



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Analiza decyzji [S1S1E>ADEC]

---

### 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

Kurs wprowadza studentów w świat analizy decyzji. Jest on podzielony na cztery części. W pierwszej połowie semestru skupimy się na wielokryterialnym wspomaganiu decyzji (WWD), które zajmuje się oceną wariantów decyzyjnych w obecności wielu kryteriów. WWD jest jedną z gałęzi badań operacyjnych i sztucznej inteligencji, z których słynie Politechnika Poznańska. W drugiej połowie semestru zaczniemy od teorii gier. Tradycyjnie uważano ją za badanie strategicznych interakcji między racjonalnymi agentami, ale obecnie częściej uważa się ją za naukę o logicznym podejmowaniu decyzji. Następnie przejdziemy do teorii wyboru społecznego, koncentrując się na łączeniu indywidualnych preferencji w zbiorową decyzję. Na koniec powrócimy do wielokryterialnego podejmowania decyzji, kładąc nacisk na problemy optymalizacyjne, w których należy znaleźć rozwiązania, które są dobre pod względem wielu istotnych celów.

### Przedmiotowe efekty uczenia się

#### Wiedza:

K1st\_W3: ma uporządkowaną wiedzę teoretyczną dotyczącą kluczowych zagadnień informatyki z zakresu analizy decyzji, w tym wspomaganie decyzji, algorytmicznej teorii gier, teorii społecznego wyboru oraz optymalizacji wielokryteriowej

K1st\_W4: zna i rozumie podstawowe techniki, metody, algorytmy oraz narzędzia wykorzystywane w procesie rozwiązywania zadań informatycznych oraz problemów decyzyjnych, w tym metod wspomaganie decyzji, algorytmy teorii gier, metody głosowania oraz algorytmy optymalizacji w nurcie klasycznym i ewolucyjnym

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; analiza decyzji, teoria gier oraz teoria społecznego wyboru 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 wspomaganie decyzji, optymalizacji wielokryteriowej czy metod głosowania

K1st\_U9: ma umiejętność prostej adaptacji istniejących oraz formułowania i implementacji nowych algorytmów w języku Python, w tym algorytmów typowych dla różnych nurtów analizy 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 czy metody wspomaganie decyzji) 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

Kurs wprowadza studentów w świat analizy decyzji. Jest on podzielony na cztery części. W pierwszej połowie semestru skupimy się na wielokryterialnym wspomaganie decyzji (WWD), które zajmuje się oceną wariantów decyzyjnych w obecności wielu kryteriów. WWD jest jedną z gałęzi badań operacyjnych i sztucznej inteligencji, z których słynie Politechnika Poznańska. W drugiej połowie semestru zaczniemy od teorii gier. Tradycyjnie uważano ją za badanie strategicznych interakcji między racjonalnymi agentami, ale obecnie częściej uważa się ją za naukę o logicznym podejmowaniu decyzji. Następnie przejdziemy do teorii wyboru społecznego, koncentrując się na łączeniu indywidualnych preferencji w zbiorową decyzję. Na koniec powrócimy do wielokryterialnego podejmowania decyzji, kładąc nacisk na problemy optymalizacyjne, w których należy znaleźć rozwiązania, które są dobre pod względem wielu istotnych celów.

## Tematyka zajęć

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 preference, 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.

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.

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 metoda, 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.

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

Teoria społecznego wyboru - metod głosowania: jak głosujemy, najśłynniejsze metody głosowania (procedury etapowe i punktowe, rozszerzenia Condorceta, reguły niestandardowe) oraz systemy wyborcze (większościowe, proporcjonalne, pół-proporcjonalne, mieszane).

Teoria społecznego wyboru - dodatkowe aspekty: własności (np. anonimowość, neutralność, monotoniczność, niezależność, Pareto optymalność, brak dyktatu, odporność); paradoksy głosowania,

twierdzenia niemożliwości (May, Arrow, Sen), manipulacja, twierdzenie Gibbarda-Satterthwaite'a, kontrola nad wyborami, indeksy mocy Shapley'a-Shubik'a oraz Banzhafa.

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).

## 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. M.J. Osborne, An Introduction to Game Theory. Oxford University Press, 2004.
3. J. Branke, K. Deb, K. Miettinen, R. Słowiński, Multiobjective Optimization: Interactive and Evolutionary Approaches. Springer, Berlin, 2008.
4. J. Fürnkranz, E. Hüllermeier, Preference Learning. Springer, Berlin, 2010.

### 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.

## 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 |