



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Automatyczne uczenie maszynowe [S2SI1E>AUM]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

1/2

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

30

Laboratorium

30

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

5,00

Koordynatorzy

dr inż. Andrzej Szwabe

andrzej.szwabe@put.poznan.pl

Wykładowcy

Wymagania wstępne

Osoba rozpoczynająca ten przedmiot powinna posiadać podstawową wiedzę z uczenia maszynowego, a w szczególności podstawową wiedzę o hiperparametrach algorytmów uczenia maszynowego oraz umiejętności programistyczne.

Cel przedmiotu

Celem przedmiotu jest zapoznanie studenta z wybranymi zagadnieniami automatyzacji nadzorowanego uczenia maszynowego, w szczególności z zakresu automatyzacji strojenia hiperparametrach algorytmów uczenia maszynowego – zgodnie z paradygmatami optymalizacji Bayesowskiej i innymi paradygmatami optymalizacji nie wykorzystującej danych o gradientie funkcji celu – oraz ze sposobami praktycznego zastosowania wybranych metod do rozwiązywania przykładowych problemów.

Przedmiotowe efekty uczenia się

Wiedza K2st_W1: ma zaawansowaną i pogłębioną wiedzę z zakresu systemów zautomatyzowanego uczenia maszynowego, podstaw teoretycznych ich budowania oraz metod, narzędzi i środowisk programistycznych wykorzystywanych do ich implementacji

K2st_W2: ma uporządkowaną i podbudowaną teoretycznie wiedzę ogólną związaną z kluczowymi

zagadnieniami z zakresu automatyzacji uczenia maszynowego

K2st_W3: ma zaawansowaną wiedzę szczegółową dotyczącą wybranych zagadnień z zakresu automatyzacji uczenia maszynowego

K2st_W4: ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach w obszarze automatyzacji uczenia maszynowego

K2st_W5: ma zaawansowaną i szczegółową wiedzę o procesach zachodzących w cyklu życia systemów zautomatyzowanego uczenia maszynowego

K2st_W6: zna zaawansowane metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań inżynierskich i prowadzeniu prac badawczych w dziedzinie zautomatyzowanego uczenia maszynowego

Umiejętności K2st_U1: potrafi pozyskiwać informacje z literatury, baz danych oraz innych źródeł (w języku polskim i angielskim), integrować je, dokonywać ich interpretacji i krytycznej oceny, wyciągać wnioski oraz formułować i wyczerpująco uzasadniać opinie

K2st_U3: potrafi planować i przeprowadzać eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski oraz formułować i weryfikować hipotezy związane ze złożonymi problemami inżynierskimi i prostymi problemami badawczymi

K2st_U4: potrafi wykorzystać do formułowania i rozwiązywania zadań inżynierskich i prostych problemów badawczych metody analityczne, symulacyjne oraz eksperymentalne

K2st_U5: potrafi — przy formułowaniu i rozwiązywaniu zadań inżynierskich — integrować wiedzę z obszaru zautomatyzowanego uczenia maszynowego oraz zastosować podejście systemowe, uwzględniające także aspekty pozatechniczne

K2st_U6: potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć (metod i narzędzi) oraz nowych produktów z obszaru zautomatyzowanego uczenia maszynowego

K2st_U8: potrafi dokonać krytycznej analizy istniejących rozwiązań technicznych oraz zaproponować ich ulepszenia

K2st_U9: potrafi ocenić przydatność metod i narzędzi służących do rozwiązania zadania inżynierskiego, polegającego na budowie lub ocenie systemu zautomatyzowanego uczenia maszynowego, w tym dostrzec ograniczenia tych metod i narzędzi

K2st_U10: potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania z zakresu zautomatyzowanego uczenia maszynowego, zadania nietypowe oraz zadania zawierające komponent badawczy

Kompetencje społeczne K2st_K1: rozumie, że w informatyce, ze szczególnym uwzględnieniem technologii zautomatyzowanego uczenia maszynowego niektóre elementy wiedzy i umiejętności bardzo szybko stają się przestarzałe

K2st_K2: rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu zautomatyzowanego uczenia maszynowego w rozwiązywaniu problemów badawczych i praktycznych

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

Problem strojenia hiperparametrów algorytmów uczenia maszynowego jako szczególny rodzaj problemu optymalizacyjnego. Warunkowe przestrzenie konfiguracji hiperparametrów. Problem kompromisu między eksploracją a eksploatacją w optymalizacji hiperparametrów. Problem różnicy między funkcją celu reprezentowaną w zbiorze uczącym a funkcją celu reprezentowaną w zbiorze walidacyjnym/testowym. Automatyzacja optymalizacji hiperparametrów algorytmów uczenia maszynowego z użyciem tradycyjnych algorytmów niewymagających modelowania surrogatywnego (przeszukiwanie kratowe, przeszukiwanie losowe). Niezależność hiperparametrów i wyższość przeszukiwania losowego nad przeszukiwaniem kratowym. Ograniczona stosowalność algorytmów optymalizacji wyszukiwania bezpośredniego (np. przeszukiwania kompasowego) do optymalizacji hiperparametrów. Optymalizacja bayesowska. Specyfika regresji w modelowaniu surogatywnym w optymalizacji bayesowskiej - łączna predykcja wartości

