

# Metody Rozmyte i Algorytmy Ewolucyjne

mgr inż. Piotr Kaczyński

Wydział Matematyczno-Przyrodniczy  
Szkoła Nauk Ścisłych  
Uniwersytet Kardynała Stefana Wyszyńskiego

Strategie ewolucyjne  
Podstawowe operatory genetyczne

# Plan wykładu

- 1 Przypomnienie
  - Metody generacji liczb losowych
  - Schemat algorytmu ewolucyjnego
- 2 Ciągłe operatory genetyczne
  - Mutacja
  - Krzyżowanie
  - Inicjacja
- 3 Strategie ewolucyjne
  - Strategia  $(1 + 1)$
  - Strategia  $(\mu + \lambda)$
  - Strategia  $(\mu, \lambda)$

# Generacja liczb losowych w komputerze

- Liczby są tylko **pseudolosowe**,
- Dostępny jest tylko generator liczb z rozkładu jednostajnego,
- Korzystając z tego generatora można wygenerować pozostałe rozkłady,
- Dla rozkładów dyskretnych podział odcinka  $(0, 1)$ ,
- Dla rozkładów ciągłych wykorzystujemy metodę **odwrotności dystrybuanty**



# Dystrybuanta i gęstość zmiennej losowej

## Definition

**Dystrybuantą** rozkładu zmiennej losowej  $X = [X_1, \dots, X_n]^T$  nazywamy funkcję  $F: \mathbb{R}^n \rightarrow \mathbb{R}$  daną wzorem

$$F(x_1, \dots, x_n) = P(X_1 < x_1, \dots, X_n < x_n)$$

## Definition

**Gęstością** rozkładu zmiennej losowej  $X = [X_1, \dots, X_n]^T$  nazywamy funkcję  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  daną wzorem

$$f(x_1, \dots, x_n) = F'(x_1, \dots, x_n)$$



## Rozkłady dyskretne

- Przyjmują wartości ze skończonego zbioru liczb  $x_1, \dots, x_n$ ,
- Każda wartość ma przyporządkowane prawdopodobieństwo  $p_1, \dots, p_n$ ,
- Oczywiście  $\sum_{i=1}^n p_i = 1$ ,
- Metoda generacji liczb z rozkładu dyskretnego
  - Każdej wartości  $x_k$  przyporządkuj liczbę

$$F(x_k) = \sum_{i=1}^k p_i$$

- Wylosuj liczbę  $u$  z rozkładu jednostajnego,
- Znajdź najmniejsze takie  $k$ , dla którego  $u \leq F(x_k)$ ,
- Zwróć znalezione  $x_k$



# Generacja liczb z rozkładu dyskretnego

## Przykład

Niech dany będą liczby  $x_1 = 2$ , której prawdopodobieństwo wypadnięcia jest  $p_1 = \frac{1}{3}$ ,  $x_2 = 7$  dla której prawdopodobieństwo wynosi  $p_2 = \frac{1}{2}$  oraz  $x_3 = 9$ , dla której  $p_3 = \frac{1}{6}$ . Mamy

$$F(x_1) = \frac{1}{3}$$

$$F(x_2) = \frac{5}{6}$$

$$F(x_3) = 1$$

Jeśli z rozkładu jednostajnego na  $(0, 1)$  wylosujemy np.  $\frac{1}{4}$  to z modelowanego rozkładu zwrócimy  $x_1 = 2$ . Jeśli rozkład jednostajny zwróci na przykład  $\frac{3}{4}$  to my zwrócimy  $x_2 = 7$  itd.



# Metoda odwrotności dystrybuanty

## Theorem

*Niech  $U$  będzie zmienną losową o rozkładzie jednostajnym na odcinku  $[0, 1]$ . Niech ponadto  $F(x)$  będzie dystrybuantą pewnej zmiennej losowej  $X$  dla której istnieje funkcja odwrotna  $F^{-1}(y)$ . Wtedy zmienna*

$$Y = F^{-1}(U)$$

*ma rozkład identyczny z rozkładem zmiennej  $X$ .*

- Jeśli można policzyć funkcję odwrotną do zadanej dystrybuanty, to można generować liczby z tego rozkładu,
- Nie we wszystkich przypadkach da się znaleźć taką funkcję,





