



**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
ІМЕНІ ТАРАСА ШЕВЧЕНКА**
ФАКУЛЬТЕТ КОМП'ЮТЕРНИХ НАУК ТА КІБЕРНЕТИКИ
Кафедра математичної інформатики



РОБОЧА ПРОГРАМА НАВЧАЛЬНОЇ ДИСЦИПЛІНИ
ОБРОБКА ПРИРОДНОЇ МОВИ
NATURAL LANGUAGE PROCESSING
для студентів

галузь знань	12 «Інформаційні технології»/ “Information Technologies”		
спеціальність	122 «Комп'ютерні науки»/ “Computer Science”		
освітній рівень	магістр/master		
освітня програма	«Математичні методи штучного інтелекту»/ “Mathematical methods of Artificial Intelligence”		
вид дисципліни	обов'язкова/mandatory		
	Форма навчання	денна	
	Навчальний рік	2020/2021	
	Семестр	4	
	Кількість кредитів ECTS	4	
	Мова викладання, навчання та оцінювання	англійська/English	
	Форма заключного контролю	екзамен/exam	
Викладач: к.ф.-м.н., асистент Тарануха В.Ю.			
Пролонговано: на 20 <u>21</u> /20 <u>22</u> н.р.  « <u>11</u> » <u>02</u> 20 <u>21</u> р. на 20___/20___ н.р. (_____) «___» ___ 20___ р			

КИЇВ – 2020

Розробник: Тарануха Володимир Юрійович, к.ф.-м.н., асистент кафедри математичної інформатики

ЗАТВЕРДЖЕНО

Завідувач кафедри математичної інформатики

(підпис)

Терещенко В.М.
(прізвище та ініціали)

Протокол № 3 від «21» травня 2020 р.

Схвалено Гарантом освітньо-наукової програми «Математичні методи штучного інтелекту» _____ (Завадський І.О.)
(підпис)

«28» серпня 2020 р.

Схвалено науково-методичною комісією факультету комп'ютерних наук та кібернетики

Протокол від «28» серпня 2020 року № 1

Голова науково-методичної комісії _____

(підпис)

(Омельчук Л.Л.)

(прізвище та ініціали)

«28» серпня 2020 року

ВСТУП

1. Мета дисципліни – поглиблення знань з комп'ютерної лінгвістики, опанування сучасних задач комп'ютерної лінгвістики, сучасних методів та підходів.

/

The purpose of the course – to improve knowledge of computational linguistics, mastering modern problems of computational linguistics, modern methods and approaches.

2. Попередні вимоги до опанування або вибору навчальної дисципліни:

1. *Знати* базову дисципліну «Штучний інтелект: принципи та методи», володіти методами розпізнавання образів та машинного навчання.
2. *Вміти* проводити наукові дослідження в умовах недостатньої, неповної і/або нечіткої інформації, володіти навичками створення методів на основі ідей та принципів, алгоритмів на основі методів.
3. *Володіти* технічною англійською мовою.

Preliminary requirements to master or choosing of the course

1. *Know* the basic discipline "Artificial Intelligence: principles and methods", master the methods of pattern recognition and machine Learning.
2. *Be able* to conduct research in conditions of insufficient, incomplete and / or fuzzy information, have the skills to create methods based on ideas and principles, algorithms based on methods.
3. *Knowledge* of technical English is required.

3. Анотація навчальної дисципліни:

Навчальна дисципліна «Обробка природної мови/Natural Language Processing» є складовою освітньо-професійної програми підготовки фахівців за другим (магістерським) рівнем вищої освіти *галузі знань* 12 «Інформаційні технології» *спеціальності* 122 «Комп'ютерні науки», *освітньо-професійної* програми «Математичні методи штучного інтелекту».

Дана дисципліна є обов'язковою навчальною дисципліною за *програмою* «Математичні методи штучного інтелекту». Викладається у 2 семестрі 2 курсу магістратури в обсязі – 4 кредити ECTS год.

У курсі передбачено 2 частини, 1 *контрольна робота*, 2 *лабораторні роботи*. Завершується дисципліна – екзаменом в 2 семестрі 2 курсу магістратури.

/

Synopsis of the course:

The discipline "Natural Language Processing" is a component of the educational-professional training program for the second (*master's*) level of higher education in the field of knowledge 12 "Information Technology" specialty 122 "Computer Science", educational-professional program "Mathematical Methods of Artificial Intelligence".

