



Karta przedmiotu

Nazwa i kod przedmiotu	Algorytmy genetyczne, PG_00068275						
Kierunek studiów	Automatyka, cybernetyka i robotyka						
Data rozpoczęcia studiów	październik 2025 r.		Rok akademicki realizacji przedmiotu		2027/2028		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć		Grupa zajęć fakultatywnych Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	3		Język wykładowy		polski		
Semestr studiów	6		Liczba punktów ECTS		2.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Elektroniki, Telekomunikacji i Informatyki -> Katedra Systemów Decyzyjnych i Robotyki						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Tomasz Białaszewski				
	Prowadzący zajęcia z przedmiotu		dr inż. Tomasz Białaszewski				
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	15.0	0.0	15.0	0.0	0.0	30
	W tym liczba godzin zajęć na odległość: 0.0						
Aktywność studenta i liczba godzin pracy	Aktywność studenta	Udział w zajęciach dydaktycznych, objętych planem studiów		Udział w konsultacjach		Praca własna studenta	RAZEM
	Liczba godzin pracy studenta	30		2.0		18.0	50
Cel przedmiotu	Celem przedmiotu jest zapoznanie studentów z teorią i praktycznym zastosowaniem algorytmów ewolucyjnych, w szczególności algorytmów genetycznych, jako efektywnej metody optymalizacji i rozwiązywania problemów obliczeniowych. Studenci poznają biologiczne inspiracje stojące za algorytmami ewolucyjnymi, a także metody ich projektowania, implementacji i analizy skuteczności. W trakcie kursu omówione zostaną zarówno klasyczne techniki optymalizacyjne, jak i zaawansowane metody heurystyczne, z naciskiem na poszukiwanie globalnych rozwiązań w problemach o wysokiej złożoności. Studenci nauczą się metod reprezentacji poszukiwanych rozwiązań, definiowania funkcji przystosowania, stosowania operatorów genetycznych, a także implementowania różnych strategii selekcji i niszowania w celu poprawy efektywności algorytmu. Dodatkowym celem jest zrozumienie teoretycznych podstaw algorytmów genetycznych, takich jak teoria schematów, oraz zdobycie umiejętności praktycznego stosowania algorytmów ewolucyjnych do optymalizacji parametrów i struktury układów inżynierskich, problemów wielokryterialnych i programowania genetycznego.						

Efekty uczenia się przedmiotu	Efekt kierunkowy	Efekt z przedmiotu	Sposób weryfikacji i oceny efektu
	[K6_W21] zna i rozumie podstawowe metody podejmowania decyzji oraz metody i techniki projektowania i eksploatacji systemów regulacji automatycznej i sterowania, zastosowania komputerów do sterowania i monitorowania systemów dynamicznych.	Student wie, jak analizować skuteczność algorytmów genetycznych i dobierać optymalne parametry sterujące. Student rozumie i potrafi zastosować zaawansowane techniki, takie jak: skalowanie przystosowania, niszczenie oraz selekcja rozwiązań wielokryterialnych.	[SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym [SW1] Ocena wiedzy faktograficznej
	[K6_U01] potrafi wykorzystywać posiadaną wiedzę matematyczną przy formułowaniu i rozwiązywaniu złożonych i nietypowych problemów związanych z kierunkiem studiów oraz innowacyjnie wykonywać zadania w warunkach nie w pełni przewidywalnych poprzez: – właściwy dobór źródeł oraz informacji z nich pochodzących, dokonywanie oceny, krytycznej analizy i syntezy tych informacji, – dobór oraz stosowanie właściwych metod i narzędzi	Student potrafi zaprojektować i zaimplementować algorytmy genetyczne w środowisku Python. Student umie wykorzystywać algorytmy ewolucyjne do rozwiązywania rzeczywistych problemów optymalizacyjnych.	[SU4] Ocena umiejętności korzystania z metod i narzędzi [SU3] Ocena umiejętności wykorzystania wiedzy uzyskanej w ramach przedmiotu
	[K6_W01] zna i rozumie w zaawansowanym stopniu matematykę w zakresie niezbędnym do formułowania i rozwiązywania prostych zagadnień związanych z kierunkiem studiów	Student rozumie i interpretuje wyniki działania algorytmów w kontekście teorii schematów i strategii ewolucyjnych	[SW1] Ocena wiedzy faktograficznej [SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym

