



STUDIJŲ DALYKO (MODULIO) APRAŠAS

Dalyko (modulio) pavadinimas	Kodas
Dirbtinio intelekto pagrindai	

Dėstytojas (-ai)	Padalinys (-iai)
Koordinuojantis: prof. dr. Olga Kurasova Kitas (-i): dr. Viktor Medvedev	Matematikos ir informatikos fakultetas Duomenų mokslo ir skaitmeninių technologijų institutas

Studijų pakopa	Dalyko (modulio) tipas
Pirmoji	Pasirenkamas

Įgyvendinimo forma	Vykdymo laikotarpis	Vykdymo kalba (-os)
Auditorinė	6 semestras	Lietuvių

Reikalavimai studijuojančiajam	
Išankstiniai reikalavimai: Algoritmai ir duomenų struktūros, Procedūrinis programavimas, Objektinis programavimas, Statistiniai duomenų analizės metodai, Optimizavimo metodai	Gretutiniai reikalavimai (jei yra):

Dalyko (modulio) apimtis kreditais	Visas studento darbo krūvis	Kontaktinio darbo valandos	Savarankiško darbo valandos
5	133	64	69

Dalyko (modulio) tikslas: studijų programos ugdomos kompetencijos		
Dalyko tikslas – siekiama, kad studentai įgytų žinių apie dirbtinį intelektą, susipažintų su dirbtiniais neuroniniais tinklais, jais sprendžiamų uždavinių klasėmis, tinklų struktūromis ir tinklų mokymo strategijomis, ugdytų praktinius gebėjimus taikyti dirbtinio intelekto metodus sprendžiant įvairius uždavinius.		
Dalyko (modulio) studijų siekiniai	Studijų metodai	Vertinimo metodai
Gebės atlikti su dirbtinio intelekto uždavinių sprendimu susijusios literatūros paiešką, atlikti analizę, įsisavinti naujas žinias ir jas pritaikyti sprendžiant praktines užduotis.	Paskaita-diskusija, sąvokų žemėlapis, pavyzdžių demonstravimas ir analizė, informacijos paieška ir analizė, savarankiškas darbas, praktinės užduotys, rašto darbas, darbo pristatymas.	Praktiniai darbai, jų pristatymas ir gynimas, kolokviumas, egzaminas.
Gebės projektuoti ir pasirinkus optimalias našiųjų skaičiavimų įgyvendinimo priemones kurti dirbtiniu intelektu grindžiamus programinius sprendimus.		
Gebės tirti dirbtinio intelekto algoritmus, vertinti jų rezultatus, formuluoti išvadas.		
Gebės spręsti duomenų analizės uždavinius, taikant dirbtinio intelekto metodus.		

Temos	Kontaktinio darbo valandos						Savarankiškų studijų laikas ir užduotys		
	Paskaitos	Konsultacijos	Seminarai	Pratybos	Laboratoriniai darbai	Praktika	Visas kontaktinis darbas	Savarankiškas darbas	Užduotys
1. Įvadinė dalis. Dirbtinio intelekto sąvokos apibrėžtis. Dirbtinio intelekto vystymosi istorija. Dirbtinio intelekto metodų tipai. Dirbtinio intelekto metodų skirtumai nuo įprasto programavimo.	6				6		12	12	Literatūros paieška ir analizė.

