



Elementy statystycznego uczenia maszynowego

Karta opisu przedmiotu

Informacje podstawowe

Kierunek studiów Informatyka (kierunek wspólny - WI) Specjalność - Jednostka organizacyjna Wydział Informatyki Poziom kształcenia Studia inżynierskie I stopnia Forma studiów Stacjonarne Profil studiów Ogólnoakademicki		Cykl dydaktyczny 2022/2023 Kod przedmiotu WIINF5.II8.08694.22 Języki wykładowe polski Obligatoryjność Obowiązkowy Blok zajęciowy Przedmioty ogólne Przedmiot powiązany z badaniami naukowymi Tak
Koordynator przedmiotu	Marcin Kurdziel	
Prowadzący zajęcia	Marcin Kurdziel, Rafał Grzeszczuk	
Okres Semestr 4	Forma zaliczenia Zaliczenie Forma prowadzenia i godziny zajęć Wykład: 14 Ćwiczenia laboratoryjne: 14	Liczba punktów ECTS 3

Efekty uczenia się dla przedmiotu

Kod	Efekty w zakresie	Kierunkowe efekty uczenia się	Metody weryfikacji
Wiedzy - Student zna i rozumie:			
W1	Student ma wiedzę z zakresu wnioskowania Bayesowskiego oraz wybranych metod estymacji parametrów modeli uczących się.	INF1A_W07	Aktywność na zajęciach, Odpowiedź ustna, Zaliczenie laboratorium

Kod	Efekty w zakresie	Kierunkowe efekty uczenia się	Metody weryfikacji
W2	Student ma wiedzę z zakresu wybranych modeli uczenia maszynowego dla problemów regresji i klasyfikacji danych.	INF1A_W07	Aktywność na zajęciach, Odpowiedź ustna, Zaliczenie laboratorium
Umiejętności - Student potrafi:			
U1	Student potrafi zaimplementować wybrane modele statystycznego uczenia maszynowego.	INF1A_U05, INF1A_U07	Wykonanie ćwiczeń laboratoryjnych, Zaliczenie laboratorium
U2	Student zna wybrane biblioteki przydatne w implementacji metod statystycznego uczenia maszynowego.	INF1A_U05, INF1A_U07	Wykonanie ćwiczeń laboratoryjnych, Zaliczenie laboratorium
U3	Student potrafi wytrenować wybrane modele statystycznego uczenia maszynowego i ocenić ich skuteczność.	INF1A_U05, INF1A_U07	Wykonanie ćwiczeń laboratoryjnych, Zaliczenie laboratorium

Treści programowe zapewniające uzyskanie efektów uczenia się dla modułu zajęć

Niniejszy kurs stanowi wprowadzenie do metod i algorytmów statystycznego uczenia maszynowego. Zasadniczy materiał kursu obejmuje wybrane modele dla problemów regresji i klasyfikacji danych. Zostaną one przedstawione zarówno w wariacie klasycznym jak i w ujęciu Bayesowskim. Materiał ten uzupełnia wprowadzenie do metod MC/MCMC i tzw. programowania probabilistycznego (ang. probabilistic programming).

Nakład pracy studenta

Rodzaje zajęć studenta	Średnia liczba godzin* przeznaczonych na zrealizowane aktywności
Wykład	14
Ćwiczenia laboratoryjne	14
Przygotowanie do zajęć	25
Samodzielne studiowanie tematyki zajęć	25
Dodatkowe godziny kontaktowe	5
Łączny nakład pracy studenta	Liczba godzin 83
Liczba godzin kontaktowych	Liczba godzin 28

* godzina (lekcyjna) oznacza 45 minut

Treści programowe

Lp.	Treści programowe	Efekty uczenia się dla przedmiotu	Formy prowadzenia zajęć
1.	1. Częstościowa i Bayesowska interpretacja prawdopodobieństwa. Twierdzenie Bayesa. Wiarygodność, rozkład a priori i rozkład a posteriori. Wnioskowanie Bayesowskie. Pojęcie rozkładu sprzężonego. Przykład: model Beta-dwumianowy. (2h) 2. Wielowymiarowy rozkład normalny i jego własności. Parametryzacja: wartość przeciętna i macierz kowariancji. Rozkład łączny, brzegowy i warunkowy zmiennych normalnych. Liniowe modele Gaussowskie (2h) 3. Modele liniowe dla problemu regresji. Regresja liniowa w ujęciu klasycznym (MLE). Bayesowska regresja liniowa. (2h) 4. Wprowadzenie do procesów Gaussowskich. Regresja procesem Gaussowskim. (2h) 5. Modele liniowe dla problemu klasyfikacji. Regresja logistyczna i wieloklasowa regresja logistyczna. Estymator MLE dla regresji logistycznej. Stochastyczny spadek wzdłuż gradientu. (2h) 6. Metody Monte Carlo we wnioskowaniu Bayesowskim. Algorytmy generowania próbek. Metody MC: importance sampling. Estymacja parametrów metodą Monte Carlo. (2h) 7. Metody MCMC: Metropolis-Hastings. Hierarchiczne modele Bayesowskie. Model generujący dla obserwacji. Programowanie probabilistyczne. (2h)	W1, W2	Wykład

