



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Optymalizacja wielokryterialna [S2SI1E>OPW]

### Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

1/1

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

### Liczba godzin

Wykład

15

Laboratorium

15

Inne (np. online)

0

Ćwiczenia

0

Projekty/seminaria

0

### Liczba punktów ECTS

3,00

### Koordynatorzy

dr inż. Michał Tomczyk

michal.tomczyk@put.poznan.pl

### Wykładowcy

dr inż. Michał Tomczyk

michal.tomczyk@put.poznan.pl

### Wymagania wstępne

Podstawowa wiedza matematyczna ze szkoły średniej. Podstawowe umiejętności programowania w języku Python, rozwijane na równoległe prowadzonym kursie z Wprowadzenia do programowania.

### Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z głównymi zagadnieniami z obszaru optymalizacji wielokryterialnej. Do tych zagadnień należą: metody klasyczne, metody ewolucyjne, wizualizacja uzyskanych rozwiązań niezdominowanych, ocena jakości działania algorytmów, właściwości i wyzwania narzucone przez problemy optymalizacji wielokryterialnej, metody uwzględniające preferencje decydenta, omówienie wybranych studiów przypadku. Studenci poznają podstawowe metody, techniki oraz algorytmy dla każdej z wymienionych dziedzin, by następnie wykorzystywać je do rozwiązywania rzeczywistych problemów.

### Przedmiotowe efekty uczenia się

Wiedza

K2st\_W1: ma zaawansowaną i pogłębioną wiedzę z zakresu szeroko rozumianych systemów informatycznych, systemów sztucznej inteligencji, podstaw teoretycznych ich budowania oraz metod,

narzędzi i środowisk programistycznych wykorzystywanych do ich implementacji.

K2st\_W2: ma uporządkowaną i podbudowaną teoretycznie wiedzę ogólną związaną z kluczowymi zagadnieniami z zakresu informatyki ze szczególnym uwzględnieniem metod sztucznej inteligencji i dziedzin pokrewnych.

K2st\_W3: ma zaawansowaną wiedzę szczegółową dotyczącą wybranych zagadnień z zakresu sztucznej inteligencji i dziedzin pokrewnych.

#### Umiejętności

K2st\_U3: potrafi planować i przeprowadzać eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski oraz formułować i weryfikować hipotezy związane ze złożonymi problemami inżynierskimi i prostymi problemami badawczymi.

K2st\_U4: potrafi wykorzystać do formułowania i rozwiązywania zadań inżynierskich i prostych problemów badawczych metody analityczne, symulacyjne oraz eksperymentalne.

K2st\_U5: potrafi — przy formułowaniu i rozwiązywaniu zadań inżynierskich — integrować wiedzę z różnych obszarów informatyki i sztucznej inteligencji (a w razie potrzeby także wiedzę z innych dyscyplin naukowych) oraz zastosować podejście systemowe, uwzględniające także aspekty pozatechniczne.

K2st\_U10: potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania informatyczne, w tym zadania z zakresu sztucznej inteligencji, zadania nietypowe oraz zadania zawierające komponent badawczy.

K2st\_U12: potrafi porozumiewać się w języku polskim i angielskim przy użyciu różnych technik w środowisku zawodowym oraz w innych środowiskach, także z wykorzystaniem narzędzi informatycznych.

K2st\_U13: potrafi przygotować i przedstawić opracowanie naukowe w języku polskim i angielskim, przedstawiające wyniki badań naukowych lub prezentację ustną dotyczącą szczegółowych zagadnień z zakresu informatyki i sztucznej inteligencji.

#### Kompetencje społeczne

K2st\_K1: rozumie, że w informatyce ze szczególnym uwzględnieniem sztucznej inteligencji wiedza i umiejętności bardzo szybko stają się przestarzałe.

K2st\_K2: rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu informatyki i sztucznej inteligencji w rozwiązywaniu problemów badawczych i praktycznych.

### Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykłady: Wykłady: zaliczenie przeprowadzone na ostatnim wykładzie. Studenci muszą rozwiązać kilka zadań teoretycznych i praktycznych. 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, [90%-100%] - 5.0.

Laboratoria: Po każdym zajęciach, studenci rozwiązują zadania programistyczne i przedstawiają rozwiązania osobie prowadzącej w następnym tygodniu. Każde zadanie jest oceniane na skali od 2.0 do 5.0. Ostateczna ocena jest obliczana jako średnia z ocen przyznanych za poszczególne zadania.

### Treści programowe

Wstęp i omówienie wybranych studiów przypadków: wstęp do zagadnienia optymalizacji wielokryterialnej, przedstawienie podstawowych pojęć, omówienie wybranych rzeczywistych studiów przypadku.

Metody klasyczne: omówienie wybranych klasycznych metod do rozwiązywania problemów optymalizacji wielokryterialnej, opartych na programowaniu liniowym, np. metoda sumy ważonej lub metoda epsilon-ograniczeń; omówienie ich wad i zalet.

Metody ewolucyjne: przedstawienie wybranych ewolucyjnych metod do rozwiązywania problemów optymalizacji wielokryterialnej, np. NSGA-II, MOEA/D, omówienie ich wad i zalet, omówienie głównych klas metod w obrębie metod ewolucyjnych, np. metody oparte na wskaźniku lub metody oparte o paradygmat dekompozycji problemu.

Wizualizacja i ocena jakości: omówienie wybranych metod oceny jakości wykonania algorytmów optymalizacji wielokryterialnej, uwzględniając metody ilościowe jak i metody wizualizacyjne.

Właściwości problemów i wyzwania: omówienie typowych cech problemów optymalizacji wielokryterialnej, np. wielomodalność oraz bias, oraz wyzwań jakie one narzucają, omówienie sposobów radzenia sobie z tymi problemami.

Metody uwzględniające informację preferencyjną: omówienie wybranych metod hybrydowych, które

zamiast przybliżyć cały front Pareta, uwzględniają informację preferencyjną decydenta celem identyfikacji podzbioru rozwiązań wysoce preferowanego przez niego/nią.

### Metody dydaktyczne

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

Laboratoria: programowanie w języku Python, przeprowadzenie eksperymentów obliczeniowych, dyskusja wybranych metod, praca zespołowa.

### Literatura

Podstawowa Multiobjective Optimization: Ineractive and Evolutionary Approaches, J. Branke, K. Deb, K. Miettinen, R. Słowiński, 2008.

Uzupełniająca Recent Advances in Evolutionary Multi-objective Optimization, S. Bechikh, Rituparna Datta, Abhishek Gupta, 2017.

Multi-Objective Optimization using Evolutionary Algorithms, K. Deb, 2001.

### Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	75	3,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	30	1,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	45	1,50