



OMNIS

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.

Optymalizacja w inżynierii lotniczej i kosmicznej

Wykład 7

Matematyczne podstawy optymalizacji 5

Wstęp do metod niedeterministycznych

1130-LK000-MSP-1037



Fundusze Europejskie
dla Rozwoju Społecznego



Rzeczpospolita
Polska

Dofinansowane przez
Unię Europejską



Politechnika Warszawska



OMNIS

Zagadnienia

- Wstęp do metod niedeterministycznych
 - funkcje testowe
 - metody losowe (Monte Carlo)
 - metody ewolucyjne (GA, ES, PSO, ACO, ABC, ...)





OMNIS

Metody niedeterministyczne

- Rozwiązanie problemów optymalizacji, w których funkcja celu ma wiele minimów lokalnych, jest bardzo trudne (czasem wręcz niemożliwe) metodami gradientowymi.
- Przykładami takich funkcji są specjalne funkcje służące do testowania algorytmów, np. Michalewicza, Schwefela, Rastrigina itp.

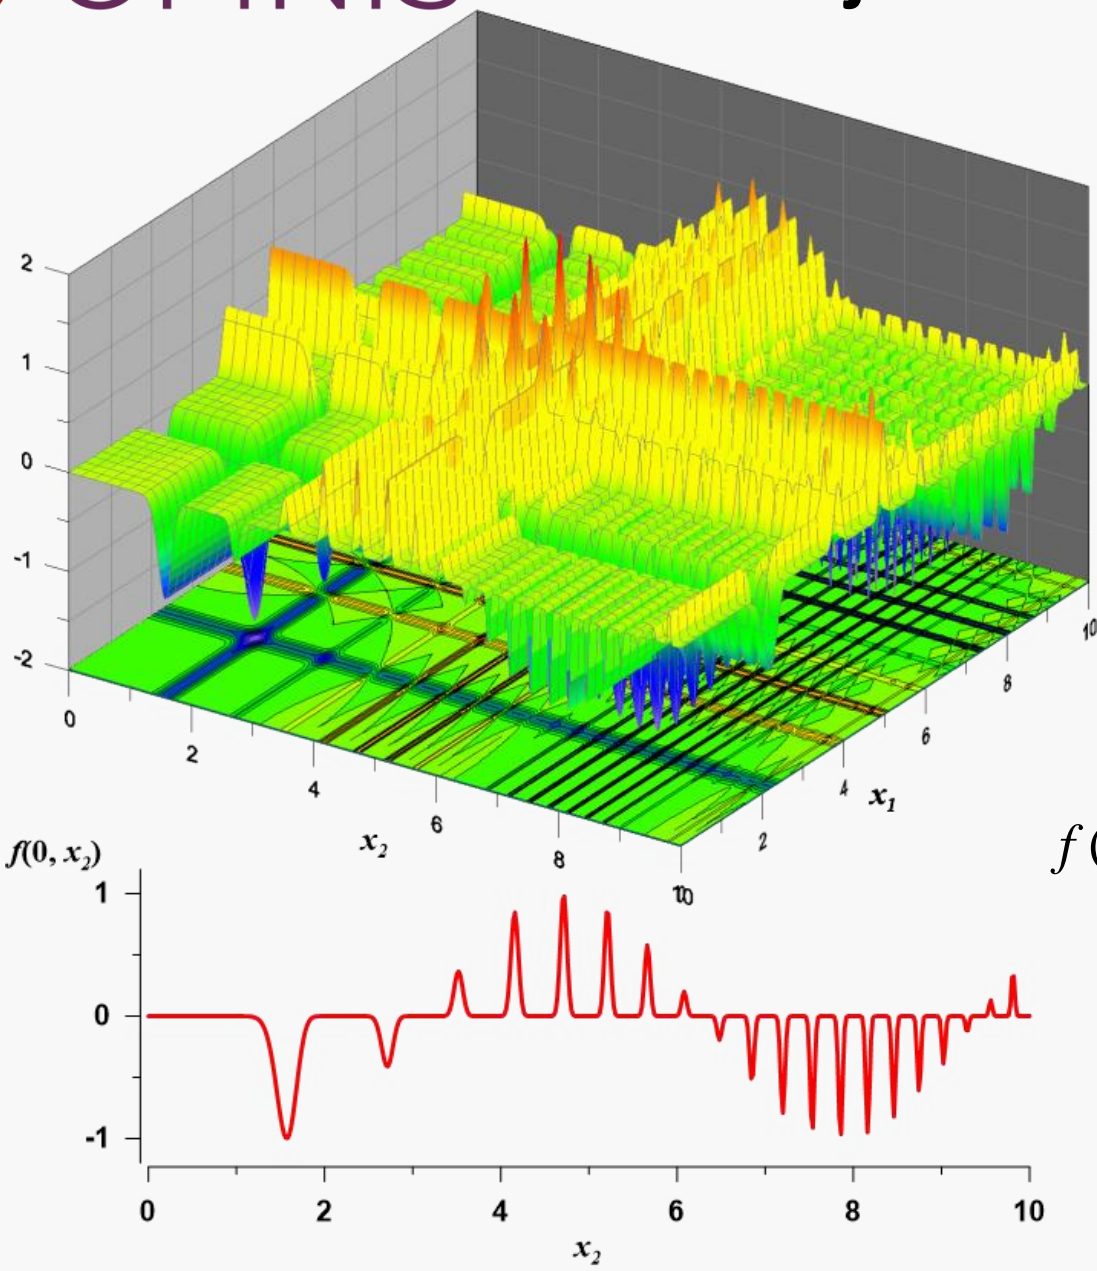




OMNIS

Funkcje testowe

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.



Funkcja Michalewicza

$$f(x_1, x_2) = -\sin(x_1) \left(\sin\left(\frac{x_1^2}{\pi}\right) \right)^{20} - \sin(x_2) \left(\sin\left(\frac{2x_2^2}{\pi}\right) \right)^{20}$$



Fundusze Europejskie dla Rozwoju Społecznego



Rzeczpospolita Polska

Dofinansowane przez Unię Europejską





Politechnika Warszawska



OMNIS

Funkcje testowe

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.



