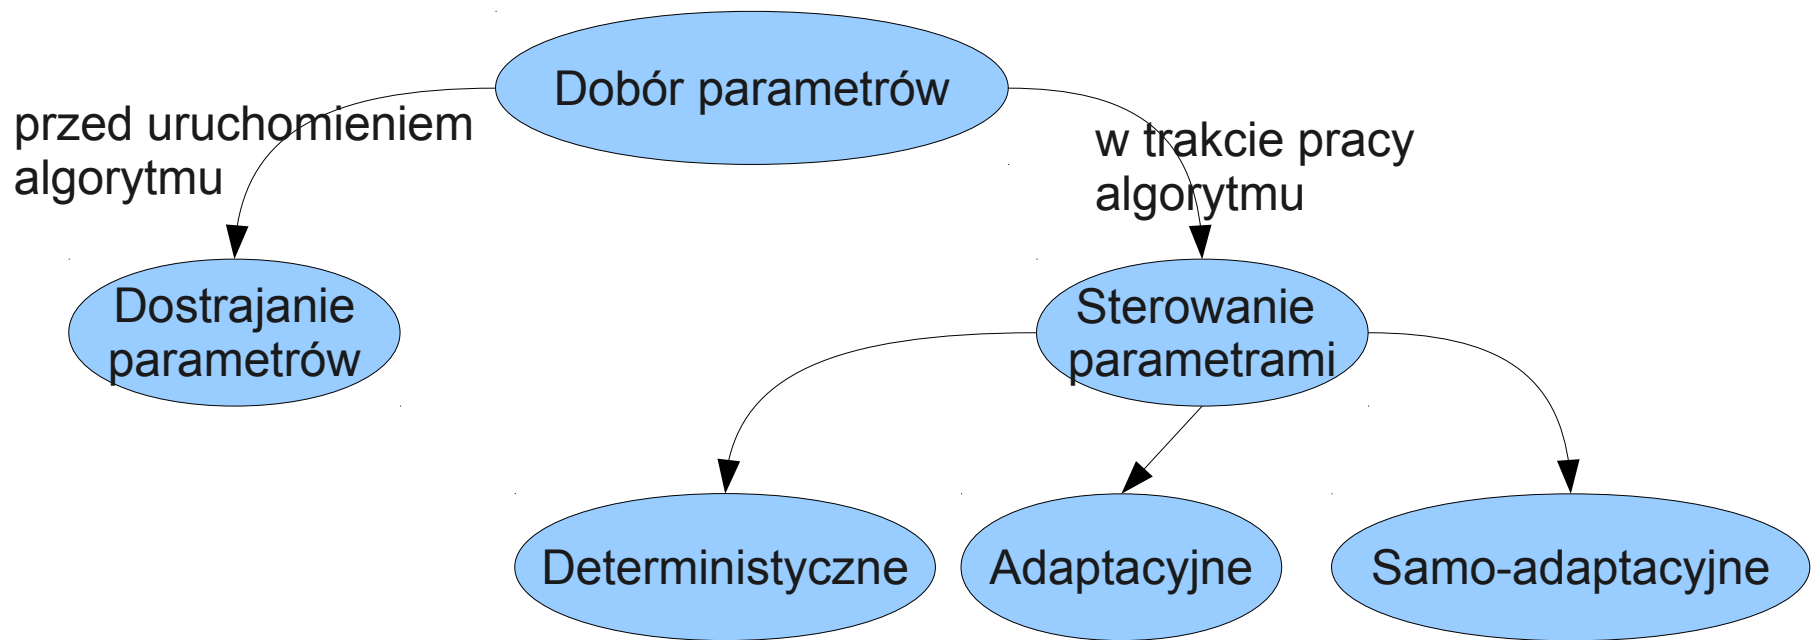


# Dobór parametrów algorytmu ewolucyjnego

# Wstęp

- Algorytm ewolucyjny posiada wiele parametrów. Przykładowo dla algorytmu genetycznego są to:
  - prawdopodobieństwa stosowania operatorów mutacji i krzyżowania.
  - operatory mutacji i krzyżowania.
  - algorytm selekcji (i jego parametry, np. współczynnik skalowania, rozmiar turnieju)
  - rozmiar populacji.
- Dobór parametrów algorytmu ma duży wpływ na jakość odnajdywanych rozwiązań.
  - Wykazały to wczesne badania eksperymentalne mające za zadanie znalezienie parametrów „optymalnych” zestawów parametrów dla wszystkich problemów.
  - Różni autorzy używali różnych problemów testowych i uzyskali różne wyniki.

