

# Feltételes optimalizálási problémák megoldása változó mintanagyságú eljárással

Krejić Nataša<sup>1</sup> Krklec Jerinkić Nataša<sup>1</sup> Rožnjik Andrea<sup>2</sup>

<sup>1</sup>Újvidéki Tudományegyetem, Természettudományi Matematikai Kar, Újvidék

<sup>2</sup>Újvidéki Tudományegyetem, Építőmérnöki Kar, Szabadka

XXXII. Magyar Operációkutatási Konferencia  
Cegléd, 2017. június 14.-16.

# Sztochasztikus optimalizálási probléma megoldása – SAA approximáció (sample average approximation)

$\xi$  valószínűségi  
vektorvátozó

$$\xi : \begin{pmatrix} \xi_1 & \xi_2 & \cdots & \xi_N \\ \frac{1}{N} & \frac{1}{N} & \cdots & \frac{1}{N} \end{pmatrix}$$

$$\min_x E[F(x, \xi)]$$

$$\min_x \frac{1}{N} \sum_{i=1}^N F(x, \xi_i)$$

$$\begin{aligned} \min_x E[F(x, \xi)] \\ E[G(x, \xi)] \geq 0 \\ E[H(x, \xi)] = 0 \end{aligned}$$

$$\begin{aligned} \min_x \frac{1}{N} \sum_{i=1}^N F(x, \xi_i), \\ \frac{1}{N} \sum_{i=1}^N G(x, \xi_i) \geq 0 \\ \frac{1}{N} \sum_{i=1}^N H(x, \xi_i) = 0 \end{aligned}$$

# Sztochasztikus optimalizálási probléma megoldása – SAA approximáció

$$\min_{\mathbf{x}} f(\mathbf{x}) = E[F(\mathbf{x}, \xi)]$$

megoldás:  $\mathbf{x}^*$

$$\min_{\mathbf{x}} f_N(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N F(\mathbf{x}, \xi_i)$$

megoldás:  $\mathbf{x}_N^*$

- $\xi_1, \xi_2, \dots, \xi_N$  független, azonos eloszlású minta
- $F(\cdot, \xi)$  folytonosan differenciálható majdnem minden  $\xi$ -re
- $f(\mathbf{x}), \nabla_{\mathbf{x}} f(\mathbf{x})$  jól definiált, véges értékű minden  $\mathbf{x}$ -re

$$\lim_{N \rightarrow \infty} \mathbf{x}_N^* = \mathbf{x}^*, \quad \lim_{N \rightarrow \infty} f_N(\mathbf{x}_N^*) = f(\mathbf{x}^*) \quad \text{m.m.}$$

Shapiro, A., Dentcheva, D., Ruszczyński, A.: Lectures on Stochastic Programming: Modeling and Theory.

MPS-SIAM Series on Optimization (2009)

SAA probléma megoldásának keresése iterációs eljárással

⇒ sok függvényértéket kell kiszámolni

⇒ változó mintanagyságú iterációs eljárások

VSS eljárás

(variable sample size):

$$\min_x \frac{1}{N} \sum_{i=1}^N F(x, \xi_i)$$

$$N^0, x^0, \quad N^1, x^1, \quad N^2, x^2, \quad \dots$$

$$N^0 \leq N^1 \leq N^2 \leq \dots$$

$$\text{lehetséges: } N^k > N^{k+1}$$

$$N^0, N^1, N^2, \dots \rightarrow \infty$$

$$N^0, N^1, N^2, \dots N^{\max}$$

# Sztochasztikus feltételes optimalizálási probléma

$$(SP) \quad \begin{aligned} & \min_x f(x) \\ & h(x) = 0 \end{aligned}$$

$$h(x) = E[H(x, \xi)]$$

$$(SAA) \quad \begin{aligned} & \min_x f(x) \\ & \hat{h}_{N_{max}}(x) = 0 \end{aligned}$$