Sprendžiamų uždavinių klasės: klasifikavimas, atpažinimas, klasterizavimas, prognozavimas. Mašininis mokymasis. Dirbtinio neurono modelis, jo sąsajos su biologiniu neuronu. Dirbtinių neuroninių tinklų tipai pagal jų architektūrą ir mokymo strategijas (prižiūrimas, neprižiūrimas, pusiau prižiūrimas mokymasis).									
2. Vienasluoksnis perceptronas. Perceptrono apibrėžtis. Perceptrono naudojimas klasifikavimo uždavinių sprendime. Pradinių svorių parinkimas. Aktyvacijos funkcijos. Paklaidos (nuostolių) funkcijos. Mokymo strategijos. Gradientinis nusileidimas: paketinis, stochastinis, mažų paketų. Charakteringas perceptrono mokymo pavyzdys. Klasų skiriamųjų paviršių radimas. Klasifikavimo tikslumo matai. Klasifikavimo matrica. Rezultatų interpretavimas.	6				6		12	12	Literatūros paieška ir analizė, praktinių užduočių atlikimas (planavimas ir vykdymas), rašto darbo parengimas, rezultatų pristatymas.
3. Daugiasluoksniai tiesioginio sklidimo neuroniniai tinklai. Tinklų architektūra. Klaidos sklidimo atgal mokymo algoritmas. Charakteringi tinklo mokymo pavyzdžiai. Neuroninio tinklo taikymai rašto ženklų atpažinime bei sprendžiant klasifikavimo uždavinius. Tinklo persimokymas ir būdai kaip to išvengti. Nykstančio gradiento problema. Neuroniniai tinklai duomenims prognozuoti. Prognozavimo tikslumo vertinimas. Programinės sistemos, kuriose įgyvendinti tiesioginio sklidimo neuroniniai tinklai.	8				8		16	18	
4. Gilieji neuroniniai tinklai. Giliųjų neuroninių tinklų sąvokos apibrėžtis. Konvoliuciniai neuroniniai tinklai: konvoliucinis sluoksnis, sujungimo sluoksnis, pilnai sujungtas sluoksnis, ReLU aktyvacijos funkcija, nuostolių funkcija, optimizatoriai, mokymo strategija, aktyvacijos funkcija išėjimų sluoksnyje. Kapsuliniai neuroniniai tinklai. Vaizdų lokalizavimas ir segmentavimas taikant neuroninius tinklus. Gilieji neuroniniai tinklai duomenims prognozuoti: RNN, LSTM, trasformeriai. Generatyvinis dirbtinis intelektas. Programinės bibliotekos gilesiems neuroniniams tinklams įgyvendinti.	8				8		16	19	
5. Saviorganizuojantys neuroniniai tinklai (SOM). Klasterizavimo uždavinio sprendimas. K-vidurkių metodas. Mokymosi strategija „Nugalėtojas laimi viską“. Neprižiūrimas mokymasis. Galimos SOM topologijos. SOM mokymo taisyklės. SOM mokymo algoritmas. SOM vizualizavimo būdai. Uždaviniai, sprendžiami taikant SOM. Programinės sistemos, kuriose įgyvendinti saviorganizuojantys neuroniniai tinklai.	4				4		8	8	
Iš viso	32				32		64	69	

Vertinimo strategija	Svoris proc.	Atsiskaitymo laikas	Vertinimo kriterijai
Praktinės užduotys	50	Semestro metu (pagal semestro pradžioje pateiktą atsiskaitymų tvarkaraštį)	Studentai privalo atlikti 5 praktines užduotis, paruošti rašto darbus (ataskaitas) ir jas individualiai apginti atsakant į užduodamus klausimus. 9–10 balai – darbas tenkina visus būtinus reikalavimus: rašto darbo struktūra aiški ir logiška, yra visos reikiamos dalys (darbo tikslas, uždaviniai, eksperimentų vykdymo aprašas, rezultatai, išvados), darbas tinkamai suformatuotas, nėra loginių, gramatinių, stiliaus ir korektūros klaidų, rezultatų analizė išsami, išvados pagrįstos, studentas atsako į užduotus klausimus; 7–8 balai – yra visos reikiamos rašto darbo dalys (darbo tikslas, uždaviniai, eksperimentų vykdymo aprašas, rezultatai, išvados), tačiau yra trūkumų: ne visos darbo dalys tinkamai suformatuotos, yra loginių, gramatinių, stiliaus ar korektūros klaidų, rezultatų analizė nepakankamai išsami, ne visos išvados yra pagrįstos, studentas atsako ne į visus užduotus klausimus. 5–6 balai – yra ne visos būtinos rašto darbo dalys, analizė yra paviršutiniška ir fragmentiška, ne visos išvados pagrįstos, yra esminių loginių klaidų, daug gramatinių, stiliaus ar korektūros klaidų, ne į visus esminius klausimus studentas geba atsakyti.