# Klasyfikacja metod doboru parameteów (Eiben i wsp., 2008)



# Dostrajanie parametrów (ang. parameter tuning).

- Polega na doborze parametrów przed uruchomieniem algorytmu ewolucyjnego.
- Następnie wykonywany jest przebieg algorytmu z ustalonymi wartościami parametrów, które pozostają stałe podczas pracy.
- Dobór parametrów na podstawie wskazówek z literatury (np. rozmiar populacji  $S \approx 50$ , prawdopodobieństwo mutacji  $p_m \approx 1/L$ , gdzie  $L$  to długość chromosomu).
- Dobór parametrów na podstawie wyników eksperymentów dla problemów testowych.
  - Parametry nie są od siebie niezależne, zatem musimy rozważać wszystkie możliwe kombinacje (albo zastosować algorytm optymalizacji globalnej do doboru parametrów).
  - Przykład: jeżeli mamy cztery parametry, z których każdy może przyjmować pięć wartości, to potrzeba  $5^4=625$  eksperymentów. Jeden eksperyment powinien obejmować min. 10 przebiegów algorytmu (w celu uśrednienia, algorytm ewolucyjny jest algorytmem probabilistycznym). Potrzebujemy zatem 6250 przebiegów algorytmu.

# Wady dostrajania parametrów

- Wymaga zaangażowania znacznych mocy obliczeniowych, nawet gdy ignorujemy interakcje pomiędzy parametrami optymalizując je jeden po drugim.
- Optymalne wartości parametrów, dobrane dla jednego problemu, mogą się nie sprawdzić dla innego problemu.
- Optymalne wartości parametrów nie są stałe w trakcie przebiegu algorytmu.

# Sterowanie parametrami (parameter control)

- Parametry zmieniają się w trakcie pracy algorytmu.
- Deterministyczne: według predefiniowanej funkcji numeru iteracji  $t$ .
- Adaptacyjne: z użyciem reguł sprzężenia zwrotnego z procesu poszukiwań.
- Samo-adaptacyjne: poprzez zakodowanie wartości parametru na chromosomie, parametr podlega ewolucji (mutacja, selekcja) wraz z osobnikiem.
- Problemy:
  - Dobranie optymalnej wartości parametru  $p$  jest trudne. Dobór optymalnej wartości  $p(t)$  jest jeszcze trudniejszy.

# Przykład

- Algorytm ewolucyjny znajduje minimum funkcji  $f(x_1, x_2, \dots, x_L)$ .  $L_i \leq x_i \leq U_i$ .
- Algorytm ewolucyjny z reprezentacją zmiennopozycyjną.
  - krzyżowanie arytmetyczne.
  - mutacja  $x_i' = x_i + N(0, \sigma)$
  - $N(0, \sigma)$  jest liczbą losową z rozkładu normalnego o wartości oczekiwanej 0 i odchyleniu standardowym  $\sigma$ .
  - $\sigma$  jest krokiem mutacji, podlegającym sterowaniu

# Sterowanie deterministyczne

- Zakładamy, że duży krok mutacji jest pożądanym we wczesnych fazach pracy algorytmu (poszukiwanie minimów lokalnych) natomiast niewielki krok mutacji jest korzystny w późnych fazach pracy algorytmu (lokalizacja rozwiązania wewnątrz obszaru przyciągania minimum).
- $\sigma$  zmienia się zgodnie ze wzorem:

$$\sigma(t) = 1 - \frac{0.9 * t}{T}$$

gdzie  $\sigma(t)$  jest wartością kroku mutacji w iteracji  $t$ .  $T$  jest całkowitą liczbą iteracji.

- $\sigma(0)=1$ ,  $\sigma(T)=0.1$ .
- Cechy rozwiązania:
  - Zmiany parametru  $\sigma$  są niezależne od postępu ewolucji.
  - Użytkownik ma pełną kontrolę nad parametrem  $\sigma$ .
  - Wartość  $\sigma$  jest w pełni przewidywalna.
  - Jedna wartość  $\sigma$  dla wszystkich osobników w populacji.



