

Dlaczego algorytmy stochastyczne są zbieżne?

Jerzy Ombach

Instytut Matematyki, Uniwersytet Jagielloński

Będlewo, Sierpień 2014

Zadania optymalizacji globalnej

Problem

Dana jest funkcja $f : A \longrightarrow \mathbb{R}$

Wyznaczyć efektywnie minimum globalne, to znaczy punkt $x_0 \in A$ taki, że

$$\forall x \in A \quad f(x_0) \leq f(x).$$

lub jego możliwie najlepsze przybliżenie.

Oznaczamy zbiór rozwiązań:

$$A^* := \{x_0 \in A : \text{dla każdego } x \in A \quad f(x_0) \leq f(x)\}.$$

Szukanie maximum globalnego funkcji f



Szukanie minimum globalnego funkcji $-f$

Przykłady zadań optymalizacji globalnej

1. Metoda największej wiarygodności

Znajdź parametr $\theta \in \Theta \subset \mathbb{R}^k$ dla którego funkcja wiarygodności jest największa.

Na przykład: $l(\theta) = g_\theta(x^1) \cdot \dots \cdot g_\theta(x^n)$, gdzie $x^1, \dots, x^n$ jest zaobserwowaną próbką prostą z rozkładu o gęstości g_θ .

2. Rozwiązywanie układu równań

znajdź rozwiązanie $x_0 \in A \subset \mathbb{R}^n$ układu równań

$$\begin{cases} g^1(x) &= & 0 \\ \dots & \dots & \dots \\ g^n(x) &= & 0 \end{cases}$$

Definiujemy funkcją: $f(x) = g^1(x)^2 + \dots + g^n(x)^2$ i szukamy minimum globalnego $x_0 \in A$.

Przykłady zadań optymalizacji globalnej

3. Szukanie wystarczająco dobrych wartości funkcji

Dana jest funkcja $g : A \longrightarrow \mathbb{R}$ oraz liczba $\alpha > \min g$.
Wyznaczyć efektywnie wartości $x_0 \in A$ takie, że

$$g(x_0) \leq \alpha.$$

Definiujemy funkcję: $f(x) = \max(g(x), \alpha)$ i szukamy minimum globalnego f , $x_0 \in A$.

Klasyczne twierdzenia

Twierdzenie

A – zwarty, f – ciągła.

$\implies$ Istnieje minimum globalne.

Twierdzenie (prowadzi do rozwiązywania układu n -równań)

A – otwarty w $\mathbb{R}^n$, f – różniczkowalna,

$x_0 \in A$ – minimum.

$\implies f'(x_0) = 0$.

Klasyczne twierdzenia

Twierdzenie (prowadzi do rozwiązywania $n + k$ równań)

$f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^k$, $k < n$,

x_0 – minimum f przy ograniczeniach

$A = \{x : g(x) = 0\}$,

f, g są klasy C^1 , rząd $g'(x_0) = k$.

$\Rightarrow$ Istnieją $\lambda \in \mathbb{R}^k$ takie, że:

$$f'(x_0) = \lambda^T g'(x_0).$$

Algorytm PRS – PURE RANDOM SEARCH

$f : A \rightarrow \mathbb{R}$ – ciągła, $A = [0, 1]^n \subset \mathbb{R}^n$.

Algorytm.

- 1 Losujemy punkt ze zbioru A zgodnie z rozkładem jednostajnym na A . Oznaczamy go jako x_0 . Kolejne punkty $x_1, x_2, x_3, \dots$, tworzymy w następujący sposób. Dla $t = 0, 1, 2, 3, \dots$:
- 2 Losujemy punkt $y_t \in A$ według rozkładu jednostajnego.
- 3 Jeżeli $f(y_t) < f(x_t)$, kładziemy $x_{t+1} = y_t$. W przeciwnym przypadku kładziemy $x_{t+1} = x_t$.

Niech X_t będzie ciągiem zmiennych losowych, których realizacje x_t określa algorytm.

Twierdzenie

$$\text{Prob}(X_t \rightarrow A^*, \text{ gdy } t \rightarrow \infty) = 1.$$

Dowód.

Lemat Borela-Cantellego

Niech $(\Omega, \Sigma, \text{Prob})$ będzie przestrzenią probabilistyczną.

Niech $C_1, C_2, C_3, \dots \in \Omega$ będzie ciągiem zdarzeń niezależnych:

$$\sum_{i=1}^{\infty} \text{Prob}(C_i) = \infty \implies \text{Prob} \left(\bigcap_{t=1}^{\infty} \bigcup_{i=t}^{\infty} C_i \right) = 1.$$

$m = \min_A f$. $A^* = \{x \in A : f(x) = m\}$.

1. Ciąg $f(X_t)$ jest nierosnący i ograniczony z dołu przez m , więc jest zbieżny do pewnej zmiennej losowej $\eta \geq m$.

2. Niech $\mathbf{Y}_t$ będą niezależnymi zmiennymi losowymi o rozkładzie jednostajnym na A , których realizacjami są punkty $\mathbf{y}_i$.

Ustalmy $\varepsilon > m$.

3. Ponieważ funkcja f jest ciągła, zbiór $B = \{x \in A : f(x) < \varepsilon\}$ jest niepusty i otwarty, więc jego miara Lebesgue'a, $\nu(B) = \alpha > 0$.

4. Określmy:

$$C_t = \{\omega \in \Omega : f(\mathbf{Y}_t(\omega)) < \varepsilon\} = \mathbf{Y}_t^{-1}(B), \text{ dla } t = 1, 2, 3, \dots$$

C_t są zdarzeniami niezależnymi.

5. Ponieważ zmienne losowe $\mathbf{Y}_t$ mają rozkład ν , więc

$\text{Prob}(C_t) = \text{Prob}_{\mathbf{Y}_t}(B) = \nu(B) = \alpha$ dla $t \geq 1$. Jest więc spełnione założenie Lematu Borela-Cantellego.

