

KARTA PRZEDMIOTU (SYLABUS)

Opis przedmiotu

Kod przedmiotu		Nazwa przedmiotu	Sztuczna inteligencja deep learning	
IAwB/O/II/ST/A-5			Artificial Intelligence Deep learning	
Język wykładowy		Polski		
Rok akademicki		2025/2026		
Kierunek w zakresie		Informatyka i Analityka w Biznesie		
		-		
Poziom studiów		studia drugiego stopnia		
Profil studiów		ogólnoakademicki		
Forma studiów		studia stacjonarne		
Semestr / semestry		semestr trzeci		
Przynależność do grupy zajęć		A. Grupa zajęć podstawowych		
Status przedmiotu		Obowiązkowy		
Formy realizacji zajęć dydaktycznych, wymiar, punkty ECTS		Forma zajęć	Liczba godzin zajęć dydaktycznych	Liczba punktów ECTS
		Wykład	30[h]	3 ECTS
		Ćwiczenia	[h]	
		Konwersatorium	[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		3 ECTS
Forma nauczania		Tradycyjna - zajęcia zorganizowane w Uczelni		
Wymagania wstępne		Wymagana znajomość z przedmiotu sztuczna inteligencja, 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:	<p>Celem przedmiotu jest zapoznanie studentów z nowoczesnymi technikami sztucznej inteligencji, ze szczególnym uwzględnieniem metod głębokiego uczenia (deep learning). Studenci poznają podstawy teoretyczne, architekturę modeli oraz praktyczne zastosowania sieci neuronowych w różnych dziedzinach, takich jak rozpoznawanie obrazów, analiza tekstu czy systemy rekomendacyjne.</p>
Treści programowe:	<p>Treści zajęć są powiązane z prowadzonymi badaniami naukowymi.</p> <p>Treści wykładów:</p> <ul style="list-style-type: none"> • podstawowe pojęcia sztucznej inteligencji i uczenia maszynowego, • sieci neuronowe: perceptron, sieci wielowarstwowe (MLP), funkcje aktywacji, backpropagation, • głębokie sieci neuronowe: CNN (Convolutional Neural Networks), RNN (Recurrent Neural Networks), LSTM, autoenkodery, • transfer learning, regularizacja, optymalizacja, eksploracja hiperparametrów, • biblioteki deep learning w Pythonie (TensorFlow, Keras, PyTorch), • przykładowe zastosowania: klasyfikacja obrazów, rozpoznawanie mowy, analiza tekstu, generowanie danych. <p>Treść laboratoriów:</p> <p>1. Wprowadzenie do Deep Learning</p> <ul style="list-style-type: none"> • Podstawowe pojęcia: neuron, warstwa, sieć neuronowa. • Omówienie architektury perceptronu wielowarstwowego (MLP). • Implementacja prostej sieci neuronowej w TensorFlow/Keras. <p>2. Praca z danymi – przygotowanie i preprocessing</p> <ul style="list-style-type: none"> • Normalizacja, standaryzacja, augmentacja danych. • Tworzenie zbiorów treningowych, walidacyjnych i testowych. <p>3. Sieci konwolucyjne (CNN)</p> <ul style="list-style-type: none"> • Podstawy CNN – warstwy splotowe, pooling, dropout. • Implementacja klasyfikacji obrazów przy użyciu CNN. • Transfer learning – wykorzystanie pretrenowanych modeli (np. ResNet, VGG16). <p>4. Sieci rekurencyjne (RNN, LSTM, GRU) w analizie sekwencji</p> <ul style="list-style-type: none"> • Podstawy RNN, architektura LSTM i GRU. • Praktyczne zastosowania – przewidywanie szeregów czasowych. <p>5. Autoenkodery i generatywne sieci przeciwstawne (GANs)</p> <ul style="list-style-type: none"> • Działanie autoenkoderów – kompresja i rekonstrukcja danych. • Implementacja prostego autoenkodera na danych obrazowych. • Tworzenie i trenowanie GANs – generowanie obrazów. <p>6. Optymalizacja i tuning modeli</p> <ul style="list-style-type: none"> • Regularizacja, dropout, batch normalization. • Dobór hiperparametrów – GridSearch, Random Search, Bayesian Optimization.

	<ul style="list-style-type: none"> • Interpretacja modeli i analiza wyników. 7. Deep Learning w zastosowaniach biznesowych i przemysłowych
Metody dydaktyczne (kształcenia):	<ul style="list-style-type: none"> - metody podające (wykład informacyjny), - metody programowane (z wykorzystaniem komputera), - Obserwacja Zajęcia prowadzone w programie Python3. a także wykorzystanie Biblioteki Numpy, Pandas, Matplotlib, Scikit-learn Tensorflow, Pytorch,
	<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>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	rozumie architekturę i zasady działania sieci neuronowych	K_W05 K_W09	wykład	Zaliczenie na ocenę	pisemny test otwarty
W2	zna i stosuje nowoczesne narzędzia do implementacji AI	K_W05 K_W09	wykład	Zaliczenie na ocenę	pisemny test otwarty
U1	potrafi zbudować, trenować i ocenić model deeplearningowy	K_U06 K_U10	laboratorium	Zaliczenie na ocenę	ocena zadań laboratoryjnych
U2	potrafi dobrać odpowiednią architekturę modelu do problemu	K_U06 K_U10	laboratorium	Zaliczenie na ocenę	ocena zadań laboratoryjnych
K1	zna przykłady zastosowań sztucznej inteligencji w praktyce, m.in. w przemyśle, medycynie i biznesie	K_K02	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja

Literatura i pomoce naukowe
Literatura podstawowa: <ol style="list-style-type: none"> 1. Sebastian Raschka, Vahid Mirjalili, Python. Machine learning i deep learning. Biblioteki scikit-learn i

TensorFlow 2. Wydanie III

2. Laurence Moroney, Sztuczna inteligencja i uczenie maszynowe dla programistów. Praktyczny przewodnik po sztucznej inteligencji
3. Valentino Zocca, Gianmario Spacagna, Daniel Slater, Peter Roelants, Deep Learning. Uczenie głębokie z językiem Python. Sztuczna inteligencja i sieci neuronowe

Literatura uzupełniająca:

1. Russell, S. J., & Norvig, P. (2020). *Artificial Intelligence: A Modern Approach* (4th ed.). Prentice Hall. ISBN: 978-0134610993. Wikipedia
2. Christian, B. (2020). *The Alignment Problem: Machine Learning and Human Values*. W.W. Norton & Company. ISBN: 978-0393635829. AI Driven
3. Sebastian, C. (2019). *Machine Learning for Beginners*. Independently published. ISBN: 978-1090647756.

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]		
	Inne godz. kontaktowe (IGK)	Zajęcia bez nauczyciela-praca własna studenta (ZBN)	Zajęcia dydaktyczne
Udział w wykładach/konwersatoriach	X	X	30 [h]
Udział w ćwiczeniach/warsztatach/laboratorium	X	X	30 [h]
Udział w konsultacjach	[h]	X	X
Przygotowanie do wykładów /laboratoriów - 7h Przygotowanie do zaliczenia – 8 h	X	15[h]	X
Sumaryczne obciążenie pracą studenta	0 [h] / 0 ECTS	15 [h] / 0,6 ECTS	60 [h] / 2,4 ECTS
Punkty ECTS za przedmiot	75 [h] / 3 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>