

Zaawansowane Metody Optymalizacji Globalnej

Michał Okulewicz

Wydział Matematyki i Nauk Informatycznych
Politechnika Warszawska

Informacje organizacyjne

- 1 Zapoznanie
- 2 Zakres przedmiotu
- 3 Literatura
- 4 Zasady zaliczenia
- 5 Zadanie optymalizacji

Prowadzący I

- Studia: magisterskie na MiNI (MSI), doktoranckie na IPI PAN (SMAD dla leniwych z modyfikacjami)
- Praca magisterska: *Porównanie wybranych metod optymalizacji globalnej*, 2011
- Rozprawa doktorska: *Zastosowanie populacyjnych metaheurystyk wykorzystujących rozkład danych problemu do rozwiązywania problemu dynamicznej marszrutyżacji*, 2017
- Obecnie:
 - hybrydowe algorytmy optymalizacji globalnej
- Rozwiązywane zagadnienia:
 - optymalizacja rozkroju kłody,
 - optymalizacja harmonogramów odbioru odpadów,
 - lokalizacja telefonów komórkowych

Prowadzący II

- Ulubione algorytmy metaheurystyczne
 - Particle Swarm Optimization,
 - Differential Evolution,
 - Variable Neighborhood Search
- Inne wykorzystywane techniki:
 - modele liniowe,
 - lasy losowe, sieci neuronowe
- Przekonania naukowe:
 - optymalizację rojem cząstek należałoby uogólnić,
 - optymalizacja rojem cząstek oferuje dobrą platformę do rozwoju różnych zachowań cząstek,
 - interakcje ludzi w zespole mogą stanowić dobre źródło inspiracji dla tych zachowań,

Prowadzący III

- algorytmy powinny być proste w implementacji, a wydajne tylko na tyle ile potrzeba, bo mojego czasu mi szkoda, a czasu procesora nie,
- polski rynek jest gotowy na wdrożenia algorytmów z zakresu sztucznej inteligencji.

Uczestnicy

- Co kończyliście?
- Czy i w czym umiecie programować?
- Dlaczego poszliście na studia doktoranckie?
- Czym się zajmujecie na doktoracie? Czym chcecie się zajmować?
- Czego się spodziewacie po tym przedmiocie?

Zakres przedmiotu I

- Zadanie optymalizacji: czyli co?
- Metody Zaawansowane: czyli jakie?
- Przestrzeń przeszukiwania: ciągłe czy dyskretne?
- Metody podstawowe
 - Algorytmy jednopunktowe: *stochastic gradient descent*, symulowane wyżarzanie, *variable neighbourhood search*, strategie ewolucyjne
 - Algorytmy populacyjne: algorytm genetyczny, algorytm ewolucyjny, ewolucja różnicowa, optymalizacja rojem cząstek →
 - Algorytmy inteligencji rojowej: boidy Reynoldsa, algorytm mrówkowy, optymalizacja rojem cząstek
- Jak testować algorytmy?

Zakres przedmiotu II

- Jaka jest rola algorytmów heurystycznych?
- Metody hybrydowe: Ewolucja Lamarcka, Algorytm Memetyczny, metody hiperheurystyczne →
- Jakie są jeszcze związki między uczeniem maszynowym a optymalizacją?
- Uogólniony algorytm roju cząstek: GAPSO
- Optymalizacja wielokryterialna
- Optymalizacja dynamiczna

Cel przedmiotu



= ?

Cel przedmiotu



\neq



Cel przedmiotu



=



Literatura I

- 1 Shi, Y.; Eberhart, R.C. (1998). "A modified particle swarm optimizer". Proceedings of IEEE International Conference on Evolutionary Computation. pp. 69–73.
- 2 Storn, R.; Price, K. (1997). "Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces". Journal of Global Optimization. 11: 341–359
- 3 Wolpert, D.H., Macready, W.G. (1997), "No Free Lunch Theorems for Optimization", IEEE Transactions on Evolutionary Computation 1, 67.
- 4 Sörensen, K. (2015). "Metaheuristics-the metaphor exposed". International Transactions in Operational Research, 22(1), 3–18.

Literatura II

- 5 Gendreau, M.; Potvin, J-Y. (2010). "Handbook of Metaheuristics". Springer.
- 6 Panigrahi, B.K.; Shi, Y.; Lim, M. (2011), "Handbook of swarm intelligence: concepts, principles and applications". Springer.
- 7 Arabas J. (2004). "Wykłady z algorytmów ewolucyjnych". WNT

Zaliczenie

- Nie ma egzaminu
- Będziemy pisać artykuł

Zaliczenie

- Nie ma egzaminu
- Będziemy pisać artykuł
- Omówienie w formie seminarium wyników cudzych badań - 3.0
- Omówienie w formie seminarium wyników własnych badań - 3.5
- Zaprezentowanie wyników własnych mających potencjał na artykuł - 4.0
- Przygotowanie i wysłanie artykułu naukowego - 4.5
- Przygotowanie i wysłanie artykułu naukowego w dobre miejsce (czasopismo 140+, konferencje PPSN, GECCO, CEC) - 5.0

Zadanie optymalizacji

- Szukamy parametrów modelu matematycznego pewnego układu, które zapewnią poprawę działania tego układu
- Problem reprezentujemy jako funkcję jakości (przystosowania, celu)
- Poszukiwane parametry są argumentami tej funkcji
- $X^* = \{x^* : \forall x \in D f(x) \preceq f(x^*)\}$

Zadanie


Znaleźć optimum funkcji $f : \mathbb{R}^n \rightarrow \mathbb{R}$,

$$\text{np. } f(x) = n + \sum_{i=1}^n (x_i^2 - \cos(2\pi x_i))$$

```
f <- function(x) {  
  if (!is.matrix(x)) {  
    x = matrix(x, ncol = length(x))  
  }  
  rowSums(x^2) - rowSums(cos(2*pi*x)) + ncol(x)  
}
```

Zadanie

Funkcja Rastrigina




Rozwiązanie (dla leniwych)

```
samples.count = 200
sample = matrix(
  runif(
    dim*samples.count,
    min(x),max(x)
  ),
  ncol=dim,
  nrow=samples.count)
values = f(sample)
sample[which.min(values),]
```

Rozwiązanie (dla leniwych)


Funkcja Rastrigina



Rozwiązanie (dla lubiących gradienty)

```
res = optim(fn = f,  
           par = sample[which.min(values),],  
           method = "L-BFGS-B",  
           lower = min(x),  
           upper = max(x))  
res$par
```


Rozwiązanie (dla lubiących gradienty)



Rozwiązanie (dla statystyków)

```
require(randomForest)
rf = randomForest(x = sample, y = values)
z = outer(X=x,
          Y=y,
          FUN=function(X1,X2)
            {predict(rf,data.frame(cbind(X1,X2)))})
```

Rozwiązanie (dla statystyków)



A gdyby to wszystko połączyć?

