

**KARTA KURSU (realizowanego w module specjalności)**  
**Data Science**

Nazwa	<b>Zaawansowane metody uczenia maszynowego</b>	
Nazwa w j. ang.	Advanced Methods of Machine Learning	
Koordynator	dr hab. Jozef Kapusta, prof. UKEN	Zespół dydaktyczny
		dr hab. Jozef Kapusta, prof. UKEN
Punktacja ECTS*	4	

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	

Efekty uczenia się

Wiedza	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
--------	-----------------------------	-------------------------------------

	<p>Po zakończeniu kursu student:</p> <p>W01: zna podstawowe algorytmy i metody uczenia maszynowego, takie jak drzewa decyzyjne, uczenie zespołowe, regresja, klasyfikatory oparte na odległości czy maszyny wektorów nośnych.</p> <p>W02: rozumie metody radzenia sobie z niezrównoważonymi zbiorami danych oraz koncepcje AutoML i uczenia federacyjnego.</p> <p>W03: posiada wiedzę na temat budowy i działania systemów rekomendacyjnych.</p> <p>W04: zna podstawy sieci neuronowych, w tym perceptron, uczenie Hebba, Adaline oraz sieci jednokierunkowe.</p> <p>W05: rozumie zasady działania nowoczesnych architektur sieci neuronowych, takich jak sieci rekurencyjne (RNN, LSTM) i konwolucyjne (CNN).</p>	<p>SD_W01 SD_W03 - SD_W06 SD_W09</p>
--	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	----------------------------------------------

	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
Umiejętności	<p>Po zakończeniu kursu student:</p> <p>U01: potrafi zaprojektować i zaimplementować modele uczenia maszynowego i głębokich sieci neuronowych, dobrać odpowiednie metody i algorytmy w zależności od typu danych oraz przeprowadzić analizę ich skuteczności i ograniczeń;</p> <p>U02: potrafi dokonać eksploracyjnej analizy danych rzeczywistych, w tym wizualizacji i interpretacji wyników, a także zaprezentować rozwiązanie w sposób czytelny dla zespołu, uwzględniając aspekty etyczne i ochrony danych.</p>	<p>SD_U02 SD_U03 SD_U05 SD_U06 SD_U08 SD_U09</p>

	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
Kompetencje społeczne	<p>Po zakończeniu kursu student:</p> <p>K01: ma świadomość społecznej i zawodowej roli specjalisty zajmującego się analizą danych i uczeniem maszynowym oraz znaczenia wpływu swojej pracy na otoczenie;</p> <p>K02: potrafi formułować i uzasadniać opinie dotyczące metod eksploracji danych, uczenia maszynowego, sztucznej inteligencji i technologii chmurowych, uwzględniając aspekty praktyczne i teoretyczne;</p> <p>K03: ma świadomość znaczenia profesjonalnego i etycznego zachowania w pracy z danymi, potrafi identyfikować i rozstrzygać dylematy etyczne związane z projektami z obszaru Data Science.</p>	<p>SD_K01 - SD_K03</p>

#### 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 uczenia się

	E – learning	Gry dydaktyczne	Ćwiczenia w szkole	Zajęcia terenowe	Praca laboratoryjna	Projekt indywidualny	Projekt grupowy	Udział w dyskusji	Referat	Praca pisemna (esej)	Egzamin ustny	Egzamin pisemny	Inne
W01					X	X	X	X					
W02					X	X	X	X					
W03					X	X	X	X					
U01					X	X	X	X					
U02					X	X	X	X					
K01								X					
K02								X					
K03								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)  <b>Obecność na wykładach jest obowiązkowa i stanowi warunek zaliczenia tej części kursu.</b>
--	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Uwagi	
-------	--

