



COURSE UNIT DESCRIPTION

| Course unit title | Course unit code |
|-------------------|------------------|
| Deep learning | |

| Lecturer(s) | Department where the course unit is delivered |
|--|---|
| Coordinator: assoc. prof. dr. Linas Petkevičius | Institute of Computer Science Faculty of Mathematics and Informatics Vilnius University |
| Other lecturers: | |

| Cycle | Type of the course unit |
|--------|-------------------------|
| Second | Optional |

| Mode of delivery | Semester or period when the course unit is delivered | Language of instruction |
|------------------|--|-------------------------|
| Face-to-face | Spring semester | English |

| Prerequisites |
|-----------------------|
| Prerequisites: |

| Number of credits allocated | Student's workload | Contact hours | Individual work |
|-----------------------------|--------------------|---------------|-----------------|
| 5 | 125 | 42 | 83 |

| Purpose of the course unit: programme competences to be developed |
|---|
| Purpose of the course unit – to acquire knowledge of regression/classification usage for complex structure data, generative models, reinforcement and deep learning. Complex data analysis, practical knowledge of machine/deep frameworks. Considered the infrastructure for work with big data, cloud computing solutions. Principles of use deep learning methods for detection and segmentation tasks. Developing teamwork skills, developing critical and analytical thinking. |
| Generic competences: |
| <ul style="list-style-type: none">To solve non-standard theoretical and empirical tasks creatively (GC1).Critically analyze and properly use the scientific literature (GC2).Use interdisciplinary knowledge (GC2) |
| Specific competences: |
| <ul style="list-style-type: none">Know and understand the basic principles and problems of data science at a higher level (SC5).Evaluate the adequacy of statistical models and correct them (SC8);Analyze large data (SC9);Prepare initial data for research and professional use of data analysis packages (SC10); |

| Learning outcomes of the course unit: students will be able to | Teaching and learning methods | Assessment methods |
|--|--|--|
| Develop applications using machine/deep learning paradigm, by applying open-source deep learning frameworks. | Lectures, problem-oriented teaching, case studies, information retrieval, literary reading, individual work, tutorials, laboratory work. | Written exam Laboratory works Defending team project |
| Design, implemented develop applied data analysis programs on complex data. | | |
| Develop the practical knowledge how to use cloud computing infrastructure for big projects | | |

| | | |
|---|--|--|
| Develop the knowledge how to prepare technical reports, present results. Develop practical skills of statistical learning procedures (training, validation, testing), be able to use generative models. | | |
|---|--|--|

| Course content: breakdown of the topics | Contact hours | | | | | | Individual work: time and assignments | | |
|---|---------------|-----------|----------|----------|----------------------|---------------------------|---------------------------------------|-----------------|---|
| | Lectures | Tutorials | Seminars | Practice | Laboratory work (LW) | <i>Tutorial during LW</i> | Contact hours | Individual work | Assignments |
| Course introduction, frameworks. | 2 | | | | 1 | | 3 | 3 | Individual literature search and analysis. Solving of practical tasks in laboratory work. For each lecture exercises from current topic is assign. Tasks involved text analysis, image recognition tasks, and structured data analysis. |
| Definitions form linear algebra, convolutions, kernels. | 2 | | | | 1 | | 3 | 3 | |
| Definitions from probability and information theory. | 2 | | | | 1 | | 3 | 3 | |
| Numerical computations, data flow paradigm, automatic differentiation. Parameters estimation, numerical optimization, regularization. | 2 | | | | 1 | | 3 | 3 | |
| Data compression, auto-encoders | 2 | | | | 1 | | 3 | 3 | |
| Convolutional neural network, classification | 2 | | | | 1 | | 3 | 3 | |
| Convolutional neural network, detection, segmentation | 2 | | | | 1 | | 3 | 3 | |
| First lab. assignment | 0 | | | | 3 | | 3 | 0 | |
| Recurrent neural networks | 2 | | | | 1 | | 3 | 3 | |
| Recurrent neural networks, text analysis | 2 | | | | 1 | | 3 | 3 | |
| Generative models, GAN | 2 | | | | 1 | | 3 | 3 | |
| Reinforcement learning | 2 | | | | 1 | | 3 | 3 | |
| Second lab. assignment | 0 | | | | 3 | | 3 | 0 | |
| Project presentations. | 2 | | | | 1 | | 3 | 3 | |
| Practical team project (during hole semester) | | | | | | | | 34 | |
| Preparation for exam. Exam. | | | | | | | | 13 | Literature and examples analysis. |
| Total | 24 | | | | 18 | | 42 | 83 | |

