



Analiza danych i uczenie maszynowe

Karta opisu przedmiotu

Informacje podstawowe

Kierunek studiów Nowoczesne Technologie w Kryminalistyce (kierunek wspólny - WIEiT, WH, WIMiC)		Cykl dydaktyczny 2025/2026	
Specjalność -		Kod przedmiotu INKTS.II20.08565.25	
Jednostka organizacyjna Wydział Informatyki, Elektroniki i Telekomunikacji		Języki wykładowe polski	
Poziom kształcenia Studia inżynierskie I stopnia		Obligatoryjność Obowiązkowy	
Forma studiów Stacjonarne		Blok zajęciowy Przedmioty kierunkowe	
Profil studiów Ogólnoakademicki		Przedmiot powiązany z badaniami naukowymi Tak	
Koordynator przedmiotu	Maciej Wielgosz		
Prowadzący zajęcia	Maciej Wielgosz		
Okres Semestr 6	Forma zaliczenia Zaliczenie	Liczba punktów ECTS 5	
	Forma prowadzenia i godziny zajęć Wykład: 28 Ćwiczenia projektowe: 28		

Cele kształcenia dla przedmiotu

C1	Przekazanie wiedzy z zakresu technik i metod uczenia maszynowego.
C2	Zapoznanie studentów z bieżącymi trendami w dziedzinie.
C3	Uświadomienie słuchaczom problemów dotyczących analizy danych pochodzących z różnych źródeł.

Efekty uczenia się dla przedmiotu

Kod	Efekty w zakresie	Kierunkowe efekty uczenia się	Metody weryfikacji
Wiedzy - Student zna i rozumie:			
W1	Zna specyfikę oraz dobre praktyki pracy z danymi pochodzącymi z różnych źródeł.	NKT1A_W05, NKT1A_W09	Aktywność na zajęciach, Udział w dyskusji
W2	Zna metody i techniki uczenia maszynowego i ich zastosowanie w analizie danych.	NKT1A_W05, NKT1A_W09	Aktywność na zajęciach, Udział w dyskusji
Umiejętności - Student potrafi:			
U1	Umie rozwiązywać zadane problemy poprzez dobór odpowiednich algorytmów uczenia maszynowego i ich wdrożenie z użyciem dostępnych bibliotek lub narzędzi wysokiego poziomu.	NKT1A_U04, NKT1A_U06, NKT1A_U07, NKT1A_U08	Projekt
Kompetencji społecznych - Student jest gotów do:			
K1	Rozumie znaczenie, korzyści i trudności związane z łączeniem danych pochodzących z różnych źródeł.	NKT1A_K04	Aktywność na zajęciach, Udział w dyskusji

Treści programowe zapewniające uzyskanie efektów uczenia się dla modułu zajęć

W trakcie realizacji modułu przedstawione zostaną techniki i metody uczenia maszynowego, ze szczególnym uwzględnieniem bieżących trendów oraz kwestii dotyczących analizy danych pochodzących z różnych źródeł. Studenci zachęceni będą do udziału w dyskusjach, a praktyczną znajomość przedstawianych zagadnień potwierdzą realizując w niewielkich grupach projekty.

Nakład pracy studenta

Rodzaje zajęć studenta	Średnia liczba godzin* przeznaczonych na zrealizowane aktywności
Wykład	28
Ćwiczenia projektowe	28
Przygotowanie do zajęć	15
Samodzielne studiowanie tematyki zajęć	30
Dodatkowe godziny kontaktowe	5
Przygotowanie projektu, prezentacji, pracy pisemnej, sprawozdania	30
Łączny nakład pracy studenta	Liczba godzin 136
Liczba godzin kontaktowych	Liczba godzin 56

* godzina (lekcyjna) oznacza 45 minut

Treści programowe

Lp.	Treści programowe	Efekty uczenia się dla przedmiotu	Formy prowadzenia zajęć
1.	Podstawowe pojęcia i klasyfikacja algorytmów uczenia maszynowego.	W2	Wykład
2.	Proces analizy danych w praktyce: dobór algorytmów i dobre praktyki.	W1, W2, U1, K1	Wykład, Ćwiczenia projektowe
3.	Bieżące trendy w uczeniu maszynowym.	W1, W2, K1	Wykład
4.	Analiza danych pochodzących z różnych źródeł.	W1, K1	Wykład, Ćwiczenia projektowe

Informacje rozszerzone

Metody i techniki kształcenia :

Kształcenie zdalne, Mini wykład, Dyskusja, Praca grupowa, Metoda projektowa (ang. Project Based Learning)

Rodzaj zajęć	Metody zaliczenia	Warunki zaliczenia przedmiotu
Wykład	Aktywność na zajęciach, Udział w dyskusji	
Ćwiczenia projektowe	Aktywność na zajęciach, Udział w dyskusji, Projekt	

Dodatkowy opis

Zajęcia są prowadzone z wykorzystaniem innowacyjnych metod dydaktycznych opracowanych w projekcie POWR.03.04.00-00-D002/16, realizowanym w latach 2017-2019 na Wydziale Informatyki, Elektroniki i Telekomunikacji w ramach Programu Operacyjnego Wiedza Edukacja Rozwój 2014-2020.

Warunki i sposób zaliczenia poszczególnych form zajęć, w tym zasady zaliczeń poprawkowych, a także warunki dopuszczenia do egzaminu

Wykonanie zadań na zajęciach oraz projektu głównego.

Sposób obliczania oceny końcowej

Równoważna ocenie z ćwiczeń projektowych.

Sposób i tryb wyrównywania zaległości powstałych wskutek nieobecności studenta na zajęciach

Wykonanie w czasie własnym/na zajęciach innej grupy wymaganych zadań.

