

Katedra Informatyki Stosowanej
Politechnika Łódzka

Algorytmy Genetyczne (Genetic Algorithm – GA)

Wprowadzenie

Wszystkie organizmy żyją w określonych przez naturę środowiskach.

Każdy organizm posiada zespół indywidualnych cech, które umożliwiają mu egzystencję i rozwój w określonych warunkach.

Zespół informacji o indywidualnych cechach zapisany jest w materiale genetycznym – genach.

Podczas reprodukcji powstaje nowy organizm, któremu zostaje przekazana informacja zawarta w materiale genetycznym rodziców.

Ogólna zasada w świecie ożywionym – potomek musi mieć przekazany taki materiał genetyczny, aby jego organizm był coraz lepiej przystosowany do życia w środowisku. W przypadku odstępstw od tej zasady organizm nie może się rozmnożyć, a w skrajnym przypadku ginie (środowisko go zabija).

Proces ewolucji

Populacja ryb



Populacja po krzyżowaniu i mutacji

Krzyżowanie

(wybór miejsca wymiaru jest przypadkowy)

P M C T T N N
P D Z N T T N

D D Z T N T W
P M N N N N N

D M C T T T N
P M N N T N N



Dwa osobniki tego typu
genotypu, bo
były najlepiej
przystosowane


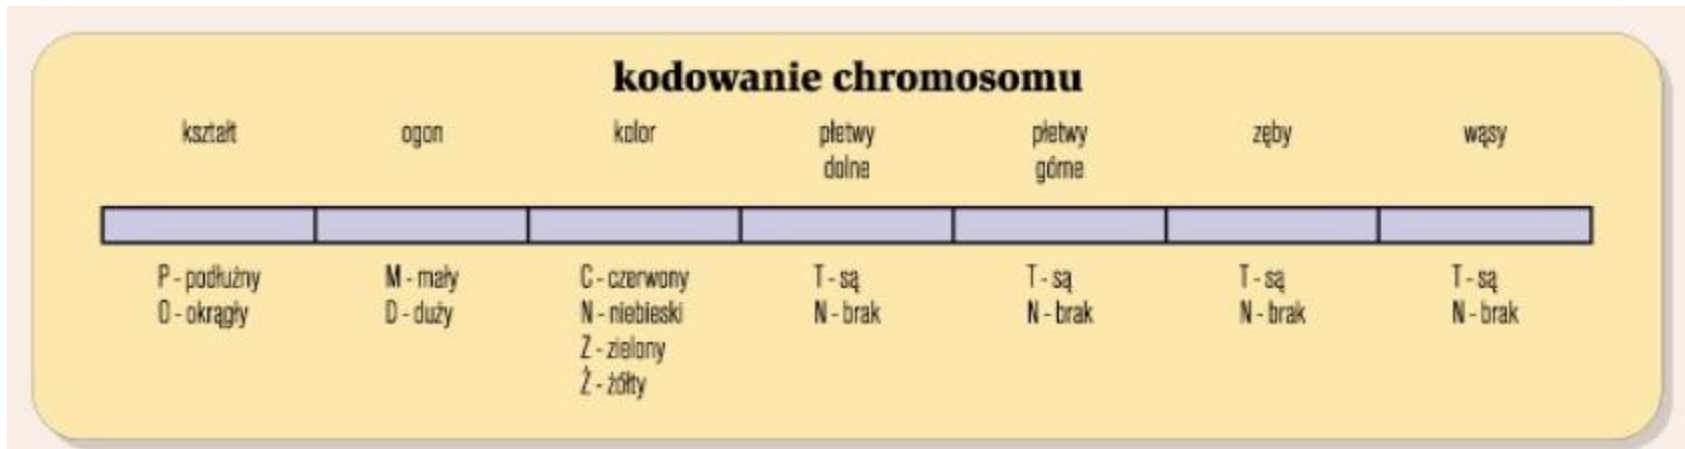
Osobnik tego typu
nie przetrwał,
bo był najmniej
przystosowany

W tym przykładzie mutacja powstała stworzył
osobnika, który nie miał szans
na powodzenie drogą ewolucji

Przyjęciem do nowej populacji
preferowane są ryby szybsze
(podobnie z innymi organami),
jakże i szlachetne

Przykład ilustrujący działanie ewolucji

Sposób kodowania właściwości ryby w chromosomie



Proces ewolucji

Populacja ryb



Populacja po krzyżowaniu i mutacji

Krzyżowanie

(wybór miejsca wymiaru jest przypadkowy)

P M C T T N N
P D Z N T T W

D D Z T N T W
P M N N N N N

D M C T T T N
P M N N T M N



Dwie osobniki tego typu genotypu, bo były najlepiej przystosowane

Osobnik tego typu nie przetrwał, bo był najmniej przystosowany

W tym przykładzie mutacja powstała stworzył osobnika, który nie miał szans na powodzenie drogą ewolucyjną

