



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wspomaganie decyzji [S1SI1E>WDEC]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

3/6

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obieralny

Liczba godzin

Wykład

30

Laboratorium

30

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

5,00

Koordynatorzy

dr hab. inż. Miłosz Kadziński prof. PP
milosz.kadzinski@put.poznan.pl

Wykładowcy

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać wiedzę z zakresu analizy matematycznej, algebry liniowej, optymalizacji kombinatorycznej, badań operacyjnych, uczenia maszynowego, uczenia głębokiego oraz wyszukiwania informacji. Musi też posiadać umiejętność programowania w języku Python.

Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z głównymi trendami analizy decyzji. Trendy te obejmują wielokryterialne wspomaganie decyzji, optymalizację wielokryteriową oraz analizę efektywności. Przedmiot ma na celu przekazanie podstawowej wiedzy na temat inteligentnych systemów wspomagania decyzji w zakresie podstaw teoretycznych i implementacji komputerowych, a w szczególności konstruktywnego uczenia się preferencji jako podejścia charakterystycznego dla sztucznej inteligencji. Uczestnicy kursu naberą wiedzę na temat wybranych metod i narzędzi szeroko rozumianej teorii decyzji wykorzystującej elementy informatyki, matematyki, sztucznej inteligencji, zarządzania i kognitywistyki.

Przedmiotowe efekty uczenia się

Wiedza:

K1st_W3: ma uporządkowaną wiedzę teoretyczną dotyczącą kluczowych zagadnień informatyki z

zakresu analizy decyzji, w tym wspomagania decyzji, optymalizacji wielokryteriowej oraz analize efektywności

K1st_W4: zna i rozumie podstawowe techniki, metody, algorytmy oraz narzędzia wykorzystywane w procesie rozwiązywania zadań informatycznych oraz problemów decyzyjnych, w tym metod wspomagania decyzji, algorytmy optymalizacji w nurcie klasycznym i ewolucyjnym oraz podejścia do analizy efektywności

K1st_W5: ma podstawową wiedzę o istotnych kierunkach rozwoju i najważniejszych osiągnięciach analizy decyzji rozumianej jako istotna dziedzina sztucznej inteligencji czerpiąca z osiągnięć innych dyscyplin naukowych (w tym ekonomii, socjologii i politologii) oraz dostarczająca dla nich rozwiązań o potencjale praktycznym

Umiejętności:

K1st_U1: potrafi pozyskiwać informacje z właściwie dobranych źródeł o różnej charakterystyce, dokonywać ich krytycznej analizy, interpretacji i syntezy oraz wyczerpująco uzasadniać formułowane opinie

K1st_U3: potrafi formułować i rozwiązywać złożone problemy decyzyjne (takie jak porządkowania, wybór, klasyfikacja, sortowanie czy optymalizacja wielokryteriowa), stosując odpowiednio dobrane metody analizy decyzji

K1st_U4: potrafi zaplanować i przeprowadzić eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki oraz wyciągać z nich wnioski w kontekście problemów decyzyjnych i wykorzystania w ich kontekście metod uczenia preferencji

K1st_U5: posiada ogólne umiejętności intelektualne z zakresu nauk społecznych i ekonomicznych niezbędne do prowadzenia działalności inżynierskiej, pozwalające na dostrzeżenie w procesie formułowania i rozwiązywania zadań informatycznych aspektów ekonomicznych, etycznych, prawnych i społecznych; inteligentne systemy wspomagania decyzji należą do najważniejszych nurtów ekonomicznych oraz społecznych SI

K1st_U7: potrafi dokonać krytycznej analizy oraz oceny sposobu funkcjonowania systemów informatycznych oraz działania metod analizy decyzji, w tym głównie metod wspomagania decyzji i uczenia preferencji, optymalizacji wielokryteriowej czy analizy efektywności

K1st_U9: ma umiejętność prostej adaptacji istniejących oraz formułowania i implementacji nowych algorytmów w języku Python, w tym algorytmów typowych dla różnych nurtów inteligentnych systemów wspomagania decyzji

K1st_U10: potrafi pozyskiwać, analizować i przetwarzać dane różnego typu (w tym dane o charakterze wielowymiarowym), dokonywać ich syntezy do wiedzy i wniosków przydatnych do rozwiązywania szerokiego spektrum problemów decyzyjnych

K1st_U11: potrafi wykorzystywać oraz adaptować modele zachowań inteligentnych (np. sztuczne sieci neuronowe, metody wspomagania decyzji oraz podejścia symulacyjne) oraz narzędzia informatyczne symulujące te zachowania

Kompetencje społeczne:

K1st_K1: rozumie, że w informatyce ze szczególnym uwzględnieniem sztucznej inteligencji wiedza i umiejętności bardzo szybko stają się przestarzałe, dostrzegając przy tym potrzebę ciągłego doskonalenia oraz podnoszenia własnych kompetencji

K1st_K2: ma świadomość istotności wiedzy i badań naukowych związanych z informatyką i sztuczną inteligencją w rozwiązywaniu praktycznych problemów o kluczowym znaczeniu dla funkcjonowania jednostek, firm, organizacji oraz całego społeczeństwa

