

Title

Aproximativní řešení a hodnota účelové funkce

Petr Lachout

MFF UK, ÚTIA AV ČR

ROBUST - Králíky - únor, 2010

Definice

Budeme se zabývat optimalizačními úlohami.

Uvažujme metrický prostor \mathcal{X} a funkci $f : \mathcal{X} \rightarrow \overline{\mathbb{R}} = [-\infty, +\infty]$.

Zajímá nás **minimální hodnota** funkce f na \mathcal{X}

$$\varphi(f) = \inf \{f(x) \mid x \in \mathcal{X}\}. \quad (1)$$

Definice

Hodnota $+\infty$ vznikne přepisem podmínek $A \subset \mathcal{X}$, za nichž minimalizujeme funkci $g : A \rightarrow \mathbb{R}$. Tedy úlohu

$$\inf \{g(x) \mid x \in A\}$$

přepisujeme na tvar

$$\inf \{f(x) \mid x \in \mathcal{X}\},$$

kde

$$\begin{aligned} f(x) &= g(x) \quad \text{pro } x \in A, \\ &= +\infty \quad \text{pro } x \notin A. \end{aligned}$$

Definice

Funkce, které nabývají pouze hodnoty $+\infty$ nebo jejichž minimální hodnota je $-\infty$, nejsou z hlediska optimalizace příliš zajímavé.

V dalším se proto omezíme pouze na funkce, které jsou **vlastní**, tj. pro něž $\varphi(f) \in \mathbb{R}$.

Definice

Definujeme množinu všech minimálních řešení

$$\Phi(f) = \{x \in \mathcal{X} \mid f(x) = \varphi(f)\}, \quad (2)$$

množiny všech ε -minimálních řešení

$$\Psi(f; \varepsilon) = \{x \in \mathcal{X} \mid f(x) \leq \varphi(f) + \varepsilon\} \quad \forall \varepsilon \in \mathbb{R}, \quad (3)$$

a úrovněvé množiny

$$\text{lev}_\Delta(f) = \{x \in \mathcal{X} \mid f(x) \leq \Delta\} \quad \forall \Delta \in \mathbb{R}. \quad (4)$$

Potřebujeme také vhodnou „míru vzdálenosti“ mezi dvěma množinami. Takovou vhodnou mírou je **excess** z množiny $A \subset \mathcal{X}$ do množiny $B \subset \mathcal{X}$

$$\text{excess}(A, B) = \sup_{a \in A} \inf_{b \in B} d(a, b), \quad (5)$$

kde d je metrika na \mathcal{X} .

Definice

Aproximativním řešením minimalizace funkce f na množině \mathcal{X} budeme rozumět $\theta \in \mathcal{X}$, které splňuje buď

$$\theta \in \Psi(f; \varepsilon)$$

nebo

$$\theta \in \text{lev}_\Delta(f),$$

pro předem zadané ε či Δ .

Definice

Zajímáme se o posloupnost minimalizačních úloh minimalizovat funkci f_t na množině \mathcal{X} pro $t \in \mathbb{N}$.

Zajímá nás asymptotické chování příslušných aproximativních řešení.

Jejich konvergence a řád konvergence.

Definice-posloupnost

Posloupností aproximativních řešení chápeme posloupnost $\theta_t \in \mathcal{X}$, $t \in \mathbb{N}$, která splňuje buď, pro předem zadaná ε_t , $t \in \mathbb{N}$ splňují

$$\theta_t \in \Psi(f_t; \varepsilon_t),$$

nebo pro předem zadaná Δ_t , $t \in \mathbb{N}$ splňují

$$\theta_t \in \text{lev}_{\Delta_t}(f_t).$$

Náhodnost

Nyní přidejme závislost sledovaných úloh na náhodě. Budeme uvažovat pravděpodobnostní prostor $(\Omega, \mathcal{A}, \text{Prob})$ a pro $t \in \mathbb{N}$

$$f_t : \mathcal{X} \times \Omega \rightarrow \overline{\mathbb{R}}, \varphi(f_t(\bullet, \omega)) \in \mathbb{R} \forall \omega \in \Omega,$$
$$\varepsilon_t : \Omega \rightarrow \mathbb{R}.$$

Případně

$$\Delta_t : \Omega \rightarrow \mathbb{R}.$$

Náhodnost

Nyní musíme zobecnit, vysvětlit pojem posloupnosti aproximativních řešení pro případ, kdy úlohy závisí na náhodě.