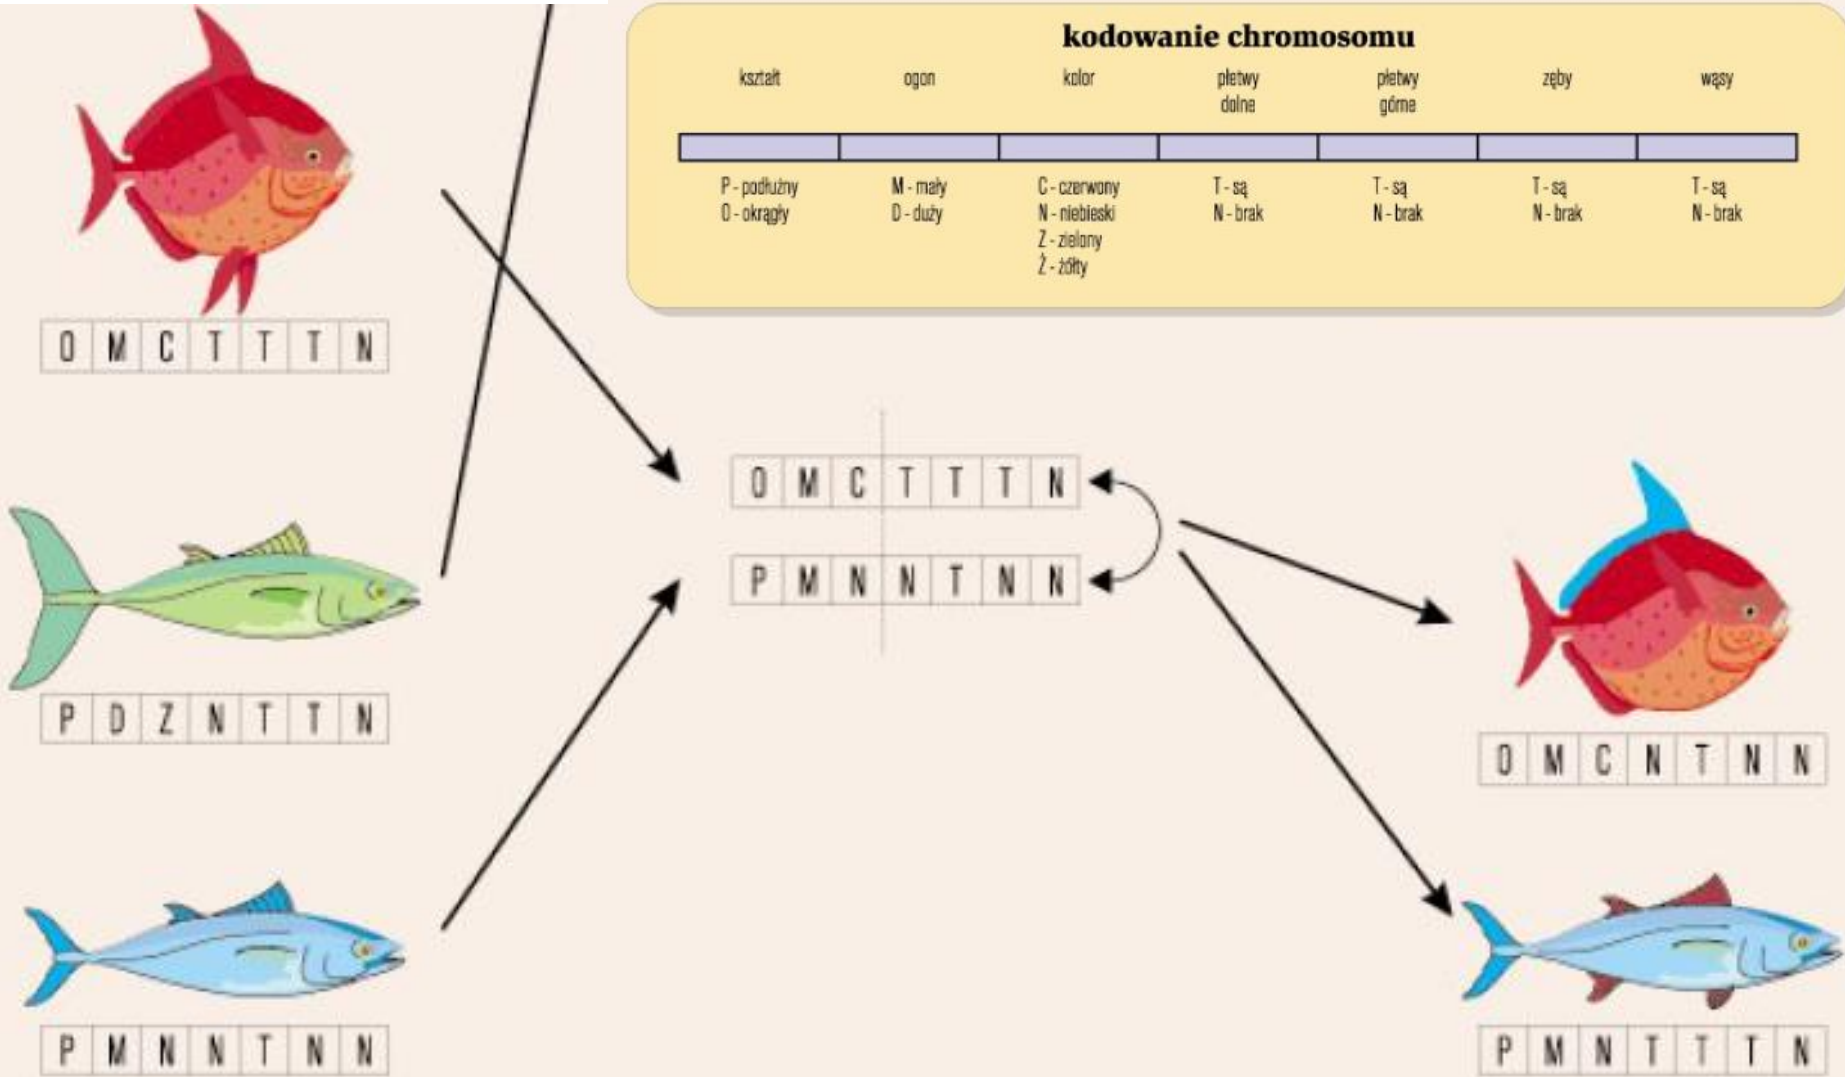
Przyjęciem do nowej populacji preferowane są ryby szybsze (podobnie z innymi organami), jaskrawe i szlachetne

Mieszanie materiału genetycznego rodziców w celu stworzenia potomka

Mieszanie właściwości ryb w chromosomach

kodowanie chromosomu

kształt	ogon	kolor	pletwy dolne	pletwy górne	zęby	wąsy
P - podłużny O - okrągły	M - mały D - duży	C - czerwony N - niebieski Z - zielony Ż - żółty	T - są N - brak	T - są N - brak	T - są N - brak	T - są N - brak



Proces ewolucji

Populacja ryb



Krzyżowanie

(wybór miejsca wymiaru jest przypadkowy)

