

KARTA KURSU

Nazwa	Sztuczna Inteligencja
Nazwa w j. ang.	Artificial intelligence

Koordinator	dr hab. prof. UKEN Jozef Kapusta	Zespół dydaktyczny
		dr hab. prof. UKEN Jozef Kapusta, mgr Justyna Golec
Punktacja ECTS*	5	

Opis kursu (cele kształcenia)

Kurs zapewnia studentom solidne podstawy w zakresie uczenia maszynowego, ze szczególnym naciskiem na jego zastosowanie w rozwiązywaniu rzeczywistych problemów. Studenci poznają kluczowe zagadnienia uczenia maszynowego, w tym uczenie nadzorowane, nienadzorowane i ze wzmocnieniem, a także zagadnienia związane z przetwarzaniem danych, wyborem cech i oceną jakości modeli.

Znaczna część kursu poświęcona jest sieciom neuronowym – od perceptronów i wielowarstwowych sieci jednokierunkowych, aż po nowoczesne architektury, takie jak sieci konwolucyjne i rekurencyjne. Studenci zapoznają się z algorytmami uczenia, takimi jak spadek gradientowy i propagacja wsteczna, oraz poznają techniki zapobiegania przeuczeniu modeli.

Zajęcia praktyczne prowadzone są z wykorzystaniem popularnych bibliotek i frameworków, co pozwala studentom samodzielnie implementować, trenować i testować własne modele. Po ukończeniu kursu studenci będą potrafili projektować i stosować modele uczenia maszynowego w różnych obszarach, takich jak klasyfikacja, regresja, przetwarzanie języka naturalnego i rozpoznawanie obrazów. Rozwiną także umiejętności krytycznej analizy jakości modeli oraz ich ograniczeń.

Warunki wstępne

Wiedza	Student posiada podstawową wiedzę z zakresu sztucznej inteligencji oraz uczenia maszynowego zdobytą w ramach kursu Podstawy sztucznej inteligencji. Zna elementarne pojęcia związane z algorytmami klasyfikacji i regresji oraz orientuje się w problematyce przetwarzania danych.
Umiejętności	Student potrafi programować w języku Python (i/lub R) na poziomie umożliwiającym implementację prostych algorytmów oraz korzystanie z bibliotek do pracy z danymi. Umie samodzielnie analizować dane wejściowe i przygotowywać je do dalszej obróbki.
Kursy	<u>Wymagane zaliczenie kursu:</u> Podstawy sztucznej inteligencji

Efekty uczenia się

	Efekt kształcenia dla kursu,	Odniesienie do efektów kierunkowych
Wiedza	Po zakończeniu kursu student:	
	W01: zna podstawowe algorytmy i metody uczenia maszynowego, takie jak drzewa decyzyjne, uczenie zespołowe, regresja, klasyfikatory oparte na odległości czy maszyny wektorów nośnych.	K_W03, K_W04, K_W05, K_W06,
	W02: rozumie metody radzenia sobie z niezrównoważonymi zbiorami danych oraz koncepcje AutoML i uczenia federacyjnego.	K_W03, K_W04, K_W05, K_W06,
	W03: posiada wiedzę na temat budowy i działania systemów rekomendacyjnych.	K_W03, K_W04, K_W05, K_W06,
	W04: zna podstawy sieci neuronowych, w tym perceptron, uczenie Hebba, Adaline oraz sieci jednokierunkowe.	K_W03, K_W04, K_W05, K_W06,
	W05: rozumie zasady działania nowoczesnych architektur sieci neuronowych, takich jak sieci rekurencyjne (RNN, LSTM) i konwolucyjne (CNN).	K_W03, K_W04, K_W05, K_W06,
	Efekt kształcenia dla kursu	Odniesienie do efektów kierunkowych
Umiejętności	Po zakończeniu kursu student:	
	U01: potrafi przygotować dane do analizy, wybrać odpowiednie cechy i dobrać właściwe metody uczenia maszynowego do rozwiązania problemu.	K_U02, K_U04, K_U05, K_U06, K_U09,
	U02: umie ocenić jakość modeli przy użyciu różnych metryk oraz porównać skuteczność różnych algorytmów.	K_U02, K_U04, K_U05, K_U06, K_U09,
	U03: potrafi zastosować uczenie zespołowe (bagging, boosting, stacking) i samodzielnie przeprowadzić eksperymenty porównawcze.	K_U02, K_U04, K_U05, K_U06, K_U09,
	U04: umie zbudować, wytrenować i zoptymalizować sieć neuronową, stosując różne warianty spadku gradientowego, metody regularyzacji i dostrajania hiperparametrów.	K_U02, K_U04, K_U05, K_U06, K_U09,
	U05: potrafi zastosować narzędzia i biblioteki programistyczne do implementacji klasycznych i nowoczesnych modeli uczenia maszynowego.	K_U02, K_U04, K_U05, K_U06,