Budeme uvažovat posloupnost zobrazení $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$.
Máme několik možností, jaké vlastnosti, kvalitu od ní vyžadovat.

Náhodnost-1

Posloupnost $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ nazveme

náhodná ε -minimální řešení, pokud

$$\hat{\theta}_t(\omega) \in \Psi(f_t(\bullet, \omega); \varepsilon_t(\omega)) \quad \forall \omega \in \Omega \quad \forall t \in \mathbb{N},$$

náhodná úrovnově-minimální řešení, pokud

$$\hat{\theta}_t(\omega) \in \text{lev}_{\Delta_t(\omega)}(f_t(\bullet, \omega)) \quad \forall \omega \in \Omega \quad \forall t \in \mathbb{N}.$$

Náhodnost-2

Posloupnost $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ nazveme

skoro jistě ε -minimální řešení, pokud existuje $\Omega_0 \subset \Omega$ takové, že $\text{Prob}(\Omega_0) = 1$ a

$$\hat{\theta}_t(\omega) \in \Psi(f_t(\bullet, \omega); \varepsilon_t(\omega)) \quad \forall \omega \in \Omega_0 \quad \forall t \in \mathbb{N},$$

skoro jistě úrovnově-minimální řešení, pokud existuje $\Omega_0 \subset \Omega$ takové, že $\text{Prob}(\Omega_0) = 1$ a

$$\hat{\theta}_t(\omega) \in \text{lev}_{\Delta_t(\omega)}(f_t(\bullet, \omega)) \quad \forall \omega \in \Omega_0 \quad \forall t \in \mathbb{N}.$$

Náhodnost-3

Posloupnost $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ nazveme

striktně asymptotická ε -minimální řešení, pokud existuje $\Omega_0 \subset \Omega$ takové, že $\text{Prob}(\Omega_0) = 1$ a $\forall \omega \in \Omega_0$

$$\hat{\theta}_t(\omega) \in \Psi(f_t(\bullet, \omega); \varepsilon_t(\omega)) \quad \forall t \in \mathbb{N} \quad \text{dostatečně velká,}$$

striktně asymptotická úrovnově-minimální řešení, pokud existuje $\Omega_0 \subset \Omega$ takové, že $\text{Prob}(\Omega_0) = 1$ a $\forall \omega \in \Omega_0$

$$\hat{\theta}_t(\omega) \in \text{lev}_{\Delta_t(\omega)}(f_t(\bullet, \omega)) \quad \forall t \in \mathbb{N} \quad \text{dostatečně velká.}$$

Náhodnost-4

Posloupnost $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ nazveme

slabě asymptotická ε -minimální řešení, pokud

$$\lim_{t \rightarrow +\infty} \text{Prob}_* \left(\omega \in \Omega : \hat{\theta}_t(\omega) \in \Psi(f_t(\bullet, \omega); \varepsilon_t(\omega)) \right) = 1,$$

slabě asymptotická úrovnově-minimální řešení, pokud

$$\lim_{t \rightarrow +\infty} \text{Prob}_* \left(\omega \in \Omega : \hat{\theta}_t(\omega) \in \text{lev}_{\Delta_t(\omega)}(f_t(\bullet, \omega)) \right) = 1.$$

Konvergence

Cílem je ukázat asymptotické chování náhodných aproximativních řešení. Jelikož však nepředpokládáme měřitelnost, je teorie konvergní trochu složitější. Budeme uvažovat čtyři typy konvergence: as , as^* , v $Prob^*$. a v distribuci. Definice těchto konvergní, jejich vlastnosti a vztahy jsou uvedeny v [VaartWellner(1996)].

▶ Definition of convergences

Konvergence

Je třeba si uvědomit, že stačí vyšetřovat pouze **náhodná ε -minimální řešení**.

Všechny ostatní typy lze na ně převést.