$$f : \mathbb{R}^n \rightarrow \mathbb{R}$$

$$H : \mathbb{R}^n \times \mathbb{R}^p \rightarrow \mathbb{R}^m$$

$\xi$  valószínűségi vektorváltozó

$$\hat{h}_N(x) := \frac{1}{N} \sum_{i=1}^N H(x, \xi_i)$$

$\xi_1, \xi_2, \dots, \xi_{N_{max}}$  független,  
azonos eloszlású minta

# Sztochasztikus feltételes optimalizálási probléma

- büntető módszer

$$\phi_N(\mathbf{x}; \mu) := f(\mathbf{x}) + \mu \hat{\theta}_N(\mathbf{x})$$

$\mu$  – büntető paraméter

$$\hat{\theta}_N(\mathbf{x}) := \|\hat{h}_N(\mathbf{x})\|^2$$

- vonalmenti keresés

Armijo feltétel:

$$\phi_{N_k}(\mathbf{x}_{k+1}; \mu_k) \leq \phi_{N_k}(\mathbf{x}_k; \mu_k) + \eta \alpha_k \nabla_{\mathbf{x}} \phi_{N_k}(\mathbf{x}_k; \mu_k)^T \mathbf{d}_k$$

Backtracking  $\implies \alpha_k$

- VSS eljárás

az elején meghatározzuk a mintát:  $\xi_1, \xi_2, \dots, \xi_{N_{max}}$

$k$ -adik iteráció:  $\xi_1, \xi_2, \dots, \xi_{N_k}$

$N_k$  kiválasztása:

$\min_{\mathbf{x}} \phi_{N_k}(\mathbf{x}; \mu_k)$  stacionárius pontjától való távolság mértéke

$$d\mathbf{m}_k = -\alpha_k \nabla_{\mathbf{x}} \phi_{N_k}(\mathbf{x}_k; \mu_k)^T d_k,$$

a  $\hat{h}_{N_k} \approx \hat{h}_{N_{max}}$  approximáció hibájának becslése

$$\epsilon_{\delta}^{N_k}(\mathbf{x}_k) = \hat{\sigma}_{N_k}(\mathbf{x}_k) 1.96 / \sqrt{N_k}$$

$$\hat{\sigma}_{N_k}^2(\mathbf{x}_k) = \frac{1}{N_k - 1} \sum_{i=1}^{N_k} \|H(\mathbf{x}_k, \xi_i) - \hat{h}_{N_k}(\mathbf{x}_k)\|^2$$

cél:

$$d\mathbf{m}_k \approx \frac{N_k}{N_{k+1}} \epsilon_{\delta}^{N_{k+1}}(\mathbf{x}_k)$$

$$N_k^{min} \leq N_{k+1} \leq N_{max}$$

# A fő algoritmus

Input:  $N_{min} \in \mathbb{N}$ ,  $\mathbf{x}_0 \in \mathbb{R}^n$ ,  $\beta, \eta \in (0, 1)$ ,  $\mu_0 > 0$ ,  $\gamma > 1$

$N_k := N_{min}$ ,  $\mathbf{x}_k := \mathbf{x}_0$ ,  $\mu_k := \mu_0$ ,  $t := 1$ ,  $N_0^{min} := N_{min}$

**for**  $k=0,1,2,\dots$

$d_k$  csökkenő keresési irány meghatározása

$\alpha_k = 1$

**while**  $\phi_{N_k}(\mathbf{x}_k + \alpha_k \mathbf{d}_k; \mu_k) > \phi_{N_k}(\mathbf{x}_k; \mu_k) + \eta \alpha_k \nabla_{\mathbf{x}} \phi_{N_k}(\mathbf{x}_k; \mu_k)^T \mathbf{d}_k$

$\alpha_k = \beta \alpha_k$

**end while**

$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$ ,  $dm_k = -\alpha_k \nabla_{\mathbf{x}} \phi_{N_k}(\mathbf{x}_k; \mu_k)^T \mathbf{d}_k$