6. Na podstawie algorytmu PRS zachodzi implikacja:

$$\eta \geq \varepsilon \implies \forall t \geq 1 \ f(\mathbf{Y}_t) \geq \eta \geq \varepsilon,$$

czyli

$$\{\eta \geq \varepsilon\} \subset \bigcap_{t=1}^{\infty} (\Omega \setminus C_t) = \Omega \setminus \bigcup_{t=1}^{\infty} C_t.$$

$$\bigcap_{t=1}^{\infty} \bigcup_{i=t}^{\infty} C_i \subset \bigcup_{t=1}^{\infty} C_t \subset \{\eta < \varepsilon\}$$

Algorytm ARS – ACCELERATED RANDOM SEARCH

$f : A \rightarrow \mathbb{R}$ – ciągła, $A = [0, 1]^n \subset \mathbb{R}^n$

Ustalamy $c > 1$ oraz $\rho > 0$ – dokładność.

Algorytm

- 0 Zadajemy $t = 1$ oraz $r_1 = 1$. Losujemy x_1 według rozkładu jednostajnego na A .
- 1 Mając $x_t \in A$ oraz $r_t \in (0, 1]$, losujemy y_t według rozkładu jednostajnego na $B(x_t, r_t) \cap A$, gdzie $B(x, r)$ jest kulą.
- 2 Jeżeli $f(y_t) < f(x_t)$, podstawiamy $x_{t+1} = y_t$ oraz $r_{t+1} = 1$.
- 3 Jeżeli $f(y_t) \geq f(x_t)$, to:
 - ❶ Jeżeli $r_t \geq \rho$, kładziemy $x_{t+1} = x_t$ oraz $r_{t+1} = r_t/c$.
 - ❷ Jeżeli $r_{t+1} < \rho$, kładziemy $r_{t+1} = 1$.
- 4 $t := t + 1$ i wracamy do kroku 2.

Twierdzenie

$$\text{Prob}(X_t \longrightarrow A^*, \text{ gdy } t \longrightarrow \infty) = 1.$$

Algorytm hybrydowy

$f : A \rightarrow \mathbb{R}$.

Ustalmy miarę $\mu_0, \nu_0 \in \mathcal{M}$. Ustalmy $\varphi : A \rightarrow A$ – „metodę lokalną”.

Algorytm.

- 1 Losujemy punkt ze zbioru A zgodnie z rozkładem μ_0 . Oznaczamy go jako x_0 . Kolejne punkty $x_1, x_2, x_3, \dots$, tworzymy w następujący sposób. Dla $t = 0, 1, 2, 3, \dots$:
- 2 Losujemy punkt $\mathbf{y}_t \in A$ według rozkładu ν_0 .
- 3 Stosujemy φ do $\mathbf{y}_t$
- 4 Jeżeli $f(\varphi(\mathbf{y}_t)) < f(x_t)$, kładziemy $x_{t+1} = \varphi(\mathbf{y}_t)$. W przeciwnym przypadku kładziemy $x_{t+1} = x_t$.

Algorytm typu multistart

$$f : A \rightarrow \mathbb{R}.$$

Ustalamy μ_0, ν_0 – miary probabilistyczne na A ,

k, m – liczby naturalne. $\varphi : A \rightarrow A$ – metoda lokalna

- 1 Losujemy niezależnie m punktów z A zgodnie z rozkładem μ_0 :
 $\mu_0: \mathbf{x} = (x_1, \dots, x_m) \in A^m$ – populacja początkowa.
- 2 Losujemy niezależnie k punktów z A zgodnie z rozkładem ν_0 :
 $\mathbf{y} = (y_1, \dots, y_k) \in A^k$.
- 3 Stosujemy φ do każdego x_i oraz y_i i dostajemy:

$$(\varphi(x_1), \dots, \varphi(x_m), \varphi(y_1), \dots, \varphi(y_k))$$

- 4 Sortujemy rosnąco używając funkcję f jako kryterium:

$$(\bar{x}_1, \dots, \bar{x}_{m+k}) \text{ gdzie } f(\bar{x}_1) \leq \dots \leq f(\bar{x}_{m+k}).$$

- 5 Tworzymy nową populację biorąc m pierwszych punktów
 $\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_m)$ i wracamy do punktu 2. biorąc $\mathbf{x} = \bar{\mathbf{x}}$.

Twierdzenie

Założenia:

- (a1) $\nu_0(I_c) = 0$ gdzie, $I_c := \{x \in A : f(x) = c\}$.
- (a2) Metoda lokalna φ jest ciągła i niesingularna względem ν_0 .
- (a3) Jeżeli $G \subset A$ jest otoczeniem A^* , to $\nu_0(G) > 0$.
- (a4) $f(\varphi(x)) \leq f(x)$, dla $x \in A$.

Wtedy:

$$\text{Prob}(X_{1,t} \longrightarrow A^*, \text{ gdy } t \longrightarrow \infty) = 1.$$

Ogólna forma problemu

Postawienie problemu

$A \subset \mathbb{R}^n$ – zwarty, $f : A \rightarrow \mathbb{R}$ funkcja ciągła osiągająca min f na A .
Zakładamy, że $\min f = 0$.

$$A^* = \{x \in A : f(x) = 0\}.$$

$$X_t = T_t(X_{t-1}, \mathbf{Y}_{t-1}) \text{ dla } t = 1, 2, 3, \dots$$

gdzie T_t są odpowiednimi operatorami, $\mathbf{Y}_t$ są zmiennymi (wektorami) losowymi.

Autonomiczność na początek: $T_t = T$, $T : A \times B \rightarrow A$.

X_0 – wektor losowy o danym rozkładzie na A

$\mathbf{Y}_t$ – wektory losowe mające wspólny rozkład na $B \subset \mathbb{R}^m$.

Problem

Czy X_t zbiegają do A^* , dla $t \rightarrow \infty$.

PRS, ARS, algorytm hybrydowy, Multistart

PRS

$$T(x, \mathbf{y}) = \begin{cases} x, & \text{gdy } f(\mathbf{y}) \geq f(x) \\ \mathbf{y}, & \text{gdy } f(\mathbf{y}) < f(x) \end{cases}$$

ARS

$$T(x, \mathbf{y}) = \begin{cases} x, & \text{gdy } f(\mathbf{y}) \geq f(x) \\ \mathbf{y}, & \text{gdy } f(\mathbf{y}) < f(x) \end{cases}$$

$\mathbf{y}_t$ NIE są losowane ze wspólnego rozkładu!!!

