



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Algorytmiczna teoria decyzji

Przedmiot

Kierunek studiów

Informatyka

Studia w zakresie (specjalność)

Sztuczna inteligencja

Poziom studiów

drugiego stopnia

Forma studiów

stacjonarne

Rok/semestr

1/2

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

polski

Wymagalność

obieralny

Liczba godzin

Wykład

15

Ćwiczenia

Laboratoria

15

Projekty/seminaria

Inne (np. online)

Liczba punktów ECTS

3

Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:

dr hab. inż. Miłosz Kadziński, prof. PP

email: milosz.kadzinski@cs.put.poznan.pl

tel. 61 665 3022

Wydział Informatyki i Telekomunikacji

Piotrowo 2, 60-965 Poznań

Odpowiedzialny za przedmiot/wykładowca:

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać wiedzę z zakresu matematyki dyskretnej, algebry liniowej, optymalizacji kombinatorycznej, badań operacyjnych i wspomaganie decyzji. Powinien posiadać umiejętności rozwiązywania podstawowych problemów programowania matematycznego, pozyskiwania informacji ze wskazanych źródeł oraz programowania w co najmniej jednym języku. Powinien również rozumieć konieczność poszerzania swoich kompetencji w zakresie modelowania rzeczywistych problemów decyzyjnych i posługiwania się narzędziami informatycznymi do ich rozwiązywania. Ponadto w zakresie kompetencji społecznych student musi prezentować takie postawy jak uczciwość, odpowiedzialność, wytrwałość, ciekawość poznawcza, kreatywność, kultura osobista, szacunek dla innych ludzi.



Cel przedmiotu

Ogólnym celem jest poznanie przez studentów teoretycznych i praktycznych aspektów szeroko rozumianej algorytmicznej teorii decyzji, a w szczególności:

1. Nabycie zaawansowanych umiejętności z zakresu teorii gier (ang. game theory), tj. analizy oraz identyfikacji optymalnych zachowań, np. w ramach gier strategicznych, rozległych czy zatłoczenia.
2. Nabycie umiejętności wykorzystania granicznej analizy danych (ang. data envelopment analysis) w problemach badania efektywności jednostek decyzyjnych.
3. Poznanie podstawowych metod optymalizacji wielokryteriowej opartych na programowaniu liniowym i algorytmach ewolucyjnych, a także nabycie umiejętności ich zastosowania do rozwiązywania rzeczywistych problemów optymalizacji.
4. Zrozumienie zasad działania algorytmów uczenia preferencji (ang. preference learning) oraz ich wykorzystania do uczenia z dużych zbiorów przykładowych decyzji.

Przedmiotowe efekty uczenia się

Wiedza

ma zaawansowaną i pogłębioną wiedzę z zakresu systemów informatycznych służących analizie decyzji (ang. decision support systems), podstaw teoretycznych ich budowania oraz metod, narzędzi i środowisk programistycznych wykorzystywanych do ich implementacji [K2st_W1]

ma zaawansowaną wiedzę dotyczącą wybranych zagadnień z zakresu informatyki w kontekście metod algorytmicznej teorii decyzji oraz ich praktycznych zastosowań [K2st_W3]

ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach na przecięciu informatyki i ekonomii [K2st_W4]

zna zaawansowane metody, algorytmy, techniki, narzędzia i systemy stosowane przy rozwiązywaniu złożonych zadań inżynierskich i prowadzeniu prac badawczych w zakresie algorytmicznej teorii decyzji [K2st_W6]

Umiejętności

potrafi - przy formułowaniu i rozwiązywaniu zadań inżynierskich - integrować wiedzę z różnych obszarów informatyki (w tym m.in. badań operacyjnych, wspomaganie decyzji, teorii gier, uczenia maszynowego) i ekonomii oraz zastosować podejście systemowe, uwzględniające także aspekty pozatechniczne [K2st_U5]

potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć (metod i narzędzi analizy i wspomaganie decyzji) oraz nowych produktów informatycznych w rozwiązywaniu problemów decyzyjnych [K2st_U6]

potrafi - stosując m.in. koncepcyjnie nowe metody analizy i wspomaganie decyzji - rozwiązywać złożone zadania informatyczne, w tym zadania nietypowe, dotyczące problemów decyzyjnych, oraz zadania zawierające komponent badawczy [K2st_U10]



potrafi porozumiewać się w języku polskim i angielskim przy użyciu różnych technik w środowisku zawodowym oraz w innych środowiskach, pełniąc rolę analityka decyzja, także z wykorzystaniem narzędzi informatycznych [K2st_U12]