$dm_k \leq \alpha_k / \mu_k^2 \implies \mathbf{z}_t = \mathbf{x}_k$ ,  $t = t + 1$

$N_{k+1}$ ,  $N_{k+1}^{min}$  meghatározása

$N_k = N_{k+1} < N_{max} \vee dm_k > \alpha_k / \mu_k^2 \xrightarrow{T} \mu_{k+1} = \mu_k$

$\Downarrow \perp$

$\mu_{k+1} = \gamma \mu_k$

**end for**



## $N_{k+1}$ meghatározása

Input:  $\epsilon_{\delta}^{N_k}(\mathbf{x}_k)$ ,  $\nu_1 \in (0, 1)$

$dm_k = \epsilon_{\delta}^{N_k}(\mathbf{x}_k) \implies N_{k+1} = N_k$

$dm_k > \epsilon_{\delta}^{N_k}(\mathbf{x}_k) \implies N = N_k$

**while**  $dm_k > \frac{N_k}{N} \epsilon_{\delta}^N(\mathbf{x}_k) \wedge N > N_k^{min}$   
 $N = N - 1$

**end while**

$N_{k+1} = N$

$\nu_1 \epsilon_{\delta}^{N_k}(\mathbf{x}_k) \leq dm_k < \epsilon_{\delta}^{N_k}(\mathbf{x}_k) \implies N = N_k$

**while**  $dm_k < \frac{N_k}{N} \epsilon_{\delta}^N(\mathbf{x}_k) \wedge N < N_{max}$   
 $N = N + 1$

**end while**

$N_{k+1} = N$

$dm_k < \nu_1 \epsilon_{\delta}^{N_k}(\mathbf{x}_k) \implies N_{k+1} = N_{max}$

## $N_{k+1}^{min}$ meghatározása

$$\underbrace{N_{k+1} \leq N_k}_{\downarrow \perp} \xRightarrow{T} N_{k+1}^{min} = N_k^{min}$$

$$\underbrace{N_{k+1} \neq N_j, j = 0, 1, \dots, k}_{\downarrow \perp} \xRightarrow{T} N_{k+1}^{min} = N_k^{min}$$

$$\underbrace{\frac{\hat{\theta}_{N_{k+1}}(x_{l(k)}) - \hat{\theta}_{N_{k+1}}(x_{k+1})}{k+1 - l(k)} < \frac{N_{k+1}}{N_{max}} \epsilon_{\delta}^{N_{k+1}}(x_{k+1})}_{\downarrow \perp} \xRightarrow{T} N_{k+1}^{min} = N_{k+1}$$

$$N_{k+1}^{min} = N_k^{min}$$

$$N_{l(k)-1} \neq N_{k+1}$$

$$N_{l(k)} = N_{l(k)+1} = \dots = N_{l(k)+s} = N_{k+1}$$

$$N_{l(k)+s+1} \neq N_{k+1}, N_{l(k)+s+2} \neq N_{k+1}, \dots, N_k \neq N_{k+1}$$

# Kikötések

**K1**  $f$  aluról korlátos az (SAA) megoldáshalmazán.

$f, H(\cdot, \xi_i) \in C^1(\mathbb{R}^n)$ ,  $i = 1, 2, \dots, N_{max}$ .

$\{x_k\}$ -nak van legalább egy torlódási pontja.

**K2**  $(\exists \kappa > 0, n_1 \in \mathbb{N}) (\forall k \geq n_1) \epsilon_\delta^{N_k}(x_k) \geq \kappa$

**K3**  $d_k$ : csökkenő keresési irány, korlátos és minden  $K \subseteq \mathbb{N}$  halmazra

$$\lim_{k \in K} g_k^T d_k = 0 \implies \lim_{k \in K} g_k = 0.$$

# Konvergencia

## Lemma

*Teljesüljön a K1 feltétel és létezzen olyan  $\bar{n} \in \mathbb{N}$ , hogy  $\mu_k = \bar{\mu}$  és  $N_k = \bar{N}$  minden  $k \geq \bar{n}$  esetén. Ekkor*