Algorytm hybrydowy

$$T(x, \mathbf{y}) = \begin{cases} x, & \text{gdy } f(x) \geq f(\varphi(\mathbf{y})) \\ \varphi(\mathbf{y}), & \text{gdy } f(\varphi(\mathbf{y})) < f(x) \end{cases}$$

Multistart

$$T(\mathbf{x}, \mathbf{y}) = \bar{\mathbf{x}}.$$

Formalizacja

$\mathcal{B}(A)$, $\mathcal{B}(B)$ σ -algebry zbiorów borelowskich na A oraz B

$\mathcal{M}$ zbiór wszystkich miar probabilistycznych na $\mathcal{B}(A)$.

$(\Omega, \Sigma, \text{Prob})$ przestrzeń probabilistyczna.

$X_0 : \Omega \rightarrow \mathbb{R}^n$ ma rozkład $\mu_0 \in \mathcal{M}$.

$\mathbf{Y}_t :: \Omega \rightarrow \mathbb{R}^m$ mają wspólny rozkład ν , dla $t = 0, 1, 2, \dots$

$X_0, \mathbf{Y}_1, \mathbf{Y}_2, \mathbf{Y}_3, \dots$ są niezależne.

T jest mierzalne $A \times B \rightarrow A$. (Wtedy X_t jest wektorem losowym.)

Twierdzenie A

Zakładamy, że A jest zwarty oraz są spełnione warunki

(A) Dla każdego $x_0 \in A$ oraz dowolnego ciągu $x_n \rightarrow x_0$:

$$T(x_n, \mathbf{y}) \rightarrow T(x_0, \mathbf{y}) \quad \text{p.w. } \nu, \quad \text{gdy } n \rightarrow \infty.$$

(B) Dla każdego $x \in A^*$ oraz $\mathbf{y} \in B$, $T(x, \mathbf{y}) \in A^*$.

(C) Dla każdego $x \in A \setminus A^*$:

$$\int_B f(T(x, \mathbf{y})) \nu(d\mathbf{y}) < f(x).$$

Wtedy, dla każdego $\varepsilon > 0$:

$$\lim_{t \rightarrow \infty} \text{Prob}(\text{dist}(X_t, A^*) < \varepsilon) = 1.$$

Założmy dodatkowo warunek:

(D) Dla każdego $x \in A$ oraz $\mathbf{y} \in B$: $f(T(x, \mathbf{y})) \leq f(x)$.

Wtedy:

$$\text{Prob}(X_t \rightarrow A^*, \text{ gdy } t \rightarrow \infty) = 1.$$

Przestrzeń miar

$\mathcal{M}$ – przestrzeń probabilistycznych miar borelowskich.

Wiadomo, że $\mathcal{M}$ jest przestrzenią metryczną zwartą, przy czym:

Ciąg miar $\mu_n \in \mathcal{M} \rightarrow \mu \in \mathcal{M} \iff$ dla każdej funkcji ciągłej h ,

$$\int_A h d\mu_n \rightarrow \int_A h d\mu,$$

gdy $n \rightarrow \infty$.

Innym równoważnym warunkiem zbieżności jest:

$$\mu_n(C) \rightarrow \mu(C),$$

gdy $n \rightarrow \infty$, dla każdego $C \in \mathcal{B}(A)$ takiego, że $\mu(\delta C) = 0$, gdzie δC oznacza brzeg zbioru C .

Operator Foiasa

$$P : \mathcal{M} \rightarrow \mathcal{M}: \quad P\mu(C) = (\mu \times \nu)(T^{-1}(C)), \text{ dla } \mu \in \mathcal{M}, \quad C \in \mathcal{B}(A),$$

$$P\mu(C) = \int_A \left(\int_B \mathbf{1}_C(T(x, \mathbf{y})) \nu(d\mathbf{y}) \right) \mu(dx), \text{ dla } \mu \in \mathcal{M}, \quad C \in \mathcal{B}(A),$$

gdzie $\mathbf{1}_C$ jest funkcją charakterystyczną C .

Oznaczamy: μ_t^T – rozkład X_t , to znaczy:

$$\mu_t^T(C) = \text{Prob}(X_t \in C) = \text{Prob}(X_t^{-1}(C)), \quad C \in \mathcal{B}(A), \quad t = 1, 2, 3, \dots$$

Zauważmy, że dla takich C :

$$\mu_t^T(C) = \text{Prob}(X_t \in C) = \text{Prob}(T(X_{t-1}, \mathbf{Y}_t) \in C) = \text{Prob}((X_{t-1}, \mathbf{Y}_t) \in T^{-1}(C)) = (\mu_{t-1}^T \times \nu)(C) = P\mu_{t-1}^T(C).$$

Czyli:

$$\mu_1^T = P\mu_0, \quad \mu_2^T = P\mu_1^T, \quad \mu_3^T = P\mu_2^T, \quad \mu_4^T = P\mu_3^T, \dots$$

i ogólnie: $\mu_t^T = P\mu_{t-1}^T, \quad t = 1, 2, 3, \dots$ Oznaczmy dodatkowo:
 $\mu_0^T = \mu_0.$

Operator Foiasa

$\{\mu_t^T : t = 0, 1, 2, 3, \dots\}$ – orbita (trajektoria) μ_0 .

Iteracje P^t definiujemy jako $P^0 = id_{\mathcal{M}}$, $P^{t+1} = P \circ P^t$, dla $t = 0, 1, 2, \dots$.

Operator Foiasa T dyktuje układ dynamiczny w następującym sensie:

$\mathcal{M}$ – przestrzeń fazowa,

$\mu \in \mathcal{M}$ – stan (punkt) układu,

$t = 0, 1, 2, 3, \dots$ – czas (dyskretny)

Orbita punktu μ : $o(\mu) = \{P^t \mu : t = 0, 1, 2, 3, \dots\}$.

