



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Algorytmy i modele inspirowane biologicznie

Przedmiot

Kierunek studiów

Artificial Intelligence

Studia w zakresie (specjalność)

Poziom studiów

drugiego stopnia

Forma studiów

stacjonarne

Rok/semestr

1/1

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

angielski

Wymagalność

obligatoryjny

Liczba godzin

Wykład

30

Ćwiczenia

Laboratoria

30

Projekty/seminaria

Inne (np. online)

Liczba punktów ECTS

5

Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:

dr hab. inż. Maciej Komosiński

e-mail: maciej.komosinski@put.poznan.pl

Wydział Informatyki i Telekomunikacji

adres: ul. Piotrowo 2, 60-965 Poznań

Odpowiedzialny za przedmiot/wykładowca:

mgr inż. Konrad Miazga

e-mail: konrad.miazga@put.poznan.pl

Wydział Informatyki i Telekomunikacji

adres: Piotrowo 2, 60-965 Poznań

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać podstawową wiedzę na temat złożoności obliczeniowej oraz problemów optymalizacji traktowanych jako problemy przeszukiwania. Powinien posiadać umiejętność modelowania i rozwiązywania prostych problemów optymalizacyjnych, umiejętność programowania oraz umiejętność pozyskiwania informacji ze wskazanych źródeł. Powinien także rozumieć potrzebę poszerzania swoich kompetencji. Ponadto w zakresie kompetencji społecznych student powinien prezentować takie postawy jak uczciwość, odpowiedzialność, wytrwałość, ciekawość poznawcza, kreatywność, kultura osobista, oraz szacunek dla innych ludzi.

Cel przedmiotu

1. Studenci zdobywają wiedzę na temat zaawansowanych algorytmów optymalizacji, w tym algorytmów inspirowanych biologicznie takich jak algorytmy ewolucyjne, mrówkowe, pszczele, roju cząstek.



2. Studenci zdobywają wiedzę o wspólnych cechach i jednolitym podejściu do wszystkich algorytmów optymalizacyjnych.
3. Studenci rozwijają umiejętności sprawnego wdrażania i oceny skuteczności algorytmów optymalizacyjnych – zarówno pod względem czasowym, jak i jakościowym.
4. Studenci uczą się wyciągać wnioski z własnych badań, sporządzać raporty z eksperymentów obliczeniowych oraz odpowiednio wizualizować ich wyniki.

Przedmiotowe efekty uczenia się

Wiedza

K2st_W1: ma zaawansowaną i pogłębioną wiedzę z zakresu szeroko rozumianych systemów sztucznej inteligencji i algorytmów optymalizacji, 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 sztucznej inteligencji ze szczególnym uwzględnieniem inspirowanych biologicznie metod optymalizacji

K2st_W3: ma zaawansowaną wiedzę szczegółową dotyczącą wybranych zagadnień z zakresu sztucznej inteligencji

K2st_W4: ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach informatyki i sztucznej inteligencji, oraz innych, wybranych, pokrewnych dyscyplin naukowych

K2st_W6: zna zaawansowane metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań inżynierskich i prowadzeniu prac badawczych w dziedzinie sztucznej inteligencji i dziedzinach pokrewnych

Umiejętności

K2st_U1: potrafi pozyskiwać informacje z literatury, baz danych oraz innych źródeł (w języku polskim i angielskim), integrować je, dokonywać ich interpretacji i krytycznej oceny, wyciągać wnioski oraz formułować i wyczerpująco uzasadniać opinie

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_U8: potrafi dokonać krytycznej analizy istniejących rozwiązań technicznych oraz zaproponować ich ulepszenia



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

K2st_K4: ma świadomość potrzeby rozwijania dorobku zawodowego oraz przestrzegania zasad etyki zawodowej

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykład: egzamin zaliczeniowy przeprowadzany jest po ostatnim wykładzie. Studenci odpowiadają na szereg pytań dotyczących materiału prezentowanego na wykładach i ćwiczeniach laboratoryjnych. Osiągnięcie powyżej 50% sumy punktów wystarczy, aby otrzymać ocenę „3”, która jest skalowana liniowo do „5” dla 100% punktów.