Převod

Nejdříve si povšimněme přímého vztahu mezi ε -optimálním řešením a level-optimálním řešením.

$$\Psi(h; \varepsilon) = \text{lev}_{\varphi(h)+\varepsilon}(h), \quad (6)$$

$$\text{lev}_{\Delta}(h) = \Psi(h; \Delta - \varphi(h)). \quad (7)$$

Konstrukce

Uvažujme posloupnost zobrazení $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ a $\varepsilon_t : \Omega \rightarrow \mathbb{R}_{+,0}$, $t \in \mathbb{N}$.

Zvolme libovolně, ale pevně, $\alpha_t : \Omega \rightarrow \mathbb{R}_+$ s vlastností $\lim_{t \rightarrow +\infty} \alpha_t(\omega) = 0$ pro každé $\omega \in \Omega$.

Nyní dokážeme vybrat $\xi_t : \Omega \rightarrow \mathcal{X}$, $t \in \mathbb{N}$ tak, že

$$\xi_t(\omega) \in \Psi(f_t(\cdot, \omega); \varepsilon_t(\omega) + \alpha_t(\omega)) \quad \forall \omega \in \Omega, \forall t \in \mathbb{N}.$$

Položme dále

$$\begin{aligned} \eta_t(\omega) &= \hat{\theta}_t(\omega) \quad \text{když } \hat{\theta}_t(\omega) \in \Psi(f_t(\cdot, \omega); \varepsilon_t(\omega)) \\ &= \xi_t(\omega) \quad \text{jinak.} \end{aligned}$$

Konstrukce dává posloupnost η_t , $t \in \mathbb{N}$, která splňuje

$$\eta_t(\omega) \in \Psi(f_t(\cdot, \omega); \varepsilon_t(\omega) + \alpha_t(\omega)) \quad \forall \omega \in \Omega, \forall t \in \mathbb{N}.$$

Nyní porovnáme asymptotické vlastnosti $\hat{\theta}_t$, $t \in \mathbb{N}$ a η_t , $t \in \mathbb{N}$.

Konstrukce-vztahy

Lemma

Nechť $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$ jsou skoro jistě ε -minimální řešení nebo striktně asymptotická ε -minimální řešení.

Pak, existuje $\Omega_0 \subset \Omega$, $\text{Prob}(\Omega_0) = 1$ tak, že pro každé $\omega \in \Omega_0$

$$\hat{\theta}_t(\omega) = \eta_t(\omega) \quad \forall t \in \mathbb{N} \quad \text{dostatečně velká.}$$

Následně pro každé $\omega \in \Omega_0$,

$$\text{Ls}(\hat{\theta}_t(\omega), t \in \mathbb{N}) = \text{Ls}(\eta_t(\omega), t \in \mathbb{N}).$$

Konstrukce-vztahy

Označme $\bar{\varepsilon}(\omega) = \limsup_{t \rightarrow +\infty} \varepsilon_t(\omega)$.

Když vezmeme náhodná zobrazení $\tau_t : \Omega \rightarrow \mathbb{R}$, pak pro každé $\omega \in \Omega_0$

$$\begin{aligned} \lim_{t \rightarrow +\infty} \tau_t(\omega) \left[f_t(\hat{\theta}_t(\omega), \omega) - f_t(\eta_t(\omega), \omega) \right] &= 0, \\ \lim_{t \rightarrow +\infty} \tau_t(\omega) \left[\text{excess} \left(\{\hat{\theta}_t(\omega)\}, \Psi(f_t(\bullet, \omega); \bar{\varepsilon}(\omega)) \right) - \right. \\ &\left. - \text{excess} \left(\{\eta_t(\omega)\}, \Psi(f_t(\bullet, \omega); \bar{\varepsilon}(\omega)) \right) \right] = 0. \end{aligned}$$

Konstrukce-vztahy

Lemma

Nechť $\hat{\theta}_t : \Omega \rightarrow \mathcal{X}$ jsou slabě asymptotická ε -minimální řešení.

Pak,

$$\lim_{t \rightarrow +\infty} \text{Prob}_* \left(\hat{\theta}_t = \eta_t \right) = 1.$$

Konstrukce-vztahy

Označme $\bar{\varepsilon}(\omega) = \limsup_{t \rightarrow +\infty} \varepsilon_t(\omega)$.