Lp.	Treści programowe	Efekty uczenia się dla przedmiotu	Formy prowadzenia zajęć
2.	1. Wprowadzenie do pakietów obliczeniowych w języku Python. (2h) 2. Wielowymiarowy rozkład normalny i liniowe modele Gaussowskie. (2h) - Liniowy model Gaussowski dla zagadnienia estymacji położenia obiektu. 3. Regresji liniowa. (2h) - Implementacja klasycznej regresji liniowej z estymatorem MLE. - Implementacja Bayesowskiej regresji liniowej. 4. Procesy Gaussowskie. (2h) - Implementacja regresji procesem Gaussowskim. 5. Regresja logistyczna. (2h) - Implementacja wieloklasowej regresji logistycznej dla zdjęć ręcznie pisanych cyfr. 6. Wnioskowanie metodami Monte Carlo. (2h) - Wprowadzenie do pakietu TensorFlow Probability. - Implementacja algorytmu Importance Sampling. 7. Programowanie probabilistyczne w TensorFlow Probability. (2h) - Opracowanie modelu generującego dla wskazanego zbioru obserwacji. - Estymacja parametrów opracowanego modelu i wnioskowanie o postawionych hipotezach dotyczących obserwacji.	U1, U2, U3	Ćwiczenia laboratoryjne

Informacje rozszerzone

Metody i techniki kształcenia :

Mini wykład

Rodzaj zajęć	Metody zaliczenia	Warunki zaliczenia przedmiotu
Wykład	Aktywność na zajęciach, Odpowiedź ustna, Zaliczenie laboratorium	Zaliczenie przedmiotu wymaga uzyskania oceny pozytywnej z ćwiczeń laboratoryjnych.
Ćwiczenia laboratoryjne	Wykonanie ćwiczeń laboratoryjnych, Zaliczenie laboratorium	Zaliczenie przedmiotu wymaga uzyskania oceny pozytywnej z ćwiczeń laboratoryjnych.

Dodatkowy opis

Wykłady z przedmiotu będą prowadzone w sposób zdalny z wykorzystaniem platformy Webex/Teams. Pozostałe zajęcia będą odbywać się w salach. Dotyczy to także zaliczeń i egzaminów odbywających się w sesjach egzaminacyjnych.

Warunki i sposób zaliczenia poszczególnych form zajęć, w tym zasady zaliczeń poprawkowych,

a także warunki dopuszczenia do egzaminu

1. Warunkiem zaliczenia ćwiczeń laboratoryjnych jest uczestnictwo w zajęciach i uzyskania oceny minimum 3.0 z każdego laboratorium.
2. W ramach zajęć laboratoryjnych mogą być przeprowadzone dodatkowe kolokwia sprawdzające wiedzę z przedmiotu. Warunkiem zaliczenia laboratorium jest zdanie tych kolokwii (jeśli będą przeprowadzone). Ocenę negatywną z kolokwium można poprawić na kolokwium zaliczeniowym pod koniec semestru.
3. Po spełnieniu warunków zaliczenia, pozytywną oceną z ćwiczeń laboratoryjnych jest średnia ocen z zadań i kolokwii zaokrąglona do najbliższej oceny przewidzianej regulaminem studiów.

Sposób obliczania oceny końcowej

1. Warunkiem uzyskania pozytywnej oceny końcowej jest uzyskanie pozytywnej oceny z ćwiczeń laboratoryjnych.
2. Oceną końcową jest ocena z ćwiczeń laboratoryjnych. Pozytywna ocena końcowa może zostać podwyższona w przypadku znaczącej aktywności studenta na wykładzie.

Sposób i tryb wyrównywania zaległości powstałych wskutek nieobecności studenta na zajęciach

Zaległości w realizacji zadań (powstałe na przykład w skutek usprawiedliwionej nieobecności) powinny być nadrobione w ramach kolejnych zajęć.

Wymagania wstępne i dodatkowe

Wiedza i umiejętności w zakresie przedmiotu "Rachunek prawdopodobieństwa i statystyka"

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

Wykład: Rejestracja audiowizualna wykładu wymaga zgody prowadzącego.

Ćwiczenia laboratoryjne: Studenci wykonują ćwiczenia laboratoryjne zgodnie z materiałami udostępnionymi przez prowadzącego. Obecność na ćwiczeniach laboratoryjnych jest obowiązkowa.

Literatura

Obowiązkowa

1. Kevin P. Murphy "Machine Learning: A probabilistic perspective", MIT Press, 2012

Dodatkowa

1. Christopher M. Bishop "Pattern Recognition and Machine Learning", Springer, 2007

Badania i publikacje

Publikacje

1. M. Jamroz, M. Kurdziel, M. Opala. "A Bayesian nonparametrics view into deep representations." Advances in Neural Information Processing Systems 33 (2020): 1440-1450.
2. 1. K. Grzegorzczak, M. Kurdziel "Disambiguated Skip-gram model", In: Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, EMNLP2018, pp 1445-1454, 2018
3. 2. P.I. Wójcik, M. Kurdziel "Training neural networks on high-dimensional data using random projection", Pattern Analysis and Applications, <https://doi.org/10.1007/s10044-018-0697-0>, 2018
4. 3. K. Grzegorzczak, M. Kurdziel "Binary Paragraph Vectors", In: Proceedings of the 2nd Workshop on Representation Learning for NLP, ACL2017, pp 121-130, 2017

Kierunkowe efekty uczenia się

Kod	Treść
INF1A_U05	Potrafi wykorzystać poznane metody i modele do tworzenia programów o charakterze użytkowym, a także potrafi adekwatnie wykorzystać znane algorytmy i struktury danych w budowie systemu komputerowego.
INF1A_U07	Potrafi ocenić, dobrać i stosować właściwe metody i narzędzia stosowane przy realizacji zadań związanych z budową systemu komputerowego, potrafi ocenić przydatność i korzystać z dostępnych bibliotek oraz komponentów oprogramowania.
INF1A_W07	Ma podstawową wiedzę z zakresu technik i zastosowań inżynierskich metod obliczeniowych oraz zagadnień sztucznej inteligencji