Wtedy

$$P^t \mu_0 = \mu_t^T, t = 0, 1, 2, \dots$$

Operator Foiasa

Podstawowe własności P

Definiujemy dla funkcji ciągłej $h : A \rightarrow \mathbb{R}$ funkcję:

$$Uh(x) = \int_B h(T(x, \mathbf{y})) \nu(d\mathbf{y})$$

- ❶ Jeżeli $\mu \in \mathcal{M}$. oraz h jest ciągła, to:

$$\int_A h d(P\mu) = \int_A Uh d\mu.$$

- ❷ Założenie **(A)** implikuje, że $P : \mathcal{M} \rightarrow \mathcal{M}$ jest odwzorowaniem ciągłym.

Układ dynamiczny

$\mathcal{M}$ – przestrzeń metryczna zwarta, $P : \mathcal{M} \rightarrow \mathcal{M}$ – odwzorowanie ciągłe.

Orbita punktu μ : $o(\mu) = \{P^t \mu : t = 0, 1, 2, 3, \dots\}$.

Zbiór graniczny punktu μ : $\omega(\mu) = \{\lambda \in \mathcal{M} : \exists t_i \rightarrow \infty, P^{t_i} \mu \rightarrow \lambda\}$.

Zbiór zwarty $\emptyset \neq \mathcal{K} \subset \mathcal{M}$ jest zbiorem niezmienniczym, jeżeli $P(\mathcal{K}) \subset \mathcal{K}$.

Niech ϱ będzie metryką na $\mathcal{M}$ zgodną z topologią,

Wiadomo, że dla każdego $\mu \in \mathcal{M}$:

- (1) $\omega(\mu) \neq \emptyset$,
- (2) $\omega(\mu)$ jest niezmienniczy,
- (3) Jeżeli $\mathcal{K} \subset \mathcal{M}$ jest zbiorem niezmienniczym, to:
 $\varrho(P^t \mu, \mathcal{K}) \rightarrow 0$ gdy $t \rightarrow \infty \iff \omega(\mu) \subset \mathcal{K}$.

Wniosek z Twierdzenie Lapunowa

$P : \mathcal{M} \rightarrow \mathcal{M}$ – operator Foiasa.

$$\mathcal{M}^* := \{\mu \in \mathcal{M} : \text{supp } \mu \subset A^*\}.$$

Twierdzenie

Zachodzą warunki Twierdzenia A:

- (A) Dla każdego $x_0 \in A$ oraz dowolnego ciągu $x_n \rightarrow x_0$:
 $T(x_n, \mathbf{y}) \rightarrow T(x_0, \mathbf{y})$ p.w. ν , gdy $n \rightarrow \infty$.
- (B) Dla każdego $x \in A^*$ oraz $\mathbf{y} \in B$, $T(x, \mathbf{y}) \in A^*$.
- (C) Dla każdego $x \in A \setminus A^*$: $\int_B f(T(x, \mathbf{y})) \nu(d\mathbf{y}) < f(x)$.

Wtedy, $\mathcal{M}^*$ jest niezmienniczy oraz dla każdej miary $\mu \in \mathcal{M}$:

$$\varrho(P^t \mu, \mathcal{M}^*) \rightarrow 0, \text{ as } t \rightarrow \infty.$$

Dowód. Funkcja: $V : \mathcal{M} \rightarrow \mathbb{R} : V\mu = \int_A f d\mu$ jest funkcją Lapunowa.

Twierdzenie A – przypomnienie

Zakładamy, że A jest zwarty oraz są spełnione warunki

(A) Dla każdego $x_0 \in A$ oraz dowolnego ciągu $x_n \rightarrow x_0$:

$$T(x_n, \mathbf{y}) \rightarrow T(x_0, \mathbf{y}) \quad \text{p.w. } \nu, \quad \text{gdy } n \rightarrow \infty.$$

(B) Dla każdego $x \in A^*$ oraz $\mathbf{y} \in B$, $T(x, \mathbf{y}) \in A^*$.

(C) Dla każdego $x \in A \setminus A^*$:

$$\int_B f(T(x, \mathbf{y})) \nu(d\mathbf{y}) < f(x).$$

Wtedy, dla każdego $\varepsilon > 0$:

$$\lim_{t \rightarrow \infty} \text{Prob}(\text{dist}(X_t, A^*) < \varepsilon) = 1.$$

Załóżmy dodatkowo warunek:

(D) Dla każdego $x \in A$ oraz $\mathbf{y} \in B$: $f(T(x, \mathbf{y})) \leq f(x)$.

Wtedy:

$$\text{Prob}(X_t \rightarrow A^*, \text{ gdy } t \rightarrow \infty) = 1.$$

Dowód Twierdzenia A

Fakt (*) Jeżeli $\mu^* \in \mathcal{M}^*$ oraz $C \in \mathcal{B}(A)$ taki, że $A^* \subset \text{int } C$, to

$$\mu^*(\delta C) = 0 \quad \text{oraz} \quad \mu^*(C) = 1.$$

Wtedy warunek zbieżności miar implikuje, że dla każdego ciągu miar

$\mu_n \in \mathcal{M}$ takiego, że $\mu_n \rightarrow \mu^*$ zachodzi: $\mu_n(C) \rightarrow 1$, as $n \rightarrow \infty$.

Ustalę $\varepsilon > 0$ i biorę $C = \{a \in A : \text{dist}(a, A^*) < \varepsilon\}$. Ustalę $\mu_0 \in \mathcal{M}$.

Twierdzenie poprzednie gwarantuje, że zbiór ω -graniczny, $\omega(\mu_0)$, jest zawarty w $\mathcal{M}^*$. Dla każdego ciągu $t_n \rightarrow \infty$, można wybrać podciąg

$t_{n_i} \rightarrow \infty$ oraz miarę $\mu^* \in \mathcal{M}^*$ takie, że $P^{t_{n_i}} \mu_0 \rightarrow \mu^*$. Zauważmy, że ma

miejsce Fakt(*). A więc $P^{t_{n_i}} \mu_0(C) \rightarrow \mu^*(C) = 1$. Ale to oznacza, że

$P^t \mu_0(C) \rightarrow 1$, as $t \rightarrow \infty$. Pamiętając, że $P^t \mu_0$ jest rozkładem wektora X_t , mamy: $\text{Prob}(\text{dist}(X_t, A^*) < \varepsilon) = \text{Prob}(X_t \in C) = P^t \mu_0(C)$. Stąd:

$$\lim_{t \rightarrow \infty} \text{Prob}(\text{dist}(X_t, A^*) < \varepsilon) = 1.$$

Dowód Twierdzenia A

Fakt ()** Dla każdego $\varepsilon > 0$:

$$\lim_{t \rightarrow \infty} \text{Prob}(f(X_t) < \varepsilon) = 1.$$

Dowód. Ustaliam $\varepsilon > 0$. Zwartość A^* oraz ciągłość f pozwalają dobrać $\delta > 0$ takie, że $\text{dist}(x, A^*) < \delta \implies f(x) < \varepsilon$. Możemy więc użyć udowodniony przed chwilą warunek biorąc w nim $\delta = \varepsilon$.

