

KARTA PRZEDMIOTU (SYLABUS)

Opis przedmiotu

Kod przedmiotu		Nazwa przedmiotu	Generatywna sztuczna inteligencja (Generative AI)	
AIwB/O/I/ST/B1-28			Generative AI	
Język wykładowy		Polski		
Rok akademicki		2026/2027		
Kierunek		Sztuczna Inteligencja w Biznesie		
w zakresie		-		
Poziom studiów		studia pierwszego stopnia		
Profil studiów		ogólnoakademicki		
Forma studiów		studia stacjonarne		
Semestr / semestry		semestr szósty		
Przynależność do grupy zajęć		B. Grupa zajęć kierunkowych B1. Grupa zajęć kierunkowych obowiązkowych		
Status przedmiotu		Obowiązkowy		
Formy realizacji zajęć dydaktycznych, wymiar, punkty ECTS		Forma zajęć	Liczba godzin zajęć dydaktycznych	Liczba punktów ECTS
		Wykład	15[h]	2 ECTS
		Ćwiczenia	[h]	
		Laboratorium	30[h]	
Powiązanie przedmiotu	z profilem studiów	Związany z prowadzoną działalnością naukową w dyscyplinie informatyka techniczna i telekomunikacja		1 ECTS
	z uprawnieniami			ECTS
	z dyscypliną	Informatyka techniczna i telekomunikacja		2 ECTS
Forma nauczania		Tradycyjna - zajęcia zorganizowane w Uczelni / zajęcia realizowane z wykorzystaniem metod i technik kształcenia na odległość		
Wymagania wstępne		Wymagana znajomość z przedmiotu analiza matematyka, bardzo dobra znajomość podstawy programowania.		
Jednostka prowadząca		Katedra Biznesu i Finansów Międzynarodowych		
Koordynator		Dr inż. Jacek Wołoszyn		
Adres strony internetowej pjo		http://weif.uniwersytetradom.pl		
Adres e-mail, telefon koordynatora		Jacek.woloszyn@urad.edu.pl (48) 361-7410		

**EFEKTY UCZENIA SIĘ, TREŚCI PROGRAMOWE, REALIZACJA ZAJĘĆ DYDAKTYCZNYCH,
WERYFIKACJA EFEKTÓW UCZENIA SIĘ**

Cel kształcenia:	Zapoznanie studentów z podstawowymi technikami sztucznej inteligencji. Wykorzystanie w praktyce wybranych bibliotek takich jak Scikit-learn, Tensorflow, Pytorch, Keras
Treści programowe:	<p>Treści zajęć są powiązane z prowadzonymi badaniami naukowymi.</p> <p>Treść wykładów:</p> <p>Celem wykładów jest przedstawienie teoretycznych podstaw, architektur modeli oraz kluczowych wyzwań związanych z generatywną AI.</p> <ol style="list-style-type: none"> 1. Wprowadzenie do Generative AI: Definicje, historia rozwoju, zastosowania (tekst, obraz, kod, audio). Generacja a dyskryminacja. Przegląd kluczowych modeli (GAN, VAE, Transformer, Diffusion) . 2. Podstawy Uczenia Głębokiego: Repetytorium niezbędnych koncepcji: sieci neuronowe, funkcje aktywacji, wsteczna propagacja, funkcje straty. Rola gradientu i inicjalizacji wag . 3. Architektury Odwzorowujące Reprezentację: Wprowadzenie do autoenkoderów. Od enkodera-dekodera do modeli generatywnych. Idea przestrzeni latentnej . 4. Modele Sekwencji: Rekurencyjne sieci neuronowe (RNN/LSTM) – ich rola jako fundamentu dla przetwarzania sekwencji . 5. Mechanizm Uwagi i Architektura Transformera: Geneza i zasada działania mechanizmu uwagi. Architektura Transformera (encoder-decoder) – kluczowy komponent nowoczesnych LLM-ów . 6. Duże Modele Językowe (LLM): Budowa, skala i możliwości modeli typu GPT. Wstępne trenowanie (pre-training) na dużych zbiorach danych. Prawa skalowania (scaling laws) . 7. Dostarczanie i Efektywna Adaptacja Modeli: Strategie dostosowywania modeli do konkretnych zadań. Fine-tuning, techniki Parameter-Efficient Fine-Tuning (PEFT), adaptory . 8. Generatywne Sieci Przeciwnika (GAN): Architektura i zasada działania GAN. Zastosowania (generowanie obrazów). Wyzwania związane z trenowaniem . 9. Modele Dyfuzyjne: Wprowadzenie do modeli dyfuzyjnych. Proces dyfuzji forward i reverse. Zastosowania w generowaniu obrazów i dźwięku . 10. Generowanie Wzbogacone o Wyszukiwanie (RAG): Koncepcja łączenia LLM-ów z zewnętrznymi bazami wiedzy. Architektura RAG, rola wektorowych baz danych i wyszukiwania semantycznego. <p>Suma: 15 [h]</p> <p>Treść laboratoriów:</p> <p>Celem laboratoriów jest nabycie przez studentów praktycznych umiejętności programistycznych w języku Python z wykorzystaniem frameworków takich jak PyTorch.</p> <ol style="list-style-type: none"> 1. Wprowadzenie do środowiska i narzędzi: Konfiguracja środowiska pracy (Python, PyTorch, Jupyter/Colab). Zapoznanie z podstawami bibliotek do uczenia maszynowego. 2. Implementacja podstaw sieci neuronowych: Budowa perceptronu wielowarstwowego (MLP) od podstaw w PyTorch do klasyfikacji prostych zbiorów (np. MNIST) .