# Sterowanie adaptacyjne

- Wartość  $\sigma(t)$  jest uaktualniana co  $n$  iteracji algorytmu zgodnie z równaniem (reguła 1/5 sukcesów).

$$\sigma(t) = \begin{cases} \sigma(t-n)/c & \text{jeżeli } p_s > \frac{1}{5} \\ \sigma(t-n)*c & \text{jeżeli } p_s < \frac{1}{5} \\ \sigma(t-n) & \text{jeżeli } p_s = \frac{1}{5} \end{cases}$$

- gdzie  $c$  jest stałą  $> 1$ ,  $p_s$  jest prawdopodobieństwem sukcesu mutacji w ciągu ostatnich  $n$  iteracji. (Mutacja kończy się sukcesem, jeżeli zmutowany osobnik ma lepsze dopasowanie).
- Własności:
  - zmiany kroku mutacji  $\sigma$  oparte są na sprzężeniu zwrotnym z procesu ewolucji.
  - $\sigma$  jest nieprzewidywalne.
  - jedna wartość  $\sigma$  dla wszystkich osobników.
  - Możliwość kontroli użytkownika (zmiana stałych  $n$  i  $c$ ).

# Sterowanie samoadaptacyjne

- Każdy osobnik ma swój własny krok mutacji  $\sigma$ .
- Jest on włączony do chromosomu, który przyjmuje postać:

$$(x_1, x_2, \dots, x_L, \sigma)$$

- Mutacja takiego chromosomu daje w wyniku chromosom  $(x_1', x_2', \dots, x_L', \sigma')$

gdzie:

$$\sigma' = \sigma * e^{N(0, \tau)}$$

$$x_i' = x_i + N(0, \sigma')$$

- Krok mutacji podlega selekcji (i wartości kroku mutacji prowadzące do kiepskich osobników nie przetrwają).
- Własności:
  - Brak kontroli użytkownika nad  $\sigma$ .
  - Trudno przewidzieć jak się zmieni  $\sigma$ .
  - $\sigma$  definiowane indywidualnie dla osobnika, nie dla populacji.

# Co może podlegać sterowaniu ?

- Praktycznie każdy komponent algorytmu ewolucyjnego może być sparametryzowany i podlegać zmianom podczas procesu ewolucji:
  - Reprezentacja
  - Funkcja dopasowania (i funkcja kary).
  - Operatory krzyżowania i mutacji i ich parametry.
  - Selekcja rodziców i sukcesja.
  - Populacja (rozmiar).
- Zakres działania parametru może być różny.
  - Osobnik (np. krok mutacji)
  - Gen (również krok mutacji, indywidualny dla każdego genu).
  - Populacja (np. rozmiar populacji).
  - Środowisko (np. funkcja dopasowanie i kary).

# Sposób wprowadzania zmian (sterowanie adaptacyjne i samo adaptacyjne)

- Na podstawie danych bezwzględnych. Wartość parametru jest zmieniana przez regułę, która odpala gdy pewne predefiniowane zdarzenie ma miejsce.
  - Zwiększ prawdopodobieństwo mutacji gdy różnorodność w populacji spadnie poniżej pewnego progu.
  - Użytkownik musi wiedzieć jak sterować danym parametrem (np. duże prawdopodobieństwo mutacji może być pomocne, gdy różnorodność w populacji jest bardzo niska).
- Na podstawie danych bezwzględnych. Wartości parametrów są określane na podstawie dopasowania osobników powstałych w wyniku ich zastosowania.
  - Algorytm ewolucyjny wykorzystuje kilka operatorów krzyżowania, probabilistycznie wybierając jeden operator dla każdej pary osobników.
  - Monitoruj jakość rozwiązań otrzymywanych przez operatory i nagradzaj najlepszych (zwiększając ich prawdopodobieństwa).
  - Zakoduje prawdopodobieństwa operatorów krzyżowania na chromosomie i poddaj je ewolucji.

# Literatura

- A. E. Eiben, J. Smith, Introduction to Evolutionary Computing, Springer, 2003, rozdział 8 poświęcony sterowaniu parametrami.
- A. E. Eiben, R. Hinterding, Z. Michalewicz, Parameter Control In Evolutionary Algorithms, IEEE Transactions On Evolutionary Computation, 3(3), 1999, s. 121-141.
- J. E. Smith, T. C. Fogarty, Operator and parameter adaptation in genetic algorithms, Soft Computing, 1(2), 1997, s. 81-87.