Fakt (*)**(folklor). Niech $\xi_n : \Omega \rightarrow \mathbb{R}$ będzie nierosnącym ciągiem zmiennych losowych zbieżnym stochastycznie do 0. Wtedy, ξ_n zmierza do 0 z prawdopodobieństwem 1.

Ciąg $\xi_t = f(X_t)$ jest stochastycznie zbieżny do 0, a z założenia **(D)** jest nierosnący. Zmierza więc do 0 z prawdopodobieństwem 1. Zwartość A oraz A^* , a także ciągłość f pociągają:

$$\{\omega : f(X_t(\omega)) \rightarrow 0, \text{ gdy } t \rightarrow \infty\} \subset \{\omega : X_t(\omega) \rightarrow A^*, \text{ gdy } t \rightarrow \infty\},$$

co oznacza, że X_t zmierzają z prawdopodobieństwem 1 do 0.

Stochastyczny algorytm ewolucyjny

Podstawowe pojęcia:

f – funkcja kosztu/funkcja przystowowania:

$(\Omega, \Sigma, \text{Prob})$ – przestrzeń probabilistyczna.

Populacja zerowa – skończony, M -elementowy, podzbiór zbioru A .

$T_t : A^M \times \Omega \longrightarrow A^M$ – mechanizm ewolucyjny zależny od czasu.

Kolejne generacje:

P_0 – populacja zerowa

$P_{t+1} = T_t(P_t, Y_{t+1}), t = 0, 1, 2, 3, \dots$, – kolejna populacje,

gdzie Y_t – obiekt losowy.

CEL

W kolejnych populacjach znajdować elementy minimalizujące koszt f .

W kolejnych populacjach znajdować elementy maksymalizujące przystosowanie f .


Mechanizmy ewolucyjne

1. Selekcja
2. Krzyżowanie
3. Mutacje
4. Dojrzewanie


Przykład

$$f : [-3, 3] \times [-3, 3] \longrightarrow \mathbb{R}$$


$$f(a, b) = \sqrt{\left((-2.5 + a)^2 + (2.5 + b)^2\right) \left((1 + a)^2 + 4(-1 + b)^2\right)} + 6(\sin(a + b))^2$$




Populacja zerowa




Tworzenie nowej gneracji




Tworzenie nowej gneracji




Tworzenie nowej gneracji




Przystosowanie = 3.55464 w punkcie $(-0.68155, 1.1676)$




Generacja numer 1




Tworzenie nowej gneracji




Przystosowanie = 1.78230 w punkcie $(-0.71062, 0.95940)$



Generacja numer 7



Przystosowanie = .404578 w punkcie $(-0.92407, 0.99629)$



Problem zbieżności

Uwaga

Jeżeli

$$\int \bar{f}(T_t(P, y)) dy \leq \bar{f}(P), \quad P \in A^M,$$

to przy pewnych dodatkowych założeniach ciąg $\{p_t^0\}$ zmierza prawie wszędzie do zbioru $A^* = \{a \in A : \forall x \in A f(x) \geq f(a)\}$.

Tutaj: $p_t^0 \in P_t$.

$$\bar{f}(p_1, \dots, p_M) := \min(f(p_1), \dots, f(p_M)) = f(p_t^0).$$

Układ nieautonomiczny

$$X_t = T_t(X_{t-1}, \mathbf{Y}_{t-1}) \text{ dla } t = 1, 2, 3, \dots,$$

gdzie T_t są mierzalne $A \times B \rightarrow A$.

$\mathcal{B}(A)$, $\mathcal{B}(B)$ σ -algebry zbiorów borelowskich na A oraz B
 $\mathcal{M}$, $\mathcal{N}$ zbiór wszystkich miar probabilistycznych na $\mathcal{B}(A)$, $\mathcal{B}(B)$.

$X_0 : \Omega \rightarrow \mathbb{R}^n$ ma rozkład $\mu_0 \in \mathcal{M}$.

$\mathbf{Y}_t :: \Omega \rightarrow \mathbb{R}^m$ mają rozkład $\nu_t \in \mathcal{N}$, dla $t = 0, 1, 2, \dots$.

$X_0, \mathbf{Y}_1, \mathbf{Y}_2, \mathbf{Y}_3, \dots$ są niezależne.

$\mathcal{T}$ - rodzina operatorów $T : A \times B \rightarrow A$ z topologią zbieżności jednostajnej.

Układ nieautonomiczny

Niech $U \subset \mathcal{T} \times \mathcal{N}$ będzie zbiorem zwartym.

Zakładamy, że dla każdego $u = (T, \nu) \in U$:

- (A) Dla każdego $x_0 \in A$ odwzorowanie $f \circ T$ jest dolnie pociągłe w punktach (x_0, y) , takich, że $y \in B \setminus D_T(x_0)$, przy czym $\nu(D_T(x_0)) = 0$.
- (B) Dla każdych $x \in A^*$, $y \in B$: $T(x, y) \in A^*$.
- (C1) Dla każdego $x \in A \setminus A^*$:

$$\int_B f(T(x, y)) \nu(dy) \leq f(x). \quad (1)$$

Istnieje domknięty podzbiór $U_0 \subset U$ taki, że:

- (C2) dla każdych $(T, \nu) \in U_0$, $x \in A \setminus A^*$:

$$\int_B f(T(x, y)) \nu(dy) < f(x). \quad (2)$$

Optymalizacja oparta na MCMC

Dana jest funkcja $f : A \rightarrow \mathbb{R}$. Chcemy znaleźć maksimum globalne f . Ze względu na dużą licznosc A nie warto przeszukiwać tego zbioru element po elemencie. Czasami jedynym możliwym podejściem jest losowanie.