P M C T T N N
P D Z N T T N

D D Z T N T N
P M N N N N N

D M C T T T N
P M N N T N N

Populacja po krzyżowaniu i mutacji



Dwa osobniki tego typu genotypy, bo były najlepiej przystosowane

Osobnik tego typu nie przetrwał, bo był najmniej przystosowany

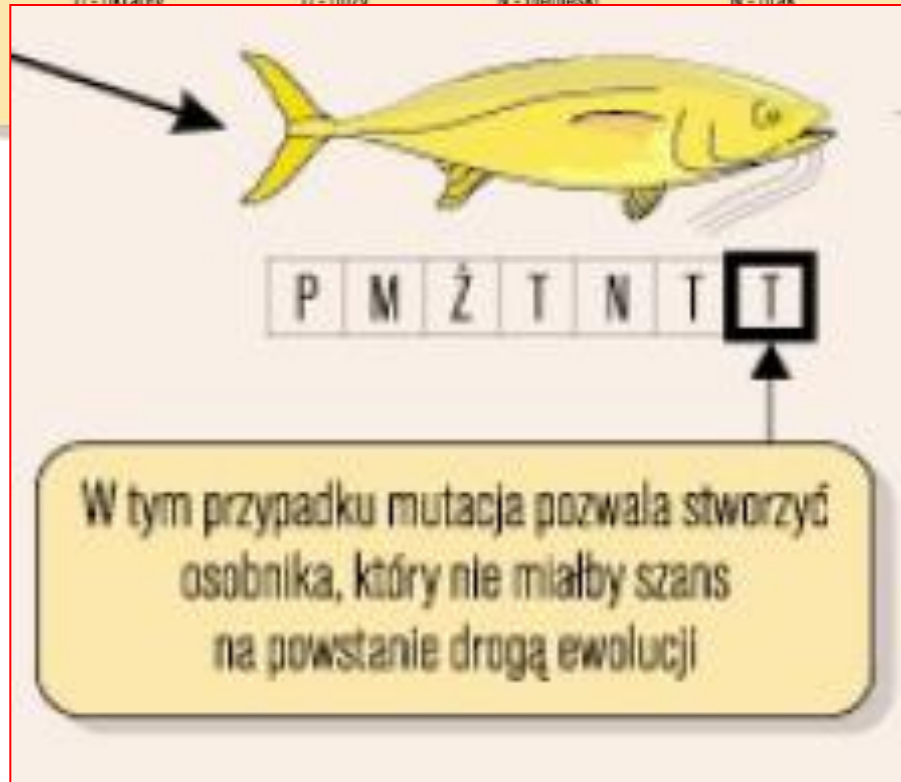
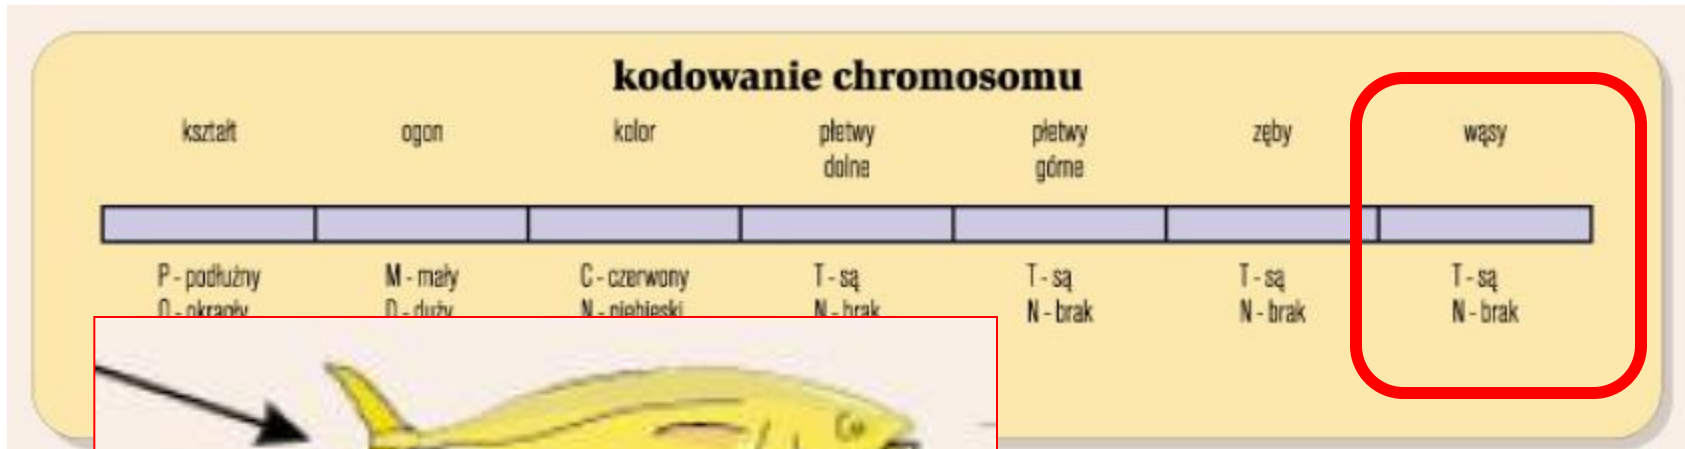
W tym przykładzie mutacja powstała stworzył osobnika, który nie miał szans na powodzenie drogą ewolucyjną

Przyjęciem do nowej populacji preferowane są ryby szybsze (podobnie z innymi organami), jaskrawe i szlachetne

Klucz genetyczny


Mutacja pozwala wytworzyć osobnika o cechach nieobecnych w populacji

Wynik mutacji w chromosomie i w zakresie właściwości ryby




Proces ewolucji

Populacja ryb



Krzyżowanie

(wybór miejsca wymiaru jest przypadkowy)



Populacja po krzyżowaniu i mutacji



Dwie osobniki tego typu pojawiły, bo były najlepiej przystosowane



Osobnik tego typu nie przetrwał, bo był najmniej przystosowany



W tym przykładzie mutacja powstała stworzył osobnika, który nie miał szans na powodzenie drogą ewolucyjną



Przyjęta została nowa populacja preferowana są ryby szybsze (podobnie z innymi organami), jasniejsze i szlachetne

Wyniki selekcji

Wyniki selekcji



P M C T T T N

Dwa osobniki tego typu przeszły, bo były najlepiej przystosowane



P D Z N T N N

kodowanie chromosomu

kształt ogon kolor pletwy dolne pletwy górne zęby wąsy



P - podłużny	M - mały	C - czerwony	T - są	T - są	T - są	T - są
O - okrągły	D - duży	N - niebieski	N - brak	N - brak	N - brak	N - brak
		Z - zielony				
		Ż - żółty				



