



**Vilniaus
universitetas**

Ataskaitinė informatikos krypties doktorantų konferencija 2026-10-08

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.

2026 m. kovo mėn. 24 d. – 2026 m. spalio mėn. 5 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

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	Publikuota ⁵			
IV (2025/2026)	1	1 ⁶			1	2	Priimta ⁷ , Įteikta ⁸			
Iš Viso	2	3	0	0	2	3	0	0	1	0

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

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	Publikuota ⁵			
IV (2025/2026)	1	1 ⁶			1	2	Priimta ⁷ , Įteikta ⁸			
Iš Viso	2	3	0	0	2	3	0	0	1	0

⁴ Bielskis A. *Advanced Machine Learning Techniques For Investment Forecasting: An Integrated Approach*. The International Conference on Optimization and Decision Science (ODS 2025), Milan, Italy, 1–4 September 2025. Oral presentation.

⁵ Bielskis A. and Belovas I. *Machine Learning Models and Ensemble Methods for Stock Index Return Forecasting*. Networks and Heterogeneous Media, Q3, 2026, 21(3), p. 848–864. DOI: 10.3934/nhm.2026035.

⁶ Bielskis A. *A Two-Level Mixture-of-Experts Model for Regime-Adaptive Financial Forecasting and Trading Strategy*. 24th Conference of the International Federation of Operational Research Societies (IFORS), Vienna, Austria, 12–17 July 2026.

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	Publikuota ⁵			
IV (2025/2026)	1	1 ⁶			1	2	Priimta ⁷ , Įteikta ⁸			
Iš Viso	2	3	0	0	2	3	0	0	1	0

⁷ Straipsnis priimtas publikavimui - Bielskis A. and Belovas I. *Stock Return Forecasting and Portfolio Construction Using an Event-Conditional Mixture-of-Experts Framework*. Electronic Research Archive, Q1.

⁸ Straipsnis įteiktas (recenzuojamas) - Bielskis A. and Belovas I. *Portfolio Construction with Regime-Gated Selective Prediction*. Expert Systems with Applications, Q1.

Ataskaitinio pusmečio darbų planas ir jų vykdymo suvestinė

Egzaminai			
Planas	Įvykdyta	Būklė	
Dalyvavimas konferencijose			
Planas	Įvykdyta	Konferencijos tipas	
Tarptautinė konferencija	Bielskis A. A Two-Level Mixture-of-Experts Model for Regime-Adaptive Financial Forecasting and Trading Strategy. 24th Conference of the International Federation of Operational Research Societies (IFORS 2026), Vienna, Austria, 12–17 July 2026. Oral presentation.		
Publikacijos			
Planas	Įvykdyta	Būklė	Publikacijos tipas
Žurnalas, turintis cituojamumo rodiklį	Bielskis A. and Belovas I. Stock Return Forecasting and Portfolio Construction Using an Event-Conditional Mixture-of-Experts Framework. Electronic Research Archive	Priimtas publikavimui	Žurnalas turi cituojamumo rodiklį, Q1
	Bielskis A. and Belovas I. Portfolio Construction with Regime-Gated Selective Prediction. Expert Systems with Applications	Pateiktas (recenzuojamas)	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.	Įvykdyta
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.	Įvykdyta
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 tyrinėjama tema tiek pasaulyje, tiek Lietuvoje. Esami metodai nuolat tobulinami, ieškoma naujų sprendimų, o rinkos tiriamos atsižvelgiant į naujausius įvykius ir procesus.
- Doktorantūroje pasirinkta tema „Vertybinių popierių kainų prognozavimas ir investicinio portfelio formavimas naudojant mašininio mokymosi algoritmus“ tęsia mano bakalauro baigiamąjį darbą „Investicinio portfelio optimizavimas“ ir magistro baigiamąjį darbą „Prognozavimo metodų analizė“.
- Tema yra svarbi, nes darbo rezultatai gali padėti investuotojams ir finansų analitikams geriau valdyti investicinius portfelius ir priimti pagrįstus sprendimus.
- Mašininio mokymosi algoritmai yra vis plačiau taikomi vertybinių popierių kainų pokyčiams prognozuoti ir investiciniams portfeliams sudaryti.

Tyrimo objektas

- Tyrimo objektas yra vertybinių popierių ir akcijų indeksų kainų bei gražų prognozavimo algoritmai ir šių prognozių pagrindu taikomi investicinių portfelių formavimo bei optimizavimo metodai.