Wymagania wstępne i dodatkowe

Podstawowa znajomość języka Python.

Zasady udziału w poszczególnych zajęciach, ze wskazaniem, czy obecność studenta na zajęciach jest obowiązkowa

Wykład: Studenci uczestniczą w zajęciach poznając kolejne treści nauczania zgodnie z sylabusem przedmiotu. Studenci winni na bieżąco zadawać pytania i wyjaśniać wątpliwości. Rejestracja audiowizualna wykładu wymaga zgody prowadzącego. Obecność nie jest obowiązkowa.

Ćwiczenia projektowe: obecność obowiązkowa na pierwszych kilku zajęciach (zadania/mini-projekty), potem konsultacje dt. głównego projektu w razie potrzeby.

Literatura

Obowiązkowa

1. Maciej Wielgosz, Machine Learning Primer, 2019. <https://maciej.wielgosz.info/machine-learning-primer>

Dodatkowa

1. John D. Kelleher, Brian MacNamee, Aoife D'Arcy. Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies. The MIT Press, 2015.
2. Ian Goodfellow, Yoshua Bengio, Aaron Courville. Deep Learning. The MIT Press, 2016. <https://www.deeplearningbook.org/>

Badania i publikacje

Publikacje

1. Maciej Wielgosz, Andrzej Skoczeń, Matej Mertik. Using LSTM recurrent neural networks for detecting anomalous behavior of LHC superconducting magnets. Nuclear Inst. and Methods in Physics Research, A, 867:40-50, 2017. doi:10.1016/j.nima.2017.06.020
2. Maciej Wielgosz, Matej Mertik, Andrzej Skoczeń, Ernesto De Matteis. The model of an anomaly detector for HiLumi LHC magnets based on Recurrent Neural Networks and adaptive quantization. Engineering Applications of Artificial Intelligence, 74:166-185, 2018. ISSN 0952-1976. doi: 10.1016/j.engappai.2018.06.012
3. Maciej Wielgosz, Andrzej Skoczeń. Using neural networks with data quantization for time series analysis in LHC superconducting magnets. International Journal of Applied Mathematics and Computer Science, 29(3):503-515, Sep 2019. ISSN 1641-876X. doi: 10.2478/amcs-2019-0037
4. Maciej Wielgosz, Marcin Pietroń. Using Spatial Pooler of Hierarchical Temporal Memory to classify noisy videos with predefined complexity. Neurocomputing, 240:84-97, May 2017. ISSN 0925-2312. doi: 10.1016/j.neucom.2017.02.046
5. M. Markiewicz, M. Wielgosz, M. Bocheński, W. Tabaczyński, T. Konieczny, L. Kowalczyk. Predictive maintenance of induction motors using ultra-low power wireless sensors and compressed recurrent neural networks. IEEE Access, 7:178891-178902, Dec 2019. ISSN 2169-3536. doi: 10.1109/ACCESS.2019.2953019
6. Maciej Wielgosz, Rafał Frączek, Paweł Russek, Marcin Pietroń, Agnieszka Dąbrowska-Boruch, Ernest Jamro, Kazimierz Wiatr. An experiment on the methods for the clustering and categorization of Polish text. Computing and Informatics, 36(1):186-204, 2017. doi: 10.4149/cai_2017_1_186
7. Krzysztof Wróbel, Maciej Wielgosz, Aleksander Smywiński-Pohl, Marcin Pietroń. Comparison of SVM and Ontology-Based Text Classification Methods. W Artificial Intelligence and Soft Computing: 15th International Conference, ICAISC 2016, Zakopane, Poland, June 12-16, 2016, Proceedings, Part I, str. 667-680, Cham, 2016. Springer. ISBN 978-3-319-39378-0. doi: 10.1007/978-3-319-39378-0_57

Kierunkowe efekty uczenia się

Kod	Treść
NKT1A_K04	Ma świadomość znaczenia wiedzy interdyscyplinarnej w procesie opisu oraz wyjaśniania różnych procesów i zjawisk społecznych
NKT1A_U04	Potrafi planować i przeprowadzać testy, eksperymenty i badania z dziedziny elektroniki, telekomunikacji i informatyki, w szczególności związane z analizą kryminalistyczną oraz analizą bezpieczeństwa, oparte na obliczeniach, symulacjach komputerowych i pomiarach.
NKT1A_U06	Potrafi pozyskiwać informacje z literatury, baz danych i innych źródeł; potrafi integrować uzyskane informacje, dokonywać ich interpretacji, a także wyciągać wnioski oraz formułować i uzasadniać opinie;
NKT1A_U07	Potrafi projektować systemy wbudowane oraz aplikacje komputerowe z uwzględnieniem zadanych kryteriów użytkowych i ekonomicznych, wspierających proces wnioskowania w kryminalistyce, przy wykorzystaniu właściwych metod, technik i narzędzi,
NKT1A_U08	Potrafi posłużyć się właściwie dobranymi metodami i urządzeniami umożliwiającymi pomiar podstawowych wielkości charakteryzujących układy elektroniczne, systemy transmisji danych oraz przetwarzania informacji; potrafi dobrać odpowiednia narzędzia informatyczne do analizy kryminalistycznej, umie ocenić przydatność poznanych technik analizy danych do rozwiązywania prostych zadań inżynierskich,
NKT1A_W05	Ma uporządkowaną wiedzę w zakresie metodyki i technik programowania; zna zasady doboru języka programowania do rozwiązywania problemów w zakresie oprogramowania sprzętu i usług; rozumie metody specyfikowania podstawowych wymagań w zakresie oprogramowania;
NKT1A_W09	Zna i rozumie metody, narzędzia oraz techniki pozyskiwania informacji i danych pozwalających opisywać procesy i zjawiska społeczne