Kompetencje społeczne

rozumie, że w informatyce wiedza i umiejętności bardzo szybko stają się przestarzałe, a żeby rozwiązywać rzeczywiste problemy decyzyjne, trzeba rozwijać nowe metody analizy decyzji, odpowiadające wyzwaniom nowych czasów [K2st_K1]

rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu algorytmicznej teorii decyzji 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 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 zaliczeniu pisemnym o różnej charakterystyce problemów do rozwiązania: pytania testowe wielokrotnego wyboru, treść do uzupełnienia, proste zadania obliczeniowe lub algorytmiczne oraz zadania problemowe o większej złożoności; kolokwium jest zaliczone pod warunkiem uzyskania co najmniej połowy punktów.
 - omówienie wyników zaliczenia,
- b) w zakresie laboratoriów weryfikowanie założonych efektów kształcenia realizowane jest przez:
 - ocenę wiedzy i umiejętności związanych z realizacją ćwiczeń laboratoryjnych oraz zadań programistycznych, a także realizację projektów rozwiązujących konkretne przypadki użycia (ang. case study);
 - ocenę sprawozdań przygotowywanych częściowo w trakcie zajęć, a częściowo po ich zakończeniu; ocena ta obejmuje także umiejętność pracy w zespole.

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

- omówienie dodatkowych aspektów zagadnienia,
- efektywność zastosowania zdobytej wiedzy podczas rozwiązywania zadanego problemu,



- umiejętność współpracy w ramach zespołu praktycznie realizującego zadanie szczegółowe w laboratorium,
- rozwój oprogramowania przydatnego w zajęciach laboratoryjnych.

Treści programowe

W ramach wykładu przedstawiane są następujące zagadnienia z zakresu teorii gier, granicznej analizy danych, optymalizacji wielokryterialnej oraz uczenia preferencji:

- 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 równowagi, 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.
- Podstawy gier iterowanych, koalicyjnych oraz Bayesowskich.
- 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.
- 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.

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.

Metody dydaktyczne

1. Wykład: prezentacja multimedialna uzupełniona przykładami ilustracyjnymi. Demonstracja wybranych systemów z dziedziny algorytmicznej teorii decyzji.
2. Ćwiczenia laboratoryjne: rozwiązywanie zadań, ćwiczenia praktyczne i programistyczne, wykonywanie eksperymentów, dyskusja, praca w zespole, studium przypadków, demonstracja wybranych systemów,



generowanie realnych problemów decyzyjnych i rozwiązywanie ich metodami dostępnymi w laboratorium, pokaz multimedialny.

Literatura

Podstawowa

1. P. Straffin, Teoria gier. Wydawnictwo Naukowe Scholar, Warszawa, 2001.
2. J. Branke, K. Deb, K. Miettinen, R. Słowiński, Multiobjective Optimization: Interactive and Evolutionary Approaches. Springer, Berlin, 2008.
3. 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.
4. J. Fürnkranz, E. Hüllermeier, Preference Learning. Springer, Berlin, 2010.

Uzupełniająca

1. M.J. Osborne, An Introduction to Game Theory. Oxford University Press, 2004.
2. A. Charnes, W.W. Cooper, A.Y. Lewin, L.M. Seiford, Data Envelopment Analysis: Theory, Methodology, and Applications, Springer, Netherlands, 1994.
3. 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.
4. M. Tomczyk, M. Kadziński, Decomposition-based interactive evolutionary algorithm for multiple objective optimization, IEEE Transactions on Evolutionary Computation, 24(2), 320-334, 2020.
5. J. Liu, M. Kadziński, X. Liao, X. Mao, Data-driven preference learning methods for value-driven multiple criteria sorting with interacting criteria, INFORMS Journal on Computing, 2020.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	75	3,0
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	30	1,5
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych, przygotowanie do zaliczenia, wykonanie projektu, przygotowanie sprawozdania) ¹	45	1,5

¹ niepotrzebne skreślić lub dopisać inne czynności