$$\lim_{k \rightarrow \infty} dm_k = 0.$$

## Lemma

*Teljesüljenek a K1 és K2 feltételek. Ekkor van olyan  $q \in \mathbb{N}$ , hogy*

$$N_k = N_{max}, \quad \text{minden } k \geq q \text{ esetén.}$$

## Tétel

*Teljesüljenek a K1-K3 feltételek. Ekkor*

$$\lim_{k \rightarrow \infty} \mu_k = \infty.$$

# Konvergencia

## Tétel

*Legyenek érvényesek a K1-K3 feltételek.*

*Ekkor a  $\{z_t\}_{t \in \mathbb{N}}$  sorozat minden  $x^*$  torlódási pontja a  $\min_x \hat{\theta}_{N_{max}}$  probléma stacionárius pontja.*

*Továbbá, ha teljesül az LICQ regularitási feltétel a  $x^*$ -ban, akkor  $x^*$  az (SAA) probléma Karush-Kuhn-Tucker pontja.*

Krejić, N., Krklec, N., Rožnjik A.: Variable sample size method for equality constrained optimization problems,

Optim. Lett. (2017), DOI: 10.1007/s11590-017-1143-8

## Numerikus vizsgálatok

- 14 teszt Hock és Schittkowski problémáiból
- determinisztikus problémák  $c(x)$  feltételi függvénnyel SAA problémákká módosítva

$H(x, \xi) = c(\xi x)$  függvénnyel,

$$\xi \sim \mathcal{N}(1, 1)$$

- 10 minta,  $N_{max} = 2000$  nagysággal problémánként
- BFGS keresési irány  $d_k = -H_k g_k$

$$H_{k+1} = \left( I - \frac{s_k y_k^T}{y_k^T s_k} \right) H_k \left( I - \frac{y_k s_k^T}{y_k^T s_k} \right) + \frac{s_k s_k^T}{y_k^T s_k}$$

$$s_k = x_{k+1} - x_k$$

$$y_k = \nabla \phi(x_{k+1}; N_{k+1}; \mu_k) - \nabla \phi(x_k; N_k; \mu_k)$$

# Numerikus vizsgálatok

- Összehasonlítás:
  - VSS
  - SAA:  $N_k = N_{max}$
  - HEUR:  $N_{k+1} = \lceil \min\{1.1N_k, N_{max}\} \rceil$
- FEV:  $H$  és  $\nabla H$  függvényértékek kiszámításának száma, egyenként számítva a  $\nabla H$  minden komponensét
- kilépési feltétel:

$$\| (\nabla_x \phi(\mathbf{x}_k; N_{max}; \mu_k), \hat{\mathbf{h}}_{N_{max}}(\mathbf{x}_k)) \| \leq 10^{-1}$$

$FEV > 10^8 \implies$  sikertelen módszer

- Dolan és Moré teljesítmény profil (performance profile) alkalmazása az eredmények kimutatására

## Teljesítmény profil

$$m \in \{VSS, SAA, HEUR\}, \quad p = 1, 2, \dots, 140$$

$FEV_{m,p}$ : az  $m$  módszerrel kapott FEV a  $p$  példára  
TELJESÍTMÉNY HÁNYADOS (performance ratio):

$$r_{m,p} = \frac{FEV_{m,p}}{\min_m FEV_{m,p}}$$

teljesítmény hányados kumulatív eloszlásfüggvénye  
módszerenként:

$$\frac{1}{140} \#\{p : r_{m,p} \leq \tau\}$$


TELJESÍTMÉNY PROFIL:

$$P(r_{m,p} \leq \tau : m \in \{VSS, SAA, HEUR\})$$

$\tau = 1 \implies$  a legjobb módszer



# Numerikus vizsgálatok



KÖSZÖNÖM A  
FIGYELMET!