

# Paskaita 1


## Teorijos pagrindai (minimeemas) teorijos pagrindai

Nagrinateleme  $f$ -js  $y = f(x)$   
apibrėžta realiųjų skaičių ašyje  $\mathbb{R}$ .  
Ieškome tokio taško  $x^0 \in \mathbb{R}$ , kad

$$f(x^0) = \min f(x), \quad x \in \mathbb{R}. \quad (1^*)$$

(Tai reiškia, kad  
 $f(x^0) \leq f(x), \quad x \in \mathbb{R}$ .)

Tokį tašką  $x^0$  vadiname  
globalaus minimumo tašku



Lokālais minimuma punkts.

Nagrinājama funkcija  $x \in [a, b]$ :

$$x \in [a, b]$$

$x^1$  ir lokālais minimuma punkts  
jē

$$f(x^1) = \min_{x \in [a, b]} f(x)$$

$$(t.y. f(x^1) \leq f(x), x \in [a, b]).$$

Aber apibriežināma ir parāšanās,  
bet ir spēcīgas nosacījuma ir  
labai šķīstīgas.

Globalais optimums ir  
ir NP nosacījums. Ir gēlme  
spēsti tap:

Rasti minimumus funkcijai uzdevumā  
rože aprēķinotā robežā  $[a, b]$ .

1. 15 matemātikas analizē paskaity  
zīdome pakankami izpētīdome  
nos šlyps:

Vejerstrasa teorema: Jaigu  $f(x)$   
gra šlydi funkcija ir  $x \in \bar{D}$ ,  
kur  $\bar{D}$  gra uzdara, aprieta robežā;

tai

a)  $\exists m$  šoks,

kad

$$f(x) \geq m, \quad \forall x \in \bar{D}$$

b)  $m$  gra fikslusi apatini rēšis  
i  $\exists x^0 \in \bar{D}$

$$m = f(x^0)$$

Minimizavime uzdaraings šuru  
spendim.

Laip saraksti  $x^0$ , cyke kery mes zinome, ked jis egzistuoja.

Galimas algoritmas (bet NP neapgausime) :

1. Surandame visus lokaliuosius minimumus tases

$$x_1^0, x_2^0, \dots, x_m^0 \in \mathcal{D}$$

$\tilde{x}^0$  - yra tas tases, kuriame

$$f(\tilde{x}^0) \leq f(x_j^0), \quad j=1, \dots, m.$$

2. Surandame krastinis tases

$$\tilde{x}^1 \in \partial \mathcal{D}$$

$$f(\tilde{x}^1) \leq f(x), \quad x \in \partial \mathcal{D}.$$

3. Palyginame

$$f(\tilde{x}^0) \text{ ir } f(\tilde{x}^1).$$

Bedingung stasioneritas syarat


$$\frac{df(x^0)}{dx} = 0$$

Titik stasioner yru kandidat berti minimum atau maksimum :


1. Pakailah syarat, kend menentukan minimum (lokal) atau :

$$\frac{d^2 f(x^0)}{dx^2} > 0$$

$$y = x^2$$



2. Jikalau  $\frac{d^2 f(x^0)}{dx^2} < 0 \Rightarrow$  maksimum (lokal)



3) 0 karp yru, jai  $\frac{d^2 f(x^0)}{dx^2} = 0$  ?

$$y = x^3$$

Kai nagrinėjame  $x \in \mathbb{R}^n$ , tai  
pakeičiame pateiktus rezultatus  
bendresiuoju:  $f = f(x_1, \dots, x_n)$ .

$$\frac{df}{dx} \rightarrow \text{grad } f = \begin{pmatrix} \frac{\partial f}{\partial x_1} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{pmatrix}$$

$$\frac{d^2 f}{dx^2} \rightarrow H = \begin{pmatrix} \frac{\partial^2 f}{\partial x_i \partial x_j} \end{pmatrix}$$

Sąlyga  $\frac{d^2 f}{dx^2} > 0$  yra suvienod.

kaip kvadratinis forma teigiamu-  
men

$$y^T H(x^0) y > 0, \quad \forall y \in \mathbb{R}^n.$$

$y$  - vektorius stulpelis

# Paskaita 1 (teorija)

## Optimizavimo uždaviniai.

Optimizavimo uždaviniai visada  
 buvo aktyvesni - keleruose veiklose  
 seluceme rasti geresni sprendimui,  
 variantu, gaminti ar proceso charakt.  
 teristikos, nei iki tici naudojame  
 ir naudoja konkurentai.

Troje paskaitoje priskirsime uza-  
 davinis, kelesse optimizavimo zingsnis  
 buvo svarbus etapas visame darbe.