Funkcja Schwefela

$$f(x_1, x_2) = -x_1 \sin \sqrt{|x_1|} - x_2 \sin \sqrt{|x_2|}$$



Fundusze Europejskie
dla Rozwoju Społecznego



Rzeczpospolita
Polska

Dofinansowane przez
Unię Europejską



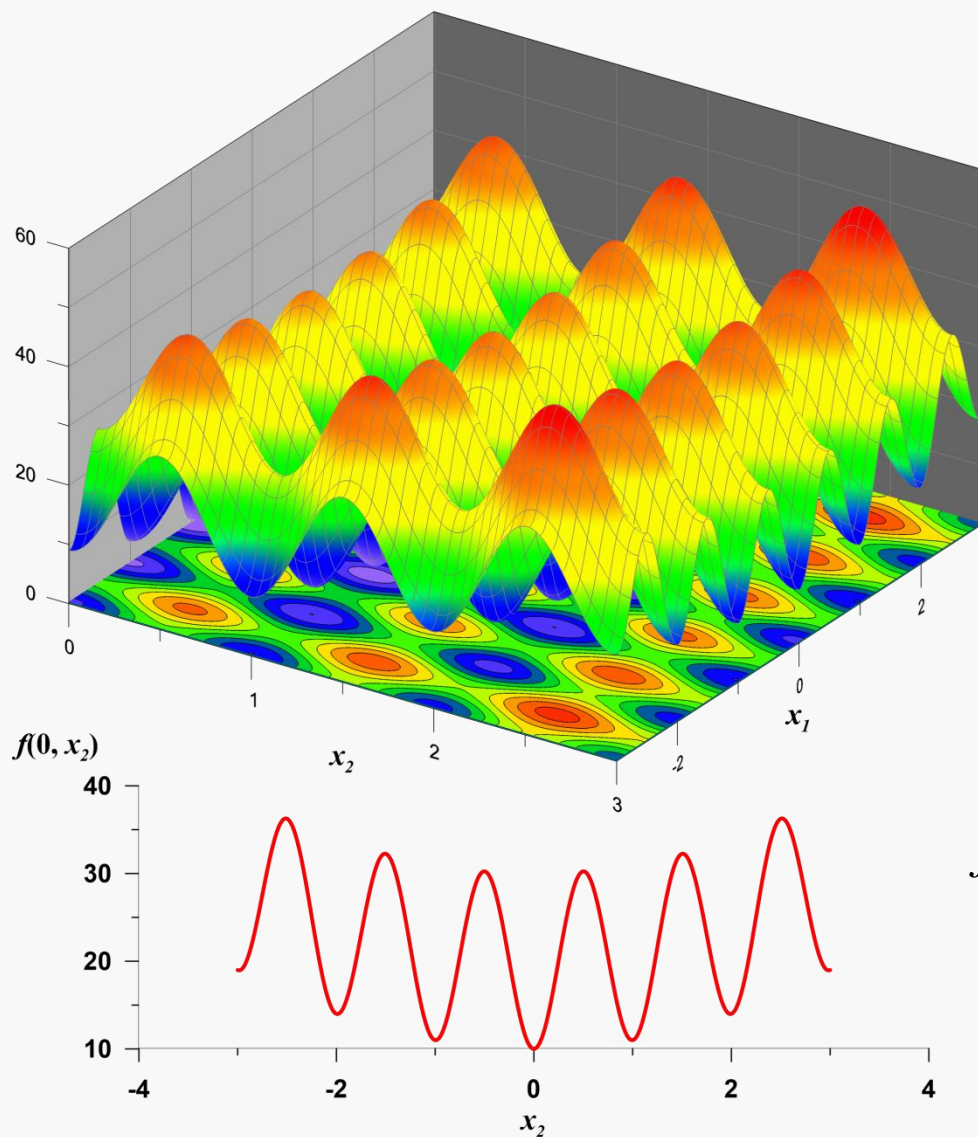
Politechnika Warszawska



OMNIS

Funkcje testowe

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.



Funkcja Rastrigina

$$f(x_1, x_2) = 20 + x_1^2 + x_2^2 - 10(\cos(2\pi x_1) + \cos(2\pi x_2))$$



Fundusze Europejskie
dla Rozwoju Społecznego



Rzeczpospolita
Polska

Dofinansowane przez
Unię Europejską



Politechnika Warszawska



OMNIS

Metody niedeterministyczne - Monte Carlo

Wszelkie metody wykorzystujące czynnik losowy w rozwiązywaniu złożonych problemów, których rozwiązanie metodami analitycznymi nie jest możliwe. Metody zaliczane do tej grupy wykorzystują elementy rachunku prawdopodobieństwa, analizę statystyczną itp. Zdobywają one coraz większą popularność w wielu dziedzinach, w tym również w optymalizacji, bowiem pozwalają podnieść skuteczność działania rozważanych algorytmów przy stosunkowo niewielkim dodatkowym nakładzie pracy. Do twórców metod Monte Carlo zalicza się polskiego matematyka, Stanisława Ulama (1909-1984).

