



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Głębokie uczenie [S1S1E>DEEPL]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

3/5

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego 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

prof. dr hab. inż. Krzysztof Krawiec

krzysztof.krawiec@put.poznan.pl

mgr inż. Jakub Bednarek

Wykładowcy

Wymagania wstępne

Podstawowa wiedza z zakresu analizy matematycznej i algebry liniowej. Wiedza nabyta podczas kursów z zakresu wstępu do AI, Statystyki i Uczenia Maszynowego. Umiejętność programowania w języku Python (najlepiej z uwzględnieniem znajomości biblioteki Numpy).

Cel przedmiotu

1. Przekazanie studentom podstawowej wiedzy z wybranymi zagadnieniami uczenia głębokiego, sieci neuronowych, uczenia reprezentacji i powiązanych zagadnień uczenia maszynowego. 2. Rozwijanie u studentów umiejętności rozwiązywania problemów i zadań uczenia maszynowego z wykorzystaniem modeli uczenia głębokiego, w tym głębokich sieci neuronowych, zwłaszcza klasyfikacji, regresji, uczeniu reprezentacji i inżynierii cech. 3. Nabranie doświadczenia w zakresie wykorzystywania tych umiejętności w wybranych zastosowaniach praktycznych. 4. Kształtowanie u studentów umiejętności efektywnej pracy nad małymi przedsięwzięciami projektowo-programistycznymi w zakresie uczenia głębokiego, w tym współpracy w małych grupach projektowych.

Przedmiotowe efekty uczenia się

Wiedza:

Student:

Ma uporządkowaną, podbudowaną teoretycznie wiedzę ogólną w zakresie modeli uczenia głębokiego, w tym zwłaszcza sieci neuronowych [K2st_W2].

Ma podbudowaną teoretycznie szczegółową wiedzę związaną z wybranymi zagadnieniami z zakresu informatyki, takimi jak: uczenie głębokie, sieci neuronowe, uczenie maszynowe, uczenie reprezentacji, inżynieria cech [K2st_W3].

Ma zaawansowaną i szczegółową wiedzę o procesach zachodzących w cyklu życia systemów informatycznych sprzętowych lub programowych stosowanych do rozwiązywania wybranych zadań charakterystycznych dla uczenia głębokiego [K2st_W5].

Zna zaawansowane metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań inżynierskich oraz przy prowadzeniu prac badawczych typowych dla klasyfikacji, regresji, inżynierii cech z wykorzystaniem uczenia głębokiego [K2st_W6].

Umiejętności:

Student:

Potrafi formułować i testować hipotezy związane z problemami rozwiązywanymi przy pomocy modeli uczenia głębokiego i prostymi problemami badawczymi charakterystycznymi dla tego obszaru sztucznej inteligencji [K2st_U3].

Potrafi wykorzystać metody eksperymentalne do formułowania i rozwiązywania zadań w obszarze zastosowań uczenia głębokiego, zwłaszcza głębokich sieci neuronowych, oraz prostych problemów badawczych [K2st_U4].

Potrafi - przy formułowaniu i rozwiązywaniu typowych dla uczenia głębokiego i sieci neuronowych - integrować wiedzę z różnych obszarów informatyki (a w razie potrzeby także wiedzę z innych dyscyplin naukowych) [K2st_U5].

Potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć dotyczących uczenia głębokiego oraz powiązanych zagadnień i technik sztucznej inteligencji [K2st_U6].

Potrafi zaproponować ulepszenia (usprawnienia) istniejących rozwiązań technicznych w obszarze uczenia głębokiego, w szczególności w oparciu o istniejące biblioteki i środowiska programistyczne takie jak TensorFlow i PyTorch [K2st_U8].

Potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania typowe dla uczenia głębokiego, w tym zadania nietypowe oraz zadania zawierające komponent badawczy, np. zaawansowane uczenie reprezentacji i/lub inżynierię cech [K2st_U10].

Kompetencje społeczne:

Student:

Rozumie, że w obszarze uczenia głębokiego wiedza i umiejętności bardzo szybko stają się przestarzałe [K2st_K1].

Rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu uczenia głębokiego, sieci neuronowych i powiązanych podejść uczenia maszynowego i sztucznej inteligencji w rozwiązywaniu problemów badawczych i praktycznych [K2st_K2].

