

## KARTA PRZEDMIOTU (SYLABUS)

### Opis przedmiotu

Kod przedmiotu		Nazwa przedmiotu	Uczenie głębokie (Deep Learning)	
AIwB/O/I/NST/B1-32			Deep Learning	
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 niestacjonarne		
Semestr / semestry		semestr czwarty		
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	8 [h]	2 ECTS
		Ćwiczenia	[h]	
		Laboratorium	15 [h]	
Powiązanie przedmiotu	z profilem studiów	Związany z prowadzoną działalnością naukową w dyscyplinie informatyka techniczna i telekomunikacja		2 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) 361-7850		

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

Cel kształcenia:	Celem przedmiotu jest zapoznanie studentów z podstawami uczenia głębokiego oraz rozwinięcie umiejętności projektowania, trenowania i oceny modeli opartych na sieciach neuronowych z wykorzystaniem współczesnych narzędzi i bibliotek programistycznych.
Treści programowe:	<p>Treści zajęć są powiązane z prowadzonymi badaniami naukowymi.</p> <p><b>Treści wykładów:</b></p> <ol style="list-style-type: none"> <li>1. Wprowadzenie do uczenia głębokiego – miejsce deep learning w sztucznej inteligencji i uczeniu maszynowym.</li> <li>2. Podstawy sztucznych sieci neuronowych – perceptron, funkcje aktywacji, warstwy sieci neuronowych.</li> <li>3. Proces uczenia sieci neuronowych – funkcje kosztu, algorytm wstecznej propagacji błędów (backpropagation), optymalizacja.</li> <li>4. Architektury głębokich sieci neuronowych – sieci wielowarstwowe (MLP), koncepcja głębokiego uczenia.</li> <li>5. Konwolucyjne sieci neuronowe (CNN) – architektura, zastosowania w analizie obrazów.</li> <li>6. Rekurencyjne sieci neuronowe (RNN) – przetwarzanie danych sekwencyjnych, modele LSTM i GRU.</li> <li>7. Wprowadzenie do przetwarzania języka naturalnego (NLP) z wykorzystaniem deep learning.</li> <li>8. Modele generatywne – autoenkodery oraz generative adversarial networks (GAN).</li> <li>9. Trenowanie modeli deep learning – przygotowanie danych, regularyzacja, zapobieganie przeuczeniu.</li> <li>10. Wykorzystanie bibliotek i frameworków deep learning (TensorFlow, Keras, PyTorch).</li> <li>11. Zastosowania deep learning w biznesie, analizie danych i systemach inteligentnych.</li> <li>12. Wyzwania i kierunki rozwoju uczenia głębokiego – etyka AI, interpretowalność modeli, odpowiedzialne AI.</li> </ol> <p>Suma: 8 [h]</p> <p><b>Treść laboratoriów:</b></p> <ol style="list-style-type: none"> <li>1. Wprowadzenie do środowiska pracy             <ul style="list-style-type: none"> <li>o Konfiguracja środowiska Python do deep learning.</li> <li>o Przegląd bibliotek: NumPy, Pandas, TensorFlow, Keras, PyTorch.</li> </ul> </li> <li>2. Podstawy sieci neuronowych             <ul style="list-style-type: none"> <li>o Implementacja prostego perceptronu.</li> <li>o Tworzenie pierwszych modeli sieci neuronowych.</li> </ul> </li> <li>3. Budowa modeli MLP             <ul style="list-style-type: none"> <li>o Projektowanie i trenowanie wielowarstwowych sieci neuronowych.</li> <li>o Analiza wyników i ocena jakości modelu.</li> </ul> </li> <li>4. Przygotowanie danych do uczenia modeli             <ul style="list-style-type: none"> <li>o Wstępne przetwarzanie danych.</li> <li>o Podział na zbiory treningowe, walidacyjne i testowe.</li> </ul> </li> <li>5. Konwolucyjne sieci neuronowe (CNN)             <ul style="list-style-type: none"> <li>o Budowa i trenowanie modeli CNN.</li> <li>o Rozpoznawanie obrazów i klasyfikacja danych wizualnych.</li> </ul> </li> <li>6. Rekurencyjne sieci neuronowe (RNN)             <ul style="list-style-type: none"> <li>o Praca z danymi sekwencyjnymi.</li> <li>o Implementacja modeli LSTM lub GRU.</li> </ul> </li> <li>7. Modele generatywne             <ul style="list-style-type: none"> <li>o Podstawy autoenkoderów.</li> </ul> </li> </ol>