Zajęcia laboratoryjne: W trakcie semestru studenci piszą raporty dotyczące głównych tematów poruszanych na zajęciach. Raporty obejmują teoretyczną i praktyczną weryfikację wiedzy, umiejętności modelowania i programowania. Ocena końcowa jest obliczana na podstawie średniej punktów uzyskanych z tych raportów. Osiągnięcie powyżej 50% sumy punktów wystarczy, aby otrzymać ocenę „3”, która jest skalowana liniowo do „5” dla 100% punktów.

Treści programowe

Wykład:

Algorytmy przeszukiwania lokalnego, przeszukiwania tabu i symulowanego wyżarzania. Algorytmy genetyczne i ewolucyjne. Selekcja i skalowanie ocen. Krzyżowanie, mutacja, twierdzenie o schematach, epistaza, MDP, NFL. Hierarchiczne AG i dekompozycja, strategie ewolucyjne, ewolucja różnicowa, reprezentacja liczb rzeczywistych. Globalna wypukłość. Programowanie genetyczne. Projektowanie ewolucyjne. Funkcje zastępcze. Mechanizmy inspirowane biologią. Sterowanie różnorodnością: w oparciu o jakość rozwiązań, o fenotyp, koncepcja MAP-Elites. Podejście Lamarcka i Baldwina. Wielokryterialne algorytmy ewolucyjne. Równoległe algorytmy ewolucyjne. Ewolucja ukierunkowana i nieukierunkowana, ograniczona i otwarta. Algorytmy optymalizacji inspirowane biologicznie: AA, PSO, ABC, GSA, CSS. Koewolucja kooperatywna i konkurencyjna. Ewolucyjna teoria gier. Obliczenia molekularne, kwantowe i membranowe.

Zajęcia laboratoryjne:

Implementacja algorytmów przeszukiwania lokalnego, symulowanego wyżarzania i przeszukiwania tabu. Porównanie jakości rozwiązań, które te algorytmy osiągają w problemach kombinatorycznych, czasu ich działania i wydajności. Analiza podobieństwa odkrytych optimum lokalnych i najlepszych rozwiązań. Projektowanie ewolucyjne: analiza wpływu intensywności mutacji; funkcje celu i krajobrazy funkcji celu;



dostosowywanie topologii przeszukiwania; ocena wypukłości i chropowatości; rola krzyżowania; różne architektury ewolucyjne; CMA-ES; wykorzystanie GP do rozwiązania problemu optymalizacji projektowania ewolucyjnego.

Metody dydaktyczne

Wykład: prezentacja multimedialna, skrypt, prezentacje na tablicy i dyskusje, pokazy programów.

Laboratorium: prezentacja przykładów na tablicy, interakcja z programami symulującymi modele inspirowane biologicznie, rozwiązywanie ilustracyjnych przykładów na tablicy i pisanie programów rozwiązujących zadane problemy, przeprowadzanie eksperymentów obliczeniowych, dyskusje, praca zespołowa.

Literatura

Podstawowa

Okwu, M. O., & Tartibu, L. K. (2020). Metaheuristic Optimization: Nature-Inspired Algorithms, Swarm and Computational Intelligence, Theory and Applications. Springer International Publishing.

Vasuki, A. (2020). Nature-Inspired Optimization Algorithms. CRC Press.

Uzupełniająca

Blum, C., Roli, A., & Sampels, M. (2008). Hybrid Metaheuristics: An Emerging Approach to Optimization. Springer Berlin Heidelberg.

Cotta, C., & van Hemert, J. (2008). Recent Advances in Evolutionary Computation for Combinatorial Optimization. Springer.

Glover, F. W., & Kochenberger, G. A. (2006). Handbook of Metaheuristics. Springer US.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,0
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	60	2,5
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/tutoriale, przygotowanie do egzaminu, wykonanie implementacji i przeprowadzenie eksperymentów, tworzenie raportów) ¹	65	2,5

¹ niepotrzebne skreślić lub dopisać inne czynności