oczekiwanej i wariancji. Regresja procesami Gaussa. Wydajna regresja dla optymalizacji bayesowskiej. Funkcja akwizycji. Specyfika optymalizacji hiperparametrów jako specjalnej klasy problemów optymalizacyjnych bez dostępności danych o gradientach funkcji celu. Algorytmy automatycznej syntezy cech dla uczenia maszynowego. Relacyjne modele danych do automatycznej syntezy cech. „Tradycyjna” automatyzacja dostrajania hiperparametrów potoków ML ograniczona do dostrajania hiperparametrów algorytmów uczenia modeli. Rozszerzona automatyzacja strojenia hiperparametrów potoków przetwarzania dla uczenia maszynowego „end-to-end”. Połączone strojenie algorytmów modelowania danych relacyjnych, algorytmów syntezy cech, algorytmów selekcji cech oraz algorytmów tzw. trenowania modelu. Algorytmy optymalizacji z użyciem wielu poziomów wierności reprezentacji danych (ang. multi-fidelity): successive halving, HyperBand, BOHB i DEHB. Podejście do problemu automatyzacji strojenia hiperparametrów algorytmów uczenia maszynowego uwzględniające całkowity koszt obliczeniowy i jego składowe: koszt obliczeniowy uzyskania kolejnych wartości funkcji celu oraz koszt obliczeniowy algorytmu optymalizacji, tj. wyznaczenia kolejnych punktów w przestrzeni dziedziny funkcji celu.

Tematyka zajęć

Problem strojenia hiperparametrów algorytmów uczenia maszynowego jako szczególny rodzaj problemu optymalizacyjnego. Warunkowe przestrzenie konfiguracji hiperparametrów. Problem kompromisu między eksploracją a eksploatacją w optymalizacji hiperparametrów. Problem różnicy między funkcją celu reprezentowaną w zbiorze uczącym a funkcją celu reprezentowaną w zbiorze walidacyjnym/testowym. Automatyzacja optymalizacji hiperparametrów algorytmów uczenia maszynowego z użyciem tradycyjnych algorytmów niewymagających modelowania surrogatywnego (przeszukiwanie kratowe, przeszukiwanie losowe). Niezależność hiperparametrów i wyższość przeszukiwania losowego nad przeszukiwaniem kratowym. Ograniczona stosowalność algorytmów optymalizacji wyszukiwania bezpośredniego (np. przeszukiwania kompasowego) do optymalizacji hiperparametrów. Optymalizacja bayesowska. Specyfika regresji w modelowaniu surrogatywnym w optymalizacji bayesowskiej - łączna predykcja wartości oczekiwanej i wariancji. Regresja procesami Gaussa. Wydajna regresja dla optymalizacji bayesowskiej. Funkcja akwizycji. Specyfika optymalizacji hiperparametrów jako specjalnej klasy problemów optymalizacyjnych bez dostępności danych o gradientach funkcji celu. Algorytmy automatycznej syntezy cech dla uczenia maszynowego. Relacyjne modele danych do automatycznej syntezy cech. „Tradycyjna” automatyzacja dostrajania hiperparametrów potoków ML ograniczona do dostrajania hiperparametrów algorytmów uczenia modeli. Rozszerzona automatyzacja strojenia hiperparametrów potoków przetwarzania dla uczenia maszynowego „end-to-end”. Połączone strojenie algorytmów modelowania danych relacyjnych, algorytmów syntezy cech, algorytmów selekcji cech oraz algorytmów tzw. trenowania modelu. Algorytmy optymalizacji z użyciem wielu poziomów wierności reprezentacji danych (ang. multi-fidelity): successive halving, HyperBand, BOHB i DEHB. Podejście do problemu automatyzacji strojenia hiperparametrów algorytmów uczenia maszynowego uwzględniające całkowity koszt obliczeniowy i jego składowe: koszt obliczeniowy uzyskania kolejnych wartości funkcji celu oraz koszt obliczeniowy algorytmu optymalizacji, tj. wyznaczenia kolejnych punktów w przestrzeni dziedziny funkcji celu.

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

Podstawowa 1. 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

2. B. Shahriari, K. Swersky, Z. Wang, R. P. Adams and N. de Freitas, "Taking the Human Out of the Loop: A Review of Bayesian Optimization," in Proceedings of the IEEE, vol. 104, no. 1, pp. 148-175, Jan. 2016, doi: 10.1109/JPROC.2015.2494218, <https://ieeexplore.ieee.org/document/7352306>

Uzupełniająca 1. Williams, C. K., & Rasmussen, C. E. (2006). Gaussian processes for machine learning (Vol. 2, No. 3, p. 4). Cambridge, MA: MIT press, <http://www.gaussianprocess.org/gpml/>

2. Brochu, E., Cora, V. M., & De Freitas, N. (2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. arXiv preprint

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	60	2,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwiiw/egzaminu, wykonanie projektu)	65	2,50