| Assessment strategy | Weight % | Deadline | Assessment criteria |
|---|----------|--|--|
| The midterm evaluation, Laboratory assignment No. 1 & 2 | 50% | The midterm evalutation will be on 6th week, and the laboratory work assignments will be settle up to 8th and 12th week of the semester. | Students have to implement software and be defended of given task applying the method presented during lectures and previous laboratory work tasks. The penalty for exceeding the deadline is 0.1 points for each week exceeding the deadline. During the midterm evaluation, the student receives theoretical and practical assignments, which are solved in the respective week. Two individual assignments are reported during the semester through laboratory work. During the defense of program, the student must demonstrate the completed task, be able to answer the lecturer questions, modify his / her program during the evaluation |
| Defending project | 20% | 16th week of the semester | Practical project: the team of 2-3 students do the project; In the begin of the semester the team select publication from the given list. In hole semester team analyze the publication and applying |

| | | | |
|--------------|-----|--|---|
| | | | to given task. Technical report up to 8 pages must be prepared. In the report defense the methodology from paper, results on new task and conclusions must be presented. |
| Written exam | 30% | | <p>Exam can be taken only when at least one laboratory assignments defended and team project defended.</p> <p>Maximum 3 points can be collected, which attribute to the 30% of the final score. The exam consists of open questions and practical exercises.</p> <p>The subject cannot be studied externally.</p> |

| Author | Publis hing year | Title | Number or volume | Publisher or URL |
|--|------------------|--|------------------|---|
| Required reading | | | | |
| Zhang, Aston and Lipton, Zachary C. and Li, Mu and Smola, Alexander J. | 2023 | Dive into Deep Learning | | Cambridge University Press |
| Goodfellow, Ian, Yoshua Bengio, Aaron Courville | 2016 | Deep learning | | MIT press, 2016, ISBN: 9780262035613 |
| Kevin P. Murphy | 2012 | Machine Learning: A Probabilistic Perspective | | MIT press, 2012, ISBN: 978-0-262-01802-9 |
| Sutton, Richard S., Andrew G. Barto | 1998 | Reinforcement learning: An introduction | Vol. 1. No. 1. | Cambridge: MIT press, 1998, ISBN: 9780262193986 |
| Recommended reading | | | | |
| T. Hastie, R. Tibshirani, J. Friedman | 2008 | The Elements of Statistical Learning | | Springer |
| David J. C. MacKay | 2003 | Information Theory, Inference, and Learning Algorithms | | Cambridge university press, ISBN: 9780521642989 |
| | | | | |
| | | | | |



DALYKO (MODULIO) APRAŠAS

| Dalyko (modulio) pavadinimas | Kodas |
|------------------------------|-------|
| Giliojo mokymosi metodai | |

| Dėstytojas (-ai) | Padalinys (-iai) |
|---|---|
| Koordinuojantis: Linas Petkevičius | Informatikos Institutas Matematikos ir informatikos fakultetas |
| Kitas (-i): | Vilniaus universitetas |

| Studijų pakopa | Dalyko (modulio) lygmuo | Dalyko (modulio) tipas |
|----------------|-------------------------|------------------------|
| Antroji | | Pasirenkamas |

| Igyvendinimo forma | Vykdymo laikotarpis | Vykdymo kalba (-os) |
|--------------------|---------------------|---------------------|
| Auditorinė | Pavasario semestras | Anglų |

| Reikalavimai studijuojančiam | |
|-----------------------------------|--|
| Išankstiniai reikalavimai: | Gretutiniai reikalavimai (jei yra): |

| Dalyko (modulio) apimtis kreditais | Visas studento darbo krūvis | Kontaktinio darbo valandos | Savarankiško darbo valandos |
|------------------------------------|-----------------------------|----------------------------|-----------------------------|
| 5 | 125 | 42 | 83 |

Dalyko (modulio) tikslas: studijų programos ugdamos kompetencijos

Sudėtingų struktūrų duomenų regresijos/klasifikavimo uždaviniai, generatyvinių, bei skatinamojo mokymo modelių kūrimas sistemų mokymosi, bei giliojo mokymo metodais. Pagrindiniai skatinamojo mokymo, panaudojimo principai, bei taikymai atpažinimo uždaviniuose. Sudėtingų struktūrų duomenų analizė, darbo įgūdžių su sistemų mokymosi ir gilaus mokymo modeliavimo paketais įgijimas. Nagrinėjama reikalinga infrastruktūra darbui su dideliais duomenimis, debesų kompiuterijos sprendimai. Komandinio darbo įgūdžių tobulinimas, kritinio ir analitinio mąstymo vystymas.

