



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Metody inteligencji maszynowej w automatyce [N2AiR1-ISA>MIMwA]

Przedmiot

Kierunek studiów

Automatyka i robotyka

Rok/Semestr

1/1

Studia w zakresie (specjalność)

Inteligentne systemy automatyki

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

niestacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

20

Laboratorium

20

Inne (np. online)

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

4,00

Koordynatorzy

dr hab. inż. Stefan Brock prof. PP
stefan.brock@put.poznan.pl

Wykładowcy

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać podstawową wiedzę z matematyki, a zwłaszcza algebry liniowej, rachunku macierzowego, elementów logiki matematycznej, a także podstaw analizy matematycznej i rachunku prawdopodobieństwa. Powinien posiadać umiejętność rozwiązywania układów równań liniowych i nieliniowych. Student powinien znać podstawy obsługi programów wspomagających obliczenia naukowe, takich jak Scilab, Octave, Matlab. Powinien posiadać umiejętność pozyskiwania informacji ze wskazanych źródeł. Powinien ponadto posiadać podstawową wiedzę z zakresu podstaw automatyki i teorii sterowania i informatyki, w zakresie znajomości wybranych języków programowania. Powinien posiadać świadomość konieczności poszerzania wiedzy teoretycznej i praktycznej i ustawicznego uaktualniania zdobytej wiedzy z uwagi na dynamiczne zmiany we współczesnej technice. Powinien również rozumieć konieczność poszerzania swoich kompetencji i być gotowym do podjęcia współpracy w ramach zespołu realizującego np. wspólny projekt.

Cel przedmiotu

1. Przekazanie studentom podstawowej wiedzy z zakresu metod uczenia maszynowego i soft-computing obejmującej zagadnienia metod regresji, klasyfikacji, grupowania, logiki rozmytej i sieci neuronowych, oraz ich wykorzystania zwłaszcza w problemach automatyki. Przykłady zastosowań obejmują sterowanie obiektami o złożonej dynamice i silnej nieliniowości modelu, trudnymi do identyfikacji. 2. Rozwijanie u studentów umiejętności rozwiązywania problemów przetwarzania danych na drodze uczenia maszynowego i odtwarzania tak pozyskanej wiedzy. 3. Kształtowanie u studentów umiejętności pracy zespołowej podczas realizacji końcowego projektu w ramach laboratorium.

Przedmiotowe efekty uczenia się

Wiedza

1. ma uporządkowaną i pogłębioną wiedzę w zakresie metod sztucznej inteligencji i ich zastosowania w systemach automatyki i robotyki; [K2_W2]
2. ma wiedzę z zakresu zastosowań wybranych metod uczenia maszynowego w układach automatyki na potrzeby identyfikacji, sterowania i diagnostyki.

Umiejętności

1. potrafi formułować i weryfikować (symulacyjnie lub eksperymentalnie) hipotezy związane z zadaniami inżynierskimi i prostymi problemami badawczymi z zakresu automatyki i robotyki; [K2_U15]
2. potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć (w tym technik i technologii) w zakresie automatyki i robotyki; [K2_U16]
4. potrafi krytycznie ocenić i dobrać odpowiednie metody i narzędzia do rozwiązania zadania z zakresu automatyki i robotyki; potrafi wykorzystać narzędzia nowatorskie i niekonwencjonalne z zakresu automatyki i robotyki; [K2_U22]
4. potrafi skonstruować algorytm rozwiązania złożonego i nietypowego zadania inżynierskiego i prostego problemu badawczego oraz zaimplementować, przetestować i uruchomić go w wybranym środowisku programistycznym dla wybranych systemów operacyjnych; [K2_U25]

Kompetencje społeczne

1. rozumie potrzebę i zna możliwości ciągłego dokształcania się – podnoszenia kompetencji zawodowych, osobistych i społecznych, potrafi inspirować i organizować proces uczenia się innych osób; [K2_K1]
2. posiada świadomość odpowiedzialności za pracę własną oraz gotowość podporządkowania się zasadom pracy w zespole;

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wiedza nabyta w ramach wykładu jest weryfikowana przez egzamin pisemny oraz indywidualną dyskusję zagadnień egzaminacyjnych. Egzamin składa się z 10-15 pytań (testowych i otwartych), różnie punktowanych. Próg zaliczeniowy: 50% punktów. Zagadnienia egzaminacyjne, na podstawie których opracowywane są pytania, zostają udostępnione studentom w trakcie semestru.