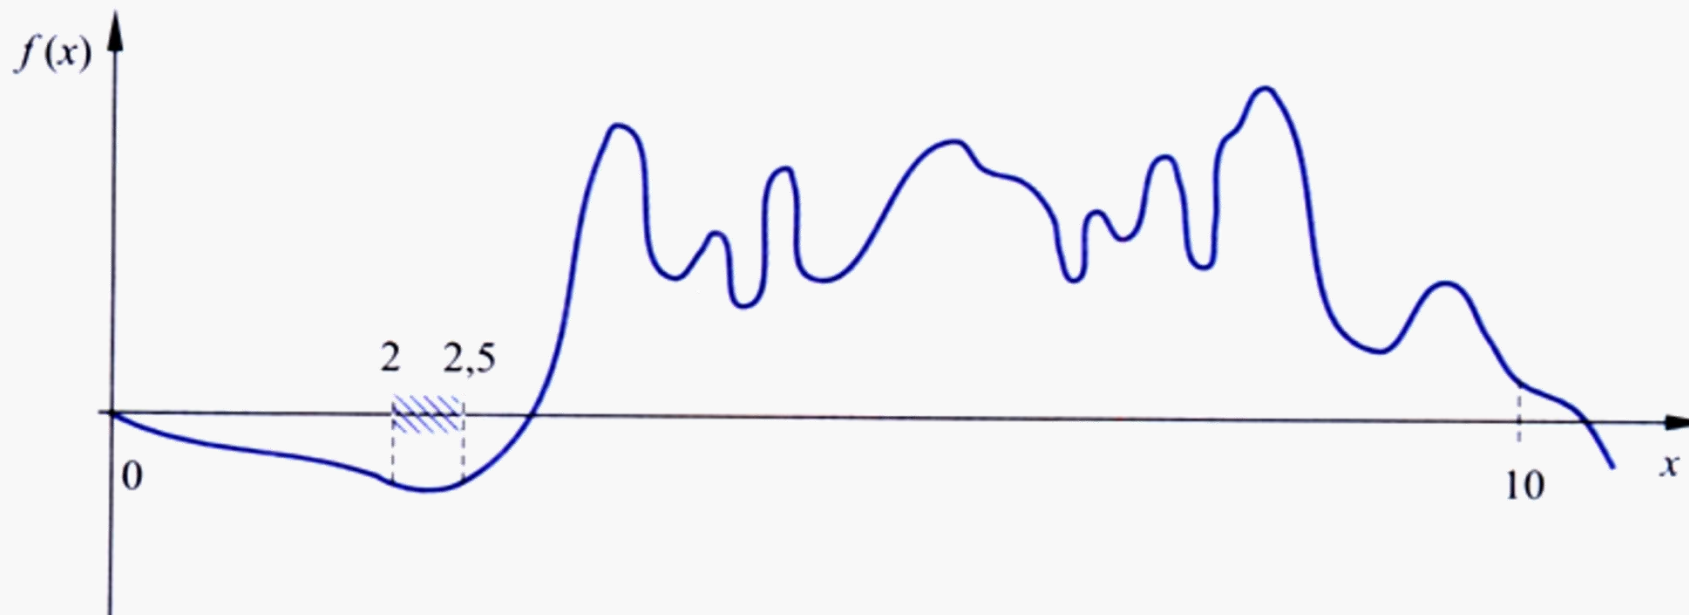




OMNIS

Metoda Monte Carlo

$$x_0 = 0, x_1 = 0,01, x_2 = 0,02, \dots, x_{1000} = 10.$$



Przykładowa, hipotetyczna funkcja o wielu minimach lokalnych

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.



Algorytm metody Monte Carlo „orzeł-reszka”

Dane wejściowe: funkcja $f : \mathbb{R}^n \supset X \rightarrow \mathbb{R}$, liczba losowanych punktów N

- 1: wylusuj N punktów $\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^N$ ze zbioru X
- 2: $y^* = f(\mathbf{x}^1)$
- 3: $\mathbf{x}^* = \mathbf{x}^1$
- 4: **for** $i = 2$ **to** N **do**
- 5: oblicz $f(\mathbf{x}^i)$
- 6: **if** $f(\mathbf{x}^i) < y^*$ **then**
- 7: $y^* = f(\mathbf{x}^i)$
- 8: $\mathbf{x}^* = \mathbf{x}^i$
- 9: **end if**
- 10: **end for**
- 11: **return** \mathbf{x}^* ▷ przybliżone rozwiązanie





- Przybliżenie minimum funkcji celu:

$$f(x) = x + \frac{1}{x^2}$$

- W przedziale $X=[0; 2.5]$
- Losujemy $N=10$ punktów ze zbioru X i obliczamy wartości funkcji f w tych punktach





Wybieramy najmniejszą z wartości funkcji celu i otrzymujemy przybliżenie minimum


$$x^* = 1,2687, \quad y^* = f(x^*) = 1,88997.$$

Jak widać na rysunku jesteśmy blisko rzeczywistego minimum, które znajduje się w punkcie