Bendrosios kompetencijos:

- Kūrybiškai spręsti nestandardinius teorinius bei empirinius uždavinius (B1);
- Kritiškai analizuoti ir tinkamai naudoti mokslinėje literatūroje pateikiamus rezultatus (B2);
- Panaudoti tarpdisciplinines žinias (B4);

Dalykinės kompetencijos:

- Žinoti bei aukštėsniame lygmenyje suvokti pagrindinius duomenų mokslo principus bei problemas (D5).
- Vertinti statistinių modelių adekvatumą bei juos tinkamai koreguoti (D8);
- Analizuoti didžiuosius duomenis (D9);
- Paruošti pradinius duomenis tyrimui ir profesionaliai naudoti duomenų analizės paketus (D10);

| Dalyko (modulio) studijų siekiniai | Studijų metodai | Vertinimo metodai |
|---|--|--|
| Susipažinti su sistemų mokymosi modelių projektavimo ir kūrimo principais, gebės juos taikyti naudojant atviro kodo karkasus. | | |
| Gebės valdyti sistemų mokymosi programų paketus, panaudoti juos sprendžiant realius uždavinius turinčius sudėtingas duomenų struktūras. | Paskaitos, probleminis dėstymas, atvejų analizė, informacijos paieška, literatūros skaitymas, savarankiškas darbas, pavyzdžių analizė, konsultacijos, laboratoriniai darbai. | Egzaminas raštu Praktinių darbų vertinimas Komandinių projektų pristatymas |
| Gebės naudotis debesų kompiuterijos sprendimais dideliems projektams. | | |
| Gebės rengti tyrimų atskaitas, suprantamai pristatyti metodologijas ir rezultatus, vertinti priemonių tinkamumą. Gebės skaityti mokslinę literatūrą, skirtą didelių duomenų masyvų analizei: kritiškai vertinti pateikiamus rezultatus, praktiškai realizuoti naujai pasiūlytus modelius; | | |

| Temos | Kontaktinio darbo valandos | | | | | | | Savarankiškų studijų laikas ir užduotys | |
|---|----------------------------|---------------|-----------|----------|-----------------------|----------|--------------------------|---|---|
| | Paskaitos | Konsultacijos | Seminarių | Pratybos | Laboratoriniai darbai | Praktika | Visas kontaktinis darbas | Savarankiškas darbas | Užduotys |
| Ivadas, kurso apžvalga, naudojami karkasai. | 2 | | | | 1 | | 3 | 3 | Savarankiška literatūros paieška ir analizė. Laboratorinių darbų užsiėmimuose daromos kiekvienam užsiėmimui parengtos užduotys, iš einamos temos, žinių užtvirtinimui. Užduotys susideda iš vaizdų, teksto ir struktūrizuotų duomenų analizės. |
| Tiesinė algebro savykos, sąsukos operacijos, branduoliai. | 2 | | | | 1 | | 3 | 3 | |
| Tikimybų teorijos ir informacijos teorijos savykos. | 2 | | | | 1 | | 3 | 3 | |
| Skaitinis skaičiavimas, duomenų strauto skaičiavimai, automatinis diferencijavimas, parametru vertinimas, skaitinis optimizavimas, reguliarizacija. | 2 | | | | 1 | | 3 | 3 | |
| Duomenų kodavimas, autoenkoderių modeliai. | 2 | | | | 1 | | 3 | 3 | |
| Konvoluciiniai neuroniniai tinklai, klasifikavimas. | 2 | | | | 1 | | 3 | 3 | |
| Konvoluciiniai neuroniniai tinklai, aptikimas, segmentavimas | 2 | | | | 1 | | 3 | 3 | |
| Pirmas atsiskaitymas | 0 | | | | 3 | | 3 | 0 | |
| Rekurentiniai neuroniniai tinklai. | 2 | | | | 1 | | 3 | 3 | |
| Rekurentiniai neuroniniai tinklai, taikymai teksto analizėje. | 2 | | | | 1 | | 3 | 3 | |
| Generatyviniai modeliai. | 2 | | | | 1 | | 3 | 3 | |
| Skatinamasis mokymas, savykos. | 2 | | | | 1 | | 3 | 3 | |
| Antras atsiskaitymas | 0 | | | | 3 | | 3 | 0 | |
| Projektų pristatymas. | 2 | | | | 1 | | 3 | 3 | |
| Komandinė užduotis (semestro metu) | | | | | | | | 34 | |
| Pasiruošimas egzaminui, konsultacija ir jo laikymas. | | | | | | | | 13 | Literatūros studijos, pavyzdžių analizė |
| | Iš viso | 24 | | | 18 | | 42 | 83 | |