Tyrimo tikslas

- Tyrimo tikslas yra sukurti ir įvertinti mašininio mokymosi metodus vertybinių popierių gražoms prognozuoti ir investiciniams portfeliams formuoti. Daugiausia dėmesio skiriama tam, ar didesnis prognozavimo tikslumas lemia geresnius portfelio rezultatus.

Mokslinės problemos

1. Finansinių duomenų rinkimas ir parengimas mašininio mokymosi modeliams.
2. Esamų mašininio mokymosi algoritmų, skirtų vertybinių popierių kainoms prognozuoti ir investiciniam portfeliui valdyti, modifikavimas (tobulinimas):
 - prognozavimo tikslumo problema;
 - rizikos valdymo problema;
 - strategijos parinkimo problema;
 - stabilumo problema;
 - palyginimo ir verifikacijos problemos.

Tyrimo uždaviniai

1. Surinkti ir apdoroti finansinius duomenis, reikalingus prognozavimui ir portfelio formavimui, ir išnagrinėti papildomą rinkos informaciją, kuri gali pagerinti prognozes ir portfelio sprendimus.
2. Ištirti esamus mašininio mokymosi algoritmus vertybinių popierių kainų ir grąžų prognozavimui bei investicinių portfelių formavimo ir optimizavimo metodus, palyginti jų prognozavimo tikslumą ir portfelių rezultatus, naudojant istorinius duomenis, ir nustatyti jų trūkumus bei ribotumus.

Tyrimo uždaviniai

3. Pasiūlyti ir pritaikyti efektyvius mašininio mokymosi metodus vertybinių popierių kainoms prognozuoti ir portfeliams formuoti; sukurti naujas mašininio mokymosi taikymo portfelių valdymui strategijas; derinti tradicinius finansų modelius su mašininio mokymosi metodais ir įvertinti jų poveikį prognozėms ir portfelio rezultatams.
4. Palyginti sukurtus mašininio mokymosi modelius ir investavimo strategijas su esamais modeliais ir strategijomis pagal jų veiksmingumą.

Bendra tyrimo schema

1. Svarbiausia idėja: vertinu ne tik prognozės tikslumą, bet ir jos ekonominę vertę, t. y. ar ji padeda priimti geresnį investicinį sprendimą.
2. Rezultatai lyginami su paprastu lygių svorių portfeliu, kuriame kapitalas po lygiai paskirstomas visiems naudojamiems investiciniams aktyvams.
3. Kiekviename tyrime tikrinu, ar modelis padeda sudaryti portfelį, kurio grąža didesnė, rizika mažesnė arba rezultatai stabilesni.



Trumpas per pusmetį gautų mokslinių rezultatų pristatymas


Vilniaus
universitetas

- Publikuotas straipsnis apie modelių ansamblius (Networks and Heterogeneous Media, trečiojo kvartilio žurnalas).
- Užbaigtas ekspertų mišinio modelis. Straipsnį priėmė spausdinti Electronic Research Archive (pirmojo kvartilio žurnalas).
- Parengtas trečiasis straipsnis apie pasirinktinį prognozavimą. Šiuo metu jį recenzuoja Expert Systems with Applications (pirmojo kvartilio žurnalas).
- Atliktas pranešimas tarptautinėje konferencijoje IFORS 2026 (Viena).
- Parengtas disertacijos juodraštis.

- 1 skyrius. Literatūros apžvalga.
- 2 skyrius. Modelių ansambliai akcijų indeksų grąžoms prognozuoti.
- 3 skyrius. Įvykiais sąlygotas ekspertų mišinys akcijų grąžoms prognozuoti.
- 4 skyrius. Portfelių sudarymas pagal rinkos režimus ir prognozių patikimumą.
- Bendrosios išvados ir santrauka lietuvių kalba.

1 tyrimas. Modelių ansambliai

- Naudojant penkis akcijų indeksus palyginti penki modeliai (LSTM, GRU, transformer, XGBoost ir DMLP) ir jų ansambliai.
- Kiekviena prognozė panaudota prekybos strategijoje. Iš viso įvertinti 545 scenarijai.
- Kiekviena indekse geriausia konfigūracija buvo ansamblis. Geriausias (GRU, LSTM ir XGBoost vidurkis, S&P 500) pasiekė 67 % bendrąją grąžą.
- Visų modelių R^2 viršijo 0,98, tačiau R^2 ir bendrosios grąžos koreliacija buvo tik $r = 0,07$.
- Taigi didelis tikslumas neparodo, kuris modelis duos geriausius prekybos rezultatus.