# Rozkład jednostajny

- Gęstość i dystrybuanta rozkładu na odcinku  $[a, b]$ ,

$$f(x) = \frac{1}{b-a} \quad \text{dla } x \in [a, b]$$

$$F(x) = \frac{1}{b-a}x \quad \text{dla } x \in [a, b]$$





## Rozkład jednostajny — metoda generacji

- Jeśli  $U$  ma rozkład jednostajny na odcinku  $[0, 1]$ , to

$$Y = (b - a)U + a$$

ma rozkład jednostajny na odcinku  $[a, b]$

### Przykład

Generacja liczb losowych z odcinka  $[7, 10]$

```
u = rand();  
y = (10-7)*u + 7;  
return y;
```




# Rozkład normalny


- Gęstość dla  $E[X] = \mu$ ,  $Var[X] = \sigma^2$

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

- Dystrybuanta nie da się wyrazić analitycznie



# Dwuwymiarowy rozkład normalny



# Generacja liczb ze std. rozkładu normalnego

- Standardowy rozkład normalny:  $\sigma = 1, \mu = 0,$
- Transformata Boxa-Mullera,

## Theorem

*Jeśli  $U_1$  oraz  $U_2$  są niezależnymi zmiennymi losowymi o rozkładzie jednostajnym na  $[0, 1)$ , to*

$$Y_1 = \sqrt{-2\ln U_1} \cos(2\pi U_2)$$

$$Y_2 = \sqrt{-2\ln U_1} \sin(2\pi U_2)$$

*są niezależne i mają standardowy rozkład normalny*

- Aby wygenerować wielowymiarowy, nieskorelowany rozkład normalny wystarczy kilkakrotnie wygenerować wartość z jednowymiarowego rozkładu normalnego/



# Generacja liczb z rozkładu normalnego

- Korzystamy z własności wartości oczekiwanej i wariancji,

$$E[aX] = aE[X]$$

$$\text{Var}[aX] = a^2 \text{Var}[X]$$

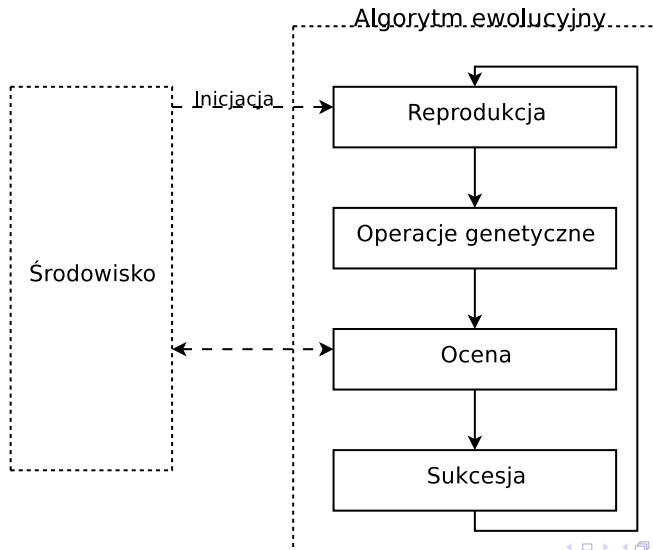
- Aby wygenerować liczbę z rozkładu normalnego o  $\mu$  oraz  $\sigma$  wystarczy wzór

$$Y = \sigma\xi + \mu$$

gdzie  $\xi$  ma standardowy rozkład normalny



# Schemat algorytmu ewolucyjnego



# Etapy algorytmu

- **Inicjacja** — proces tworzenia nowych osobników, inicjowania ich chromosomów i obliczania funkcji przystosowania,
- **Reprodukcja** — kopiowanie osobników z uwzględnieniem wartości funkcji przystosowania,
- **Operacje genetyczne** — mutacja (jeden osobnik) i krzyżowanie (wiele osobników),
- **Ocena** — obliczenie funkcji przystosowania dla nowych osobników,
- **Sukcesja** — wybór odpowiednich osobników do następnej epoki,



# Zadanie rzeczywistoliczbowe

- Poprzednio rozważano chromosomy z genami binarnymi,
- Krzyżowanie wymieniające,
- Mutacja zmieniająca bit na przeciwny,
- **Co zrobić w przypadku chromosomów  $x \in \mathbb{R}^n$  ?**
- Wprowadzamy inne operatory krzyżowania i mutacji