Zamiast losować zgodnie z rozkładem jednostajnym na A chcemy losować z takiego rozkładu π , że:

$$\pi(x) \geq \pi(y) \iff f(x) \geq f(y).$$

Przykład: $\beta > 0$

$$\pi_\beta(x) = \frac{\exp(\beta f(x))}{C}, \quad C = \sum_{y \in A} \exp(\beta f(y))$$

Podstawowa zasada:

Wyznacz próbkę z rozkładu π i znajdź wartość największą f na tej próbce. Punkt x_0^π , w którym ta wartość jest osiągnięta jest „statystycznie” blisko zbioru $\{a \in A : \forall x \in A f(x) \leq f(a)\}$.

Metoda: Markov Chain Monte Carlo

A – skończony, $\#A$ (bardzo duże)

π – rozkład prawdopodobieństwa na A , $\pi_i > 0$ dla $i \in A$.

Chcemy losować punkty ze zbioru A zgodnie z rozkładem π .

Metoda MCMC

Określa się na zbiorze A pewien ergodyczny łańcuch Markowa $\mathbf{P}$, którego stanem stacjonarnym jest π .

Wybierając teraz dowolny $x_0 \in A$ i generując kolejne punkty $x_1, x_2, \dots$ mamy gwarancję, że dla dużych n , x_n są losowane faktycznie zgodnie z rozkładem π .

Twierdzenie

Algorytm Metropolis'a (opisany poniżej w szczególnym przypadku – problem plecakowy) generuje punkty będące realizacjami pewnego ergodycznego łańcucha Markowa o stanie stacjonarnym π .

Problem plecakowy

Maksymalizuj wartość

$$f(x) = c^T x$$

przy ograniczeniu

$$w^T x \leq W, \quad x^i \in \{0, 1\},$$

$c = (c^1, \dots, c^k)$ wektor cen,

$w = (w^1, \dots, w^k)$ wektor wag,

W – maksymalna waga dopuszczalna.

$$A = \{x \in \{0, 1\}^k : w^T x \leq W\}$$

Przykładowe dane: $W = 20$,

$[cena, waga] = [50, 10], [20, 5], [20, 4], [10, 1], [5, 3], [5, 5], [4, 4], [3, 3], [3, 3], [3, 3], [2, 2], [3, 1], [3, 1], [2, 1], [2, 1], [2, 1], [2, 1], [1, 1], [1, 1], [1, 1]$

Rozwiązanie:

$$x^* = (1, 1, 1, 1, 0, 0, \dots, 0), \quad f(x^*) = 100.$$

Algorytm Metropolisia w przypadku problemu plecakowego

Ustalmy $\beta > 0$ oraz $T > 0$.

Wyberzmy punkt początkowy $x_1 \in A$. Podstawmy $x \leftarrow x_1$

Od $t = 1$ do $T - 1$ wykonuj:

- 1 Wylosuj J spośród liczb $1, \dots, k$.
- 2 Niech $y = (x^1, \dots, x^{J-1}, 1 - x^J, x^{J+1}, \dots, x^k)$.
- 3 Jeżeli $y \notin A$, to $x_{t+1} \leftarrow x_t$.

W przeciwnym przypadku:

- 4 Niech $\alpha = \begin{cases} \exp(-\beta c^J), & \text{gdy } x^J = 1 \\ 1 & \text{gdy } x^J = 0 \end{cases}$.
- 5 Wylosuj $u \in \{0, 1\}$ zgodnie z rozkładem

$$\text{Prob}(0) = 1 - \alpha, \quad \text{Prob}(1) = \alpha.$$

Jeżeli $u = 0$, wtedy $x_{t+1} \leftarrow x_t$.

Jeżeli $u = 1$, wtedy $x_{t+1} \leftarrow y$.

Dla dużych T , X_T ma w przybliżeniu rozkład π_β .

Przykład: $T = 100$, $\beta = 0.5$, $x_1 = (0, \dots, 0)$.

[1, 0, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0]	[88, 20]
[0, 1, 1, 1, 0, 0, 1, 1, 0, 0, 0, 1, 1, 1, 0, 0, 0, 0, 0, 0]	[65, 20]
[0, 0, 1, 1, 1, 1, 0, 0, 0, 0, 1, 1, 1, 1, 1, 0, 1, 0, 0, 0]	[54, 20]
[0, 1, 0, 1, 1, 0, 1, 0, 0, 0, 1, 1, 0, 1, 0, 1, 1, 0, 0, 1]	[51, 20]
[0, 1, 1, 1, 0, 0, 0, 1, 0, 0, 1, 0, 1, 1, 0, 0, 1, 0, 1, 1]	[64, 20]
[0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 1, 0, 1, 1, 0, 1, 0, 1, 1, 1]	[46, 17]
[0, 1, 0, 1, 0, 1, 0, 0, 1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0]	[46, 20]
[1, 0, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 1, 0, 1, 1, 0, 0, 0, 0]	[75, 20]
[1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 1, 1, 1, 1, 1, 1, 1, 0, 0]	[68, 20]
[0, 0, 1, 0, 1, 1, 0, 0, 0, 0, 1, 1, 1, 0, 0, 1, 1, 0, 1, 1]	[44, 20]

Metoda: Simulated Annealing

W algorytmie Metropolis'a wolno zwiększamy β :
Na przykład:

$$\beta(t) = \log t,$$

$$\beta(t) = 1.0001^t,$$

$$\beta(t) = b_0 \left(1 + \frac{1}{T}\right)^{at},$$

gdzie T jest liczbą kroków, b_0 oraz a są dodatnie.

Dalsze modyfikacje algorytmu Metropolis'a

Oryginalny algorytm

Ustalmy $\beta > 0$ oraz $T > 0$.