This discipline is a mandatory course in the program "Mathematical Methods of Artificial Intelligence". It is taught in the 2nd semester of the 2nd year of master's degree in the amount of 4 *ECTS credits*.

The course provides 2 *parts*, 1 *test*, 2 *laboratory work*. The discipline ends with an exam in the 2nd semester of the 2nd year of master's degree study.

4. Завдання (навчальні цілі):

Набуття знань, умінь та навичок (компетентностей) на рівні новітніх досягнень у комп'ютерній лінгвістиці, відповідно до кваліфікації фахівця з інформаційних технологій. Зокрема, розвивати:

- здатність аналізувати та використовувати інтелектуальні інформаційні технології;
- здатність до проектування та реалізації систем штучного інтелекту на сучасних обчислювальних системах.

/

Learning objectives:

Acquisition of knowledge, skills and abilities (competencies) at the level of the latest advances in computational linguistics, according to the qualification of an information technology specialist. In particular it aims to develop:

- ability to analyze and use intelligent information technologies .;
- ability to design and implement artificial intelligence systems on modern computer

systems.

5. Результати навчання за дисципліною/ Results of learning:

Результат навчання (1. знати; 2. вміти; 3. комунікація; 4. автономність та відповідальність) Results of learning		Форми (та/або методи і технології) викладання і навчання / Forms (and/or methods and technologies) of teaching	Методи оцінювання та пороговий критерій оцінювання (за необхідності) / Methods of evaluation and evaluation threshold (if necessary)	Відсоток у підсумкові й оцінці з дисципліни/ Percentage in final mark
Код	Результат навчання/ Learning results			
PH1.1	Знати методи аналізу природномовних текстів та відповідні алгоритми / Know the methods of analysis of natural language texts and appropriate algorithms	Лекція, лабораторне заняття / Lecture, Laboratory work	Активна робота на лекції, усні відповіді. Тест (60% правильних відповідей) / Activity during lectures, oral answers, Test (60% correct answers)	35%
PH 2.1	Вміти аналізувати мовні явища для заданої природної мови. / Be able to analyze linguistic phenomena for a given natural language.	Лабораторне заняття, самостійна робота / Laboratory work, Individual work	Захист лабораторної роботи / Laboratory works 1,2	15%
PH 2.2	Вміти формалізувати нестрогі методи аналізу до чітких алгоритмів та підбирати			20%

	оптимальний інструментарій для виконання задачі / <i>Be able to formalize loose methods of analysis to create algorithms and select the optimal tools for the task</i>			
PH 2.3	Вміти застосувати наявний інструментарій, перш за все програмні бібліотеки з комп'ютерної лінгвістики та машинного навчання. / <i>Be able to use existing tools, especially software libraries in computer linguistics and machine learning areas</i>			20%
PH 3.1	Обґрунтовувати власний погляд на задачу, спілкуватися з колегами з питань аналізу задач та проектування алгоритму / <i>Be able to justify own view of the problem, communicate with colleagues in the design and development of programs, prepare written reports</i>	Лабораторне заняття/ <i>Laboratory work</i>		5%
PH4.1	Відповідально ставитися до виконуваних робіт, нести відповідальність за їх якість / <i>Responsibly treat the works performed, be responsible for their quality</i>	Самостійна робота / <i>Individual work</i>	Поточне оцінювання самостійної роботи / <i>Accomplishment of tasks assigned to Individual work</i>	5%

6. Співвідношення результатів навчання дисципліни із програмними результатами навчання

Результати навчання дисципліни Програмні результати навчання/ Teaching results Program results of teaching	1.1	2.1	2.2	2.3	3.1	4.1
ПРНЗ. Опанувати нові інструменти роботи з даними, здійснюючи обробку веб-логів, текст-аналіз і машинне навчання, для прогнозування бізнес-процесів та ситуаційного управління, сентимент-аналізу відгуків, розробки рекомендаційних систем для сфери електронної комерції, медіа, соціальних мереж, банкінгу, реклами тощо				+	+	+