K1st_K3: zna przykłady wadliwie działających systemów sztucznej inteligencji, które doprowadziły do strat ekonomicznych, społecznych lub środowiskowych

K1st_K5: potrafi myśleć i działać w sposób przedsiębiorczy, m.in. znajdując komercyjne zastosowania dla tworzonych systemów sztucznej inteligencji, mając na uwadze nie tylko korzyści ekonomiczne, ale również aspekty prawne i społeczne

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykłady: egzamin (po ustaleniu ze studentami - może być podzielony na dwie części). Studenci muszą rozwiązać zadania obliczeniowe dotyczące zagadnień prezentowanych na poszczególnych wykładach. Każde zadanie jest oceniane indywidualnie i za jego rozwiązanie przyznawana jest określona liczba punktów. Punkty są sumowane i następująca skala jest wykorzystywana do określenia oceny: <50% - 2.0, [50% , 60%) - 3.0, [60% , 70%) - 3.5, [70% , 80%) - 4.0, [80% , 90%) - 4.5, and [90% , 100%] - 5.0.

Laboratoria: Po każdym zajęciach, studenci rozwiązują zadania programistyczne i przedstawiają rozwiązania osobie prowadzącej laboratoria w ciągu dwóch tygodni. Każde zadanie jest oceniane na skali od 2.0 do 5.0. Ostateczna ocena jest obliczana jako średnia z ocen przyznanych za poszczególne zadania z zastrzeżeniem, że najgorsza ocena uzyskana w trakcie semestru nie jest brana pod uwagę.

Treści programowe

Wprowadzenie do wielokryterialnego wspomaganie decyzji (WWD) oraz metod PROMETHEE: badania operacyjne vs. analiza decyzji, wielokryterialne problemy decyzyjne, informacja preferencyjna, model preferencji, ogólny schemat metod WWD, przegląd metod z rodziny PROMETHEE, cząstkowe funkcje preferencji, stopnie preferencji, konstrukcja rankingu w metodzie PROMETHEE I oraz II, wybór najbardziej preferowanego zbioru wariantów z użyciem PROMETHEE V, przykładowe zastosowania metod PROMETHEE.

Wielokryterialne sortowanie oraz metoda ELECTRE TRI-B: zasada działania metody ELECTRE TRI-B, przegląd metod ELECTRE, testy zgodności i niezgodności, wiarygodność relacji przewyższania, procedura SRF do wyznaczenia wartości wag kryteriów, pesymistyczna i optymistyczna procedura przydziału wariantów do klas, przykładowe zastosowania ELECTRE TRI-B.

Wielokryterialny ranking oraz metody ELECTRE III oraz ELECTRE IV: zasada działania metod porządkujących warianty z rodziny ELECTRE, konstrukcja wartościowanej relacji przewyższania, procedury destylacji, typu końcowych rankingów, przykładowe zastosowania ELECTRE III.

Wieloatrybutowa Teoria Wartości oraz metody dezagregacji preferencji z rodziny UTA: addytywna funkcja wartości, metod połowienia, metoda SWING, dezagregacja preferencji, regresja porządkowa dla problemów porządkowania i sortowania, metoda UTA, współczynnik tau Kendalla, wykrywanie niespójności w informacji preferencyjnej, metoda UTADIS, przykładowe zastosowania metod z rodziny UTA.

Analiza odporności: dezagregacja preferencji, niejednoznaczność w reprezentowaniu preferencji pośrednich przez założony model preferencji, procedury eksploatacji służące do weryfikacji stabilności wyniku, konieczne, możliwe i skrajne wyniki, analiza stochastyczna oraz indeksy akceptowalności.

Analytical Hierarchy Process (AHP) oraz całka Choquet: hierarchiczna strukturalizacja problemu, priorytyzacja elementów hierarchii, porównania parami na skali ilorazowej, metod głównych wektorów własnych, obliczenia wyników dla metody AHP, sprawdzenie poziomu spójności, warunek zachowania porządku, odwrócenie rankingu, przykładowe zastosowania metody AHP, metoda sumy ważonego, znaczenie wag w różnych metodach, całka Choquet.

Podejście zbiorów przybliżonych dla problemów klasyfikacji: granule wiedzy, dolne i górne przybliżenia, brzegi klas, redukt i rdzeń, reguły decyzyjne, algorytm LEM2 do indukcji reguł, reguły pewne, możliwe i przybliżone, algorytm klasyfikacji bucket brigade, przykładowe zastosowania teorii zbiorów przybliżonych.

Podejścia zbiorów przybliżonych dla problemów sortowania: stożki dominacji, dolne i górne unie klas, brzegi unii klas, redukt i rdzeń, reguły decyzyjne, algorytm DOMLEM do indukcji reguł, algorytmy klasyfikacji, przykładowe zastosowania metody DRSA.