			1–4 balai – rašto darbas blogai struktūrizuotas, turi labai daug esminių klaidų, studentas neatsako į klausimus. 0 balų – rašto darbas nėra pateiktas arba nėra apgintas. Yra laikoma, kad studentas yra atsiskaitęs už darbą, kai rašto darbas įkeltas į sistemą ir apgintas. Pavėlavus 2 savaites atsiskaityti, įvertinimas mažinamas dviem balais, 3 savaites – trimis balais. Vėliau darbas nebus vertinamas. Praktines užduotis būtina atsiskaityti ne vėliau kaip paskutinę praktinių užsiėmimų paskaitą.
Kolokviumas	20	Semestro viduryje	Kolokviumo užduotį sudaro 20 atvirojo ir uždarojo tipo klausimų. 2 balai – puikios žinios ir gebėjimai. 18–20 teisingų atsakymų, 1,5 balai – geros žinios ir gebėjimai. 15–17 teisingų atsakymų, 1 balas – vidutinės žinios ir gebėjimai, yra klaidų. 10–14 teisingi atsakymai; 0,5 balo – žinios ir gebėjimai dar patenkina minimalius reikalavimus, tačiau daug klaidų. 5–9 teisingų atsakymų; 0 balų – nepatenkinami minimalūs reikalavimai. 0–4 teisingi atsakymai.
Egzaminas	30	Egzaminų sesijos metu	Studentas įgyja teisę laikyti egzaminą tik tuo atveju, jeigu jo suminis praktinių užduočių įvertinimas yra ne mažesnis nei 50 % galimo maksimalaus suminio įvertinimo. Egzamino užduotį sudaro 30 atvirojo ir uždarojo tipo klausimų. 3 balai – puikios žinios ir gebėjimai. 25–30 teisingų atsakymų, 2 balai – geros žinios ir gebėjimai. 19–24 teisingų atsakymų, 1,5 balo – vidutinės žinios ir gebėjimai, yra klaidų. 13–18 teisingi atsakymai; 1 balas – žinios ir gebėjimai nesiekia vidutinių, yra esminių klaidų. 7–12 teisingi atsakymai; 0 balų – nepatenkinami minimalūs reikalavimai. 0–6 teisingi atsakymai. Egzaminą eksternu laikyti negalima.

Autorius(-iai)	Leidimo metai	Pavadinimas	Periodinio leidinio Nr. ar leidinio tomas	Leidimo vieta ir leidykla ar internetinė nuoroda
Privaloma literatūra				
Kurasova O., Medvedev V.	2024	Dirbtinio intelekto pagrindai		VU virtuali mokymo aplinka https://emokymai.vu.lt
Dzemyda, G., Kurasova, O., Žilinskas, J.	2008	Daugiamatčių duomenų vizualizavimo metodai		Vilnius: Mokslo aidai. http://web.vu.lt/mii/j.zilinskas/DzemydaKurasovaZilinskasDDVM.pdf
Deisenroth, M. P., Faisal, A. A., Ong, C. S.	2020	Mathematics for Machine Learning.		Cambridge University Press, https://mml-book.com
Haykin, S. O.	2009	Neural Networks and Learning Machines (3rd Edition).		Pearson Prentice Hall
Zhang, A., Lipton, Z. C., Li, M., Smola, A. J.	2023	Dive into deep learning., arXiv preprint arXiv: 2106.11342		Cambridge University Press http://d2l.ai/index.html
Papildoma literatūra				
Baldi P.	2021	Deep Learning in Science		Cambridge University Press https://doi.org/10.1017/9781108955652
Chollet F.	2021	Deep Learning with Python		Manning Publications Co
Géron A.	2017	Hands-On Machine Learning with Scikit-Learn and TensorFlow		O'Reilly Media, Inc.
Goodfellow, I., Bengio, Y., Courville, A.	2016	Deep learning. MIT press.		https://www.deeplearningbook.org/
Mehlig B.	2021	Machine Learning with Neural Networks: An Introduction for Scientists and Engineers		Cambridge University Press, https://doi.org/10.1017/9781108860604