# Mutacja rozkładem normalnym

- Mutacja jest losowym zaburzeniem genów,
- Losowa modyfikacja rozkładem normalnym

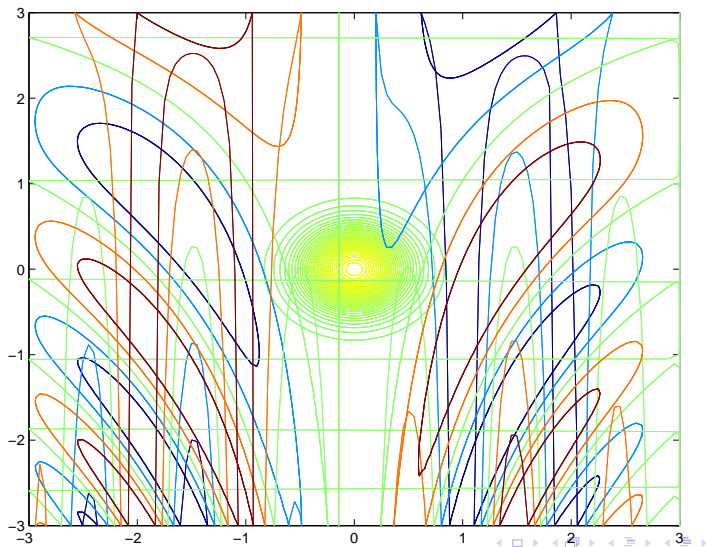
$$Y_i = X_i + \sigma \xi_i$$

gdzie  $Y_i$  to  $i$ -ty gen po mutacji,  $X_i$  jest  $i$ -tym genem przed mutacją,  $\xi$  to zmienna losowa o standardowym rozkładzie normalnym,

- Parametr  $\sigma$  modyfikuje **zasięg** mutacji,
- Małe zmiany są bardziej prawdopodobne niż duże,
- Losowanie odbywa się dla **każdego genu osobno**.



# Mutacja rozkładem normalnym II



## Krzyżowanie uśredniające

- Krzyżowanie dwuosobnikowe,
- Powstaje jeden osobnik, który jest średnią z obu rodziców

$$Y = \lambda X^1 + (1 - \lambda)X^2$$

gdzie  $Y$  osobnik potomny,  $X^1$  oraz  $X^2$  osobniki rodzicielskie, natomiast  $\lambda$  jest zmienną losową o rozkładzie jednostajnym na  $(0, 1)$ ,

- Osobnik potomny leży w losowym punkcie **odcinka** łączącego osobniki rodzicielskie,
- Zakładamy intuicyjnie, że pomiędzy dwoma dobrymi rozwiązaniami leży trzecie, jeszcze lepsze,
- Bardzo dobry do funkcji wypukłych,



# Inicjacja w $\mathbb{R}^n$

- Problem: przestrzeń  $\mathbb{R}^n$  jest nieskończonej miary,
- W praktyce: ograniczamy przestrzeń w której mogą znaleźć się początkowo osobniki,
- Najczęściej ograniczenia kostkowe

## Przykład

Jeśli założymy, że początkowo każdy gen ma spełniać

$$a \leq x_i \leq b$$

to każdy gen w każdym chromosomie należy wybrać z rozkładem jednostajnym na odcinku  $[a, b]$ ,



# Wstęp

- Jedno z najstarszych podejść do algorytmów genetycznych,
- Stosują typowe operatory krzyżowania i mutacji,
- Są działającymi i sprawdzonymi algorytmami genetycznymi,
- Nie trzeba dobierać każdego operatora z osobna



# Strategia (1 + 1)

- Pierwsza strategia ewolucyjna,
- Przetwarza tylko **jednego** osobnika z jednym chromosomem,
- Brak krzyżowania,
- Mutacja z zaburzeniem rozkładem normalnym

$$Y_i = X_i + \sigma\xi_i$$

- Zasięg mutacji zmienny w czasie — reguła 1/5 sukcesów



## Schemat strategii (1 + 1)

- $t = 0$
- inicjacja  $X^t$
- Ocena  $X^t$
- while not warunek stopu do
  - $Y^t = \text{mutacja } X^t$
  - ocena  $Y^t$
  - if  $f(Y^t) > f(X^t)$  then
    - $X^{t+1} = Y^t$
  - else
    - $X^{t+1} = X^t$
- $t = t + 1$