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Ocena formująca:

a) w zakresie wykładów:

- na podstawie odpowiedzi na pytania dotyczące materiału omówionego na poprzednich wykładach,

b) w zakresie laboratoriów / ćwiczeń:

- na podstawie oceny bieżącego postępu realizacji zadań,

Ocena podsumowująca:

a) w zakresie wykładów weryfikowanie założonych efektów kształcenia realizowane jest przez:

- ocenę wiedzy i umiejętności wykazanych na egzaminie pisemnym składającym się z 5-8 pytań egzaminacyjnych powiązanych bezpośrednio z treścią wykładu. W przybliżeniu połowa pytań dotyczy zagadnień teoretycznych (zdefiniuj, opisz, scharakteryzuj, etc.), a druga połowa zadań obliczeniowych. Łączna liczba punktów to 25, do uzyskania oceny 3.0 wymagane jest osiągnięcie 13 punktów.

b) w zakresie laboratoriów weryfikowanie założonych efektów kształcenia realizowane jest przez:

- ocenę postępu prac w kilku punktach kontrolnych w trakcie semestru, na podstawie projektu i jego dokumentacji, przygotowywanych częściowo w trakcie zajęć, a częściowo po ich zakończeniu; ocena ta obejmuje także umiejętność pracy w zespole,

- ocenę i obronę przez studenta finalnego sprawozdania z realizacji projektu, połączoną z prezentacją przed pozostałymi uczestnikami kursu.

Uzyskiwanie punktów dodatkowych za aktywność podczas zajęć, a szczególnie za:

- efektywność zastosowania zdobytej wiedzy podczas rozwiązywania zadanego problemu,
- uwagi związane z udoskonaleniem materiałów dydaktycznych,
- wskazywanie trudności percepcyjnych studentów umożliwiające bieżące doskonalenia procesu dydaktycznego.

Treści programowe

Program wykładu obejmuje następujące zagadnienia:

Ogólnym celem jest poznanie przez studentów teoretycznych i praktycznych aspektów szeroko rozumianego uczenia głębokiego i sztucznych sieci neuronowych, a w szczególności:

1. Opanowanie podstaw głębokiego uczenia i sztucznych sieci neuronowych jako metod uczenia maszynowego i optymalizacji.
2. Poznanie algorytmów i metod uczenia modeli głębokich, ze szczególnym naciskiem na uczenie reprezentacji i inżynierię cech.
3. Nabycie umiejętności stosowania modeli uczenia głębokiego i sztucznych sieci neuronowych do rozwiązywania problemów klasyfikacji, detekcji, regresji, widzenia komputerowego, oraz interpretacji sekwencji i analizy szeregów czasowych.

Dla realizacji powyższych celów program wykładu obejmuje: Wprowadzenie. Definicja uczenia głębokiego jako specyficznego paradygmatu uczenia maszynowego, optymalizacji i modelowania. Definicja parametrów i hiperparametrów modeli. Omówienie modularnej charakterystyki modeli uczenia głębokiego. Opis najważniejszych i najczęściej wykorzystywanych komponentów uczenia głębokiego, w tym warstw gęstych, splotowych, agregujących, zwijających, redukujących, oraz połączeń rezydualnych. Komponenty nieliniowe i normalizacyjne. Taksonomia funkcji straty i charakterystyka najczęściej wykorzystywanych funkcji straty. Architektury głębokie dla rozwiązywania problemów klasyfikacji, regresji i autoasocjacji. Architektury głębokie dla analizy sekwencji, w szczególności warstwy rekurencyjne. Modele generatywne. Przegląd architektur stanowiących kamienie milowe w tym obszarze badań na bazie publikacji naukowych, ze szczególnym naciskiem na architektury splotowe i rekurencyjne, w tym: AlexNet, VGG, ResNet, GoogleLeNet, UNet, LSTM, GRU, GAN, PatchGAN, DCGAN, oraz wybrane architektury typu autoenkoder i transformer.

Zajęcia laboratoryjne prowadzone są w formie piętnastu 2-godzinnych ćwiczeń, odbywających się w laboratorium, poprzedzonych 6-godzinną sesją instruktażową (trzy spotkania) na początku semestru.

Ćwiczenia realizowane są przez 2-osobowe zespoły studentów.

Program laboratorium obejmuje następujące zagadnienia:

- Wprowadzenie (2h): Prezentacja założeń części laboratoryjnej przedmiotu.
- Prezentacja narzędzi informatycznych wykorzystywanych w części laboratoryjnej (biblioteki programistyczne, środowiska programistyczne).
- Sesja instruktażowa (4h): Ćwiczenia polegające na implementacji wybranych modeli sieci neuronowych w popularnych środowiskach (Python, Keras, Tensorflow, Pytorch).
- Testowanie zaimplementowanych algorytmów na danych rzeczywistych i sztucznych.
- Ocena poprawności i skuteczności algorytmów (w szczególności złożoność czasowa).
- Dobre praktyki projektowania i implementacji sieci neuronowych; typowe błędy i sposoby ich unikania.
- Realizacja projektów w grupach (24h): Realizacja, w grupach dwuosobowych, projektów programistycznych mających na celu realizację konkretnych zadań.