| Vertinimo strategija | Svoris proc. | Atsiskaitymo laikas | Vertinimo kriterijai |
|---|--------------|--|--|
| Pirmas atsiskaitymas rašant laboratorinių atsiskaitymą, bei pirmas ir antras laboratorinis darbas | 50 % | Semestro viduryje ir pabaigoje (apie 8-a ir 15-a savaites) Pirmas laboratorinių darbų atsiskaitymas vyks 6 savaitę. Individualios užduotys atitinkamai atskaitomos iki 8 ir 12 semestro savaitės | <p>Laboratorinių užsiėmimų metu atsiskaitymų savaitę yra duodama užduotis, studentas per užsiėmimą turi parašyti programą ir ją apginti. Užduotis yra iš laboratoriųose darbuose spėstų uždaviniių.</p> <p>Praėjus atsiskaitymo terminui, įvertinimas mažinamas po 0,1 balo už kiekvieną vėluojamą savaitę. Tarpinio atsiskaitymo metu, studentas gauna teorines ir praktines užduotis, kurias sprendžia atitinkamos savaitės metu (1 balas).</p> <p>Dvi individualios užduotys atskaitomos semestro metu per laboratorių darbus (2 ir 2 balas atitinkamai). Atsiskaitymo metu, studentas turi pademonstruoti atliktą užduotį, gebeti atsakyti į dėstytojo klausimus, atsiskaitymo metu pamodifikuoti savo programą.</p> |
| Projekto gynimas | 20% | Semestro | Praktinis projektas: studentai yra suskirstomi į grupes po 2-3 studentus; semestro pradžioje studentų grupė iš duoto publikacijų sąrašo pasirenka |

| | | | |
|-----------------|------|-----------------------------|---|
| | | pabaigoje (16-a savaitė) | publikaciją. Semestro eigoje studentai išnagrinėja publikaciją jį įsisavina ir išsprendžia dėstytojo pasiūlytą problemą remiantis duota publikacija ir parašo ataskaitą (iki 8psl.). Projekto pristatymo metu pristatoma naudota metodologija, bei pristatomi tyrimo rezultatai ir išvados. |
| Egzaminas raštu | 30 % | Pagal sesijos tvarkaraštį | Egzaminą laikyti galima, jei semestro metu buvo apgintas komandinis projektas ir atsiskaitytas bent viena individuali užduotis. Dalyvavimas egzamine privalomas. Egzamino metu galima surinkti iki 3 taškų, kurie atitinka 30% galutinio įvertinimo. Egzaminą sudaro atviri klausimai ir praktinės užduotys Dalyko studijavimas eksternu negalimas. |

| Autorius | Leidimo metai | Pavadinimas | Periodinio leidinio Nr. ar leidinio tomas | Leidimo vieta ir leidykla ar internetinė nuoroda |
|--|---------------|--|---|--|
| Privalomoji literatūra | | | | |
| Zhang, Aston and Lipton, Zachary C. and Li, Mu and Smola, Alexander J. | 2023 | Dive into Deep Learning | | Cambridge University Press |
| Goodfellow, Ian, Yoshua Bengio, Aaron Courville | 2016 | Deep learning | | MIT press, 2016, ISBN: 9780262035613 |
| Kevin P. Murphy | 2012 | Machine Learning: A Probabilistic Perspective | | MIT press, 2012, ISBN: 978-0-262-01802-9 |
| Sutton, Richard S., Andrew G. Barto | 1998 | Reinforcement learning: An introduction | Vol. 1. No. 1. | Cambridge: MIT press, 1998, ISBN: 9780262193986 |
| | | | | |
| | | | | |
| Papildoma literatūra | | | | |
| T. Hastie, R. Tibshirani, J. Friedman | 2008 | The Elements of Statistical Learning | | Springer |
| David J. C. MacKay | 2003 | Information Theory, Inference, and Learning Algorithms | | Cambridge university press, ISBN: 9780521642989 |
| | | | | |
| | | | | |