/						
Master new tools for working with data, processing web logs, text analysis and machine learning, for forecasting business processes and situational management, sentiment analysis of feedback, development of recommendation systems for e-commerce, media, social networks, banking, advertising etc.						
ПРН9. Володіти методами та технологіями організації та застосування даних у задачах обчислювального інтелекту, будувати моделі прийняття рішень на основі теорії розпізнавання образів, нейромереж та нечіткої логіки. / Know methods and technologies of data organizing and application in the tasks of artificial intelligence, build decision making models in the terms of image recognition theory, neural networks and fuzzy logic.	+	+	+	+		+
ПРН10. Використовувати інтелектуальні агенти, мультиагентні системи, машинне навчання та самонавчання, генетичні, кооперативні та розподілені еволюційні алгоритми для комп'ютерного розв'язання задач, що вимагають людського рівня мислення./ Use intelligent agents, multi-agent systems, machine learning and self-learning, genetic, cooperative and distributed evolutionary algorithms to solve computer problems that require a human level of thinking.			+	+		+
ПРН16. Знати та вміти застосовувати математичні методи штучного інтелекту. / Know and be able to apply mathematical methods of artificial intelligence.	+	+	+	+		+

7. Схема формування оцінки/Mark forming scheme.

7.1 Форми оцінювання студентів:

- семестрове оцінювання/evaluation in semester:

1. Активна робота на лекції, усні відповіді/ Active work on lectures, oral answers: PH1.1, PH2.1 – 5 балів/3 бали;
2. Контрольна робота/Test: PH 1.1, PH 1.2.,— 15 балів/9 балів
3. Виконання завдань, винесених на самостійну роботу/ Tasks assigned to independent work: PH2.1, PH2.2, PH2.3, PH4.1 – 5 балів/3 бали
4. Лабораторна робота 1/Laboratory work 1: PH2.1, PH 2.2, PH2.3, PH3.1 – 15 балів/9 балів.
5. Лабораторна робота 2/Laboratory work 2: PH2.1, PH 2.2, PH2.3,PH3.1 – 20 балів/12 балів.

- підсумкове оцінювання (у формі екзамену)/ final evaluation (exam):

- максимальна кількість балів які можуть бути отримані студентом на екзамені : 40 балів;
 - результати навчання які будуть оцінюватись: PH1.1, PH2.1, PH2.2, PH2.3, PH3.1.
 - форма проведення і види завдань: письмова.
- Види завдань: 4 теоретичних та 2 практичних завдання.

/

- the maximum number of points that can be obtained by a student on the exam: - 40 points;
- learning outcomes that will be evaluated: PH1.1, PH2.1, PH2.2, PH2.3, PH3.1.
- form and types of tasks: written.

Types of tasks: 4 theoretical and 2 practical tasks.

Загальні вимоги:

- Оцінки нижче від мінімального порогового рівня не додаються, що у семестрі, що на іспиті.
- Мінімальний пороговий рівень для сумарної оцінки за всіма компонентами становить 60% від максимально можливої кількості балів.

General guidelines

- Scores below the minimum threshold are not added both in semester and during exam.
- The minimum threshold for the total assessment of all components is 60% of the maximum possible number of points.

Критерії оцінювання на екзамені/exam scoring

Завдання	Тема завдання	Максимальний відсоток від 40 балів	Всього відсотків
Завдання 1, 2 / Task 1,2	Письмові запитання зі списку наведеного нижче / Written question from the list Exam questions	25%	50%
Завдання 3 / Task 3	Для заданного набору речень англійською мовою виконати його розбір за відповідними граматиками складових та залежностей / For a given set of sentences in English to perform its analysis of the corresponding grammars of components and dependencies	25%	25%
Завдання 4 / Task 4	Для заданного набору речень (української мови) скласти словник невідомих слів, виконати його розбір евристичним аналізом на морфемні характеристики, та виконати побудову граматичної структури за граматиною залежностей / For a given set of sentences in Ukrainian language to compile a dictionary of unknown words, perform its analysis by heuristic analysis of morpheme characteristics, and perform the construction of a grammatical structure on the grammar of dependencies	25%	25%
	Всього/Total		100%

Умови лабораторних робіт/Laboratory works:

Лабораторна робота 1/Learning topic structures from corpora: Використовуючи відомий студенту метод машинного навчання побудувати модель тематичної структури текстового корпусу. / Using the method of machine learning known to the student to build a model of the thematic structure of the text corpus.

Лабораторна робота 2/Improving topic structures OR Sequence transformations:

А) На основі тематичної структури створеної в першій лабораторній роботі та використовуючи перетворення послідовностей створити на вибір:

- систему підтримки перекладу,
- чат-бота,
- систему автоматичного реферування.

Б) На основі першої лабораторної роботи побудувати точнішу систему визначення тематичної структури текстового корпусу за рахунок використання раніше не вживаних ресурсів/програмних бібліотек. Помилка l_1 не повинна перевищувати 0,5.

/

А) Based on the topic structure created in the first laboratory work and sequence transformation to make one of:

- translation support system,
- chatbot,
- automatic abstracting system.

