
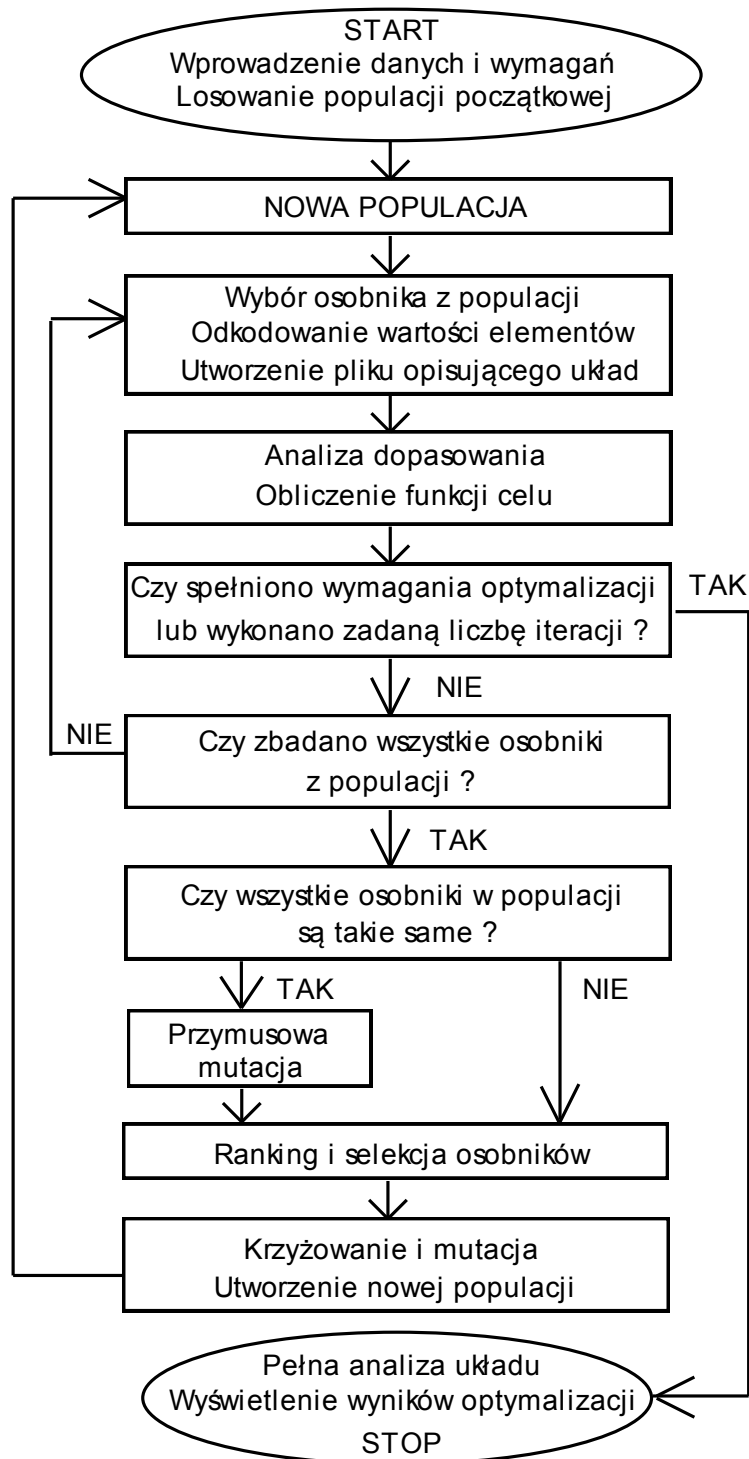


# Podstawowe pojęcia algorytmów genetycznych




# Struktura algorytmu genetycznego




# ALGORYTMY GENETYCZNE


## Efektywność a odporność metod optymalizacji



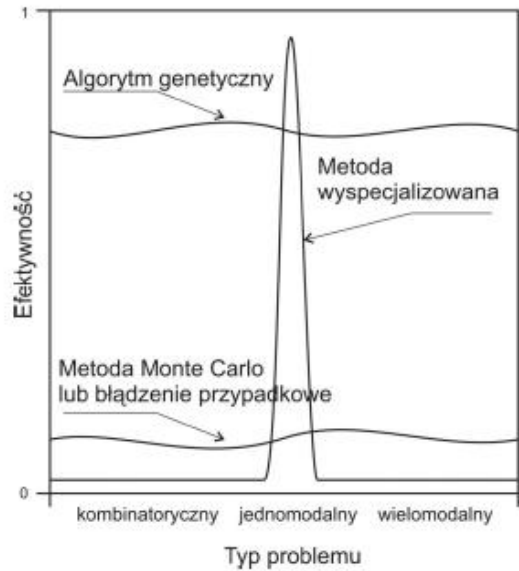
Funkcja o jednym maksimum



Funkcja o wielu maksimach





Nieregularna funkcja o wielu maksimach



Efektywność różnych metod

Przykład:



wymagania optymalizacyjne:  $WFS_0 = 1,25$  w paśmie **40-80MHz**.

Przyjęte ograniczenia na wartości elementów:

- indukcyjność: 0,002 - 8,192  $\mu\text{H}$ ,
- pojemność: 0,020 - 81,92 pF.

Wartości elementów były kodowane **12 bitami**.

Każdy osobnik składał się z **4 chromosomów** (liczba dwójników LC w układzie), które łącznie zawierały **5 genów** (całkowita liczba pojedynczych elementów tworzących układ). Zatem każdy osobnik miał długość **60 bitów** (5 parametrów  $\times$  12 bitów/parametr). Dawało to teoretycznie  $2^{60}$  ( $1,1 \times 10^{18}$ ) możliwych rozwiązań.

Przyjęto następujące parametry algorytmu genetycznego:

- krzyżowanie jednopunktowe,
- mutacja 4%,
- mutacja wymuszona 90%,
- maksymalna liczba iteracji 500,
- liczba osobników w populacji 30.
- dodatkowo jeden osobnik w populacji początkowej zawierał informacje o punkcie startowym.

Optymalizacja dwiema metodami: gradientową i AG.

Wybrano cztery niewiele różniące się punkty startowe:


P1 - L1, L2, L3 = 1 $\mu$ H, C1, C2 = 10pF

P2 - L1, L2, L3 = 1 $\mu$ H, C1, C2 = 1,0pF

P3 - L1, L2, L3 = 1 $\mu$ H, C1, C2 = 0,8pF

P4 - L1, L2, L3 = 1 $\mu$ H, C1, C2 = 0,7pF

metoda gradientowa



algorytmy genetyczne




Tabela. Wartości elementów po optymalizacji

	Algorytm gradientowy	Algorytm genetyczny 500 iteracji, mutacja 4%			
	Najlepsze rozwiązanie	P1	P2	P3	P4
L1, $\mu$ H	0,418	0,346	1,032	0,900	0,258
L2, $\mu$ H	0,314	0,326	0,280	0,286	0,384
L3, $\mu$ H	0,247	0,260	0,214	0,258	0,318
C1, pF	21,48	27,20	10,24	31,50	32,70
C2, pF	62,42	62,10	63,82	67,02	45,76