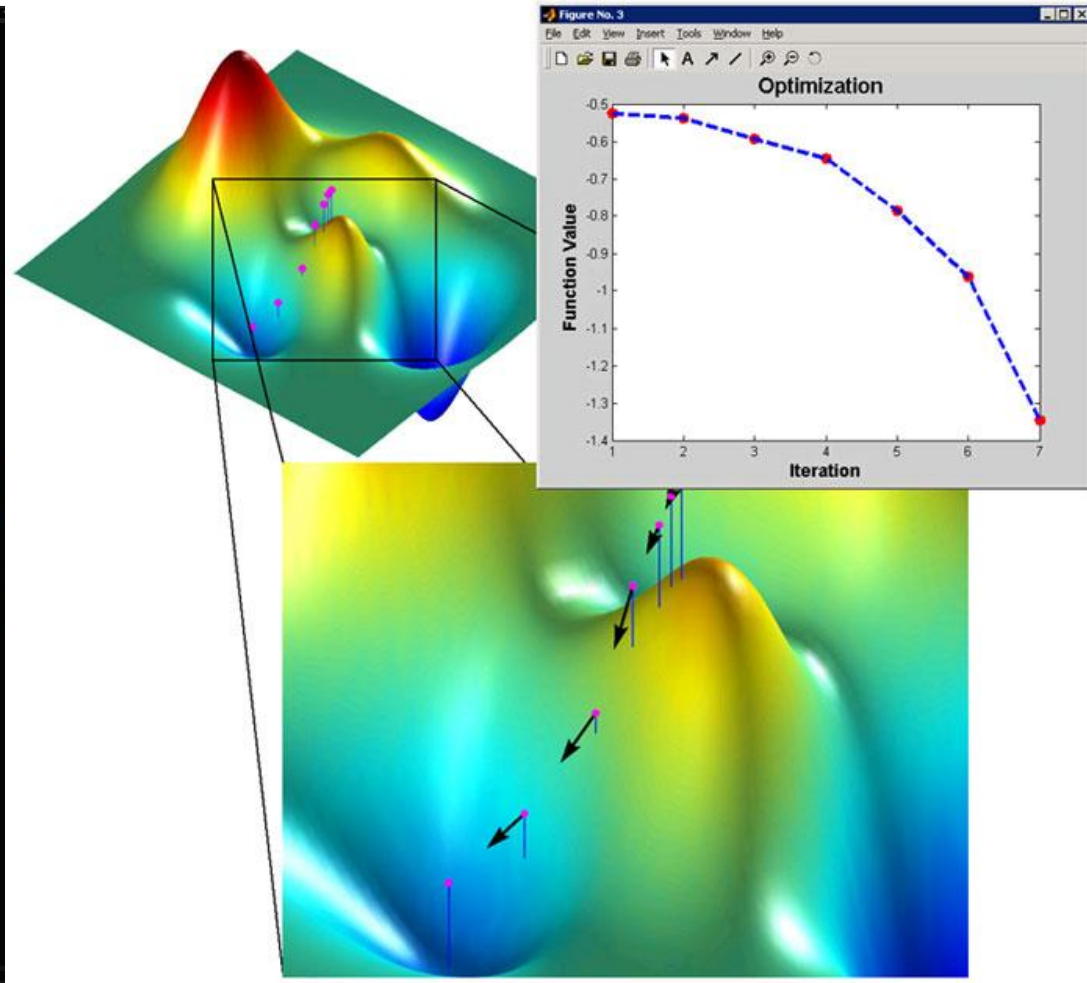

O D N N N N N

Osobnik tego typu nie przeszedł, bo był najgorzej przystosowany


Optymalizacja, wyznaczenie spośród dopuszczalnych rozwiązań danego problemu rozwiązania najlepszego za względu na przyjęte kryterium (wskaźnik) jakości (np. koszt, zysk, niezawodność).

Istnieje wiele metod optymalizacji, wśród których wyróżnić można metody ukierunkowanego poszukiwania optimum oraz metody poszukiwania przypadkowego.