	<ul style="list-style-type: none"> <li>○ Wprowadzenie do sieci GAN.</li> </ul> <p>8. Optymalizacja i regularyzacja modeli</p> <ul style="list-style-type: none"> <li>○ Dropout, batch normalization.</li> <li>○ Monitorowanie procesu uczenia.</li> </ul> <p>9. Projekt praktyczny</p> <ul style="list-style-type: none"> <li>○ Budowa i trenowanie modelu deep learning dla wybranego problemu analizy danych.</li> </ul> <p>10. Prezentacja i analiza wyników projektu</p> <ul style="list-style-type: none"> <li>• Interpretacja wyników modeli.</li> <li>• Ocena jakości i możliwości zastosowania modelu.</li> </ul> <p>Suma: 15[h]</p>
Metody dydaktyczne (kształcenia):	<ul style="list-style-type: none"> <li>- metody podające (wykład informacyjny),</li> <li>- metody programowane (z wykorzystaniem komputera),</li> <li>- Obserwacja</li> </ul> <p>Zajęcia prowadzone w programie Python</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. Sposób obliczenia oceny końcowej z przedmiotu określa regulamin studiów.</p> <p>Sposób obliczania oceny z poszczególnych form zajęć przedstawia się następująco:</p> <p>Ocenę z laboratorium to ocena testu.</p> <p>Na ocenę z wykładu składa się wynik otwartego testu pisemnego. 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 podstawowe pojęcia, metody oraz architektury stosowane w uczeniu głębokim, w tym działanie sztucznych sieci neuronowych oraz mechanizmy ich trenowania.	K_W03 K_W05 K_W09	wykład	Zaliczenie na ocenę	pisemny test otwarty
W1	zna i rozumie możliwości oraz ograniczenia modeli uczenia głębokiego oraz ich zastosowania w analizie danych, przetwarzaniu obrazów i tekstu.	K_W03 K_W05 K_W09	wykład	Zaliczenie na ocenę	pisemny test otwarty
U1	potrafi przygotować dane oraz zaprojektować i wytrenować prosty model uczenia głębokiego z wykorzystaniem wybranych bibliotek programistycznych.	K_U01 K_U06 K_U11	laboratorium	Zaliczenie na ocenę	pisemny test otwarty
U2	potrafi ocenić jakość działania modeli deep learning oraz interpretować	K_U01 K_U06 K_U11	laboratorium	Zaliczenie na ocenę	pisemny test otwarty

	uzyskane wyniki w kontekście rozwiązywanego problemu.				
K1	jest gotów do samodzielnego poszerzania wiedzy w zakresie metod uczenia głębokiego oraz ich zastosowań w analizie danych i systemach inteligentnych.	K_K04 K_K05	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja
K2	jest gotów do odpowiedzialnego wykorzystywania metod sztucznej inteligencji, uwzględniając aspekty etyczne oraz ograniczenia technologiczne modeli.	K_K04 K_K05	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja

Literatura i pomoce naukowe	
<p><b>Literatura podstawowa:</b></p> <ol style="list-style-type: none"> <li>Goodfellow I., Bengio Y., Courville A., Deep Learning, MIT Press, 2016. [ISBN: 9780262035613]</li> <li>Géron A., Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, 3rd Edition, O'Reilly Media, 2022. [ISBN: 9781098125974]</li> <li>Chollet F., Deep Learning with Python, 2nd Edition, Manning Publications, 2021. [ISBN: 9781617296864]</li> <li>Raschka S., Liu Y., Mirjalili V., Machine Learning with PyTorch and Scikit-Learn, Packt Publishing, 2022. [ISBN: 9781801819312]</li> </ol> <p><b>Literatura uzupełniająca:</b></p> <ol style="list-style-type: none"> <li>Bishop C. M., Pattern Recognition and Machine Learning, Springer, 2006. [ISBN: 9780387310732]</li> <li>Nielsen M., Neural Networks and Deep Learning, Determination Press, 2015. [ISBN: 9781593279509]</li> <li>Zhang A., Lipton Z., Li M., Smola A., Dive into Deep Learning, Cambridge University Press, 2023. [ISBN: 9781108841092]</li> <li>Patterson J., Gibson A., Deep Learning: A Practitioner's Approach, O'Reilly Media, 2017. [ISBN: 9781491914250]</li> <li>Wołoszyn, J. W., &amp; Molga, A. M. (2025). Comparative Analysis of Classification Models Based on the Xception Architecture Using SE and CBAM Attention Modules for Microorganism Image Classification-Research problems and objectives of the analysis. W J. W. Wołoszyn &amp; A. M. Molga (Redaktorzy), <i>21st Century Computer Science - Challenges and Dilemmas : Artificial Intelligence - The Future of IT</i> (No. 345; s. 19–28). Uniwersytet Radomski im. Kazimierza Pułaskiego. <a href="https://katalog.uniwersytetradom.pl/1783601768532/ksiazka/21st-century-computer-science-challenges-and-dilemmas?bibFilter=178">https://katalog.uniwersytetradom.pl/1783601768532/ksiazka/21st-century-computer-science-challenges-and-dilemmas?bibFilter=178</a></li> <li>Wołoszyn, J. W., &amp; 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 &amp; A. M. Molga (Redaktorzy), <i>21st Century Computer Science - Challenges and Dilemmas : Artificial Intelligence - The Future of IT</i> (No. 345; s. 29–43). Uniwersytet Radomski im. Kazimierza Pułaskiego. <a href="https://katalog.uniwersytetradom.pl/1783601768532/ksiazka/21st-century-computer-science-challenges-and-dilemmas?bibFilter=178">https://katalog.uniwersytetradom.pl/1783601768532/ksiazka/21st-century-computer-science-challenges-and-dilemmas?bibFilter=178</a></li> </ol> <p>Szczegółowy wykaz dodatkowych źródeł i pomocy naukowych na pierwszych zajęciach podają prowadzący.</p>	

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	23 [h]

Przygotowanie do zajęć, Przygotowanie do zaliczenia	27 [h]	X
Sumaryczne obciążenie pracą studenta	27 [h]/ 1,1 ECTS	23 [h]/ 0,9 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>