	Efekt kształcenia dla kursu	Odniesienie do efektów kierunkowych
	Po zakończeniu kursu student: K01: rozumie znaczenie krytycznej analizy wyników uzyskanych przy pomocy modeli sztucznej inteligencji i potrafi wskazać ich ograniczenia. K02: potrafi pracować indywidualnie i zespołowo przy projektach wymagających implementacji i oceny modeli uczenia maszynowego.	 K_K01, K_K06 K_K03

Studia stacjonarne

Organizacja											
Forma zajęć	Wykład (W)	Ćwiczenia w grupach									
		A		K		L		S		P	E
Liczba godzin	20					30					

Studia niestacjonarne

Organizacja											
Forma zajęć	Wykład (W)	Ćwiczenia w grupach									
		A		K		L		S		P	E
Liczba godzin	10					20					

Opis metod prowadzenia zajęć:

Wykłady mają charakter teoretyczno-praktyczny i służą wprowadzeniu w zagadnienia związane z uczeniem maszynowym i nowoczesnymi metodami sztucznej inteligencji. Omawiane są algorytmy, architektury sieci neuronowych oraz przykłady ich zastosowania w rzeczywistych problemach.

Ćwiczenia laboratoryjne polegają na implementacji wybranych algorytmów i testowaniu poznawanych metod uczenia maszynowego oraz sporządzaniu dokumentacji projektowej. Podczas zajęć studenci są zobowiązani osiągnąć wskazane przez prowadzącego rezultaty. Zajęcia, podczas których dochodzi do testowania określonej metody, kończą się weryfikacją poprawności jej implementacji, dokonywaną przez prowadzącego.

W trakcie kursu studenci otrzymują do realizacji praktyczny projekt wymagający kompleksowego podejścia do problematyki implementacji i wykorzystania wybranej metody sztucznej inteligencji. Projekt ten wykonywany jest częściowo poza zajęciami laboratoryjnymi i stanowi istotny element oceny końcowej.

Formy sprawdzania efektów kształcenia

	E – learning	Gry dydaktyczne	Ćwiczenia w szkole	Zajęcia terenowe	Praca laboratoryjna	Projekt indywidualny	Projekt grupowy	Udział w dyskusji	Referat	Kolokwium	Egzamin ustny	Egzamin pisemny	Inne
W01					X	X		X		X			
W02					X	X		X		X			
W03					X	X		X		X			
W04					X	X		X		X			
W05					X	X		X		X			
U01					X	X		X					
U02					X	X		X					
U03					X	X		X					
U04					X	X		X					
U05					X	X		X					
K01						X		X					
K02						X		X					

Kryteria oceny	Osiągnięcie efektów kształcenia podanych powyżej uprawnia studentów do uzyskania oceny nie wyższej niż dostateczna.
	Warunkiem zaliczenia kursu jest aktywny udział w ćwiczeniach oraz uzyskanie wymaganej liczby punktów z projektów i testu końcowego.
	W ramach zajęć laboratoryjnych studenci implementują i omawiają wybrane algorytmy uczenia maszynowego. Ostatnia część każdego ćwiczenia poświęcona jest prostym projektom indywidualnym, które są oceniane punktowo (łącznie maksymalnie 60 punktów za wszystkie ćwiczenia). Kurs kończy się testem sprawdzającym wiedzę teoretyczną i praktyczną, za który można uzyskać maksymalnie 40 punktów.
	Dodatkowe punkty mogą zostać przyznane za projekty domowe wykonywane indywidualnie.
	Ocena końcowa ustalana jest na podstawie sumy punktów uzyskanych z ćwiczeń i testu, według następującej skali: 0-50 punktów: niedostateczny (2.0) 51-60 punktów: dostateczny (3.0) 61-70 punktów: dostateczny plus (3.5) 71-80 punktów: dobry (4.0) 81-90 punktów: dobry plus (4.5) 91-100 punktów: bardzo dobry (5.0) Obecność na wykładach jest obowiązkowa i stanowi warunek zaliczenia tej części kursu.
Uwagi	

Treści merytoryczne (wykaz tematów)

