

# Algorytmy ewolucyjne

Piotr Lipiński

## Klasyczny problem optymalizacji

- Niech  $F : \Omega \rightarrow \mathbb{R}$  będzie funkcją określoną na zbiorze  $\Omega$  i przyjmującą wartości rzeczywiste.
- Problem minimalizacji funkcji  $F$  na zadanym zbiorze  $D \subseteq \Omega$  polega na znalezieniu minimum funkcji  $F$  na zbiorze  $D$  (i punktu, w którym funkcja to minimum przyjmuje), tzn. na znalezieniu  $x_0 \in D$  takiego, że dla każdego  $x \in D \setminus \{x_0\}$  zachodzi  $F(x_0) < F(x)$ .
- Problem maksymalizacji funkcji  $F$  na zadanym zbiorze  $D \subseteq \Omega$  polega na znalezieniu maksimum funkcji  $F$  na zbiorze  $D$  (i punktu, w którym funkcja to maksimum przyjmuje), tzn. na znalezieniu  $x_0 \in D$  takiego, że dla każdego  $x \in D \setminus \{x_0\}$  zachodzi  $F(x) < F(x_0)$ .
- Każdy problem minimalizacji może zostać przekształcony do problemu maksymalizacji i każdy problem maksymalizacji może zostać przekształcony do problemu minimalizacji.
- UWAGI:
  - Zbiór  $\Omega$  nazywamy **przestrzenią poszukiwań**.
  - Funkcję  $F$  nazywamy **funkcją celu**.
  - Zbiór  $D$  nazywamy **zbiorem rozwiązań dopuszczalnych**.
  - W praktyce, często rozszerza się problem zastępując nierówności ostre nieostryimi i starając się znaleźć wszystkie punkty  $x_0$  spełniające powstały warunek.
  - W praktyce, często nie jest ważne znalezienie dokładnych punktów minimów czy maksimów funkcji celu, a jedynie ich przybliżen lub punktów, w których funkcja celu przyjmuje wartości "dostatecznie niskie" lub "dostatecznie wysokie" z praktycznego punktu widzenia.

## Klasyczny problem optymalizacji

- Przykład 1 (funkcje analityczne):
  - Znaleźć minimum funkcji  $F(x) = 3x^2 - 2x + 1$ .
  - Znaleźć minimum funkcji  $F(x, y) = x^{17}y^{13} - 2x^{11} + 3y^7 + 5$ .
  - Znaleźć minimum funkcji  $F(x)$ , określonej jak wyżej, ale rozwiązaniami dopuszczalnymi są jedynie liczby całkowite.
- Przykład 2 (problemy kombinatoryczne):
  - Problem komiwojażera.
  - Problem QAP.
  - Problem Q3AP.
- Przykład 3 (funkcje "obliczeniowe" / Black Box Optimization):
  - W praktyce często mamy do czynienia z funkcjami, których dokładne matematyczne definicje i wzory nie są znane. Funkcje takie są obliczane w zadany sposób, na przykład w procesie symulacji pewnych zjawisk. Cała nasza wiedza o takiej funkcji to znajomość procedury obliczania jej wartości dla danego argumentu.
- Przykład 4:
  - Funkcje pochodzące z systemów uczenia maszynowego: systemów ekspertowych, systemów klasyfikujących, systemów wspomaganie decyzji.
- Przykład 5:
  - Funkcje określone na drzewach, grafach czy innych złożonych obiektach.

Piotr Lipiński, Wykład z algorytmów ewolucyjnych

3

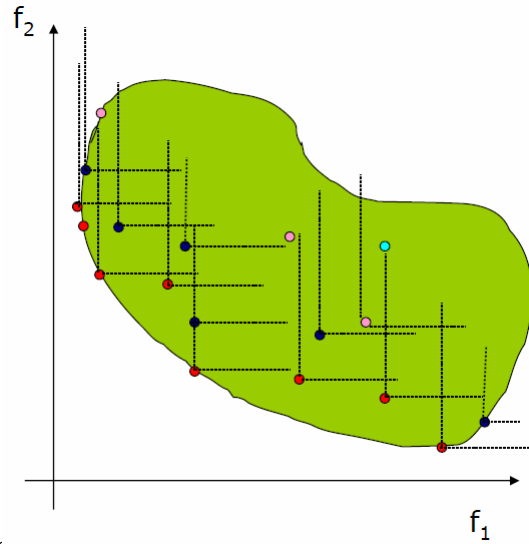
## Problem optymalizacji wielokryterialnej

