prognozes, šiame tyrime naudojamas optimizuotas svorių paskirstymo metodas. Tam pasitelkiamos šios technikos:
 1. Gradientinis nuolydžio optimizavimas (Gradient Descent Optimization)
 2. Elastinis tinklas (Elastic Net)
 3. Tiesinė regresija (Linear Regression)

Ši optimizavimo strategija leidžia modeliams prisitaikyti prie besikeičiančių rinkos sąlygų ir sumažinti prognozavimo paklaidas.

Trumpas per pusmetį gautų mokslinių rezultatų pristatymas

Vilniaus
universitetas

- Semestro metu buvo adaptuoti prieš tai aprašyti parinkti modeliai bei jų ansambliai atliekant indeksų kainų prognozavimą.
- Šie rezultatai buvo pristatyti mokslinėje konferencijoje Italijoje bei šiais rezultatais paruoštas straipsnis, kuris įteiktas žurnalui „Romanian Journal of Information Science and Technology (ROMJIST)“.

- Rezultatai parodė, kad visi modeliai pasiekė labai aukštą statistinį tikslumą ($R^2 \approx 0,98$), tačiau tai ne visada virto pelningomis prekybos strategijomis. Pavyzdžiui, GRU ir Transformer pasižymėjo geru pritaikymu istoriniams duomenims, bet dažnai sugeneravo neigiamas grąžas.
- LSTM užtikrino stabiliausią pelningumą su vidutiniais nuosmukiais, o XGBoost demonstravo didžiausią kintamumą – vienais atvejais pasiekė aukščiausią grąžą (+34 %), kitais – giliausius nuostolius (−40 %).

Bendras visų modelių pelningumo apibendrinimas

Vilniaus
universitetas


Algoritmas	N-SC	MSE	MAE	R-SQ	Max-D	Sandoriai	Grąža	Max-Grąža	Min-Grąža	RT	DT
LSTM	5	53511	133,63	98,06%	-11%	44,40	6,27%	12,41%	-0,54%	28%	-18%
XGB	5	53779	134,06	98,03%	-20%	30,00	4,32%	33,60%	-40,16%	28%	-18%
Average	130	53502	133,77	98,06%	-16%	50,41	4,27%	66,46%	-29,80%	28%	-18%
ENet_Ensemble	130	79665	184,68	97,10%	-2%	1,15	0,07%	20,72%	-9,90%	28%	-18%
DMLP	5	53633	134,61	98,07%	-19%	48,60	-0,15%	50,34%	-23,74%	28%	-18%
GD_Ensemble	130	58388	145,30	97,84%	-9%	7,66	-1,28%	45,76%	-23,87%	28%	-18%
LR_Ensemble	130	58320	144,08	97,87%	-11%	10,95	-2,14%	46,83%	-37,20%	28%	-18%
Transformer	5	53923	134,22	98,06%	-18%	48,20	-5,14%	8,20%	-23,62%	28%	-18%
GRU	5	53560	133,89	98,06%	-19%	48,40	-9,42%	15,77%	-27,19%	28%	-18%

Bendras modelio efektyvumas apibendrintas lentelėje. Pateiktos reikšmės rodo vidurkius, apskaičiuotus pagal nurodytą scenarijų skaičių (N-SC). Papildomi rodikliai apima didžiausią nuosmukį (MAX-D), bendrą grąžą (Grąža), mažiausią grąžą (Min-Grąža), didžiausią grąžą (Max-Grąža), grąžos slenkstį (RT) ir nuosmukio slenkstį (DT), kurie nustatomi lyginant investavimą į pasirinktą indeksą su nieko nedarymo (hold) scenarijumi.

- Ansamblių rezultatai atskleidė, kad paprastas vidurkinimas tarp skirtingų modelių (pvz., LSTM+DMLP+XGB arba GRU+XGB) dažnai pranoko adaptuotas svorio skaičiavimo metodikas (LR, Elastic Net, SGD).
- Tai rodo, jog paprastas, bet stabilus modelių jungimas gali geriau atspindėti rinkos dinamiką nei sudėtingi, bet mažiau patvarūs metodai.
- Iš visų indeksų labiausiai prognozuojami ir pelningi buvo DAX (GDAXI) bei NASDAQ-100 (NDX), o FTSE 100 ir DJI parodė silpnesnius rezultatus. Tai leidžia manyti, kad modelių efektyvumas priklauso nuo konkrečios rinkos struktūros – likvidumo, sektorių sudėties, volatilumo.