$$x^{\min} = 1,25992, \quad y^{\min} = f(x^{\min}) = 1,88988.$$

Różnica między wyznaczoną wartością a rzeczywistym minimum wynosi


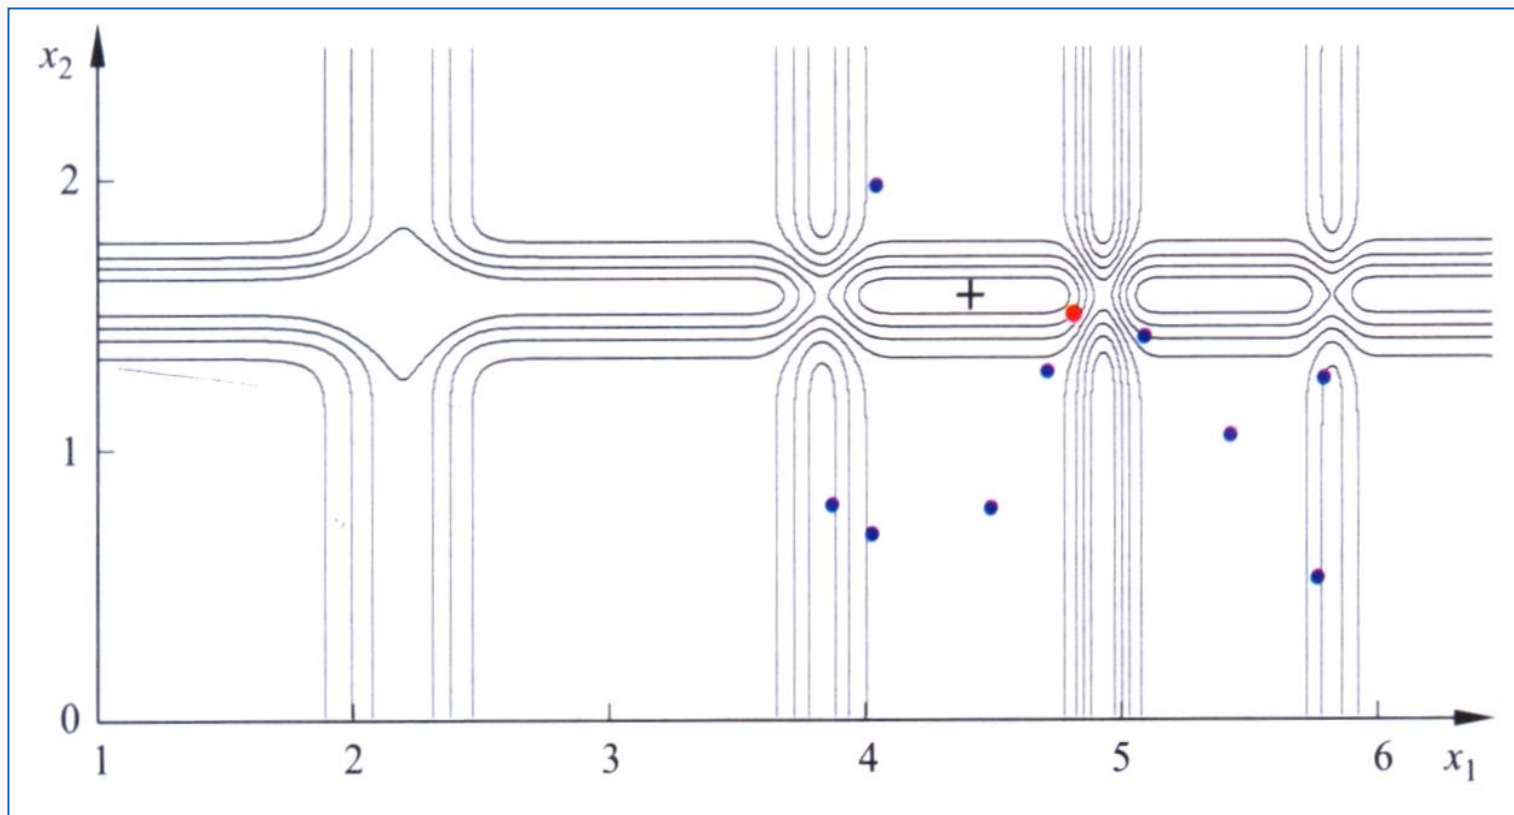
$$y^* - y^{\min} = 1,88997 - 1,88988 = 0,00009.$$



i	x_i	$f(x_i)$
1	1.16081	1.90294
2	0.55117	3.84294
3	0.39271	6.87691
4	0.4622	5.14322
5	0.72467	2.6289
6	0.50855	4.37518
7	2.12431	2.34591
8	0.94911	2.05922
9	2.28764	2.47872
10	1.2687	1.88997

Wyniki działania metody „orzeł-reszka”





Punkty wyznaczone metodą orzeł-reszka dla funkcji Michalewicza





Algorytm zmodyfikowanej metody „orzeł-reszka”

Dane wejściowe: funkcja $f : \mathbb{R}^n \supset X \rightarrow \mathbb{R}$, liczba losowanych punktów N , liczba pełnych przebiegów algorytmu M