1. Wprowadzenie do uczenia maszynowego, drzewa decyzyjne, entropia, indeks GINI.
2. Uczenie zespołowe w uczeniu maszynowym – Bagging, Boosting i Stacking (Random Forest, AdaBoost, XGBoost, Gradient Boosted Decision Tree).
3. Regresja i metryki oceny jakości modeli.
4. Maszyny wektorów nośnych (Support Vector Machines).
5. Klasyfikatory oparte na miarach odległości.
6. Niezrównoważone zbiory danych, AutoML, uczenie federacyjne.
7. Systemy rekomendacyjne.
8. Sieci neuronowe: neurony logiczne, uczenie Hebba, adaptacyjny neuron liniowy (Adaline).
9. Sieć neuronowa jednokierunkowa (feedforward neural network).
10. Spadek gradientowy (batch, stochastic, mini-batch), współczynnik uczenia, metoda Adam, dropout, hiperparametry w sieciach neuronowych.
11. Sieci rekurencyjne (RNN) i sieci długiej pamięci krótkotrwałej (LSTM).
12. Konwolucyjne sieci neuronowe (CNN): splot i pooling, najważniejsze architektury CNN.

Wykaz literatury podstawowej

Wybrane rozdziały:

1. Fox, E., Guestrin, C. *Machine Learning Specialization*, University of Washington
<https://www.coursera.org/specializations/machine-learning>
2. Zhang, A., Lipton, Z. C., Li, M., Smola, A.J. (2024). *Dive into Deep Learning*. Cambridge University Press. 574 p. <https://www.d2l.ai/>
3. Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (2nd ed.). O'Reilly Media. 849 pp.
4. Burkov, A. (2019). *The Hundred-Page Machine Learning Book*. Andriy Burkov Publishing. 160 pp.
5. Ameisen, E. (2021). *Uczenie maszynowe w aplikacjach. Projektowanie, budowa i wdrażanie*. Gliwice: Helion. 224 s.
6. Szeliga, M. (2019). *Praktyczne uczenie maszynowe*. Warszawa: Wydawnictwo Naukowe PWN. 468 s.

Wykaz literatury uzupełniającej

1. Raschka, S., & Mirjalili, V. (2019). *Python Machine Learning* (3rd ed.). Packt Publishing. 770 pp.
2. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. 775 pp.
3. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. 738 pp.
4. Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press. 1,106 pp.
5. Domingos, P. (2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books. 352 pp.
6. Géron, A. (2023). *Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow* (wyd. 3). Gliwice: Helion. 776 s.
7. Kapusta, J., Držik, D., Šteflovíč, K., Szabó Nagy, K. (2024). Text Data Augmentation Techniques for Word Embeddings in Fake News Classification. *IEEE ACCESS*. 12, 31538-31550
8. Szabó Nagy, K., Kapusta, J., Munk, M. (2023). Feature extraction from unstructured texts as a combination of the morphological and the syntactic analysis and its usage in fake news classification tasks. *NEURAL COMPUTING AND APPLICATIONS*. 35 (9), 22055-22067

Bilans godzinowy zgodny z CNPS (Całkowity Nakład Pracy Studenta) **studia stacjonarne**

liczba godzin w kontakcie z prowadzącymi	Wykład	20
	Konwersatorium (ćwiczenia, laboratorium itd.)	30
	Pozostałe godziny kontaktu studenta z prowadzącym	15
liczba godzin pracy studenta bez kontaktu z prowadzącymi	Lektura w ramach przygotowania do zajęć	10
	Realizacja zadań domowych (problemowych) po zapoznaniu się z niezbędną literaturą przedmiotu	15
	Przygotowanie projektu lub prezentacji na podany temat (praca indywidualna lub w grupie)	10
	Przygotowanie do egzaminu/zaliczenia/kolokwium	25
Ogółem bilans czasu pracy		125
Liczba punktów ECTS w zależności od przyjętego przelicznika		5

Bilans godzinowy zgodny z CNPS (Całkowity Nakład Pracy Studenta) **studia niestacjonarne**

liczba godzin w kontakcie z prowadzącymi	Wykład	10
	Konwersatorium (ćwiczenia, laboratorium itd.)	20
	Pozostałe godziny kontaktu studenta z prowadzącym	15
liczba godzin pracy studenta bez kontaktu z prowadzącymi	Lektura w ramach przygotowania do zajęć	15
	Realizacja zadań domowych (problemowych) po zapoznaniu się z niezbędną literaturą przedmiotu	20
	Przygotowanie projektu lub prezentacji na podany temat (praca indywidualna lub w grupie)	15
	Przygotowanie do egzaminu/zaliczenia/kolokwium	30
Ogółem bilans czasu pracy		125
Liczba punktów ECTS w zależności od przyjętego przelicznika		5