- Šie rezultatai atskleidžia esminę išvalgą: aukštas statistinis tikslumas nebūtinai reiškia finansinį pelningumą. Vien tik klaidų rodiklių (MSE, MAE, R^2) naudojimas yra nepakankamas vertinant prognozavimo modelius finansų srityje.
- Tikslesnę informaciją suteikia pelningumo rodikliai – bendra grąža, maksimali korekcija ir rizikos–grąžos santykiai.
- LSTM modelis pasirodė kaip patikimiausias pavienis metodas, o XGBoost – rizikingiausias, bet potencialiai pelningiausias. Ansambliai, jungiantys heterogeninius modelius, parodė didžiausią tvarumą ir pritaikomumą.

R^2 šiluminis žemėlapis skirtinguose modeliuose ir indeksuose. Didesnės vertės rodo geresnį statistinį atitikimą.




Gražos šiluminis žemėlapis pagal modelius ir indeksus.
Teigiamos vertės (žalia) rodo pelningas strategijas, o
neigiamos vertės (raudona) – nuostolius.

Vilniaus
universitetas



R^2 ir gražos visuose modeliavimuose. Silpnas ryšys vizualiai patvirtina, kad didelis statistinis tikslumas nereiškia pelningumo.




- Buvo pasiektos išvados:
 - Tikslumas $\neq$ pelningumas. Aukštas R^2 ne visada užtikrina finansinę sėkmę.
 - Ansambliai turi pranašumą. Modelių deriniai dažnai pranoksta pavienius metodus.
 - Svorio optimizavimo ribotumai. Sudėtingi svorių metodai ne visada veiksmingesni už paprastą vidurkinimą.
 - Indeksų skirtumai. GDAXI ir NDX buvo sėkmingiau prognozuojami, o FTSE ir DJI – prasčiausiai.
 - Praktinė nauda. Finansų prognozavime būtina derinti statistinius ir finansinius rodiklius bei valdyti riziką.

- Šiame darbe buvo naudojamos tik uždarymo kainų gražos kaip pagrindinis signalas. Rezultatai parodė, kad vien šio rodiklio gali nepakakti formuojant pelningas strategijas. Todėl tolimesni tyrimai orientuosis į dvi kryptis:
 - Portfelio formavimą tarp kelių aktyvų. Tai leis išnaudoti diversifikaciją, analizuoti tarprinkines sąsajas ir pritaikyti ansamblius platesniame investavimo kontekste.
 - Papildomų kintamųjų integraciją. Įtraukiant dienos vidinius rodiklius, makroekonominius duomenis, rinkos nuotaikų matavimus bei volatilumo indeksus, modeliai gali pagerinti kryptingumo tikslumą ir sumažinti triukšmo poveikį.
- Taip ateities darbai pereis nuo vieno indekso prognozavimo prie daugiamatės, portfelio grįstos prognozės, kurios tikslas – užtikrinti ne tik statistinį tikslumą, bet ir realų finansinį pelningumą.