Wyberzmy punkt początkowy $x_1 \in A$. Podstawmy $x \leftarrow x_1$

Od $t = 1$ do $T - 1$ wykonuj:

- 1 Wylosuj J spośród liczb $1, \dots, k$.
- 2 Niech $y = (x^1, \dots, x^{J-1}, 1 - x^J, x^{J+1}, \dots, x^k)$.
- 3 Jeżeli $y \notin A$, to $x_{t+1} \leftarrow x_t$.
W przeciwnym przypadku:
- 4 Niech $\alpha = \begin{cases} \exp(-\beta c^J), & \text{gdy } x^J = 1 \\ 1 & \text{gdy } x^J = 0 \end{cases}$.
- 5 Wylosuj $u \in \{0, 1\}$ zgodnie z rozkładem

$$\text{Prob}(0) = 1 - \alpha, \quad \text{Prob}(1) = \alpha.$$

Jeżeli $u = 0$, wtedy $x_{t+1} \leftarrow x_t$.

Jeżeli $u = 1$, wtedy $x_{t+1} \leftarrow y$.

Dalsze modyfikacje algorytmu Metropolis'a

Modyfikacje

Ustalmy **funkcję β (wolno) rosnącą, $\beta(t) > 0$** oraz $T > 0$.
 Wybierzmy punkt początkowy $x_1 \in A$. Podstawmy $x \leftarrow x_1$
 Od $t = 1$ do $T - 1$ wykonuj

- 1 Wylosuj J spośród liczb $1, \dots, k$ **według rozkładu**

$$\text{Prob}(J = i) = \frac{c^i}{\sum_{s=1}^k c^s}.$$

- 2 Niech $y = (x^1, \dots, x^{J-1}, 1 - x^J, x^{J+1}, \dots, x^k)$.

- 3 Jeżeli $y \notin A$, to $x_{t+1} \leftarrow x_t$.

W przeciwnym przypadku:

- 4 Niech $\alpha = \begin{cases} \exp(-\beta(t)c^J), & \text{gdy } x^J = 1 \\ 1 & \text{gdy } x^J = 0 \end{cases}$.

- 5 Wylosuj $u \in \{0, 1\}$ zgodnie z rozkładem

$$\text{Prob}(0) = 1 - \alpha, \quad \text{Prob}(1) = \alpha.$$

Jeżeli $u = 0$, wtedy $x_{t+1} \leftarrow x_t$.

Jeżeli $u = 1$, wtedy $x_{t+1} \leftarrow y$.

Przykład: $T = 100$, $\beta = \beta(t) = 0.5(1 + \frac{1}{T})^t$, $x_1 = (0, \dots, 0)$.

[1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0]	[93, 20]
[0, 1, 1, 1, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0]	[60, 20]
[1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]	[100, 20]
[1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0]	[93, 20]
[1, 1, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]	[100, 20]
[1, 1, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0]	[86, 20]
[1, 0, 1, 1, 0, 0, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 0, 1, 0, 0]	[88, 20]
[1, 0, 1, 0, 0, 0, 0, 1, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]	[76, 20]
[0, 1, 1, 1, 1, 0, 0, 0, 1, 0, 1, 0, 0, 0, 0, 1, 1, 0, 0, 0]	[64, 20]
[1, 0, 1, 1, 0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 1, 1, 0, 0, 0, 0]	[89, 20]

SIMULATED ANNEALING

$f : A \rightarrow \mathbb{R}$ – ciągła, A – zwarty, $B \subset \mathbb{R}^m$

Dane:

ξ_t – ciąg i.i.d o rozkładzie ν na B .

r_t – ciąg i.i.d o rozkładzie jednostajnym na $(0, 1)$.

$\beta_t > 0$ – ciąg liczb, taki, że $\lim_{t \rightarrow \infty} \beta_t = \infty$.

$Q : A \times B \rightarrow A$ – odwzorowanie mierzalne.

X_0 zmienna losowa na A niezależna od zmiennych ξ_t, r_t ,

$$X_{t+1} = \begin{cases} Q(X_t, \xi_{t+1}) & \text{gdy } f(Q(X_t, \xi_{t+1})) < f(X_t) \\ Q(X_t, \xi_{t+1}) & \text{gdy } f(Q(X_t, \xi_{t+1})) \geq f(X_t) \text{ oraz} \\ & r_t \leq \exp(-\beta_t) \cdot |f(Q(X_t, \xi_{t+1})) - f(X_t)| \\ X_t & \text{w przeciwnym przypadku} \end{cases}$$

SIMULATED ANNEALING

Twierdzenie, Dawid Tarłowski

Założmy, że:

- (E) dla każdego $x \in A$ miara ν zbioru punktów nieciągłości odwzorowania $y \rightarrow Q(x, y)$ równa się zero.
- (F) dla każdego $x \in A \setminus A^*$,
 $\nu(\{y \in B : f(Q(x, y)) < f(x)\}) > 0$.

Wtedy dla każdego $\varepsilon > 0$:

$$\text{Prob}(d(X_t, A^*) < \varepsilon) \rightarrow 0, \text{ dla } t \rightarrow \infty.$$

oraz

$$E(f(X_t)) \rightarrow \min_A f, \text{ dla } t \rightarrow \infty.$$

Algorytmu Gibbsa

Niech $A = \mathcal{X} = \mathcal{X}_1 \times \dots \times \mathcal{X}_k$

Często $\mathcal{X}$ to $\mathbb{R}^k$ lub jej podzbiór. Albo $\mathcal{X} \subset \{0, 1\}^k$.

Niech π będzie rozkładem na A (niekoniecznie w pełni znanym)

Założmy, że dla dowolnego $x \in \mathcal{X}$ potrafimy losować ze wszystkich rozkładów warunkowych postaci

$$\pi(\cdot | x_{-i}),$$

gdzie $i = 1, \dots, k$ oraz $x_{-i} = (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_k)$.

Zadanie: wylosować próbkę z rozkładu π .

Algorytmu Gibbsa

Problem plecakowy c.d.

$$A = \{x \in \{0, 1\}^k : w^T x \leq W\}$$

$$\pi_\beta(x) = \frac{\exp(\beta f(x))}{C}, \quad C = \sum_{y \in A} \exp(\beta f(y)),$$

gdzie $f(x) = c^T x$, c – wektor cen, $\beta > 0$ – parametr algorytmu.

$\pi_\beta(\cdot | x_{-i})$ – rozkład dwupunktowy

Gdy $w_{-i}^T x_{-i} + c_i \leq W$, wtedy $\pi_\beta(0 | x_{-i}) = \frac{1}{1 + e^{c_i}}$, $\pi_\beta(1 | x_{-i}) = \frac{e^{c_i}}{1 + e^{c_i}}$.