#### Treści merytoryczne (wykaz tematów)

<ol style="list-style-type: none"> <li>1. Wprowadzenie do uczenia maszynowego, drzewa decyzyjne, entropia, indeks GINI.</li> <li>2. Uczenie zespołowe w uczeniu maszynowym – Bagging, Boosting i Stacking (Random Forest, AdaBoost, XGBoost, Gradient Boosted Decision Tree).</li> <li>3. Regresja i metryki oceny jakości modeli.</li> <li>4. Maszyny wektorów nośnych (Support Vector Machines).</li> <li>5. Klasyfikatory oparte na miarach odległości.</li> <li>6. Niezrównoważone zbiory danych, AutoML, uczenie federacyjne.</li> <li>7. Systemy rekomendacyjne.</li> <li>8. Sieci neuronowe: neurony logiczne, uczenie Hebba, adaptacyjny neuron liniowy (Adaline).</li> <li>9. Sieć neuronowa jednokierunkowa (feedforward neural network).</li> <li>10. Spadek gradientowy (batch, stochastic, mini-batch), współczynnik uczenia, metoda Adam, dropout, hiperparametry w sieciach neuronowych.</li> <li>11. Sieci rekurencyjne (RNN) i sieci długiej pamięci krótkotrwałej (LSTM).</li> <li>12. Konwolucyjne sieci neuronowe (CNN): splot i pooling, najważniejsze architektury CNN.</li> </ol>
----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

#### Wykaz literatury podstawowej

<ol style="list-style-type: none"> <li>1. Fox, E., Guestrin, C. <i>Machine Learning Specialization</i>, University of Washington <a href="https://www.coursera.org/specializations/machine-learning">https://www.coursera.org/specializations/machine-learning</a></li> <li>2. Zhang, A., Lipton, Z. C., Li, M., Smola, A.J. (2024). <i>Dive into Deep Learning</i>. Cambridge University Press. 574 p. <a href="https://www.d2l.ai/">https://www.d2l.ai/</a></li> <li>3. Géron, A. (2019). <i>Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow</i> (2nd ed.). O'Reilly Media. 849 pp.</li> <li>4. Burkov, A. (2019). <i>The Hundred-Page Machine Learning Book</i>. Andriy Burkov Publishing. 160 pp.</li> <li>5. Ameisen, E. (2021). <i>Uczenie maszynowe w aplikacjach. Projektowanie, budowa i wdrażanie</i>. Gliwice: Helion. 224 s.</li> <li>6. Szeliga, M. (2019). <i>Praktyczne uczenie maszynowe</i>. Warszawa: Wydawnictwo Naukowe PWN. 468 s.</li> </ol>
-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

#### Wykaz literatury uzupełniającej

<ol style="list-style-type: none"> <li>1. Raschka, S., &amp; Mirjalili, V. (2019). <i>Python Machine Learning</i> (3rd ed.). Packt Publishing. 770 pp.</li> <li>2. Goodfellow, I., Bengio, Y., &amp; Courville, A. (2016). <i>Deep Learning</i>. MIT Press. 775 pp.</li> <li>3. Bishop, C. M. (2006). <i>Pattern Recognition and Machine Learning</i>. Springer. 738 pp.</li> <li>4. Murphy, K. P. (2012). <i>Machine Learning: A Probabilistic Perspective</i>. MIT Press. 1,106 pp.</li> <li>5. Domingos, P. (2015). <i>The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World</i>. Basic Books. 352 pp.</li> <li>6. Géron, A. (2023). <i>Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow</i> (wyd. 3). Gliwice: Helion. 776 s.</li> <li>7. Kapusta, J., Držik, D., Šteflovíč, K., Szabó Nagy, K. (2024). Text Data Augmentation Techniques for Word Embeddings in Fake News Classification. <i>IEEE ACCESS</i>. 12, 31538-31550</li> <li>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. <i>NEURAL COMPUTING AND APPLICATIONS</i>. 35 (9), 22055-22067</li> </ol>
--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

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	10
liczba godzin pracy studenta bez kontaktu z prowadzącymi	Lektura w ramach przygotowania do zajęć	15
	Przygotowanie krótkiej pracy pisemnej lub referatu po zapoznaniu się z niezbędną literaturą przedmiotu	
	Przygotowanie projektu lub prezentacji na podany temat (praca w grupie)	15
	Przygotowanie do egzaminu/zaliczenia	
Ogółem bilans czasu pracy		90
Liczba punktów ECTS w zależności od przyjętego przelicznika		4

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	20
	Przygotowanie krótkiej pracy pisemnej lub referatu po zapoznaniu się z niezbędną literaturą przedmiotu	
	Przygotowanie projektu lub prezentacji na podany temat (praca w grupie)	20
	Przygotowanie do egzaminu/zaliczenia	
Ogółem bilans czasu pracy		85
Liczba punktów ECTS w zależności od przyjętego przelicznika		4