Treści przedmiotu	Wykład: 1. Omówienie struktury kursu. Przedstawienie zasad oceniania i zaliczenia. 2. Przegląd biologicznych inspiracji stojących za algorytmami genetycznymi, takich jak mechanizmy dziedziczenia, mutacji, rekombinacji i selekcji naturalnej. Porównanie ewolucji biologicznej z procesami wykorzystywanymi w algorytmach optymalizacyjnych. 3. Omówienie klasycznych metod optymalizacji, takich jak metody gradientowe, optymalizacja dynamiczna, programowanie liniowe i nieliniowe. Porównanie ich efektywności z podejściami heurystycznymi i ewolucyjnymi w kontekście złożonych problemów obliczeniowych. 4. Klasyfikacja metod optymalizacyjnych ze względu na sposób przeszukiwania przestrzeni rozwiązań. Analiza skuteczności różnych podejść w zależności od rodzaju problemu. 5. Opis ogólnej struktury algorytmu genetycznego, jego podstawowych elementów (populacja, selekcja, krzyżowanie, mutacja). Kluczowe parametry wpływające na skuteczność procesu ewolucji. 6. Metody kodowania rozwiązań w algorytmach genetycznych: reprezentacja binarna, rzeczywista, permutacyjna i inne. Sposoby dekodowania genotypu na fenotyp i ich wpływ na efektywność wyszukiwania optymalnych rozwiązań. 7. Definiowanie funkcji przystosowania oraz jej znaczenie w procesie ewolucji. Przegląd metod oceny jakości osobników, takich jak funkcja kosztu, ranking osobników, normalizacja i różne techniki skalowania przystosowania. 8. Omówienie metod selekcji osobników do kolejnych pokoleń: selekcja ruletkowa, selekcja turniejowa, selekcja rankingowa, selekcja elitarna. Porównanie ich wpływu na szybkość i efektywność optymalizacji. 9. Analiza operatorów genetycznych: krzyżowania (jednopunktowego, dwupunktowego, jednorodnego, arytmetycznego), mutacji (losowej, niejednorodnej, adaptacyjnej) oraz ich wpływu na dywersyfikację i eksplorację przestrzeni rozwiązań. 10. Omówienie podejść do zarządzania populacją w kolejnych generacjach: pełne zastępowanie populacji, strategię elitarną, mechanizmy częściowej wymiany oraz ich znaczenie dla szybkości konwergencji i unikania przedwczesnej zbieżności. 11. Modyfikacje wartości funkcji przystosowania w celu poprawy efektywności selekcji. Skalowanie liniowe, potęgowe, z odchyleniem standardowym. 12. Wprowadzenie do teorii schematów jako narzędzia analizy działania algorytmów genetycznych. Omówienie hipotezy schematów Hollanda i jej konsekwencji dla projektowania skutecznych operatorów genetycznych. 13. Przegląd technik zapobiegających zbyt szybkiemu zbieżności populacji do jednego rozwiązania: metoda zatłoczenia, niszowanie oraz ich zastosowanie w problemach optymalizacji wielomodalnej. 14. Zastosowanie algorytmów ewolucyjnych do problemów wielokryterialnych. Przegląd popularnych metod, takich jak NSGA-II (Nondominated Sorting Genetic Algorithm), MOEA/D (Multi-Objective Evolutionary Algorithm based on Decomposition). 15. Przegląd praktycznych zastosowań algorytmów genetycznych i ewolucyjnych w optymalizacji konstrukcji inżynierskich, sieci neuronowych, projektowaniu układów elektronicznych, mechanice, robotyce i innych dziedzinach. Laboratorium: Implementacja metod: 1. Kodowania rozwiązań dla danego problemu optymalizacyjnego. 2. Przekształcania funkcji celu do zadanego problemu optymalizacji 3. Selekcji 4. Krzyżowania i mutacji 5. Strategii podstawień 6. Niszowania 7. Oceny zadań wielokryterialnych Zastosowanie zaimplementowanych mechanizmów algorytmów genetycznych do tworzenia wybranej wersji GA dla danego problemu optymalizacji.									
Wymagania wstępne i dodatkowe										
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table><tr><td>Sposób oceniania (składowe)</td><td>Próg zaliczeniowy</td><td>Składowa oceny końcowej</td></tr><tr><td>Zaliczenie w formie egzaminu</td><td>50.0%</td><td>60.0%</td></tr><tr><td>Realizacja zadań laboratoryjnych</td><td>50.0%</td><td>40.0%</td></tr></table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	Zaliczenie w formie egzaminu	50.0%	60.0%	Realizacja zadań laboratoryjnych	50.0%	40.0%
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej								
Zaliczenie w formie egzaminu	50.0%	60.0%								
Realizacja zadań laboratoryjnych	50.0%	40.0%								