- Niech  $\Omega$  będzie przestrzenią poszukiwań.
- Rozpatrujemy  $K$  funkcji celu:  $F_1 : \Omega \rightarrow \mathbb{R}, F_2 : \Omega \rightarrow \mathbb{R}, \dots, F_K : \Omega \rightarrow \mathbb{R}$ .
  - Funkcje te definiują różne kryteria oceny elementów przestrzeni poszukiwań. Zwykle nazywa się je funkcjami kryteriów, a nie funkcjami celu. Stąd też pochodzi nazwa problemu – optymalizacja wielokryterialna.
  - Przyjmijmy, że problem polega na minimalizacji funkcji kryteriów. Problem, w którym niektóre funkcje kryteriów należy maksymalizować można sprowadzić do równoważnego problemu z minimalizowaniem wszystkich funkcji kryteriów.
  - Funkcje kryteriów zazwyczaj są ze sobą sprzeczne (maksymalizacja jednej funkcji pociąga za sobą minimalizację innej).
- Element  $\mathbf{x} \in \Omega$  dominuje element  $\mathbf{y} \in \Omega$ , jeśli  $F_k(\mathbf{x}) \leq F_k(\mathbf{y})$  dla każdego  $k = 1, 2, \dots, K$  oraz  $F_k(\mathbf{x}) < F_k(\mathbf{y})$  dla pewnego  $k = 1, 2, \dots, K$ .
  - Element  $\mathbf{y} \in \Omega$  jest elementem zdominowanym jeśli istnieje element  $\mathbf{x} \in \Omega$ , który go dominuje.
  - Element  $\mathbf{y} \in \Omega$  jest elementem niezdominowanym jeśli nie istnieje element  $\mathbf{x} \in \Omega$ , który go dominuje.
- Zbiór elementów niezdominowanych nazywamy frontem Pareto.
- Problem optymalizacji wielokryterialnej z przestrzenią poszukiwań  $\Omega$  i funkcjami kryteriów  $F_1 : \Omega \rightarrow \mathbb{R}, F_2 : \Omega \rightarrow \mathbb{R}, \dots, F_K : \Omega \rightarrow \mathbb{R}$  polega na wyznaczeniu frontu Pareto.
- Analogicznie określa się problem optymalizacji wielokryterialnej z ograniczeniami.

Piotr Lipiński, Wykład z algorytmów ewolucyjnych

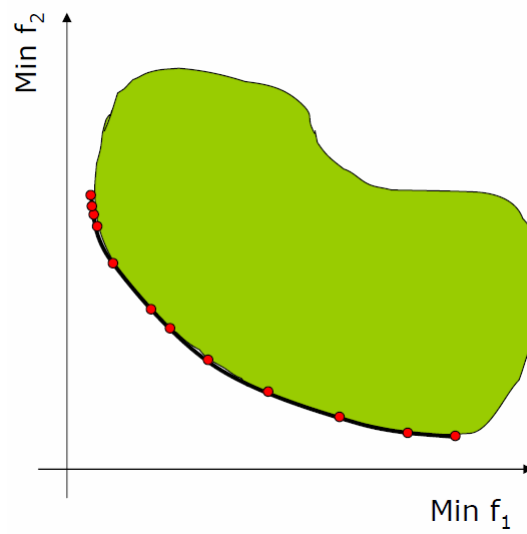
4

## Problem optymalizacji wielokryterialnej



Piotr Lipiński, Wykład z algorytmów ewolucyjnych

## Problem optymalizacji wielokryterialnej



Piotr Lipiński, Wykład z algorytmów ewolucyjnych

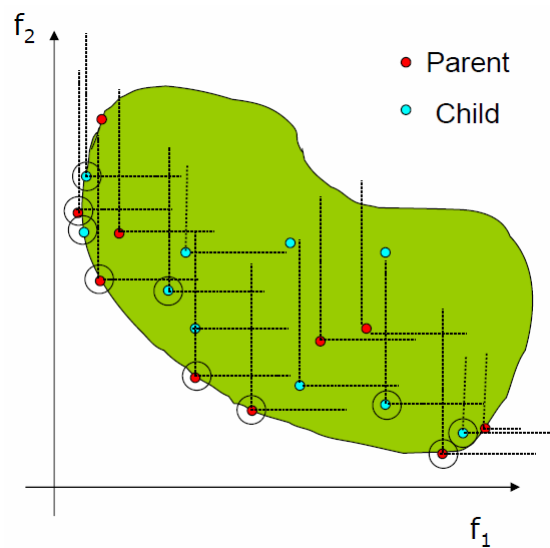
6

## Problem optymalizacji wielokryterialnej

- Popularne algorytmy ewolucyjne do optymalizacji wielokryterialnej:
  - Multi-Objective Genetic Algorithm, MOGA (Fonseca, Fleming, 1993)
  - Non-Dominated Sorting Genetic Algorithm, NSGA (Srinivas, Deb, 1995)
  - Niche-Pareto Genetic Algorithm, NPGA (Horn, Nafpliotis, Goldberg, 1994)
  - Non-Dominated Sorting Genetic Algorithm II, NSGA-II (Deb, et al., 2000)
  - SPEA, SPEA2
  - MOEA/D


## NSGA-II

- Oryginalny algorytm NSGA-II opiera się na SGA, w którym zmieniono operator wyboru nowej populacji.