## Reguła 1/5 sukcesów

- Reguła stosowana do zmiany parametru  $\sigma$ ,
- Jeśli przez kolejnych  $k$  generacji liczba mutacji zakończonych sukcesem jest większa niż 1/5 ogólnej liczby wykonanych mutacji, to należy zwiększyć zasięg mutacji

$$\sigma' = c_i \sigma, \quad c_i > 1$$

- Gdy dokładnie 1/5 mutacji kończy się sukcesem, wartość  $\sigma$  pozostaje ta sama,
- W przeciwnym wypadku należy zawęzić zasięg mutacji

$$\sigma' = c_p \sigma, \quad c_p < 1$$

- **Adaptacja mutacji pozwala na dokładniejsze przeszukiwanie optimów lokalnych**





# Strategia $(\mu + \lambda)$

- Jedna z najczęściej wykorzystywanych w praktyce,
- Uogólnienie strategii  $(1 + 1)$ , rozważana jest **populacja osobników**,
- Samoczynny mechanizm adaptacji zastępujący regułę  $1/5$  sukcesów,
- Wprowadzono operator krzyżowania,
- Kodowanie osobników **dwuchromosomowe**
  - Chromosom  $X$  z rozwiązaniem zadania,
  - Chromosom  $\sigma$  z wariancjami dla mutacji poszczególnych genów,



# Schemat strategii $(\mu + \lambda)$

- $t = 0$
- Inicjacja  $P^t$
- Ocena  $P^t$
- while not warunek stopu do
  - $T^t =$  reprodukcja  $P^t$
  - $O^t =$  krzyżowanie i mutacja  $T^t$  ( $\lambda$  osobników)
  - ocena  $O^t$
  - $P^{t+1} = \mu$  najlepszych osobników z  $P^t \cup O^t$
  - $t = t + 1$



# Mutacja

- Losowana jest wartość  $\psi$  ze standardowego rozkładu normalnego,
- Każdy element chromosomu wariancji  $\sigma$  jest modyfikowany wg wzoru

$$\sigma'_i = \sigma_i \exp(\tau' \psi + \tau \xi_i)$$

gdzie  $\xi$  jest zmienną losową o standardowym rozkładzie normalnym, a  $\tau$  i  $\tau'$  są parametrami,

- Mutowany jest chromosom  $X$  przy użyciu chromosomu wariancji  $\sigma$

$$X'_i = X_i + \sigma'_i \xi_i$$

gdzie  $\xi_i \sim N(0, 1)$

- Typowe wartości parametrów  $\tau$  oraz  $\tau'$  to

$$\tau = \frac{K}{\sqrt{2n}}, \quad \tau' = \frac{K}{\sqrt{2\sqrt{n}}}$$



# Krzyżowanie i reprodukcja

- Krzyżowanie uśredniające z zastosowaniem tego samego współczynnika dla wszystkich chromosomów
- Dwa osobniki potomne i dwa rodzicielskie

$$X'^1 = \rho X^1 + (1 - \rho) X^2$$

$$X'^2 = \rho X^2 + (1 - \rho) X^1$$

$$\sigma'^1 = \rho \sigma^1 + (1 - \rho) \sigma^2$$

$$\sigma'^2 = \rho \sigma^2 + (1 - \rho) \sigma^1$$

$$\rho \sim U(0, 1)$$

- Reprodukcja — proste losowanie  $\lambda$  osobników ze zwracaniem wśród  $\mu$  osobników populacji bazowej



# Strategia $(\mu, \lambda)$

- Modyfikacja strategii  $(\mu + \lambda)$ ,
- Problemy z bardzo silnymi osobnikami,
- Osobniki takie „nie umierają”,
- Wpływa to na stagnację populacji
- Każdy osobnik w strategii  $(\mu, \lambda)$  żyje dokładnie jedną epokę



# Schemat strategii $(\mu, \lambda)$

- $t = 0$
- Inicjacja  $P^t$
- Ocena  $P^t$
- while not warunek stopu do
  - $T^t =$  reprodukcja  $P^t$
  - $O^t =$  krzyżowanie i mutacja  $T^t$  ( $\lambda$  osobników)
  - ocena  $O^t$
  - $P^{t+1} = \mu$  najlepszych osobników z  $O^t$
  - $t = t + 1$

