



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Nauka o danych i uczenie maszynowe dla e-handlu [S2SI1E>NDUM]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

2/3

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obieralny

Liczba godzin

Wykład

20

Laboratorium

20

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

2,00

Koordynatorzy

dr inż. Andrzej Szwabe

andrzej.szwabe@put.poznan.pl

Wykładowcy

Wymagania wstępne

Osoba rozpoczynająca ten przedmiot powinna posiadać podstawową wiedzę ze statystyki, nauki o danych (ang. data science) i uczenia maszynowego oraz umiejętności programowania w języku Python.

Cel przedmiotu

Celem przedmiotu jest zapoznanie studenta z wybranymi problemami e-handlu - w szczególności rozwiązywalnymi z użyciem metod nauki o danych i uczenia maszynowego - oraz ze sposobami praktycznego zastosowania wybranych metod do rozwiązywania przykładowych problemów.

Przedmiotowe efekty uczenia się

Wiedza K2st_W2: Student ma uporządkowaną i podbudowaną teoretycznie wiedzę o kluczowych zagadnieniach z zakresu nauki o danych i uczenia maszynowego dla e-handlu ze szczególnym uwzględnieniem metod sztucznej inteligencji skutecznie stosowalnych do rozwiązywania wybranych istotnych problemów e-handlu

K2st_W3: Student ma zaawansowaną wiedzę szczegółową dotyczącą wybranych zagadnień z zakresu sztucznej inteligencji dla e-handlu

K2st_W5: Student ma zaawansowaną i szczegółową wiedzę o procesach zachodzących w cyklu życia

systemów sztucznej inteligencji dla e-handlu

K2st_W6: Student zna zaawansowane metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań inżynierskich i prowadzeniu prac badawczych w dziedzinie sztucznej inteligencji dla e-handlu

Umiejętności K2st_U6: Student potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć (metod i narzędzi) oraz nowych produktów w zakresie sztucznej inteligencji dla e-handlu

K2st_U8: Student potrafi dokonać krytycznej analizy istniejących rozwiązań w zakresie sztucznej inteligencji dla e-handlu oraz zaproponować ich ulepszenia (usprawnienia)

K2st_U9: Student potrafi ocenić przydatność metod i narzędzi służących do rozwiązania zadania inżynierskiego, polegającego na budowie lub ocenie systemu sztucznej inteligencji dla e-handlu lub jego składowych, w tym dostrzec ograniczenia tych metod i narzędzi

K2st_U10: Student potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania z zakresu sztucznej inteligencji dla e-handlu, zadania nietypowe oraz zadania zawierające komponent badawczy

K2st_U11: Student potrafi — zgodnie z zadaną specyfikacją, uwzględniającą aspekty pozatechniczne — zaprojektować złożony system predykcyjny dla e-handlu oraz zrealizować ten projekt — co najmniej w części — używając właściwych metod, technik i narzędzi, w tym przystosowując do tego celu istniejące lub opracowując nowe narzędzia

Kompetencje społeczne K2st_K1: Student rozumie, że w obszarze sztucznej inteligencji dla e-handlu niektóre składniki wiedzy i umiejętności bardzo szybko stają się przestarzałe

K2st_K2: Student rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu sztucznej inteligencji w rozwiązywaniu problemów badawczych i praktycznych w obszarze nauki o danych i uczenia maszynowego dla e-handlu

K2st_K4: Student ma świadomość potrzeby rozwijania dorobku zawodowego w zakresie nauki o danych i uczenia maszynowego dla e-handlu oraz przestrzegania zasad etyki zawodowej

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Ocena podsumowująca:

a) w zakresie wykładów: ocena wiedzy i umiejętności wykazanych na sprawdzianie składającym się z kilkunastu pytań o charakterze testu lub krótkich zadań. Przekroczenie 50% punktów pozwala uzyskać ocenę dostateczną.

b) w zakresie laboratoriów: ocena realizacji ćwiczeń laboratoryjnych, odpowiedzi pisemnych (zapisywanych jako komentarze w plikach Jupyter Notebook) oraz sprawozdań przygotowywanych częściowo w trakcie zajęć, a częściowo po ich zakończeniu (jako praca domowa).

Treści programowe

Podstawy nauki o danych (ang. data science), analityki danych i praktycznego predykcyjnego uczenia maszynowego dla e-handlu (ang. e-commerce). Kluczowe wskaźniki wydajności (ang. Key Performance Indices, KPIs) w e-handlu. Ocena wydajności aktywnych algorytmów służących maksymalizacji KPI w oparciu o tradycyjne, pasywne prognozy uczenia maszynowego. Metodologia testów A/B w e-handlu. Modelowanie KPI w e-handlu na potrzeby algorytmów regresji i bezpośredniej optymalizacji KPI. Platformy analityczne e-handlu (np. Google Analytics). Usługi reklamowe e-handlu (np. Google Ads, Google Shopping). Reprezentacja danych produktów e-handlu, w tym format danych pliku danych o produktach w Zakupach Google i taksonomia produktów Google. Platformy reklamowe e-handlu (np. Google Merchant Center). Integracja danych z platform analitycznych e-handlu i platform reklamowych e-handlu (np. Google Merchant Center). Platformy analityczne e-handlu (np. Google Analytics). Usługi reklamowe dla e-handlu (np. Google Ads, Google Shopping). Platformy reklamowe dla e-handlu (np. Google Merchant Center). Integracja danych z platform analitycznych i platform reklamowych dla e-handlu (np. Google Merchant Center). Zastosowanie uczenia maszynowego (w tym uczenia głębokiego, ang. deep learning) do predykcji kluczowych miar i kluczowych wskaźników efektywności (KPI) dla e-handlu: współczynnika klikalności (ang. click-through rate, CTR), współczynnika konwersji (ang. conversion rate, CR), współczynnika zwrotu z wydatków na reklamę (ang. Return On Advertising Spend, ROAS). Przewidywanie tzw. długoterminowej wartości klienta (ang. Customer Lifetime Value, CLV) z użyciem uczenia maszynowego dla e-handlu. Optymalizacja parametrów funkcji licytacji powierzchni reklamowej dla e-handlu (np. stawek, ang. bids). Potoki uczenia maszynowego dla predykcyjnych systemów dla e-handlu. Horyzontalna dekompozycja systemów predykcyjnych dla wdrożenia skonteneryzowanego w środowiskach chmurowych. Algorytmy do optymalizacji hiperparametrów potoków uczenia maszynowego dla systemów predykcyjnych w e-handlu.