Tematyka zajęć

Program wykładu obejmuje następujące zagadnienia:

Ogólnym celem jest poznanie przez studentów teoretycznych i praktycznych aspektów szeroko rozumianego uczenia głębokiego i sztucznych sieci neuronowych, a w szczególności:

1. Opanowanie podstaw głębokiego uczenia i sztucznych sieci neuronowych jako metod uczenia maszynowego i optymalizacji.
2. Poznanie algorytmów i metod uczenia modeli głębokich, ze szczególnym naciskiem na uczenie reprezentacji i inżynierię cech.
3. Nabycie umiejętności stosowania modeli uczenia głębokiego i sztucznych sieci neuronowych do rozwiązywania problemów klasyfikacji, detekcji, regresji, widzenia komputerowego, oraz interpretacji sekwencji i analizy szeregów czasowych.

Dla realizacji powyższych celów program wykładu obejmuje: Wprowadzenie. Definicja uczenia

głębokiego jako specyficznego paradygmatu uczenia maszynowego, optymalizacji i modelowania. Definicja parametrów i hiperparametrów modeli. Omówienie modularnej charakterystyki modeli uczenia głębokiego. Opis najważniejszych i najczęściej wykorzystywanych komponentów uczenia głębokiego, w tym warstw gęstych, spłotowych, agregujących, zwijających, redukujących, oraz połączeń rezydualnych. Komponenty nieliniowe i normalizacyjne. Taksonomia funkcji straty i charakterystyka najczęściej wykorzystywanych funkcji straty. Architektury głębokie dla rozwiązywania problemów klasyfikacji, regresji i autoasocjacji. Architektury głębokie dla analizy sekwencji, w szczególności warstwy rekurencyjne. Modele generatywne. Przegląd architektur stanowiących kamienie milowe w tym obszarze badań na bazie publikacji naukowych, ze szczególnym naciskiem na architektury spłotowe i rekurencyjne, w tym: AlexNet, VGG, ResNet, GoogleLeNet, UNet, LSTM, GRU, GAN, PatchGAN, DCGAN, oraz wybrane architektury typu autoenkoder i transformer.

Zajęcia laboratoryjne prowadzone są w formie piętnastu 2-godzinnych ćwiczeń, odbywających się w laboratorium, poprzedzonych 6-godzinną sesją instruktażową (trzy spotkania) na początku semestru.

Ćwiczenia realizowane są przez 2-osobowe zespoły studentów.

Program laboratorium obejmuje następujące zagadnienia:

- Wprowadzenie (2h): Prezentacja założeń części laboratoryjnej przedmiotu.
- Prezentacja narzędzi informatycznych wykorzystywanych w części laboratoryjnej (biblioteki programistyczne, środowiska programistyczne).
- Sesja instruktażowa (4h): Ćwiczenia polegające na implementacji wybranych modeli sieci neuronowych w popularnych środowiskach (Python, Keras, Tensorflow, Pytorch).
- Testowanie zaimplementowanych algorytmów na danych rzeczywistych i sztucznych.
- Ocena poprawności i skuteczności algorytmów (w szczególności złożoność czasowa).
- Dobre praktyki projektowania i implementacji sieci neuronowych; typowe błędy i sposoby ich unikania.
- Realizacja projektów w grupach (24h): Realizacja, w grupach dwuosobowych, projektów programistycznych mających na celu realizację konkretnych zadań.

Metody dydaktyczne

Wykład: prezentacja multimedialna, ilustrowana przykładami podawanymi na tablicy, demonstracja.

Ćwiczenia laboratoryjne: rozwiązywanie zadań, projektowanie systemów indywidualnie i w małych grupach (typowo dwuosobowych), implementacja modeli sieci neuronowych, przeprowadzanie eksperymentów obliczeniowych, dyskusja, prezentacja wyników eksperymentów obliczeniowych i działania zaimplementowanych metod.

Literatura

Podstawowa:

1. Josh Patterson, Adam Gibson, Deep learning : praktyczne wprowadzenie. Grupa Wydawnicza Helion. 2018.
2. Ian Goodfellow, Yoshua Bengio, Aaron Courville, Deep learning: systemy uczące się. Wydawnictwo Naukowe PWN, 2018.
3. Francois Chollet, Deep Learning: Praca z językiem Python i biblioteką Keras, Helion 2019 (oryginał: Deep Learning with Python).

Uzupełniająca:

1. Valentino Zocca, Gianmario Spacagna, Deep learning: uczenie głębokie z językiem Python: sztuczna inteligencja i sieci neuronowe, Grupa Wydawnicza Helion, 2018.
2. Krzysztof Krawiec Jerzy Stefanowski. Uczenie maszynowe i sieci neuronowe. Politechnika Poznańska. Wydawnictwo, 2004.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	62	2,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	63	2,50