2 tyrimas. Įvykiais sąlygotas ekspertų mišinys

1. Event-MoE modelis jungia tris ekspertus: LSTM, GRU ir transformer.
2. Jų prognozes sujungia mokomas tinklas, kuris kiekvienam ekspertui parenka svorį ir atsižvelgia į FOMC, CPI ir NFP pranešimų datas.
 1. FOMC: JAV Federalinio rezervų sprendimai dėl palūkanų normų;
 2. CPI: vartotojų kainų indeksas, rodantis infliaciją;
 3. NFP: JAV darbo vietų skaičiaus pokytis ne žemės ūkio sektoriuje.
3. Antroji modelio dalis yra režimų panašumo sluoksnis. Jis derina skirtingų istorinių laikotarpių duomenimis apmokytus mišinius pagal tai, kiek dabartinė rinka panaši į kiekvieną laikotarpį.


Kaip veikia antrasis tyrimas: nuo duomenų iki portfelio

- Tyrimui naudojamos 40 akcijų dienos kainos ir FOMC, CPI bei NFP pranešimų kalendorius (apie 870 datų).
- Kiekvienai dienai apskaičiuojama trylika požymių: šeši techniniai, šeši pagal pranešimų kalendorių ir vienas, rodantis, kokiam laikotarpiui į priekį atliekama prognozė.
- Prognozė sudaroma pagal ankstesnių 30 dienų duomenis.
- Kiekvieno istorinio laikotarpio ekspertų mišinys mokomas naudojant visų keturiasdešimtys akcijų duomenis kartu.
- Pagal galutines prognozes atrenkamos akcijos ir sudaromas portfelis, įvertinus sandorių kaštus.




Kaip veikia Event-MoE modelis

- Kiekvienas ekspertas (LSTM, GRU ir transformer) pagal tuos pačius duomenis pateikia savo prognozę.
- Svorius parenkantis tinklas naudoja rinkos būsenos ir pranešimų požymius, todėl artėjant pranešimui svoriai gali keistis.
- Galutinė prognozė yra svertinė ekspertų prognozių suma (paveiksle Σ).
- Išplėstiniame modelio variante papildomai naudojamas tiesinis ekspertas.
- Taigi modelis kiekvieną dieną pats nusprendžia, kuriam ekspertui suteikti didesnę svorį.




Režimų panašumas ir makroekonominiai pranešimai

- Kiekvienam istoriniam laikotarpiui sudaromas profilis: kiekvieno požymio vidurkis ir standartinis nuokrypis.
- Dabartinė rinka lyginama su kiekvieno laikotarpio profiliu. Kuo laikotarpis panašesnis, tuo didesnę svorį gauna jo mišinio prognozė.
- Pranešimų požymiai rodo, kiek dienų liko iki kito FOMC, CPI ar NFP pranešimo (nuo 0 iki 5), ir ar pranešimas skelbiamas tą dieną (1 arba 0).
- Trumpi laikotarpiai, pasirinkti pagal atskiras krizes, mokymui suteikė per mažai duomenų, todėl geriau veikė ilgesni, iš dalies persidengiantys laikotarpiai.



2 tyrimo rezultatai: kas pagerino prognozes

- Didžiausią pagerėjimą davė ekspertų mokymas visų keturiasdešimties akcijų duomenimis: mėnesio informacijos koeficientas padidėjo nuo 0,034 iki 0,086 (maždaug 2,5 karto).
- Tik taip mokyto modelio mėnesio informacijos koeficientas buvo teigiamas visais testavimo metais ($t = 2,24$).
- Makroekonominių pranešimų kalendorius informacijos koeficientą padidino 0,006.
- Taigi ekspertams trūko ne modelio sudėtingumo, o duomenų.



2 tyrimo rezultatai: portfeliai

- Geriausias diversifikuotas mėnesio portfelis (Event-MoE) uždirbo 34,94 % per metus, jo Sharpe rodiklis buvo 1,96.
- Tai daugiau nei 1/N portfelio (30,67 %, Sharpe rodiklis 1,77) bei MinVariance ir MaxSharpe portfelių, kurie prognozių nenaudoja, rezultatai.
- Didžiausias nuosmukis buvo mažesnis nei 1/N portfelio (16,9 % ir 18,7 %), o per testavimo laikotarpį 10 000 išaugo iki 27 620.
- Jobsono ir Korkie testas reikšmingo skirtumo nuo 1/N neparodė ($p = 0,70$).
- Visų 18 portfelių informacijos koeficiento ir Sharpe rodiklio koreliacija buvo tik $r = 0,28$, todėl modelius verta rinktis pagal portfelio rezultatus.