- 1: wylosuj dowolny punkt $\mathbf{x}^R \in X$
- 2: $y^R = f(\mathbf{x}^R)$
- 3: **for** $i = 1$ **to** M **do**
- 4: wykonaj N losowań jak w metodzie „orzeł-reszka” i wybierz najlepszy wynik $\mathbf{x}^{(i)}$
- 5: wyznacz minimum lokalne \mathbf{x}^* wybraną metodą deterministyczną, startując z punktu $\mathbf{x}^{(i)}$ (gdy metoda wymaga m punktów startowych wykorzystaj m najlepszych wyników z przeprowadzonych N losowań)
- 6: **if** $f(\mathbf{x}^*) < y^R$ **then**
- 7: $y^R = f(\mathbf{x}^*)$
- 8: $\mathbf{x}^R = \mathbf{x}^*$
- 9: **end if**
- 10: **end for**
- 11: **return** $\mathbf{x}^* = \mathbf{x}^R$ ▷ przybliżone rozwiązanie





OMNIS

Metody niedeterministyczne – Algorytmy genetyczne

Algorytmy genetyczne są kolejną grupą metod wykorzystujących czynniki losowe. Zaliczane są do narzędzi sztucznej inteligencji, a za twórcę idei tych algorytmów, opartych na zasadach podobnych do tych znanych z genetyki, uważany jest John Holland, który opublikował ją w 1975 r.

Algorytmy genetyczne znajdują wiele zastosowań, między innymi w optymalizacji, i są zaliczane do grupy metod niedeterministycznych. Zachodzi jednak tutaj istotna różnica w porównaniu do podejścia metod Monte Carlo. W algorytmach genetycznych kolejne losowane punkty są bowiem istotnie zależne od punktów otrzymanych wcześniej w tym sensie, że punkty w kolejnych iteracjach są losową modyfikacją punktów otrzymanych w poprzedniej iteracji. Ponadto, do poszukiwania rozwiązań optymalnych wykorzystuje się zakodowaną postać zmiennych optymalizacji.






OMNIS

Algorytmy Genetyczne (GA)

Motto:



Zamiast pracowicie poszukiwać najlepszego rozwiązania problemu informatycznego lepiej pozwolić, żeby komputer sam sobie to rozwiązanie wyhodował !





OMNIS

Algorytmy Genetyczne (GA)

- Podstawą Algorytmu Genetycznego jest znany z ewolucji fakt, że największe prawdopodobieństwo przeżycia ma osobnik o najwyższym stopniu przystosowania (oraz jego potomstwo)
- Optymalizacja jako wybór najlepszego rozwiązania jest bliska efektowi znanemu z ewolucji





- Populacja - jest określonym zbiorem osobników,
- Osobnik - zakodowany w postaci chromosomu zbiór parametrów zadania,
- Chromosom - uporządkowany ciąg genów,
- Gen – jest cechą, pojedynczym elementem genotypu,
- Genotyp - to zespół chromosomów danego osobnika (choć często jest to po prostu pojedynczy chromosom),
- Fenotyp - to zdekodowana struktura, czyli po prostu zbiór parametrów zadania.





- Populacja jest to zbiór osobników (chromosomów). Liczebność populacji jest z góry określona i pozostaje stała podczas całej procedury obliczeń. W trakcie swojego działania algorytm genetyczny będzie modyfikował populację zgodnie z pewnym przyjętym odgórnie schematem. Nazwa populacja nie jest tutaj przypadkowa. Przy tworzeniu nowej populacji stosuje się mechanizmy podobne do mechanizmów obserwowanych w przyrodzie. Mówiąc ogólnie, nowe osobniki są potomkami pary rodzicielskiej pochodzącej od populacji z iteracji wcześniejszej. W ten sposób dziedziczą pewne cechy rodziców z poprzedniej populacji, a jednocześnie nabywają nowych cech, na skutek działania czynnika losowego.





- Osobnik (Genotyp, Chromosom) jest obiektem reprezentującym zmienne optymalizacji. Składa się on z uporządkowanego ciągu genów o określonej długości. Ciąg ten stanowi zakodowaną postać punktu w przestrzeni rozwiązań dopuszczalnych. Mamy tutaj dowolność w wyborze sposobu kodowania, jednak powinien on jak najlepiej odpowiadać rozważanemu problemowi. Najczęściej geny przyjmują tylko dwie wartości: 0 i 1 i wówczas zmienna optymalizacji jest kodowana binarnie. Jak łatwo zauważyć, mając do dyspozycji chromosom o określonej długości (o skończonej liczbie genów), jesteśmy w stanie zakodować tylko skończony zbiór punktów. W praktyce ustala się pewien zbiór reprezentantów dla zbioru dopuszczalnego X .