В) On the basis of the first laboratory work to build a more accurate system for determining the topic structure of the text corpus through the use of previously unused resources / software libraries. Error l_1 should not exceed 0.5.

Запитання для підготовки до екзамену/Exam questions:

1. Синтаксичні і граматичні класи слів./ Syntactic and grammatical classes of words.
2. Імовірнісні контекстно-вільні граматики та граматики залежностей./ Probabilistic context-free grammars and dependencies grammars.
3. Онтології: Word Net, CYC./ Ontologies: Word Net, CYC.
4. Дискурс. Теорія риторичної структури (RST). Теорія центрування./ Discourse Theory of Rhetorical Structure (RST). The centering theory.
5. Виділення термінів та сутностей у тексті./ Term and entites detection.
6. Анафора, її типи. Розв'язання анафори. / Anaphora, its types. Anaphora resolution.
7. Визначення значень багатозначних слів на основі WordNet, CYC./ Word sense disambiguation based on WordNet, CYC.
8. Визначення значень багатозначних слів на основі машинного навчання./ Word sense disambiguation based on Machine Learning.
9. Побудова тематичного класифікатора великого розміру./ Construction of a thematic classifier of a large size.
10. Визначення емоційної направленості тексту для коротких текстів (Twitter). /Sentiment analysis for short texts (Twitter).
11. Автоматичне перетворення послідовностей. / Automatic sequence transformation.
12. Автоматичний переклад. /Translation.
13. Системи підтримки діалогу./ Dialogue systems.
14. Побудова онтологій./Ontology building.

7.2 Організація оцінювання/Evaluation process:

Обов'язковим є виконання завдань, винесених на самостійну роботу, лабораторних робіт та

модульних контрольних робіт за графіком робочої програми./ It is mandatory to perform tasks assigned to independent work, laboratory work and modular tests according to the schedule of the work program.

Терміни проведення форм оцінювання/Deadlines:

1. *Контрольна робота (тест): до 2 тижня семестру./ Test: up to the end of 2 weeks of the semester.*
2. *Лабораторна робота 1 (проект): до 3 тижня семестру./ Laboratory work 1 (project): up to the end of 3 weeks of the semester.*
3. *Лабораторна робота 2 (проект): до 4 тижня семестру./ Laboratory work 2 (project): up to the end of 4 weeks of the semester.*

Студент має право на одне перескладання кожної контрольної роботи із можливістю отримання максимально 85% початково визначених за цю контрольну роботу балів. Термін перескладання визначається викладачем.

У випадку відсутності студента з поважних причин відпрацювання та перездачі контрольних робіт здійснюються у відповідності до „Положення про порядок оцінювання знань студентів при кредитно-модульній системі організації навчального процесу” від 1 жовтня 2010 року.

Студент має право здавати лабораторні роботи після закінчення визначеного для них терміну, але з втратою двох балів за кожен тиждень, який пройшов з моменту закінчення терміну її здачі.

/

The student can have second attempt to pass each test with (max. mark is 85% of initial course points for the test). The time of testing is set by lecturer.

Should the student be absent for valid reason re-testing and remedial training are performed according to “Regulations on evaluation of student’s knowledge under credit-module learning process” by 1 October 2010.

The student can submit lab works after deadline but with penalty to earned course points for each week after deadline.

7.3 Шкала відповідності оцінок

Відмінно / Excellent	90-100
Добре / Good	75-89
Задовільно / Satisfactory	60-74
Незадовільно / Failed	0-59