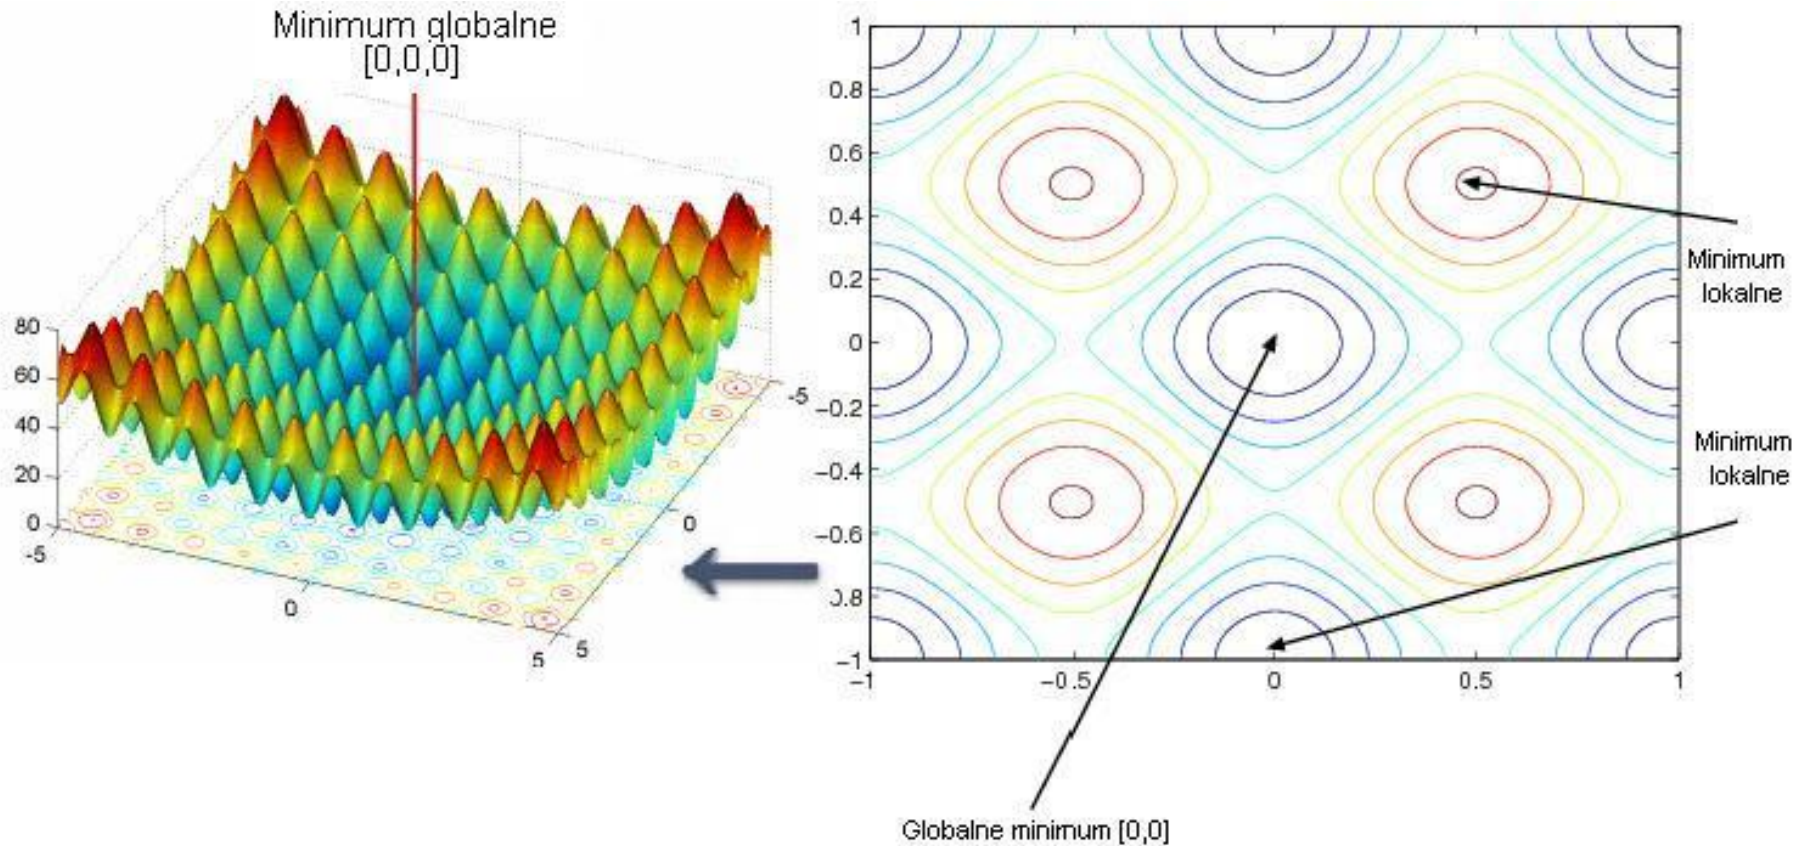
Poszukiwanie ukierunkowane zwykle oparte jest na jakiejś odmianie metody najszybszego spadku



Źródłem problemów przy ukierunkowanej optymalizacji są głównie ekstrema lokalne




Trudność znalezienia globalnego minimum



Przedstawiony na rysunku wykres tzw. funkcji Rastrigina obrazuje trudności jakie napotkać można przy poszukiwaniu optimum. Funkcja ta posiada wartość najmniejszą w punkcie $(0,0,0)$, jednak zanim algorytm przeszukiwania znajdzie to minimum globalne, może napotkać wiele minimów lokalnych.

Stochastyczne poszukiwanie rozwiązań nie gwarantuje sukcesu

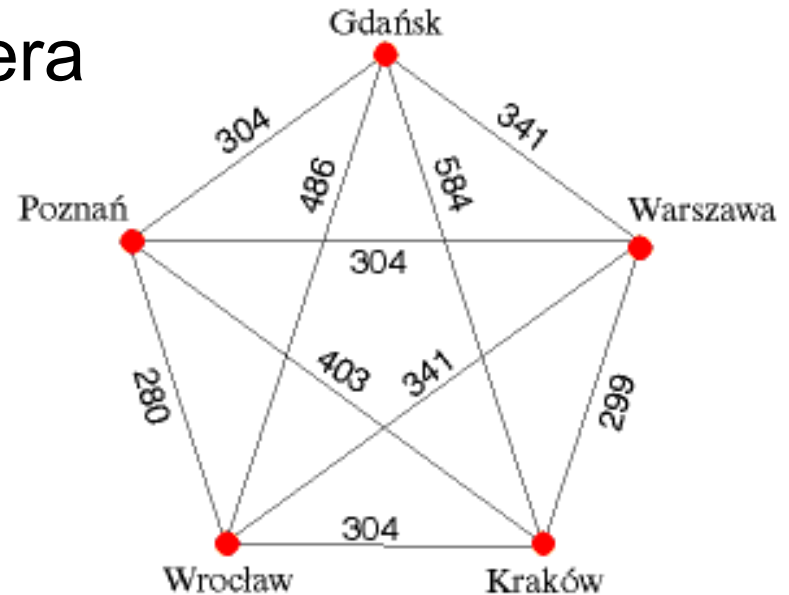


Od problemu minimów lokalnych wolne są
probabilistyczne metody optymalizacji

Rozwiązanie wielu problemów optymalizacji może zajmować bardzo dużo czasu

Przykład: Problem Komiwojażera


Czas potrzebny do rozwiązania problemu komiwojażera w zależności od ilości miast (przy założeniu, że komputer przetwarza **milion** instrukcji na sekundę)




Ilość miast	10	50	100	300
Czas [mikrosekundy]	$\sim 3,6 * 10^6$	$\sim 10^{16}$	$\sim 10^{31}$	$\sim 10^{623}$

Dla porównania – liczba mikrosekund od wielkiego wybuchu, w którym narodził się nasz Wszechświat jest rzędu 10^{24} .

