



## 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 decyzyjnego, 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) <sup>1</sup>	45	1,5

<sup>1</sup> niepotrzebne skreślić lub dopisać inne czynności