Zalecana lista lektur	Podstawowa lista lektur	Arabas J.: Wykłady z algorytmów ewolucyjnych. WNT, Warszawa 2001. Berg P., Singer M.: Język genów, poznawanie zasad dziedziczenia. Prószyński i S-ka, Warszawa 1997. Goldberg D.E.: Genetic algorithms in search, Optimisation and Machine Learning. Addison-Wesley, Massachusetts 1989. Michalewicz Z., Fogel D. B.: How to solve it: Modern Heuristics. 2nd edition, Springer-Verlag, Berlin 2004. Michalewicz Z.: Genetic Algorithms + Data Structures = Evolution Programms, Springer-Verlag, 3rd edition, Heidelberg - Berlin 1996. Miller R. E.: Optimization. Foundations and applications. A Wiley-Interscience Publication, John Wiley & Sons, Inc. New York 2000. Rutkowski L.: Metody i techniki sztucznej inteligencji. Wydawnictwo Naukowe PWN, Warszawa 2005.
	Uzupełniająca lista lektur	Koza J. R.: Genetic Programming: On the Programming of Computers by Means of Natural Selection. The MIT Press, MA, Cambridge 1992. Man K.S, Tang K.S., Kwong S., Lang W.A.H.: Genetic Algorithms for Control and Signal Processing. Springer-Verlag, London 1997.
	Adresy eZasobów	
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	1. Czy algorytm genetyczny, posługujący się wyłącznie operatorem krzyżowania (bez mutacji), jest w stanie odnaleźć maksimum globalne funkcji przystosowania? 2. Populacja składa się z 4 osobników o następujących przystosowaniach: 169, 576, 64 oraz 361. Wyznacz przeskalowane przystosowanie osobników korzystając ze liniowego skalowania ze współczynnikiem zwielokrotnienia równym 2. 3. Zakładając, że osobnik pasujący do schematu S ma stopień przystosowania wyższy od średniego przystosowania aktualnej populacji o 25%, określ, w którym pokoleniu schemat ten zmonopolizuje populację o wielkości 20, 50, 100 i 200 osobników. Przy obliczeniach pominąć efekt krzyżowania i mutacji. 4. Podaj zasadę mutacji genotypowej w przypadku kodowania triallelicznego. 5. Wymień i krótko opisz operacje krzyżowania przy reprezentacji zmiennopozycyjnej. 6. Pewna przestrzeń rozwiązań zawiera 2097152 punktów. Podaj dolne i górne oszacowanie liczby schematów przetwarzanych podczas cyklu ewolucyjnego dla kodowania binarnego oraz dla kodowania ósemkowego. Przy założeniu, że populacja składa się z 50 osobników.	
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy	

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.