Pradetu nuo paprasto klasifikuojos  
 (ja jau minėjome *reus kintamuoju f(x)*  
*atvejint*)

- a) lokalus ekstremumas
- b) globalus ekstremumas.

## Lokalus minimums (maksimums)

Def. Tarsime, kad  $X$  yra metris  
erobis aibe ( $f, y$  galime apskaidinti  
atstump tarp elements).  $f$  metu  $f(x, y)$   
Funkcijai (realus kintamojo) tašku  
 $x^* \in X$  yra lokalus minimums tašku  
(elementas, pv. vektorius), jei  $\exists \varepsilon > 0$ :

$$f(x^*) \leq f(x), \quad \forall x : \rho(x, x^*) \leq \varepsilon$$

Analogiskai apibriskime maksimumus  
savybes.

Aibes  $X$  savybes yra svarbios, kai  
sudarysime minimumus uždavinij sprendi-  
mo algoritmus

- a) atvira aibe  $X$
- b) uždara aibe  $X$
- c) iskloti aibe  $X$



- 9 -


## Global minimum

$x^* \in X$  yra globalus minimumas  
taškas (funkcijai  $f(x)$ ), jei

$$f(x^*) \leq f(x), \quad \forall x \in X.$$

Ekstremumo taškas yra griežtas  
(strong) globalus minimumas taškas,  
jei

$$f(x^*) < f(x), \quad \forall x \in X \text{ ir } x \neq x^*.$$



- nėra griežtas  
(otipras)

globalus ekstremumo  
taškas

Globalaus ekstremumo taškes  
radimus yra daug sunkesnis  
uždavinys (skaičiavimų operacijos skaičius  
daug didesnis)

Todėl:

a) dažnai apsiribojame fik eueristiniai  
algoritmais, leidžiančiais rasti  
globalaus sprendinio artimus.

b) supaprastiname uždavinį (sema-  
tiname jo dimensiją), bet šio užda-  
vinio globalaus ekstremumo taškus  
randame daug efektyviau.

Aptarsime abiejus variantus.

a) Padalīsim  $X \in \mathbb{N}$  svētī

$$X = X_1 \cup X_2 \cup \dots \cup X_N$$

Katruvienu šīs svētī veidojam po  
lokalām ekstrēmuma tāsks

$$x_j^*$$

Tarp jās saraudame mēdāusip

$$\bar{x}^* = \min_{1 \leq j \leq N} x_j^*$$

Šis euristisks algoritms teorētiski paprasta  
gra šedgums, kad jēgu resnīe  
vīrus lokāliis ekstrēmums tāsks  
(svētī  $X$  vīdējs  $n$  aut krests), tai  
šada gēdame Aikslāu īsprests  $n$   
globālam ekstrēmums vīdāvīd

b) suityje  $X$  generuojame (dažindam  
sua) atskituosai parenkame)

$N$  tašky  $x_j \in X, j=1, \dots, N.$

Apskaičiuojame

$$f_j = f(x_j), \quad j=1, \dots, N.$$

Randame globalaus minimumo  
artinę:

$\bar{x}^*$  yra uždav.

arp min  $f_j$   
 $1 \leq j \leq N$

sprendinys

Šiuo metu  
žinomas geriausias  
artinys -  
o gal ir globalaus  
minimumo taškas

$$\bar{x}^* = x_k : f_k \leq f_j, \quad j=1, \dots, N.$$

Optimizavimo uždavinių sprendimo  
algoritmus pažymėjimas:

1. Kiek reikšmų reikia atlikti,  
jei norime rasti sprendimą (tam  
tikrai tikslumui).
2. Kokia informacija yra naudojama  
reikšmėjant algoritmus:

2.1.  $f(x)$  reikšmės

2.2.  $f(x)$ ,  $f'(x)$  reikšmės

2.3.  $f(x)$ ,  $f'(x)$ ,  $f''(x)$  reikšmės

Sąrašas skaičiuotuvui analitinės išvestinės  
reikšmės yra sudėtinga (reikšmų  
daug reikšmų, ypač jei sprendžiame  
daugelį kintamųjų uždav.)

2.4. Išvestines galima skaičiuoti  
apreksimuodami skaitiniais algoritmais

---

Stiprus argumentas, Abulinti  
optimizavimo algoritmus yra  
išsivystę - reikinių technologijų  
poreikiai:

- a) Masinis mokymasis (ML)
- b) DNT (ANN)
- c) Dirbtinis intelektas (AI)

Ap mokymo metu minimuosius  
netikties funkcija (loss function)  
ir nuo šio žingsnio tikslus  
problemas sudaryto Neuroninis  
Atvirkšto galimybės