Následně, když vezmeme náhodná zobrazení $\tau_t : \Omega \rightarrow \mathbb{R}$, pak

$$\tau_t \left[f_t(\hat{\theta}_t) - f_t(\eta_t) \right] \xrightarrow[t \rightarrow +\infty]{\text{Prob}^*} 0,$$

$$\tau_t \left[\text{excess} \left(\{\hat{\theta}_t\}, \Psi(f_t; \bar{\varepsilon}) \right) - \right. \\ \left. - \text{excess} \left(\{\eta_t\}, \Psi(f_t; \bar{\varepsilon}) \right) \right] \xrightarrow[t \rightarrow +\infty]{\text{Prob}^*} 0.$$

Appendix-Topology

We have to recall a few from topological terminology.

Definition

For a sequence η_n , $n \in \mathbb{N}$ in a metric space \mathcal{W} , we denote the set of its cluster points by $\text{Ls}(\eta_n, n \in \mathbb{N})$, i.e.

$$\text{Ls}(\eta_n, n \in \mathbb{N}) = \left\{ \psi \in \mathcal{W} \mid \exists \text{ subsequence s.t. } \lim_{k \rightarrow +\infty} \eta_{n_k} = \psi \right\}.$$

Back

Appendix-Topology

Definition

For a sequence A_n , $n \in \mathbb{N}$ subsets of a metric space \mathcal{W} , we denote the set of its cluster points by $\text{Ls}(A_n, n \in \mathbb{N})$, i.e.

$$\text{Ls}(A_n, n \in \mathbb{N}) = \left\{ \psi \in \mathcal{W} \mid \begin{array}{l} \exists \text{ subsequence } A_{n_k} \text{ and a sequence } \eta_k \in A_{n_k} \\ \text{s.t. } \lim_{k \rightarrow +\infty} \eta_k = \psi \end{array} \right\}.$$

Appendix-Topology

Definition

We say that a sequence η_n , $n \in \mathbb{N}$ in a metric space \mathcal{W} is compact if each its subsequence possesses at least one cluster point.

Compact sequence in metric space possesses an equivalent description.

Lemma

Let η_n , $n \in \mathbb{N}$ be a sequence in a metric space \mathcal{W} . Then, the following statements are equivalent:

1. The sequence is compact.
2. There is a compact $L \subset \mathcal{W}$ tak, že $\eta_n \in L$ for all $n \in \mathbb{N}$.
3. The set $\{\eta_n \mid n \in \mathbb{N}\} \cup \text{Ls}(\eta_n, n \in \mathbb{N})$ is compact.



Appendix-Topology

Lemma

Let η_n , $n \in \mathbb{N}$ be a sequence in a metric space \mathcal{W} and $K \subset \mathcal{W}$ be a compact. If for every open set $G \supset K$ there is an $n_G \in \mathbb{N}$ tak, že $\eta_n \in G$ for all $n \in \mathbb{N}$, $n \geq n_G$.

Then the sequence is compact and $Ls(\eta_n, n \in \mathbb{N}) \subset K$.

Appendix-Nonmeasurable mappings

This auxiliary section contains all necessary theory on nonmeasurable mappings. Definitions and relations are taken from [VaartWellner(1996)], chapter 1.9., p.52-56. All proofs can be found in [VaartWellner(1996)], also.

Definition

For a set $B \subset \Omega$ its outer probability is defined as

$$\text{Prob}^*(B) = \inf \{ \text{Prob}(A) \mid B \subset A, A \in \mathcal{A} \}$$

and the inner probability is

$$\text{Prob}_*(B) = \text{Prob}^*(\Omega \setminus B).$$

Appendix-Nonmeasurable mappings

Definition

For a mapping $T : \Omega \rightarrow \overline{\mathbb{R}}$ the outer integral is defined as

$$E^* [T] = \inf \{ E[U] \mid U \geq T, U : \Omega \rightarrow \overline{\mathbb{R}} \text{ measurable and } E[U] \text{ exists} \}$$

and the inner integral is

$$E_* [T] = -E^* [-T].$$

Appendix-Nonmeasurable mappings

Lemma

For any mapping $T : \Omega \rightarrow \overline{\mathbb{R}}$ there exists a measurable funkce $T^* : \Omega \rightarrow \overline{\mathbb{R}}$ with

1. $T^* \geq T$;
2. $T^* \leq U$ a.s. for every measurable $U : \Omega \rightarrow \overline{\mathbb{R}}$ with $U \geq T$.