Zaletą algorytmów genetycznych jest to, że jeśli rozważany problem ma **kilka rozwiązań** to zostaną one wszystkie znalezione




Na bazie tych
obserwacji
powstała
koncepcja, żeby
poszukiwaniami
optymalnego
rozwiązania
(uzyskiwanego
za pomocą
komputera)
kierował proces
ewolucji.



Metody ewolucyjne powstały i zostały rozwinięte w tym celu, żeby znajdować **przybliżone** rozwiązania problemów optymalizacyjnych w taki sposób, by znajdować wynik w miarę szybko oraz uniknąć pułapek minimów lokalnych

Obliczenia ewolucyjne powstały w wyniku kombinacji kilku elementów:



+



+

$$H\Psi(x, t) = i\hbar \frac{\partial \Psi(x, t)}{\partial t}$$

Rozwoju technik obliczeniowych

Postępu wiedzy o ewolucji biologicznej

Osiągnięć nowych teorii optymalizacji

Sposób działania algorytmu genetycznego można przedstawić następująco:

- 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.

Punktem wyjścia jest opisanie
rozważanego zadania
w kategoriach wektora
(najczęściej binarnego)
zwanego chromosomem.



Cecha
kodowana na
tej pozycji
nie występuje
w rozwiązaniu



Cecha
kodowana na
tej pozycji
występuje
w rozwiązaniu

Podstawowe definicje

Populacja – zbiór osobników o określonej liczebności,

Osobnicy populacji – zakodowane w postaci chromosomów zbiory parametrów zadania (punkty przestrzeni poszukiwań),

Chromosomy – łańcuchy (ciągi kodowe) – uporządkowane ciągi genów,

Gen – pojedynczy element genotypu,

Genotyp – struktura, zespół chromosomów danego osobnika,

Fenotyp – zestaw wartości odpowiadający danemu genotypowi,

Allel – długość genu,

Locus – pozycja wskazująca położenie danego genu w łańcuchu.

Operatory genetyczne

Krzyżowanie.

Polega na wymianie materiału genetycznego pomiędzy losowo dobranymi parami osobników wybranych podczas selekcji. W wyniku krzyżowania powstają nowe chromosomy, które wejdą w skład kolejnej populacji (pokolenia). Okazuje się, że chromosomy powstałe w wyniku krzyżowania często są lepiej przystosowane (mają większą wartość funkcji przystosowania) niż ich “rodzice”.

Krzyżowanie proste

Przy klasycznym rozmieszczeniu genów w chromosomie jest to operacja stosunkowo prosta. Jeśli mamy dwa chromosomy to wybieramy (losowo) miejsce, w którym je rozcinamy (oba w tym samym miejscu). Punkt rozcięcia to inaczej **punkt krzyżowania**. Po rozcięciu wymieniamy odcięte części. W ten sposób powstają dwa nowe chromosomy

Operatory genetyczne

Selekcja

Polega na wyborze z bieżącej populacji najlepiej przystosowanych osobników, których materiał genetyczny zostanie poddany operacji krzyżowania i przekazany osobnikom następnej populacji. Kryterium wyboru jest tu wartość funkcji przystosowania.

Mutacja (zachodząca zwykle z niewielkim prawdopodobieństwem)

Polega na zmianie wartości losowo wybranego genu. Zadaniem operatora mutacji jest zapewnienie zmienności chromosomów (np. niedopuszczenie do powstania całej populacji identycznych osobników) i tym samym stworzenie możliwości wyjścia procedury optymalizacji z maksimum lokalnych funkcji przystosowania.

Konstruowanie algorytmu genetycznego

Dla konstrukcji algorytmu genetycznego niezbędne jest określenie 6 składowych:

1. Genetycznej reprezentacji potencjalnych rozwiązań problemu ,
2. Funkcji oceniającej jakość rozwiązania,
3. Metody generowania populacji rozwiązań początkowych
4. Operatorów genetycznych zmieniających geny w chromosomach
5. Stałych parametrów charakteryzujących algorytm (rozmiaru populacji, prawdopodobieństwa zastosowanie operatorów genetycznych itp.)
6. Warunków zakończenia generowanie kolejnych populacji

Każdy przebieg algorytmu składa się z 3 kroków:

1. Liczony jest **wskaźnik przystosowania** dla osobników bieżącego pokolenia
2. Z populacji wybierane są losowo osobniki
Prawdopodobieństwo wyboru konkretnego osobnika jest tym większe, im większy jest jego wskaźnik przystosowania. Osobniki najlepiej przystosowane mogą zostać wybrane wielokrotnie, najslabsze – ani razu.
3. Na wybranych osobnikach używa się **operatorów genetycznych**. Od tego momentu stanowią one nową populację przetwarzaną w następnej iteracji.


Elementarny algorytm genetyczny

Elementarny algorytm genetyczny jest skonstruowany z trzech następujących operacji: Reprodukacja, Krzyżowanie, Mutacja

Reprodukacja to proces, w którym indywidualne ciągi kodowe zostaną powielone w stosunku zależnym od wartości, jakie przybiera dla nich funkcja celu f (funkcja przystosowania). Jest to inaczej pewien miernik zysku, który chcemy zmaksymalizować.

Krzyżowanie (proste) to proces polegający na losowym kojarzeniu ciągów z puli rodzicielskiej w pary, losowy wybór **punktu krzyżowania** ciągów oraz zamiany wszystkich znaków na prawo od punktu krzyżowania

Mutacja polega na sporadycznej zmianie elementu ciągu kodowego.