COURSE UNIT (MODULE) DESCRIPTION

Course unit (module) title	Code
Fundamentals of Artificial Intelligence	

Lecturer(s)	Department(s) where the course unit (module) is delivered
Coordinator: Prof. Dr. Olga Kurasova Other(s): Dr. Viktor Medvedev	Faculty of Mathematics and Informatics Institute of Data Science and Digital Technologies

Study cycle	Type of the course unit (module)
First	Optional

Mode of delivery	Period when the course unit (module) is delivered	Language(s) of instruction
Face-to-face	6 th semester	Lithuanian

Requirements for students	
Prerequisites: Students must have completed the following courses: Algorithms and Data Structures, Procedural and Object-based Programming, Statistical Data Analysis and Optimization Methods.	Additional requirements (if any):

Course (module) volume in credits	Total student workload	Contact hours	Self-study hours
5	133	64	69

Purpose of the course unit (module): programme competencies to be developed
To provide students with knowledge on artificial intelligence, familiarize them with the classes of problems solved by artificial neural networks, the architecture of networks, and the training strategies, to develop the practical abilities to apply artificial intelligence methods for solving various problems.

Learning outcomes of the course unit (module)	Teaching and learning methods	Assessment methods
Ability to perform a search and analysis of the proper literature related to artificial intelligence, to absorb new knowledge on artificial intelligence and to apply it to solve various problems.	Lecture-discussion; Concept maps; Example demonstration and analysis; Literature search and analysis; Self-dependent work; Teamwork; Practical tasks; Written works; Report preparation and presentation.	Practical tasks; their presentation and defence; Mid-term exam, Final exam
Ability to predict the trending direction of the development of artificial intelligence technologies.		
Ability to design and implement software solutions based on artificial intelligence, to choose optimal implementation tools.		
Ability to design and implement artificial intelligence-based algorithms for multiprocessor systems; understanding the application of high-performance computing in data analysis.		
Ability to plan and perform research experiments, investigating artificial intelligence algorithms, evaluate the obtained results, and draw conclusions.		
Ability to solve data mining problems by applying artificial intelligence methods.		

Content: breakdown of the topics	Contact hours						Self-study work: time and assignments		
	Lectures	Tutorials	Seminars	Exercises	Laboratory work	Internship/work placement	Contact hours	Self-study hours	Assignments
1. Introduction. Definition of artificial intelligence. History of artificial intelligence. Types of artificial intelligence methods. Classes of problems: classification, recognition, clustering, prognosis. Machine learning. Model of an artificial neuron and its relation to a biological neuron. Types of artificial neural networks according to their architecture and training strategies (supervised, unsupervised, semi-supervised learning).	6				6		12	12	Literature search and analysis
2. Single-layer perceptron. Definition of a single-layer perceptron. Use of a perceptron in classification. Selecting the initial values of weights. Activation functions. Loss functions. Training strategy. Gradient descent: batch, stochastic, mini-batch. A typical example of training. Class decision boundaries. Classification accuracy measures. Confusion matrix. Interpretation of results.	6				6		12	12	Literature search and analysis; Performing practical tasks; Preparation of written work – report;
3. Multilayer feed-forward neural networks. Network architecture. Error back-propagation algorithm. A typical example of network training. Application of neural networks for optical character recognition and solving classification problems. Network overfitting and how to avoid it. Vanishing gradient problem. Neural networks for data prediction. Evaluating the prediction accuracy. Feed-forward neural network software.	8				8		16	18	Presentation of results.
4. Deep neural networks. Definition of deep neural networks. Convolutional neural networks: convolution layer, pooling layer, fully connected layer, ReLU activation function, loss functions, optimizers, training strategy, and activation function in the output layer. Capsule neural networks. Image localization and segmentation using neural networks. Deep neural networks for data prediction: RNN, LSTM, transformers. Generative artificial intelligence. Software libraries for implementing deep neural networks.	8				8		16	19	
5. Self-organizing maps. Solving the clustering problem. K-means method. Learning strategy “Winner takes all”. Unsupervised learning. SOM topologies. SOM learning rules. SOM training algorithm. SOM visualization ways. Problems solved by applying SOM. SOM software.	4				4		8	8	
Total	32				32		64	69	