The funkce T^* is called a minimal measurable majorant of T and is not uniquely defined.

The funkce $T_* = -(-T)^*$ is called a maximal measurable minorant of T .

Appendix-Nonmeasurable mappings

Lemma

For any $T : \Omega \rightarrow \overline{\mathbb{R}}$

1. $E^*[T] = E[T^*]$ if one of these integrals exists;
2. $E_*[T] = E[T_*]$ if one of these integrals exists.

Definition

Let \mathcal{X} be a metric space with metric d and $X_n, X : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be arbitrary maps.

- ▶ X_n , $n \in \mathbb{N}$ converges *almost surely* to X if

$$\text{Prob}_* \left(\lim_{n \rightarrow +\infty} d(X_n, X) = 0 \right) = 1.$$

We use notation $X_n \xrightarrow[n \rightarrow +\infty]{as} X$.

- ▶ X_n , $n \in \mathbb{N}$ converges *almost uniformly* to X if for every $\varepsilon > 0$ there exists a measurable set $A_\varepsilon \subset \Omega$ with $\text{Prob}(A_\varepsilon) \geq 1 - \varepsilon$ and $d(X_n, X) \rightarrow 0$ uniformly on A_ε , i.e.

$\sup_{\omega \in A_\varepsilon} d(X_n(\omega), X(\omega)) \rightarrow 0$. We use notation $X_n \xrightarrow[n \rightarrow +\infty]{au} X$.

Definition

- ▶ $X_n, n \in \mathbb{N}$ converges *outer almost surely* to X if

$$d(X_n, X)^* \xrightarrow[n \rightarrow +\infty]{as} 0 \quad \text{for some versions of } d(X_n, X)^* .$$

We use notation $X_n \xrightarrow[n \rightarrow +\infty]{as^*} X$.

- ▶ $X_n, n \in \mathbb{N}$ converges *in outer probability* to X if

$$\text{for every } \varepsilon > 0 \quad \text{Prob}^*(d(X_n, X) > \varepsilon) \rightarrow 0.$$

We use notation $X_n \xrightarrow[n \rightarrow +\infty]{\text{Prob}^*} X$.

▶ Random approximate solutions

Appendix-Nonmeasurable mappings

There are known relations between all of these notions of convergences.

Lemma

Let \mathcal{X} be a metric space, $X : \Omega \rightarrow \mathcal{X}$ be Borel measurable and $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be a sequence of arbitrary maps. Then,

- ▶ $X_n \xrightarrow[n \rightarrow +\infty]{as^*} X$ implies $X_n \xrightarrow[n \rightarrow +\infty]{\text{Prob}^*} X$ and $X_n \xrightarrow[n \rightarrow +\infty]{as} X$;
- ▶ $X_n \xrightarrow[n \rightarrow +\infty]{as^*} X$ if and only if $X_n \xrightarrow[n \rightarrow +\infty]{au} X$.

Definition

Let \mathcal{X} be a metric space. The sequence $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ of arbitrary maps is called *asymptotically measurable* if

$$E^* [f (X_n)] - E_* [f (X_n)] \xrightarrow{n \rightarrow +\infty} 0$$

for every bounded continuous funkce $f : \mathcal{X} \rightarrow \mathbb{R}$.

Definition

Let \mathcal{X} be a metric space. The sequence $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ of arbitrary maps is called *strongly asymptotically measurable* if

$$f(X_n)^* - f(X_n)_* \xrightarrow[n \rightarrow +\infty]{as} 0$$

for every bounded continuous funkce $f : \mathcal{X} \rightarrow \mathbb{R}$.

Appendix-Nonmeasurable mappings

Definition

Let \mathcal{X} be a metric space, $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be an asymptotically measurable sequence and $X : \Omega \rightarrow \mathcal{X}$ be random variable. We say that X_n , $n \in \mathbb{N}$ converges *in distribution* to X if

$$E^* [f (X_n)] \xrightarrow[n \rightarrow +\infty]{} E [f (X)]$$

for every bounded continuous funkce $f : \mathcal{X} \rightarrow \mathbb{R}$.

We use notation $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X$.