## NSGA-II – Fast Nondominated Sorting

- Jak wyznaczać kolejne fronty Pareto?
  - Niech  $M$  oznacza liczbę kryteriów, a  $N$  oznacza liczbę osobników.
  
- Naiwnie -  $O(MN^3)$ :
  - potrzeba  $O(MN)$  porównań do określenia czy dany osobnik jest zdominowany czy niezdominowany
  - potrzeba  $O(MN^2)$  porównań do wyznaczenia frontu Pareto (PF0)
  - potrzeba  $O(MN^3)$  porównań do wyznaczenia wszystkich kolejnych frontów Pareto (PF0, PF1, ...)
    - przypadek pesymistyczny: może być  $N$  jednoelementowych frontów Pareto



Piotr Lipiński, Wykład z algorytmów ewolucyjnych

9

## NSGA-II – Fast Nondominated Sorting


- Jak wyznaczać kolejne fronty Pareto?
  - Niech  $M$  oznacza liczbę kryteriów, a  $N$  oznacza liczbę osobników.
  
- Sprytnie -  $O(MN^2)$ :
  - Dla każdego osobnika  $x$ , wyznaczamy *domination count*  $N_x$  (liczbę osobników, które dominują  $x$ ) oraz zbiór  $S_x$  (zbiór osobników, które dominuje osobnik  $x$ ). Wymaga to  $O(MN^2)$  porównań.
  - Osobniki z PF0 będą miały  $N_x = 0$ .
  - Dla każdego osobnika  $x$ , który ma  $N_x = 0$  odwiedzamy każdego osobnika  $y$  z  $S_x$  i obniżamy jego  $N_y$  o 1. Jeśli po obniżeniu  $N_y$  wyniesie 0, to umieszczamy osobnika na pomocniczej liście  $Q$ . Osobniki, które znajdują się na liście  $Q$  tworzą PF1.
  - Powtarzamy poprzedni punkt dla osobników z listy  $Q$ , dopóki jest ona niepusta (czyszcząc listę  $Q$  i tworząc ją od nowa). Osobniki, które w kolejnych iteracjach znajdują się na liście  $Q$  będą tworzyć PF2, PF3, ....

Piotr Lipiński, Wykład z algorytmów ewolucyjnych

10

## NSGA-II – Fast Nondominated Sorting

- Jak wyznaczać kolejne fronty Pareto?
  - Niech  $M$  oznacza liczbę kryteriów, a  $N$  oznacza liczbę osobników.
  
- Sprytnie -  $O(MN^2)$ :
  - Dla każdego osobnika  $y$  z PF1, PF2 i kolejnych, początkowa  $N_y$  może wynosić najwyżej  $N-1$  (bo  $N$  to liczba wszystkich osobników, a co najmniej jeden z nich musi być w PF0).
  - Zatem każdy osobnik może być odwiedzony co najwyżej  $N-1$  razy zanim jego  $N_y$  spadnie do zera.
  - Zatem wyznaczenie PF1, PF2, i dalszych ma złożoność  $O(N^2)$ .
  - Łączna złożoność więc to  $O(MN^2 + N^2) = O(MN^2)$ .




Piotr Lipiński, Wykład z algorytmów ewolucyjnych

11

## NSGA-II – Crowding Distance

- Jak wymusić równomierne rozproszenie frontu Pareto?




Piotr Lipiński, wykład z algorytmów ewolucyjnych

12

## NSGA-II – Crowding Distance

- W NSGA-II wprowadzono miarę oceny osobników zwaną Crowding Distance:
  - założmy, że rozpatrujemy problem optymalizacji dwukryterialnej
  - dla osobnika  $x$  znajdujemy w aktualnej populacji jego "dwóch najbliższych sąsiadów"  $y$  i  $z$  (w przestrzeni kryteriów, nie w przestrzeni poszukiwań!):
    - pierwszy sąsiad  $y$  ma być lepszy od  $x$  względem pierwszego kryterium
    - drugi sąsiad  $z$  ma być lepszy od  $x$  względem drugiego kryterium
  - punkty  $y$  i  $z$  rozpinają prostokąt, długości boków tego prostokąta oznaczmy przez  $a$  i  $b$
  - Crowding Distance osobnika  $x$ , to  $CR(x) = a + b$ .
  - jeśli jeden z sąsiadów nie istnieje, to przyjmujemy, że odpowiedni bok prostokąta ma długość nieskończoną, czyli  $CR(x) = \infty$ .
- Policzenie Crowding Distance dla całej populacji ma złożoność  $O(MN \log N)$ 
  - Rozpatrujemy kolejne kryteria, dla każdego kryterium sortujemy populację i wyliczamy różnicę między kolejnymi wartościami kryterium.