8. Структура навчальної дисципліни. Тематичний план лекційних занять

№ п.п.	Назва лекції / Lecture name	Кількість годин / Hours		
		Лекції/ Lecture s	Лабораторні / Labs	Самост. робота / Individual work
Частина 1. Внутрішні задачі / Module 1 Internal problems				
1.	Тема 1. Синтаксичні і граматичні класи слів. Імовірнісні контекстно-вільні граматики та граматики залежностей. <i>Самостійна робота:</i> розібрати текст граматиною складових та граматиною залежностей. Topic 1. Syntactic and grammatical classes of words. Probabilistic context-free grammars and dependencies grammars. Ontologies: Word Net, CYC. <i>Individual work:</i> parse the text with the grammar of components and the grammar of dependencies.	2	2	10
2.	Тема 2. Онтології: Word Net, CYC. <i>Самостійна робота:</i> побудувати окіл речення. Topic 2. Ontologies: Word Net, CYC. <i>Individual work:</i> make near-neighbor set for sentence.	2		10
3.	Тема 2. Дискурс. Теорія риторичної структури (RST). Теорія центрування. Визначення значень багатозначних слів на основі WordNet, CYC. <i>Самостійна робота:</i> визначити значення багатозначних слів у тексті за допомогою WordNet Topic 2. Discourse Theory of Rhetorical Structure (RST). The centering theory. Word sense disambiguation based on WordNet, CYC. <i>Individual work:</i> determine the meaning of polysemous words in the text using WordNet	2		10
4.	Тема 3. Визначення значень багатозначних слів на основі машинного навчання. Виділення термінів та сутностей у тексті. <i>Самостійна робота:</i> для заданного тексту встановити сутності Topic 3. Machine learning based word sense disambiguation. Term and entites detection. <i>Individual work:</i> find entities for a given text	2	1	10
5.	Тема 3. Анафора, її типи. Розв’язання анафори. <i>Самостійна робота:</i> для заданного тексту встановити анафори Topic 3. Anaphora, its types. Anaphora resolution. <i>Individual work:</i> set anaphors for a given text			10
5.	Контрольна робота /Test		1	
Частина 2. Системи для споживачів/ Module 2 End user systems				
6.	Тема 4. Побудова тематичного класифікатора великого розміру. Побудова онтології	2	2	10

	<i>Самостійна робота:</i> спроектувати тематичний класифікатор для заданої області. Topic 4. Construction of a thematic classifier of a large size. Ontology building. <i>Individual work:</i> design a thematic classification system for a given area.			
7.	Тема 5. Визначення емоційної направленості тексту для коротких текстів (Twitter). <i>Самостійна робота:</i> спроектувати систему визначення емоційної направленості тексту Topic 5. Sentiment analysis for short texts (Twitter). <i>Individual work:</i> design a system for sentiment analysis	2	2	10
8.	Тема 6. Автоматичне перетворення послідовностей. Переклад. <i>Самостійна робота:</i> спроектувати систему машинного перекладу Topic 6. Automatic sequence transformation. Translation. <i>Individual work:</i> design a machine translation system	2	2	10
9.	Тема 7. Автоматичне перетворення послідовностей: системи підтримки діалогу. <i>Самостійна робота:</i> спроектувати систему підтримки діалогу Topic 7. Automatic sequence transformation: dialogue systems. <i>Individual work:</i> design a dialog system	2		10
	ВСЬОГО/TOTAL	18	10	90

Загальний обсяг 120 год., в тому числі/ Total duration 120 hours, namely:

Лекції/ Lectures – 18 год./h.

Лабораторні роботи / Laboratory works – 10 год./h.

Консультації/ Consultations - 2 год./h.

Самостійна робота/ Individual work - 90 год. /h.

9. Рекомендовані джерела/Literature:

Основна:

1. Волошин В.Г. Комп'ютерна лінгвістика: Навчальний посібник. – Суми: Університетська книга, 2004. –382 с.
2. Партико З.В. Прикладна і комп'ютерна лінгвістика, Львів, «Афіша», 2008, - 221 с.
В тому числі й інтернет ресурси
3. The Oxford handbook of computational linguistics R. Mitkov (Ed) Oxford University Press Ел. ресурс. Режим доступу:
http://books.google.com.ua/books/about/The_Oxford_handbook_of_computational_lin.html?id=OaClhre-vW4C&redir_esc=y
4. Daniel Jurafsky and James H. Martin Speech and Language Processing: An Introduction to Natural Language Processing, Speech Recognition, and Computational Linguistics. 2nd edition, 2009 Ел. ресурс. Режим доступу: http://rapidlibrary.com/files/speech-and-language-processing-an-introduction-to-natural-language-processing-djv_23726564.html

Додаткова:

5. Український правопис / Ін-т мовознавства ім. О.О. Потебні НАН України, Ін-т укр. мови НАН України. — К. : Наук. думка, 2007. — 288 с.
6. The Oxford Handbook of Applied Linguistics / Ed. by R.Kaplan. NY: Oxford university press, 2002, 672 P.
7. J. Allen, “Natural language understanding” Menlo Park, Calif. Benjamin/Cummings 1995, 654 P.
В тому числі й інтернет ресурси
8. Сайт проекту WordNet Ел. ресурс. Режим доступу <http://wordnet.princeton.edu/>
9. Український журнал комп’ютерної лінгвістики.Ел. ресурс. Режим доступу <http://franko.lviv.ua/ujcl/>