Appendix-Nonmeasurable mappings

Lemma

Let \mathcal{X} be a metric space, $X : \Omega \rightarrow \mathcal{X}$ be Borel measurable and separable, and $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be a sequence of arbitrary maps. Then,

$X_n \xrightarrow[n \rightarrow +\infty]{as^*} X$ if and only if $X_n \xrightarrow[n \rightarrow +\infty]{as} X$ and X_n , $n \in \mathbb{N}$ is strongly asymptotically measurable.

Appendix-Nonmeasurable mappings

Lemma

Let \mathcal{X} be a metric space, $X : \Omega \rightarrow \mathcal{X}$ be Borel measurable and separable, and $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be a sequence of arbitrary maps, which is asymptotically measurable. Then, $X_n \xrightarrow[n \rightarrow +\infty]{as} X$ implies $X_n \xrightarrow[n \rightarrow +\infty]{\text{Prob}^*} X$.

Appendix-Nonmeasurable mappings

Lemma

Let \mathcal{X} be a metric space, $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be an asymptotically measurable sequence and $X : \Omega \rightarrow \mathcal{X}$. Then

- ▶ If $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X$ then X is measurable, i.e. it is a random variable.
- ▶ $X_n \xrightarrow[n \rightarrow +\infty]{as^*} X$ implies $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X$.
- ▶ $X_n \xrightarrow[n \rightarrow +\infty]{\text{Prob}^*} X$ implies $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X$.
- ▶ If $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X$ and $X \equiv c$ is nonrandom then $X_n \xrightarrow[n \rightarrow +\infty]{\text{Prob}^*} X$.

Portmanteau lemma

Lemma

Let \mathcal{X} be a metric space, $X_n : \Omega \rightarrow \mathcal{X}$, $n \in \mathbb{N}$ be an asymptotically measurable sequence and $X : \Omega \rightarrow \mathcal{X}$ be random variable. Then the following is equivalent:

▶ $X_n \xrightarrow[n \rightarrow +\infty]{\mathcal{D}} X.$



$$E^* [f (X_n)] \xrightarrow[n \rightarrow +\infty]{} E [f (X)] \quad \forall f \in C_b (\mathcal{X}).$$



$$E_* [f (X_n)] \xrightarrow[n \rightarrow +\infty]{} E [f (X)] \quad \forall f \in C_b (\mathcal{X}).$$

Portmanteau lemma








$$\liminf_{n \rightarrow +\infty} \text{Prob}_* (X_n \in G) \geq \text{Prob}(X \in G) \quad \forall G \in \mathcal{G}(\mathcal{X}).$$








$$\limsup_{n \rightarrow +\infty} \text{Prob}^* (X_n \in F) \leq \text{Prob}(X \in F) \quad \forall F \in \mathcal{F}(\mathcal{X}).$$

▶ Random approximate solutions

References

-  Hoffmann-Jørgensen, J.: *Probability with a View Towards to Statistics I, II*. Chapman and Hall, New York, 1994.
-  Kelley, J.L.: *General Topology*. D. van Nostrand Comp., New York, 1955.
-  Lachout, P.: Stability of stochastic optimization problem - nonmeasurable case. *Kybernetika* **44,2**(2008), 259-276.
-  Lachout, P.: Stochastic optimization sensitivity without measurability. In: *Proceedings of MMEI held in Herlány (2007)*, 179-184.
-  Lachout, P.; Liebscher, E.; Vogel, S.: Strong convergence of estimators as ε_n -minimizers of optimization problems. *Ann. Inst. Statist. Math.* **57,2**(2005), 291-313.

References

-  Lachout, P.; Vogel, S.: On Continuous Convergence and Epi-convergence of Random Functions. Part I: Theory and Relations. *Kybernetika* **39,1**(2003), 75-98.
-  Robinson, S.M.: Analysis of sample-path optimization. *Math. Oper. Res.* **21,3**(1996), 513-528.
-  Rockafellar, T.; Wets, R.J.-B.: *Variational Analysis*. Springer-Verlag, Berlin, 1998.
-  Vajda, I.; Janžura, M.: On asymptotically optimal estimates for general observations. *Stochastic Processes and their Applications* **72,1**(1997), 27-45.
-  van der Vaart, A.W.; Wellner, J.A.: *Weak Convergence and Empirical Processes* Springer, New York, 1996.