	<ol style="list-style-type: none"> 3. Autoenkodery w praktyce: Implementacja autoenkodera i analiza przestrzeni latentnej. Porównanie z autoenkoderem wariacyjnym (VAE) . 4. Wprowadzenie do Transformerów: Implementacja prostego mechanizmu uwagi. Korzystanie z gotowych implementacji transformerów (np. z biblioteki Hugging Face). 5. Praca z gotowymi modelami językowymi: Ładowanie i uruchamianie wstępnie wytrenowanych modeli (GPT-2, Llama, BERT). Podstawy inżynierii promptu . 6. Dostrajanie modeli (Fine-tuning): Praktyczne dostrojenie niewielkiego modelu językowego do wybranego zadania, np. analizy sentymentu lub generowania tekstu w określonym stylu . 7. Implementacja Generatywnych Sieci Przeciwnika (GAN): Budowa prostej sieci GAN do generowania obrazów (np. cyfr) i analiza procesu trenowania . 8. Wprowadzenie do Modeli Dyfuzyjnych: Korzystanie z gotowych, wstępnie wytrenowanych modeli dyfuzyjnych do generowania obrazów na podstawie promptów tekstowych. 9. Budowa prostej aplikacji z RAG: Implementacja systemu RAG, który odpowiada na pytania na podstawie dostarczonych dokumentów. Wykorzystanie bibliotek do embedingu i wektorowej bazy danych (np. ChromaDB, FAISS) . 10. Projekt końcowy / warsztaty integracyjne: Konsultacje i praca nad projektami zaliczeniowymi. Prezentacja i dyskusja nad uzyskanymi wynikami oraz potencjalnymi problemami etycznymi (halucynacje, bias) . <p>Suma: 30[h]</p>
Metody dydaktyczne (kształcenia):	<ul style="list-style-type: none"> - metody podające (wykład informacyjny), - metody programowane (z wykorzystaniem komputera), - Obserwacja <p>Zajęcia prowadzone w programie Python3. a także wykorzystanie Biblioteki Numpy, Pandas, Matplotlib, Scikit-learn Tensorflow, Pytorch,</p>
	<p>Warunkiem zaliczenia przedmiotu jest osiągnięcie wszystkich wymaganych efektów uczenia się określonych dla danego przedmiotu. Uzyskanie pozytywnych ocen ze wszystkich form zajęć wchodzących w skład danego przedmiotu jest równoznaczne z jego zaliczeniem i zdobyciem przez studenta liczby punktów ECTS przyporządkowanej temu przedmiotowi.</p> <p>Sposób obliczenia oceny końcowej z przedmiotu określa regulamin studiów.</p> <p>Sposób obliczania oceny z poszczególnych form zajęć przedstawia się następująco:</p> <p>Na ocenę z laboratorium składa się: punktowa ocena wykonanego projektu</p> <p>Na ocenę z wykładu składa się wynik otwartego testu pisemnego.</p> <p>Ocena z egzaminu – wynik otwartego testu pisemnego.</p> <p>Zdobyte w poszczególnych formach zajęć punkty przeliczane zostają na ocenę wg skali:</p> <p>Ocena 2 poniżej 51%</p> <p>Ocena 3 od 51%</p> <p>Ocena 3,5 od 61%</p> <p>Ocena 4 od 71%</p> <p>Ocena 4,5 od 81%</p> <p>Ocena 5 od 91%</p>