■ w z k s z e n i i
r u z k a w
i

punkt
krzyżowania

A1=	0	1	1	0	1
A2=	1	1	0	0	0


Ciągi skrzowane

A1'=	0	1	1	0	0
A2'=	1	1	0	0	1

A3=	0	1	1	0	1
A3'=	0	1	0	0	0

Powtórzenie: Operatory algorytmu genetycznego

1. Selekcja – np. koło ruletki



Elementy algorytmu:

1. Wybór (losowy) populacji początkowej
2. Ocena przystosowania
3. Selekcja chromosomów
4. Krzyżowanie
5. Mutacja

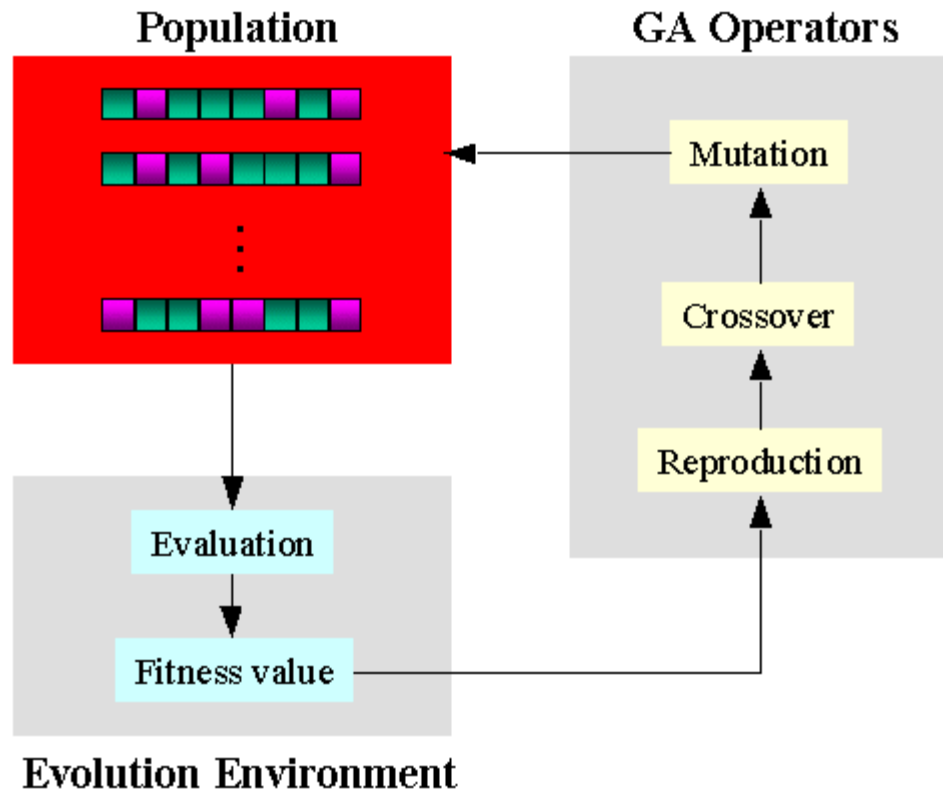
Schemat działania algorytmu genetycznego.

Zadanie:

Znaleźć maksimum funkcji $f(x)=x^2$, gdzie $x \in \langle 0;31 \rangle$

1. Wybieramy ciąg pięciobitowy umożliwiający operowanie na liczbach od 0 do 31.
2. Wybieramy losowo populację złożoną z czterech ciągów kodowych i liczymy wskaźnik dostosowania dla każdego ciągu.

Nr ciągu	Populacja początkowa (wygenerowana losowo)	Wartość x	$f(x)=x^2$	Wskaźnik przystosowania	Oczekiwana liczba kopii	Liczba kopii wygenerowanych wg reguły ruletki
1	0 1 1 0 1	13	169	0,14	0,58	1
2	1 1 0 0 0	24	576	0,49	1,97	2
3	0 1 0 0 0	8	64	0,06	0,22	0
4	1 0 0 1 1	19	361	0,31	1,23	1
Suma			1170	1,00	4,00	4
Średnia			293	0,25	1,00	1
Maksimum			576	0,49	1,97	2



Genetic Algorithm Evolution Flow

Przykładowy sposób zastosowania operatora krzyżowania:

Osobniki rodzicielskie:




Osobniki potomne:



Działanie operatora krzyżowania:

- a) krzyżowanie jednopunktowe (*one-point crossover*),
- b) krzyżowanie dwupunktowe (*two-point crossover*).



Działanie operatora mutacji

Mutowana
pozycja

1 0 1 1 0 0 1


przed mutacją

1 0 0 1 0 0 1

po mutacji

Przykładowy sposób zastosowania operatora mutacji


Osobnik rodzicielski:




Osobnik potomny:




Mutacje mogą także przyjmować bardziej skomplikowane formy:




(a) Replacement




(b) Random swap




(c) Adjacent swap



(d) End-for-end swap




(e) Inversion



(f) Deletion

Porównanie skutków krzyżowania i mutacji



W przypadku algorytmów genetycznych można mówić o dwóch typach interpretacji populacji:
podejściu typu Michigan i Pittsburg.