2 tyrimo rezultatai: portfeliai



Vilniaus
universitetas

Equity curves at the monthly horizon (net of cost), TopK-K7 vs 1/N




3 tyrimas. Pasirinktinis prognozavimas

- Modelis gali ne tik pirkti ar parduoti, bet ir susilaikyti nuo prekybos, kai prognozė nepakankamai patikima arba rinkos režimas netinkamas.
- Rinkos režimams nustatyti naudojamas Gaussian mixture model (GMM). Išbandyta 28 800 konfigūracijų (LSTM, XGBoost ir KNN).
- Prekiaujant kas mėnesį, didžiausias nuosmukis sumažėjo nuo 18,6 % iki maždaug 11 %, o išlaikyti apie du trečdaliai grąžos.
- Pagal Calmar rodiklį tokie portfeliai pranoko 1/N portfelį 68 procentuose konfigūracijų.



Kaip veikia 3 tyrimas

- LSTM, XGBoost ir KNN modeliai prognozuoja ne grąžą, o tikimybę, kad akcijos kaina kils.
- Rinkos režimus nustato Gaussian mixture model (GMM). Prekiauti leidžiama tik tame režime, kuriame validavimo laikotarpiu buvo pakankamai stebėjimų ir modelis buvo pakankamai tikslus.
- Modelis perka, kai režimas tinkamas ir tikimybė viršija viršutinį slenkstį, o parduoda, kai tikimybė mažesnė už apatinį slenkstį. Kitais atvejais jis susilaiko nuo prekybos.
- Atrinktos akcijos sudaro lygių svorių portfelį. Visi slenksčiai nustatomi tik pagal validavimo duomenis.



- Sukūrėme sistemą, kurioje kiekvienos prognozės ekonominė vertė įvertinama prekybos strategijoje. Ji parodė, kad vien tikslumas neparodo, kuri strategija pelningiausia.
- Akcijų indeksų tyrime modelių ansambliai pasiteisino: kiekviename indekse geriausia konfigūracija buvo ansamblis.
- Kai ekspertus mokėme visų keturiasdešimties akcijų duomenimis, mėnesio informacijos koeficientas išaugo maždaug 2,5 karto.
- Event-MoE modelis leido sudaryti geriausią diversifikuotą mėnesio portfelį: 34,94 % per metus, Sharpe rodiklis 1,96. Tai daugiau nei 1/N portfelio, o didžiausias nuosmukis mažesnis (16,9 % ir 18,7 %).
- Taisyklė, leidžianti modeliui neprekiuoti, kai prognozė nepakankamai patikima, veikia kaip praktiška rizikos valdymo priemonė. Prekiaujant kas mėnesį, ji sumažino didžiausią nuosmukį nuo 18,6 % iki maždaug 11 % ir išlaikė apie du trečdalius grąžos.

- Didelis prognozavimo tikslumas nebūtinai lemia pelningą prekybą, todėl prognozavimo modelius reikia vertinti pagal iš jų prognozių sudarytus portfelius.
- Kelių akcijų sutelktų duomenų naudojimas gali pagerinti mėnesio grąžų prognozes labiau nei modelio sudėtingumo didinimas.
- Įvertinus sandorių kaštus, įvykiais sąlygotu ekspertų mišiniu galima sudaryti portfelį, kurio grąža ir Sharpe rodiklis didesni, o nuosmukis mažesnis nei lygių svorių portfelio, nors skirtumas nėra statistiškai reikšmingas.
- Pasirinktinė prekyba gali gerokai sumažinti nuosmukį ir išlaikyti didžiąją dalį grąžos, o griežtas režimų filtras gali pabloginti rezultatus naujuose duomenyse.

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 specifika. 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 pat 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 dėščiau „Informacinės saugos pagrindai“ pratybas informacinių sistemų inžinerijos ketvirtakursiams. 2023-2024 mokslo metų pirmojo pusmečio metu dėščiau „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. Daktaro disertacijos gynimas.



**Vilniaus
universitetas**

Ačiū už dėmesį

Aivaras Bielskis

VU DMSTI doktorantas

aivaras.bielskis@mif.stud.vu.lt