OMNIS

Algorytmy Genetyczne (GA) - pojęcia

- Funkcja przystosowania jest to funkcja powiązana z funkcją celu analizowanego zadania optymalizacji. Aby algorytm genetyczny mógł działać, musimy dysponować funkcją przystosowania, dla której poszukujemy maksimum. Wartości funkcji przystosowania pozwalają na liczbową ocenę przystosowania poszczególnych chromosomów. Zgodnie bowiem z główną ideą algorytmów genetycznych, chodzi o to, aby populacje chromosomów w kolejnych iteracjach były lepiej przystosowane niż populacje wcześniejsze.





- określenie sposobu kodowania rzeczywistych parametrów problemu w postaci **chromosomu**,
- przyjęcie postaci **funkcji przystosowania** oceniającej analizowany zestaw parametrów pod względem jakości poszukiwanego rozwiązania,
- **losowy** dobór punktów startowego zestawu parametrów,
- **selekcja** najlepiej przystosowanych chromosomów do nowej populacji,
- zastosowanie na nowej populacji **operatorów genetycznych** w postaci krzyżowania i mutacji,
- **sprawdzenie** wartości funkcji przystosowania.





Strategie Ewolucyjne to klasa algorytmów optymalizacyjnych inspirowanych procesami biologicznej ewolucji, stosowanych głównie do rozwiązywania problemów w przestrzeniach ciągłych. Zostały opracowane w latach 60. przez Ingo Rechenberga i Hansa-Paula Schwefela jako narzędzie do inżynierskiej optymalizacji kształtów.

Kluczowe cechy strategii ewolucyjnych:

- Reprezentacja rzeczywista: W przeciwieństwie do klasycznych algorytmów genetycznych (często operujących na ciągach binarnych), ES pracują bezpośrednio na wektorach liczb rzeczywistych.
- Główna rola mutacji: Mutacja jest kluczowym operatorem, zazwyczaj realizowanym poprzez dodanie do zmiennych losowych wartości o rozkładzie normalnym (Gausa).
- Samoadaptacja: Algorytmy te potrafią jednocześnie ewoluować rozwiązanie oraz parametry samej strategii (np. zasięg mutacji), co pozwala im automatycznie dostosowywać się do topografii funkcji celu.





OMNIS

Metody zachowań stadnych

Metody zachowań stadnych (ang. Swarm Intelligence – inteligencja rojowa) to algorytmy metaheurystyczne inspirowane zbiorowym zachowaniem grup zwierząt, takich jak ptaki, ryby czy mrówki. Ich zaletą jest to, że proste reguły pojedynczych jednostek prowadzą do powstania złożonej i inteligentnej struktury grupy.





- Optymalizacja rojem cząstek (PSO – Particle Swarm Optimization)
 - Inspirowana stadem ptaków szukających pożywienia. Każda „cząstka” porusza się w przestrzeni rozwiązań, pamiętając swoją najlepszą pozycję oraz najlepszą pozycję znaną przez całe stado.
- Algorytm mrowiska (ACO – Ant Colony Optimization)
 - Oparty na sposobie, w jaki mrówki znajdują najkrótszą drogę do źródła pokarmu za pomocą feromonów.
- Algorytm sztucznej kolonii pszczół (ABC – Artificial Bee Colony)
 - Modeluje proces zbierania nektaru przez pszczoły. Wyróżnia się trzy grupy pszczół: robotnice (eksploatują znane źródła), obserwatorzy (wybierają źródła na podstawie tańca robotnic) oraz zwiadowców (szukają nowych terenów).
- Algorytm świetlika (Firefly Algorithm)
 - Wykorzystuje zjawisko przyciągania się świetlików za pomocą światła.
- Algorytm kukułki (Cuckoo Search)
 - Inspirowany pasożytnictwem lęgowym kukułek. Algorytm opiera się na strategii podrzucania jaj do obcych gniazd i tzw. lotach Lévy'ego (długich skokach w poszukiwaniu nowych obszarów).





OMNIS Optymalizacja w inżynierii lotniczej i kosmicznej

Otwartość. Modernizacja. Nowoczesność. Integracja. Społeczność.

Dziękuję za uwagę