Assessment strategy	Weight, %	Deadline	Assessment criteria
Practical tasks	50	During the semester (according to the timetable given at the beginning of the semester)	The students must perform 5 practical tasks, present the reports, and defend them individually by answering the questions asked. 9-10 points – the report satisfies all the necessary requirements: the report structure is clear and logical, there are all the necessary parts (work aim, tasks, description of experiments, results, conclusions), the report is properly formatted, there are no logical, grammatical, stylistic and proofreading errors, the analysis of the results is comprehensive, the conclusions are reasoned, the student answers all questions asked. 7-8 points – all the required parts of the report are presented (work aim, tasks, description of experiments, results, conclusions), but there are shortcomings: not all parts of the report are properly formatted, there are logical, grammatical, stylistic and proofreading errors, the analysis of the

			results is not sufficiently detailed, not all the conclusions are justified, and the student does not answer all the questions asked. • 5-6 points – not all the necessary parts of the report are presented, the analysis is superficial and fragmentary, not all the conclusions are justified, there are fundamental logical errors, many grammatical, stylistic and proofreading errors. The student is not able to answer all the essential questions. • 1-4 points – the report is poorly structured, it has a large number of fundamental errors, the student does not answer the questions. • 0 point – the report is not presented, or it is not defended. A student is considered to have completed the practical task when the report is uploaded to the system and defended. If the delay is 2 weeks, the grade is reduced by 2 points; if the delay is 3 weeks, the grade is reduced by 2 points. Thereafter, the practical task will not be evaluated. Practical tasks must be submitted no later than the last practical lecture.
Mid-term exam	20	Middle of the semester	The mid-term exam is performed after some topics and tests students' theoretical knowledge. The questionnaire consists of 20 open and closed-ended questions: • 2 points – perfect knowledge and abilities. 18-20 correct answers, • 1.5 points – good knowledge and abilities. 15-17 correct answers; • 1 point – average knowledge and abilities, there are mistakes. 10-14 correct answers; • 0.5 point – knowledge and abilities are below average, there are essential mistakes. 5-9 correct answers; • 0 points – the minimal requirements are not satisfied. 0-6 correct answers.
Final exam	30	Exam session	The exam is allowed to be taken if the practical tasks are assessed at no less than 50% of the possible scores. A test consists of 30 questions of open and closed types: • 3 points – perfect knowledge and abilities. 25-30 correct answers, • 2 points – good knowledge and abilities. 19-24 correct answers; • 1.5 points – average knowledge and abilities. 13-18 correct answers; • 1 point – knowledge and abilities are below average, there are essential mistakes. 7-12 correct answers; • 0 points – the minimal requirements are not satisfied. 0-6 correct answers. There is no possibility of taking the exam externally.

Author	Year of publication	Title	Issue of a periodical or volume of a publication	Publishing place and house or web link
Compulsory reading				
Kurasova, O., Medvedev, V.	2024	Basics of Artificial Intelligence		https://emokymai.vu.lt
Deisenroth, M. P., Faisal, A. A., Ong, C. S.	2020	Mathematics for Machine Learning.		Cambridge University Press, https://mml-book.com
Haykin, S. O.	2009	Neural Networks and Learning Machines (3rd Edition).		Pearson Prentice Hall
Zhang, A., Lipton, Z. C., Li, M., Smola, A. J.	2023	Dive into deep learning., arXiv preprint arXiv: 2106.11342		Cambridge University Press http://d2l.ai/index.html
Optional reading				
Baldi P.	2021	Deep Learning in Science		Cambridge University Press https://doi.org/10.1017/9781108955652
Chollet F.	2021	Deep Learning with Python		Manning Publications Co
Géron A.	2017	Hands-On Machine Learning with Scikit-Learn and TensorFlow		O'Reilly Media, Inc.
Goodfellow, I., Bengio, Y., Courville, A.	2016	Deep learning. MIT press.		https://www.deeplearningbook.org/
Mehlig B.	2021	Machine Learning with Neural Networks: An Introduction for Scientists and Engineers		Cambridge University Press, https://doi.org/10.1017/9781108860604