Umiejętności nabyte w ramach zajęć laboratoryjnych weryfikowane są na podstawie sporządzonych sprawozdań i końcowego kolokwium zaliczeniowego, składającego się z 5-7 pytań/zadań różnie punktowanych w zależności od stopnia ich trudności. Próg zaliczeniowy: 50% punktów.

Treści programowe

1. Rys historyczny metod sztucznej inteligencji, koncepcja uczenia maszynowego. Pojęcie uczenia nadzorowanego i nienadzorowanego. Podstawowe, wybrane metody statystycznego opisu zbioru danych. Miary centralne i rozproszenia. Histogram i jądrowy estymator gęstości.
2. Regresja liniowa: pojęcie hipotezy, funkcji kosztu. Metody uczenia: prostego gradientu, uczenia wsadowego "Batch Gradient Descent". Hipotezy dla wielu zmiennych. Ocena poprawności działania algorytmu regresji liniowej. Równanie normalne.
3. Pojęcie klasyfikacji, regresja logistyczna. Pojęcie liniowej separowalności problemu klasyfikacji, Klasyfikacja wieloklasowa. Ocena jakości klasyfikatorów, wrażliwość i specyficzność.
4. Przeuczenie i regularyzacja. Poprawa jakości pracy algorytmu regresji liniowej: Uczenie / walidacja / testowanie.
5. Pojęcie klasteryzacji, przykłady zastosowań. Analiza skupień metodą K-średnich.
6. Zasada redukcji wymiaru metodą analizy głównych składowych PCA. Ocena utraty danych w metodzie

PCA

7. Pojęcie układu rozmytego. Realizacja zadań rozmywania i wyostrzania. Regulator PI/PD/PID realizowany w układzie rozmytym.

8. Koncepcja sieci neuronowych. Biologiczne sieci neuronowe: neuron biologiczny, sieci neuronowe, modele matematyczne neuronu biologicznego, funkcje aktywacji, perceptron, neuron jako klasyfikator. Uczenie pojedynczego neuronu. Pojęcie wstecznej propagacji błędu, poprawa szybkości uczenia.

Wykorzystanie ANN w układach sterowania. Sieci neuronowe ze sprzężeniem zwrotnym.

9. Metoda klasyfikacji danych za pomocą maszyny wektorów nośnych (SVM): koncepcja SVM, algorytmy SVM, dobór funkcji jądrowej.

10. Metoda lasów losowych - koncepcja, implementacja i zastosowania.

11. Metoda uczenia ze wzmocnieniem. Odniesienia do struktury układów sterowania. Metody uczenia. Zastosowanie w układach sterowania o zmiennych parametrach.

12. Wybrane narzędzia programistyczne dla metod uczenia maszynowego.

Studenci w trakcie wykładu analizują tematy projektów powiązanych z badaniami naukowymi jednostki, zwłaszcza w zakresie aplikacji wybranych metod uczenia maszynowego i logiki rozmytej w układach sterowania złożonych obiektów elektromechanicznych.

Program laboratorium obejmuje następujące zagadnienia: dobór danych uczących, tworzenia zbioru walidacyjnego i testowego dla metod uczenia maszynowego; zapoznanie się z metodami uczenia maszynowego prezentowanymi na wykładzie. Analiza i syntaza układu wnioskowania rozmytego. Implementacja wybranych metod w układach sterowania - modelowanie i synteza regulatora.

Metody dydaktyczne

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

2. Ćwiczenia laboratoryjne: wykonanie ćwiczeń laboratoryjnych, badanie przygotowanych problemów realizacji i metod uczenia maszynowego, dyskusja, praca w zespole, warsztaty - samodzielne opracowanie projektu do rozwiązania postawionego problemu sterowania, optymalizacji, klasyfikacji, itp.

Literatura

Podstawowa

1. Materiały wykładowe sukcesywnie udostępniane przez prowadzącego w postaci elektronicznej.

2. Osowski S., Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2000 rok

3. Rutkowska D., Piliński M., Rutkowski L: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte PWN Warszawa

Uzupełniająca

1. Geron A.: Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow, Helion 2018

2. Raschka S.: Python. Uczenie Maszynowe, Helion 2018

3. Chollet F.: Deep Learning, Helion, 2019

4. Sejnowski T. J.: Deep Learning. Głęboka rewolucja. Poltex, 2019

Bilans nakładu pracy przeciętnego studenta

| | Godzin | ECTS |
|--|--------|------|
| Łączny nakład pracy | 100 | 4,00 |
| Zajęcia wymagające bezpośredniego kontaktu z nauczycielem | 40 | 1,50 |
| Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu) | 60 | 2,50 |