

# WYKŁAD 11

## Algorytmy ewolucyjne

### PLAN WYKŁADU

- Zasady konstruowania algorytmów ewolucyjnych
- Algorytmy genetyczne
  - schemat ogólny
  - operatory genetyczne
- Parę słów o teorii
- Strategie ewolucyjne


## PODSTAWOWE POJĘCIA

**Osobnik** - podstawowa jednostka podlegająca ewolucji. Zakładamy zwykle, że ów osobnik przebywa w pewnym **środowisku**, do którego może być lepiej lub gorzej przystosowany. "Celem" ewolucji jest stworzenie osobnika możliwie dobrze przystosowanego do danego środowiska.

**Fenotyp** - ujawniające się "na zewnątrz" cechy danego osobnika.

**Genotyp** - "plan konstrukcyjny", kompletny i jednoznaczny opis osobnika zawarty w jego genach.


**Populacja** - zespół osobników zamieszkujących wspólnie środowisko i konkurujących o jego zasoby.



## PODSTAWOWE ZASADY

- **Genotyp danego osobnika w czasie jego życia nie ulega zmianie**, natomiast ulega on modyfikacjom podczas rozmnażania się. Zmiany te mogą wynikać albo z niewielkich, losowych **mutacji**, albo ze zmieszania (**skrzyżowania**) cech osobników rodzicielskich.
- **Zmiany w genotypie powodują zmiany fenotypu** osobników potomnych, co wpływa na stopień ich przystosowania do środowiska. Zmiany fenotypu (nabyte) nie podlegają dziedziczeniu w sensie genetycznym.
- **Zmiany w genotypie mają charakter przypadkowy**. Zmiany korzystne dla osobnika zdarzają się równie często, jak niekorzystne lub obojętne.
- **Osobniki są oceniane poprzez porównanie ich przystosowania do danego środowiska**. Te, które są lepiej przystosowane, mają większą szansę rozmnożyć się. Osobniki gorzej przystosowane przegrywają konkurencję o ograniczone zasoby środowiska i giną.

## ZASTOSOWANIE: PROBLEMY OPTYMALIZACYJNE



*Zmianom (mutacja, krzyżowanie) podlega genotyp osobnika, podczas gdy selekcji poddawane są fenotypy. Istotą ewolucji jest połączenie zjawiska losowych, nieukierunkowanych zmian genotypu ze ściśle ukierunkowaną presją środowiska na fenotyp.*

## HISTORIA

1958, 1964 (Friedberg, Fogel) - **programowanie ewolucyjne** automatów skończonych.

1965 (Bienert, Rechenberg, Schwefel) - **strategie ewolucyjne**, zastosowania praktyczne.

1975 (Holland) - **algorytmy genetyczne** i ich teoria.

Lata 80-te - liczne zastosowania algorytmów genetycznych.

Koniec lat 80-tych (Fogel) - współczesna wersja programowania ewolucyjnego.



- Z. Michalewicz. *Algorytmy genetyczne + struktury danych = programy ewolucyjne*.
- D.E. Goldberg. *Algorytmy genetyczne i ich zastosowania*. WNT, Warszawa 1995.
- J.R. Koza. *Genetic Programming: On the Programming of Computers by Means of the Natural Selection*. The MIT Press, 1992.


# ALGORYTM GENETYCZNY

Cel: znaleźć maksimum funkcji  $f(x)$ .  
Założenie: funkcja ta jest  dodatnia.

1. Tworzymy  $N$  osobników losowych.

$N$


2. Stosujemy operacje mutacji i krzyżowania



3. Liczymy wartości funkcji celu.

$f(x)$   
...  
...  
 $f(x)$

4. Dokonujemy selekcji.



*Osobnik:*  
*ciąg zerojedynkowy*

5. Powtarzamy od punktu 2.

## SCHEMAT DZIAŁANIA (1)

### Etap wstępny: kodowanie problemu

Osobnik – ciąg binarny stałej długości.

Aby rozwiązać konkretne zadanie, musimy zakodować przestrzeń stanów (czyli wszystkie potencjalne rozwiązania) w języku binarnym.

Jeżeli zadanie polega na znalezieniu maksimum jakiejś funkcji, możemy owej funkcji użyć jako stopnia przystosowania osobnika do środowiska. Często musimy sami taką funkcję skonstruować.

### Drugi krok algorytmu: mutacje i krzyżowania


**Mutacja:** losujemy osobnika, następnie jeden z jego bitów. Zamieniamy wartość tego bitu na przeciwną. Mutacja dotyka średnio 0.1% bitów w populacji.

↓  
100100110010    ⇒    100101110010

## SCHEMAT DZIAŁANIA (2)

### Krzyżowanie (*crossing-over*)

Łączymy osobniki w pary. Dla każdej pary ustalamy (w drodze losowania, prawdopodobieństwo rzędu 20-50%), czy dojdzie do ich skrzyżowania. Jeśli tak, losujemy miejsce (bit) w chromosomie jednego z rodziców, po czym zamieniamy miejscami fragmenty chromosomów poczynając od wylosowanego miejsca.




## SCHEMAT DZIAŁANIA (3)

### Czwarty krok algorytmu: selekcja

Liczmy wartości funkcji celu osobników. Następnie, spośród  $N$  osobników populacji pośredniej losujemy  $N$  osobników populacji końcowej (z powtórzeniami), za pomocą algorytmu "koła ruletki":

1. Liczymy sumę wartości funkcji celu:  $f_{\text{sum}} = f(x_1) + \dots + f(x_N)$ .
2. Liczymy wkład każdego osobnika w sumę:  $p(x_i) = f(x_i) / f_{\text{sum}}$
3. Dokonujemy  $N$ -krotnego losowania osobników zgodnie z rozkładem  $p(x_i)$ .