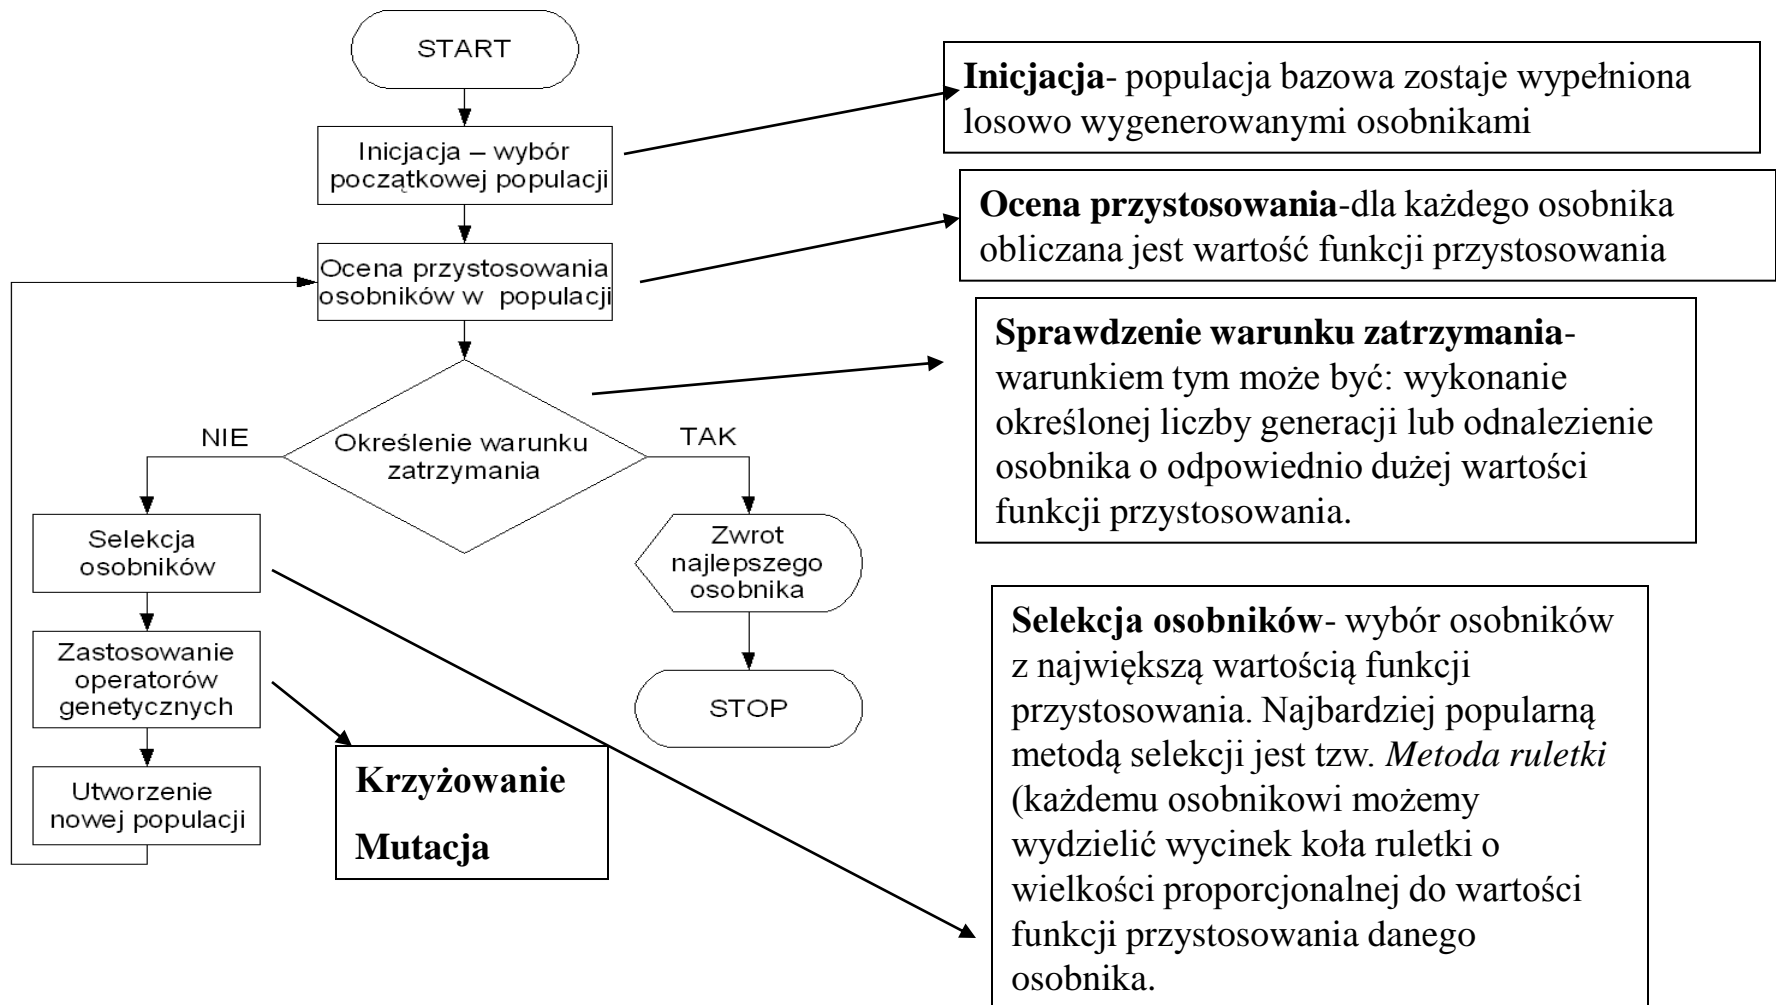
W podejściu Michigan wszystkie osobniki są traktowane jako jednostki (oceniane są poszczególne osobniki).

Poszczególne osobniki w populacji rywalizują ze sobą, chcąc przetrwać.

Natomiast w podejściu Pittsburg całą populację traktuje się jako jednostkę, która podlega działaniu operatorów genetycznych (oceniana jest cała populacja). W tym przypadku można dopatrzeć się wzajemnej współpracy osobników w celu wykształcenia jak najlepszej społeczności.

Obie interpretacje mają swoje uzasadnienie i można pokazać problemy, w których warto zastosować albo jedno, albo drugie podejście.

Schemat blokowy działania AG



Szczegółowy przebieg rozwiązywania problemu przez algorytm genetyczny nie jest możliwy do przewidzenia


A general spatial search type of Genetic Algorithm solution



Przykład
zastosowania
algorytmu
genetycznego
do prognozowania
notowań giełdy




Efekt działania algorytmu genetycznego jest taki, że jakość rozwiązania w kolejnych pokoleniach jest coraz lepsza




Proces doskonalenia nie przebiega w sposób ciągły, gdyż zmiany genetyczne muszą często podlegać kumulacji zanim dadzą zauważalny efekt


Zachowanie małej populacji (500) przy niewielkiej złożoności rozwiązywanego zadania (multiplexer 6 wejściowy)




Zachowanie dużej populacji (2000) przy niewielkiej złożoności rozwiązywanego zadania (multiplexer 6 wejściowy)



Zachowanie małej populacji (500) przy dużej złożoności rozwiązywanego zadania (multiplexer 11 wejściowy)



Zachowanie dużej populacji (2000) przy dużej złożoności rozwiązywanego zadania (multiplexer 11 wejściowy)



Sztuczne życie (*AL- Artificial Life*)

to dziedzina nauki, która zajmuje się badaniem zjawisk życia, symulowaniem procesów biologicznych oraz tworzeniem systemów opartych na zachowaniach charakterystycznych dla naturalnych żywych organizmów.

W 1968 roku brytyjski
matematyk John Conway
stworzył Grę w Życie
(*Game of Life*)

273.73 FPS




12.00 IPS

0 # 302



Zapisz tablicę [Ctrl+S]



100 %



1024 x 768 @ 100