Geriausio bendro rezultato modelio kapitalas laikui bėgant

Vilniaus
universitetas



Bendruosius gebėjimus stiprinančios veiklos

Vilniaus
universitetas

Dalyko pavadinimas	Data	Programos trukmė val.	Programos apimtis kreditais ECTS	Trumpas turinio aprašas
Lietuvos akademinė elektroninė biblioteka (eLABa): autoriaus sąsaja	2022-11-08	1,5	0,15	Paskaitos tikslas – supažindinti su Lietuvos akademinės elektroninės bibliotekos sistemos funkcijomis, struktūra, galimybėmis, eLABa autoriaus sąsaja, dokumentų registravimu ir viso teksto (failų) įkėlimu, įrašų importu, licencinių sutarčių pasirašymu ir eLABa ataskaitų formavimu.
LATEX	2022-11-08 2022-11-15	8	1,25	Šiame dalyke studentai supažindinti su teksto redagavimo programa LaTeX. 1. Instaliavimas ir paruošimas darbui; 2. Preambulė; 3. Teksto redagavimas; 4. Formulės ir specialūs simboliai; 5. Paveikslėliai ir lentelės; 6. Nuorodos ir bibliografija; 7. Aplinkos; 8. Pateiktys.
Mokslinių tyrimų duomenų valdymo įvadas	2023-11-08	1,5	0,15	Mokymų tikslas – supažindinti su mokslinių tyrimų duomenų ir jų valdymo sąvokomis bei mokslinių tyrimų duomenų gyvavimo ciklu. Juose bus aptariami svarbiausi sudėtiniai mokslinių tyrimų duomenų valdymo aspektai ir pateikiama praktiškų darbinių duomenų priežiūros bei organizavimo patarimų.
Mokslinių tyrimų duomenų valdymo plano sudarymas	2023-11-09	1	0,1	Paskaitos tikslas - supažindinti su duomenų valdymo plano kaip kartu su projekto paraiška teikiamo dokumento specifiška. Paskaitoje bus aptariama, į ką vertėtų atkreipti dėmesį rengiant duomenų valdymo planą ir bus pristatyti duomenų valdymo plano rengimą palengvinantys įrankiai (DVP Vedlys, DMP Online ir kt.).
FAIR duomenų principai	2023-11-09	1	0,1	Mokymų tikslas – supažindinti su mokslinių tyrimų duomenų pateikimo rekomendacijomis, plačiau žinomomis kaip „FAIR principai“. Šių principų laikymasis padidina mokslinio tyrimo metu sukurtų duomenų pridėtinę vertę, be to šių principų laikytis reikalauja Europos Sąjungos mokslo finansavimo programos ir kai kurie akademiniai leidėjai. Mokymuose sužinosite, kokias duomenų savybes įvardija kiekviena akronimo FAIR raidė ir ką daryti, kad šias savybes turėtų Jūsų sukurti duomenys. Formatas: paskaita (1 val.) ir savarankiško darbo užduotys

Bendruosius gebėjimus stiprinančios veiklos

Duomenų talpyklos ir duomenų žurnalai	2023-11-10	1	0,1	Paskaitos tikslas - supažindinti su mokslinių tyrimų duomenų saugojimui ir publikavimui skirtomis platformomis - duomenų talpyklomis. Bus aptariami pagrindiniai duomenų talpyklų tipai, pristatomos populiariausios bendro pobūdžio talpyklos, patariama, kaip pasirinkti tinkamą talpyklą savo duomenims. Taip kalbėsime, kas yra duomenų žurnalai ir kuo jie skiriasi nuo įprastų mokslinių žurnalų.
MIDAS naudojimas	2023-11-10	1	0,1	Paskaitoje bus supažindinama su Nacionaliniu mokslinių tyrimų duomenų archyvu (MIDAS) bei jo funkcijomis: publikuotų duomenų peržiūra, duomenų įkėlimu ir publikavimu, bendradarbiavimą palengvinančiomis funkcijomis, naudotojo paskyros tvarkymu.
Informacijos saugojimas ir citavimas naudojantis programa Zotero	2023-11-14	1,5	0,15	Trumpas programos Zotero pristatymas. Praktinis darbas su programa Zotero: Įdiegimas ir pasiruošimas darbui; Mokslinių informacijos šaltinių išsaugojimo galimybės; Citavimo nuorodų ir literatūros sąrašo sudarymas; Papildomos programos funkcijos.
Pedagoginė veikla			1	2022-2023 mokslo metų pirmojo pusmečio metu dėčiau „Informacinės saugos pagrindai“ pratybas informacinių sistemų inžinerijos ketvirtakursiams. 2023-2024 mokslo metų pirmojo pusmečio metu dėčiau „Finansų inžinerija ir modeliavimas“ pratybas informacinių sistemų inžinerijos trečiakursiams. 2022-2023 mokslo metų antrojo pusmečio metu Recenzavau du Programų sistemų programos bakalauro baigiamuosius darbus „Giliųjų neuroninių tinklų taikymas kriptovaliutų kainų ir tendencijų prognozavimui“ ir „Nordpool elektros kainų prognozavimas naudojant dirbtinio intelekto algoritmus“; 2023-2024 mokslo metų pirmojo pusmečio metu recenzavau Informacinių technologijų programos bakalauro baigiamąjį darbą „Decentralizuota vertybinių popierių valdymo sistema paremta blokų grandinių technologija“.

Kito pusmečio darbo planas

1. Gautų rezultatų analizė ir apibendrinimas
2. Publikacija žurnale su citavimo rodikliu. Straipsnis įteiktas rugsėjo mėnesį į Q1 žurnalą Romanian Journal of Information Science and Technology (ROMJIST). <https://www.romjist.ro>
3. Paruošti ir pateikti antrą straipsnį iki 2026 metų kovo mėnesio.



**Vilniaus
universitetas**

Ačiū už dėmesį

Aivaras Bielskis

VU DMSTI doktorantas

aivaras.bielskis@mif.stud.vu.lt