## TEORIA

- **Schematy:** ciągi typu  $100^{**}1^{*}1^{**}$  (gwiazdka oznacza „cokolwiek”)
- **Twierdzenie o schematach:** jeśli schemat odpowiada osobnikom średnio lepszym niż inne, to jego reprezentanci są coraz liczniejsi (wzrost wykładniczy) w miarę trwania ewolucji
- **Ukryta równoległość:** w jednym kroku badamy niewiele osobników, jednak każdy z nich odpowiada wykładniczo wielu różnym schematom
- **Hipoteza o cegiełkach:** jeśli rozwiązanie zadania może być skonstruowane z silnych, krótkich schematów, wówczas algorytm genetyczny ma szansę łatwo je znaleźć

## MOCNE STRONY

- **Metoda jest uniwersalna.** Aby tego samego programu użyć w innym problemie, przeważnie wystarczy zmienić funkcję celu.
- Algorytmy ewolucyjne potrafić poradzić sobie również tam, gdzie optymalizowana funkcja jest zaszumiona, zmienia się w czasie, ma wiele ekstremów lokalnych.
- Aby znaleźć rozwiązanie, nie musimy prawie nic wiedzieć o optymalizowanej funkcji (“czarna skrzynka”).
- **Metoda jest szybka:** znalezienie rozwiązania często jest możliwe po przejrzaniu zaskakująco niewielkiej części przestrzeni stanów.
- Ponieważ algorytm genetyczny jest algorytmem randomizowanym, możemy powtarzać obliczenia wielokrotnie w nadziei otrzymania lepszych wyników.

## SŁABE STRONY


- Metoda jest uniwersalna, więc nie tak skuteczna, jak bywają algorytmy specjalizowane (*rada: stosować algorytmy hybrydowe*).
- Sukces jest możliwy wyłącznie przy prawidłowym zakodowaniu problemu i odpowiednim dobraniu funkcji celu. Niestety, nie ma jednoznacznej teorii mówiącej, jak to robić. Jest to często - podobnie jak dobór parametrów mutacji i krzyżowania - sprawa wyczucia i doświadczenia programisty (*rada: nabierać doświadczenia!*).
- Ponieważ algorytm genetyczny jest algorytmem randomizowanym, nigdy nie mamy pewności, że znaleźliśmy rozwiązanie optymalne (*rada: zadowolić się rozwiązaniem przybliżonym*).

## STRATEGIE EWOLUCYJNE

*Inna - obok algorytmów genetycznych - popularna metoda ewolucyjna. Główny obszar zastosowań: optymalizacja funkcji rzeczywistych wielowymiarowych.*


**Zadanie:** znaleźć maksimum funkcji  $f: R^n \rightarrow R$  na danym przedziale  $[a_1, b_1] \times \dots \times [a_n, b_n]$ .

**Rozwiązanie:** przez  $\mathbf{x}=(x_1, \dots, x_n)$  oznaczmy przykładowe rozwiązanie (punkt z przestrzeni stanów,  $x_i \in [a_i, b_i]$ ). Każdemu wektorowi  $\mathbf{x}$  przyporządkujemy pomocniczy wektor wartości rzeczywistych dodatnich:  $\sigma=(\sigma_1, \dots, \sigma_n)$ . Para  $(\mathbf{x}, \sigma)$  będzie stanowiła kod genetyczny osobnika.



## SCHEMAT DZIAŁANIA

1. Tworzymy losową populację złożoną z  $N$  osobników postaci  $(\mathbf{x}, \sigma)$ .
2. Dopisujemy do niej  $M$  osobników potomnych, tworzonych na podstawie losowo wybranych osobników z poprzedniego pokolenia za pomocą mutacji i krzyżowania.
3. Dla każdego osobnika w populacji pośredniej liczymy wartość optymalizowanej funkcji.
4. Spośród  $N+M$  osobników wybieramy  $N$  najlepszych względem  $f(\mathbf{x})$ . Te osobniki przeżyją i utworzą następne pokolenie.
5. Powtarzamy od punktu 2. z aktualną populacją  $N$ -osobnikową.



## OPERATORY

**Mutacji** podlegają zwykle wszystkie osobniki dodawane do populacji pośredniej. Mutacja polega na zmianie parametrów  $(\mathbf{x}, \sigma)$  zgodnie ze wzorami:

$$\sigma_i = \sigma_i \cdot e^{N(0, \Delta)}$$

$$x_i = x_i + N(0, \sigma_i)$$

gdzie  $N(0, \sigma)$  oznacza liczbę losową wygenerowaną zgodnie z rozkładem normalnym o wart. oczekiwanej 0 i odchyleniu standardowym  $\sigma$ .

**Krzyżowaniu** podlega część (np. 25%) osobników dodawanych do populacji pośredniej. Osobnik potomny składany jest z genów dwóch losowo wybranych osobników rodzicielskich.

$(x_1, x_2, x_3, x_4, x_5, \sigma_1, \sigma_2, \sigma_3, \sigma_4, \sigma_5)$

$(x_1, y_2, y_3, x_4, y_5, \sigma_1, \tau_2, \tau_3, \sigma_4, \tau_5)$

$(y_1, y_2, y_3, y_4, y_5, \tau_1, \tau_2, \tau_3, \tau_4, \tau_5)$

**Uwaga:** wartości  $x_i$  są dziedziczone zawsze razem z odpowiadającymi im wartościami pomocniczymi  $\sigma_i$ .