Efekty uczenia się dla przedmiotu w odniesieniu do efektów kierunkowych i formy zajęć				Metody weryfikacji efektów uczenia się	
Numer efektu uczenia się	Opis efektów uczenia się dla przedmiotu (PEU) Student, który zaliczył przedmiot (W) zna i rozumie/ (U) potrafi /(K) jest gotów do:	Kierunkowy efekt uczenia się (KEU)	Forma zajęć	Forma weryfikacji (zaliczeń)	Metody sprawdzania i oceny
W1	Zna i rozumie w zaawansowanym stopniu architektury i mechanizmy działania kluczowych modeli generatywnych, w tym autoenkoderów wariacyjnych (VAE), generatywnych sieci przeciwnika (GAN), modeli dyfuzyjnych oraz transformatorów, a także metody ich trenowania i optymalizacji..	K_W03 K_W05	wykład	Zaliczenie na ocenę	pisemny test otwarty
W2	Zna i rozumie specyfikę dużych modeli językowych (LLM), mechanizm uwagi, techniki dostrajania (fine-tuning, PEFT) oraz koncepcję generowania wzbogaconego o wyszukiwanie (RAG), a także wyzwania związane z ich wdrażaniem, takie jak halucynacje, koszty obliczeniowe i zgodność z regulacjami.	K_W03 K_W05	wykład	Zaliczenie na ocenę	pisemny test otwarty
U1	Potrafi samodzielnie implementować, uruchamiać i modyfikować wybrane modele generatywne z wykorzystaniem frameworków do uczenia głębokiego (np. PyTorch), a także dostosowywać wstępnie wytrenowane modele do konkretnych zastosowań poprzez techniki fine-tuningu i inżynierii promptu.	K_U04 K_U05	laboratorium	Zaliczenie na ocenę	ocena zadań laboratoryjnych
U2	Potrafi projektować i tworzyć proste aplikacje wykorzystujące modele generatywne, w tym systemy RAG łączące LLM z zewnętrznymi bazami wiedzy, oraz krytycznie oceniać jakość i wiarygodność generowanych treści.	K_U04 K_U05	laboratorium	Zaliczenie na ocenę	ocena zadań laboratoryjnych
K1	Jest gotów do współpracy w interdyscyplinarnych zespołach przy realizacji projektów wykorzystujących generatywną AI, uwzględniając aspekty techniczne, etyczne i społeczne oraz potencjalny wpływ generowanych treści na odbiorców.	K_K03 K_K04 K_K05	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja
K2	Jest gotów do śledzenia dynamicznego rozwoju technologii generatywnej AI, krytycznej analizy nowych narzędzi i modeli oraz ciągłego podnoszenia swoich kompetencji w tym obszarze, mając świadomość ich znaczenia dla przyszłości inżynierii i biznesu.	K_K03 K_K04 K_K05	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja

Literatura i pomoce naukowe
<p>Literatura podstawowa:</p> <ol style="list-style-type: none"> 1. Vaswani A., Shazeer N., Parmar N. i in., <i>Attention Is All You Need</i>, 31st Conference on Neural Information Processing Systems (NeurIPS), Long Beach 2017. [DOI: 10.48550/arXiv.1706.03762] 2. Goodfellow I., Pouget-Abadie J., Mirza M. i in., <i>Generative Adversarial Networks</i>, Communications of the ACM, Vol. 63, Nr 11, 2020, s. 139–144. (Przedruk przełomowej pracy z 2014 roku z aktualnym komentarzem) 3. Foster D., <i>Generative Deep Learning: Teaching Machines to Paint, Write, Compose, and Play</i>, 2nd Edition, O'Reilly Media, Sebastopol 2023. 4. Illingworth S., Forsyth R., <i>GenAI in Higher Education: Redefining Teaching and Learning</i>, Bloomsbury Academic, Londyn 2026.