Gdy $w_{-i}^T x_{-i} + c_i > W$, wtedy $\pi_\beta(0 | x_{-i}) = 1$, $\pi_\beta(1 | x_{-i}) = 0$.

Algorytmu Gibbsa

Losowy algorytm Gibbsa

- 0 $X := x_0 \in \mathcal{X}$ (ustalony)
- 1 $i \sim U(\{1, \dots, k\})$
- 2 $x'_i \sim \pi_0(\cdot | x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_k)$
- 3 $X = (x_1, \dots, x_{i-1}, x'_i, x_{i+1}, \dots, x_k)$
- 4 przejdź do kroku 1.

Przykład: $T = 100$, $\beta = 0.5$, $x_0 = (0, \dots, 0)$.

$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 1, 1, 1, 0, 1, 0]$	$[63, 19]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 1, 0, 1, 0, 1, 0]$	$[61, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 1, 0]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 1, 0]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 1, 0]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 1, 0]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 1, 0]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 0, 1]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 0, 1]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 0, 1]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 1, 0, 1]$	$[60, 18]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 1]$	$[59, 17]$
$[1, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 1]$	$[59, 17]$

Algorytmu Gibbsa

Losowemu Algorytmowi Gibbsa odpowiada pewien łańcuch Markowa $(X_n)_{n \in \mathbb{N}}$ o rozkładzie stacjonarnym π .

Jądro przejścia algorytmu ma postać:

$$P(x, \cdot) = \frac{1}{k} \sum_{i=1}^k P_i(x, \cdot),$$

gdzie $P_i(x, \cdot)$ jest rozkładem o funkcji gęstości:

$$p_i(x, y) = \mathbf{1}_{\{x_{-i}\}}(y_{-i}) \cdot \pi(y_i | x_{-i}).$$

$\mathbf{1}_{\{x_{-i}\}}$ oznacza tutaj funkcję charakterystyczną w punkcie x_{-i} , tzn. wszystkie współrzędne x i y są równe poza indeksem i -tym

Algorytmu Gibbsa

Twierdzenie, Iwona Żerda

Jeżeli rozkład π na $\mathbb{R}^k$ ma podwójnie różniczkowalną i dodatnią funkcję gęstości p taką, że

$$\forall_{i=1,\dots,k} \quad \limsup_{|x| \rightarrow \infty} \frac{\partial^2}{\partial x_i^2} \log p(x) < 0,$$

$$\exists_{\delta > 0} \quad \liminf_{|x| \rightarrow \infty} \min_i \sup_{|t| < \delta} \operatorname{sgn}(x_i) \cdot \frac{\partial}{\partial x_i} \log p(x + \operatorname{sgn}(x_i) t e_i) = -\infty,$$

to losowy algorytm Gibbsa o rozkładzie stacjonarnym π jest geometrycznie zbieżny. To znaczy, istnieje stała $\rho < 1$ oraz funkcja $M : \mathcal{X} \rightarrow [0, \infty)$ takie, że

$$\forall_{x \in \mathcal{X}} \quad \pi\text{-p.w.} \quad \|P^n(x, \cdot) - \pi(\cdot)\|_{tv} \leq M(x) \rho^n,$$

gdzie $\|\mu - \nu\|_{tv} = \sup_{B \in \mathcal{B}(\mathcal{A})} |\mu(B) - \nu(B)|$.

Niektóre podręczniki

- ① J. Arabas, Wykłady z algorytmów ewolucyjnych, WNT, 2004.
- ② j. Kusiak, A. Danielewska-Tułęcka, Piotr Oprocha, Optymalizacja, wybrane metody z przykładami zastosowań. PWN, 2009.
- ③ S. Luke, Essentials of Metaheuristics, preprint.
- ④ N. Madras, Lectures on Monte Carlo Methods, AMS, 2002.
- ⑤ A.P. Meyn and R.L. Tweedie, Markov Chains and Stochastic Stability, Springer Verlag 1993.
- ⑥ W. Niemiro, Symulacje stochastyczne i metody Monte Carlo, UW 2013.
- ⑦ R. Schaefer, Podstawy genetycznej optymalizacji globalnej, UJ, 2002



Ali Ahrari, Ali Asghar Atai, *Grenade Explosion Method-A novel tool for optimization of multimodal functions*, preprint, 2009.



M. J. Appel, R. Labarre, D. Radulovic, *On Accelerated Random Search*, SIAM J. Optim. Vol. 14(2003), 708-731,



M. Clerc and J. Kennedy, *The particle swarm - explosion, stability, and convergence in a multidimensional complex space*, Transactions on Evolutionary Computation 6(2002), 58-73.



Y. Hani, L. Amodeo, F. Yalaoui, H. Chen, *Ant colony optimization for solving an industrial layout problem*, European Journal of Operational Research 183(2007) 633 – 642.



D.Karaboga,B.Basturk , *A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm*, Journal of Global Optimization 39(2007). 459 – 471.



Jorge Nocedal and Stephen J. Wright, *Numerical Optimization*, Springer, 1999.



J. Ombach, *Stability of evolutionary algorithms*, Journal Math Anal Appl. 342(2008), 326 - 333.



J. Ombach, *A Proof of Convergence of General Stochastic Search for Global Minimum*, Journal of Difference Equations and Applications 13 (2007), pp. 795 – 802.



J. Ombach, D. Tarłowski, *Nonautonomous Stochastic Search in Global Optimization*, J. Nonlinear Sci., DOI: 10.1007/s00332-011-9112-3



Dawid Tarłowski, *Nonautonomous stochastic search for global minimum in continuous optimization*, J MATH ANAL APPL vol. Volume 412 Issue 2 (2014), 631-645.



Marcin Radwański, *Convergence of nonautonomous evolutionary algorithm*, UIAM, 45(2007), 197 - 206.



Darrell Whitley, Soraya Ranaa, John Dzuberaa and Keith E. Mathiasb, *Evaluating evolutionary algorithms*, Artificial Intelligence 85(1996) 245 - 276..

D Z I Ę K U J Ę
Z A U W A G Ę