Piotr Lipiński, Wykład z algorytmów ewolucyjnych

13

## NSGA-II – Ranking osobników

- Fast Nondominated Sorting i Crowding Distance są używane do porównywania osobników i tworzenia ich rankingu.




Piotr Lipiński, wykład z algorytmów ewolucyjnych

14

## NSGA-II – Ranking osobników

- Ranking tworzony jest według dwóch kryteriów:
  - ranga osobnika (czyli numer frontu Pareto do którego należy, im niższy tym lepiej)
  - Crowding Distance osobnika (im wyższy tym lepiej)
  
- Dokładniej: Definiujemy relację  $<$  na zbiorze osobników. Niech  $x$  i  $y$  będą dwoma osobnikami, wówczas:
  - Jeśli  $\text{rang}(x) < \text{rang}(y)$ , to  $x < y$
  - Jeśli  $\text{rang}(x) > \text{rang}(y)$ , to  $y < x$
  - Jeśli  $\text{rang}(x) = \text{rang}(y)$ , to
    - Jeśli  $\text{CR}(x) > \text{CR}(y)$ , to  $x < y$
    - Jeśli  $\text{CR}(x) < \text{CR}(y)$ , to  $y < x$
    - Jeśli  $\text{CR}(x) = \text{CR}(y)$ , to **dowolnie**

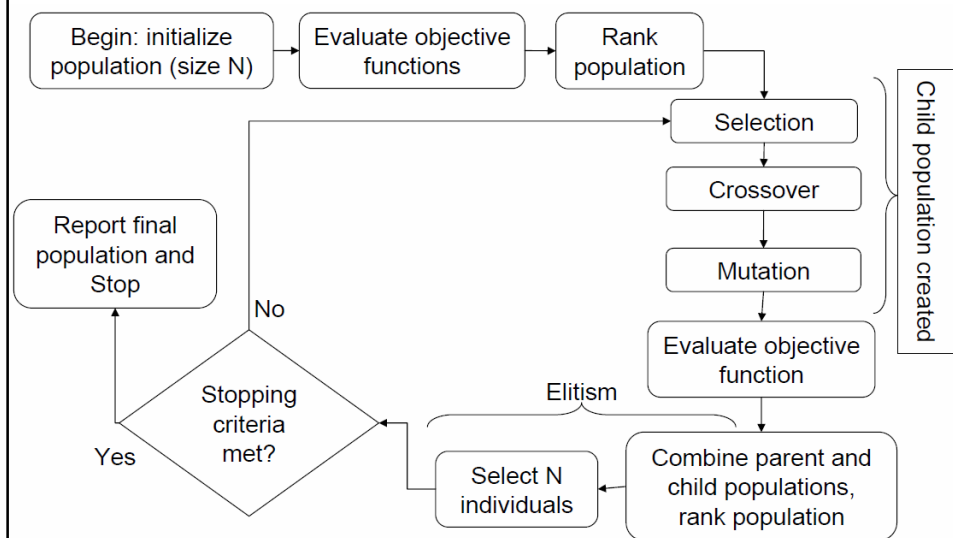


Piotr Lipiński, Wykład z algorytmów ewolucyjnych

15

## NSGA-II


- Oryginalny algorytm NSGA-II opiera się na SGA, w którym zmieniono operator wyboru nowej populacji.





## Hypervolume

- Jak oceniać działanie algorytmu optymalizacji wielokryterialnej?
- Celem algorytmu jest wyznaczenie frontu Pareto, a dokładniej:
  - umieszczenie osobników na dokładnym froncie Pareto,
  - umieszczenie ich w taki sposób, żeby były "równomiernie rozproszone".
- Popularna używana miara jakości to hypervolume (HV)




- Jeśli znany jest dokładny front Pareto  $FP^*$ , to można policzyć relative hypervolume (HVR) jako  $HVR(FP) = HV(FP) / HV(FP^*)$ .

Piotr Lipiński, Wykład z algorytmów ewolucyjnych

17

## MOO dla problemów optymalizacji z ograniczeniami

- Infeasibility Driven Evolutionary Algorithm (IDEA) to przykład algorytmu opartego na NSGA-II do rozwiązywania problemów optymalizacji z ograniczeniami.
  - Pierwsze kryterium  $F_1 = F: \Omega \rightarrow R$  definiowane jest przez oryginalną funkcję celu.
  - Drugie kryterium  $F_2: \Omega \rightarrow R$  definiowane jest przez "stopień złamania ograniczeń".



Piotr Lipiński, Wykład z algorytmów ewolucyjnych

18