5. Alamm J., Grootendorst M., *Hands-On Large Language Models: Language Understanding and Generation*, O'Reilly Media, Sebastopol 2024.

Literatura uzupełniająca:

6. Radford A., Narasimhan K., Salimans T., Sutskever I., *Improving Language Understanding by Generative Pre-Training*, OpenAI, 2018. (Oryginalna praca o GPT)
7. Rombach R., Blattmann A., Lorenz D. i in., *High-Resolution Image Synthesis with Latent Diffusion Models*, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022, s. 10684-10695.
8. Lewis P., Perez E., Piktus A. i in., *Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks*, 34th Conference on Neural Information Processing Systems (NeurIPS), 2020.
9. Tomczak J. M., *Deep Generative Modeling*, Springer Nature, Cham 2022.
10. Hu E. J., Shen Y., Wallis P. i in., *LoRA: Low-Rank Adaptation of Large Language Models*, International Conference on Learning Representations (ICLR), 2022.
11. Bommasani R., Hudson D. A., Adeli E. i in., *On the Opportunities and Risks of Foundation Models*, Center for Research on Foundation Models (CRFM), Stanford University, 2022. (Raport o modelach fundamentalnych)
12. Holtzman A., Buys J., Du L. i in., *The Curious Case of Neural Text Degeneration*, International Conference on Learning Representations (ICLR), 2020.
13. Wołoszyn, J. W., & Molga, A. M. (2025). Comparative Analysis of Classification Models Based on the Xception Architecture Using SE and CBAM Attention Modules for Microorganism Image Classification-Methodology and experimental research. W J. W. Wołoszyn & A. M. Molga (Redaktorzy), 21st Century Computer Science - Challenges and Dilemmas : Artificial Intelligence - The Future of IT (No. 345; s. 29–43). Uniwersytet Radomski im. Kazimierza Pułaskiego. <https://katalog.uniwersytetradom.pl/1783601768532/ksiazka/21st-century-computer-science-challenges-and-dilemmas?bibFilter=178>
14. 21st Century Computer Science - Challenges and Dilemmas : Artificial Intelligence - The Future of IT. (2025). W J. W. Wołoszyn & A. M. Molga (Redaktorzy), Monografie - Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego (No. 345; s. 155). Uniwersytet Radomski im. Kazimierza Pułaskiego.

Szczegółowy wykaz dodatkowych źródeł i pomocy naukowych na pierwszych zajęciach podają prowadzący.

Nakład pracy studenta potrzebny do osiągnięcia zakładanych efektów uczenia się – bilans punktów ECTS		
Udział w zajęciach, aktywność	Obciążenie studenta [h]	
	Praca własna studenta - zajęcia bez nauczyciela (ZBN)	Zajęcia dydaktyczne
Udział w wykładach i laboratoriach	X	45 [h]
Przygotowanie do zajęć, Przygotowanie do zaliczenia	5 [h]	X
Sumaryczne obciążenie pracą studenta	5 [h]/ 0,2 ECTS	45 [h]/ 1,8 ECTS
Punkty ECTS za przedmiot	2 ECTS	

Informacje dodatkowe, uwagi
<p>W przypadku studentów ze szczególnymi potrzebami, w tym: z niepełnosprawnością, przewlekle chorych, określone powyżej (w karcie) metody i formy weryfikacji efektów uczenia się dostosowuje się odpowiednio do indywidualnych potrzeb tych studentów.</p> <p>Szczegółowe zasady i formy wsparcia studentów ze szczególnymi potrzebami: w tym z niepełnosprawnością, przewlekle chorych podczas zajęć, zaliczeń i egzaminów określono w: Regulaminie Studiów, Zasadach Studiowania, Procedurze dotyczącej zapewnienia dostępności procesu kształcenia studentom ze szczególnymi potrzebami, w tym: z niepełnosprawnością, przewlekle chorych.</p>