Tematyka zajęć

Kluczowe wskaźniki wydajności (ang. Key Performance Indices, KPIs) w e-handlu. Ocena wydajności aktywnych algorytmów służących maksymalizacji KPI w oparciu o tradycyjne, pasywne prognozy uczenia maszynowego. Metodologia testów A/B w e-handlu. Modelowanie KPI w e-handlu na potrzeby algorytmów regresji i bezpośredniej optymalizacji KPI. Platformy analityczne e-handlu (np. Google Analytics). Usługi reklamowe e-handlu (np. Google Ads, Google Shopping). Reprezentacja danych produktów e-handlu, w tym format danych pliku danych o produktach w Zakupach Google i taksonomia produktów Google. Platformy reklamowe e-handlu (np. Google Merchant Center). Integracja danych z platform analitycznych e-handlu i platform reklamowych e-handlu (np. Google Merchant Center). Platformy analityczne e-handlu (np. Google Analytics). Usługi reklamowe dla e-handlu (np. Google Ads, Google Shopping). Platformy reklamowe dla e-handlu (np. Google Merchant Center). Integracja danych z platform analitycznych i platform reklamowych dla e-handlu (np. Google Merchant Center). Zastosowanie uczenia maszynowego (w tym uczenia głębokiego, ang. deep learning) do predykcji kluczowych miar i kluczowych wskaźników efektywności (KPI) dla e-handlu: współczynnika klikalności (ang. click-through rate, CTR), współczynnika konwersji (ang. conversion rate, CR), współczynnika zwrotu z wydatków na reklamę (ang. Return On Advertising Spend, ROAS). Przewidywanie tzw. długoterminowej wartości klienta (ang. Customer Lifetime Value, CLV) z użyciem uczenia maszynowego dla e-handlu. Optymalizacja parametrów funkcji licytacji powierzchni reklamowej dla e-handlu (np. stawek, ang. bids). Potoki uczenia maszynowego dla predykcyjnych systemów dla e-handlu. Horyzontalna dekompozycja systemów predykcyjnych dla wdrożenia skonteneryzowanego w środowiskach chmurowych. Algorytmy do optymalizacji hiperparametrów potoków uczenia maszynowego dla systemów predykcyjnych w e-handlu.

Metody dydaktyczne

Wykład: prezentacja slajdów ilustrowana przykładami podawanymi na tablicy, odwołania do wybranych elementów ćwiczeń laboratoryjnych

Ćwiczenia laboratoryjne: prezentacja w formacie Jupyter Notebook ilustrowana przykładami podawanymi na tablicy oraz wykonanie zadań podanych przez prowadzącego – ćwiczenia praktyczne

Literatura

1. Turban, E., Whiteside, J., King, D., & Outland, J. (2017). Introduction to electronic commerce and social commerce. Springer, https://eprints.ukh.ac.id/id/eprint/260/1/2017_Book_IntroductionToElectronicCommer.pdf
 2. Chopra, P., Dixon, E., Enos, E., & Brodmerkle, S. (2013). Practical Web Analytics for User Experience: How Analytics Can Help You Understand. Exchange, https://www.academia.edu/download/44998812/Practical_Web_Analytics_for_Use_-_Michael_Beasley.pdf
 3. Tallis, M., & Yadav, P. (2018, December). Reacting to variations in product demand: An application for conversion rate (cr) prediction in sponsored search. In 2018 IEEE International Conference on Big Data (Big Data) (pp. 1856-1864). IEEE, <https://arxiv.org/pdf/1806.08211>
- Uzupełniająca
1. Policarpo, L. M., da Silveira, D. E., da Rosa Righi, R., Stoffel, R. A., da Costa, C. A., Barbosa, J. L. V., ... & Arcot, T. (2021). Machine learning through the lens of e-commerce initiatives: An up-to-date systematic literature review. Computer Science Review, 41, 100414, <https://www.sciencedirect.com/science/article/pii/S157401372100054X/pdf>
 2. Hutter, F., Kotthoff, L., & Vanschoren, J. (2019). Automated machine learning: methods, systems, challenges (p. 219). Springer Nature, https://www.automl.org/wp-content/uploads/2019/05/AutoML_Book.pdf
 3. Shah, C. (2020). A hands-on introduction to data science. Cambridge University Press, https://toc.library.ethz.ch/objects/pdf03/z01_1-108-47244-3_01.pdf
 4. Laura, I., & Santi, S. (2017). Introduction to Data Science: A Python Approach to Concepts, Techniques and Applications

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	50	2,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	40	1,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwiiw/egzaminu, wykonanie projektu)	10	0,50