Graniczna analiza danych (ang. data envelopment analysis): badanie efektywności jednostek decyzyjnych, rzeczywiste przykłady zastosowań analizy efektywności, modele CCR i BCC nastawione na zmniejszenie nakładów lub zwiększenie efektów, super-efektywność, efektywność krzyżowa, ograniczenia na wagi, analiza odporności, wykorzystanie symulacji Monte Carlo.

Aspekty kognitywistyczne: heurystyki decyzyjne oraz skrzywienia przy podejmowaniu decyzji.

Gry strategiczne: zastosowanie teorii gier w różnych dziedzinach, pojęcia stabilności i efektywności, mechanizmy rozstrzygania gier, strategie dominujące, Pareto optymalność, czysta i mieszana równowaga Nasha, iteracyjna eliminacja strategii zdominowanych, równowaga skorelowana.

Gry zatłoczenia: przykłady i definicje; gry potencjalne jako narzędzie analizy gry zatłoczenia; istnieje równowaga, dynamika lepsze odpowiedzi, cena anarchii.

Gry rozległe (ekstensywne): reprezentacja w postaci drzewa dla gier z pełną informacją, strategie rozłożone w czasie, określenie najlepszej odpowiedzi przy wzięciu pod uwagę kolejności podejmowania akcji; perfekcja we fragmencie gry; algorytm wstecznej indukcji; słynne gry: ultimatum i stonoga.

Metody optymalizacji wielokryterialnej: przykłady rzeczywistych problemów, podejścia klasyczne oparte na sumie ważonej, ograniczeniach z wykorzystaniem "epsilon" oraz funkcji skalaryzującej osiągu, algorytmy ewolucyjne bazujące na frontach (NSGA-II i SPEA2), wskaźnikach (SMS EMOA) oraz mechanizmie dekompozycji (MOEA/D).

Uczenie preferencji: przykłady zastosowań uczenia preferencji, miary oceny działania metod, podstawowe techniki uczenia preferencji, regresja Choquistyczna, wykorzystanie sieci neuronowych w uczeniu preferencji.

Zajęcia laboratoryjne prowadzone są w formie piętnastu 2-godzinnych ćwiczeń, odbywających się w laboratorium. Poszczególne zagadnienia omawiane w ramach wykładu są ilustrowane zadaniami podczas zajęć laboratoryjnych. Ponadto studenci analizują rzeczywiste problemy decyzyjne (ang. case study), które pozwalają na zastosowania wiedzy nt. poznanych metodologii w praktyce.

Tematyka zajęć

brak

Metody dydaktyczne

Wykład: slajdy multimedialne dotyczące różnych dziedzin analizy decyzji, ilustrowane przykładami oraz zadania obliczeniowe, służące jako podsumowanie wykładu i przygotowanie do zaliczenia.

Laboratoria: rozwiązywanie zadań ilustrujących na tablicy, programowanie w języku Python, przeprowadzenie eksperymentów obliczeniowych, dyskusja wybranych metod, praca zespołowa.

Literatura

Podstawowa:

1. A. Ishizaka, P. Nemery, Multi-criteria Decision Analysis: Methods and Software, Wiley, 2013.
2. S. Greco, M. Ehrgott, J.R. Figueira (eds.), Multiple Criteria Decision Analysis: State of the Art Surveys, Springer, 2016
3. R. Słowiński, Y. Yao (eds.), Rough Sets, Part C of the Handbook of Computational Intelligence, Springer, 2015, pp. 329-451.
4. J. Branke, K. Deb, K. Miettinen, R. Słowiński, Multiobjective Optimization: Interactive and Evolutionary Approaches. Springer, Berlin, 2008.
5. J. Fürnkranz, E. Hüllermeier, Preference Learning. Springer, Berlin, 2010.
6. W.W. Cooper, L.M. Seiford, M. Lawrence, K. Tone, Data Envelopment Analysis: A Comprehensive Text with Models, Applications, References and DEA-Solver Software, Springer, US, 2007.

Uzupełniająca:

1. S. Corrente, S. Greco, M. Kadziński, R. Słowiński, Robust ordinal regression in preference learning and ranking, Machine Learning 93 (2), 381-422, 2013.
2. M. Cinelli, M. Kadziński, M. Gonzalez, R. Słowiński, How to support the application of multiple criteria decision analysis? Let us start with a comprehensive taxonomy, Omega 96, 102261, 2020.
3. M. Cinelli, M. Kadziński, G. Miebs, M. Gonzalez, R. Słowiński, Recommending Multiple Criteria Decision Analysis Methods with A New Taxonomy-based Decision Support System, European Journal of Operational Research, 2022.
4. M. Kadziński, S. Greco, R. Słowiński, Robust ordinal regression for dominance-based rough set approach to multiple criteria sorting, Information Sciences 283, 211-228, 2014.
5. MK. Tomczyk, M. Kadziński, Decomposition-based interactive evolutionary algorithm for multiple objective optimization, IEEE Transactions on Evolutionary Computation 24 (2), 320-334, 2019.
6. M. Kadziński, A. Labijak, M. Napieraj, Integrated framework for robustness analysis using ratio-based efficiency model with application to evaluation of Polish airports, Omega 67, 1-18, 2017.

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