

# Laboratoriniai darbas 6

AVM modelio realizavimas  
gradientiniu algoritmu  
(sub-gradient descent).

Proz. surime dvi klases ir jos atskleidžia  
pamendojant tiesę (hiper~~tesę~~ plokštumą).

• Tiesės lygtis (3 parametrai  $b_0, b_1, b_2$ )

$$b_0 + b_1 x_1 + b_2 x_2 = 0$$

(pirmame etape sumoškime parametru  
skaičius, imdami  $b_0 = 0$  - tiesę eina per  
centrinį tašką  $(0, 0)$ ).

$$b_1 x_1 + b_2 x_2 = 0$$

• apmokymus duomenys (22 failai)

$$X_j = (x_1^j, x_2^j, y_j), \quad j = 1, 2, \dots, n.$$

# Sub-gradient descent

$f: \mathbb{R}^n \rightarrow \mathbb{R}^n$  yra iškyta (convex) f-ja.

Klasikinis sub-gradientinis metodas.


$$x^{(k+1)} = x^{(k)} - \alpha_k g^{(k)},$$

čia  $g^{(k)}$  yra bet kuris f-jos  $f$  subgradientas taške  $x^{(k)}$ .

Pastaba. Jei  $f$  yra diferencijuojama f-ja, tai  $g^k = \nabla f$  yra gradientas taške  $x^k$ .

Saugome geriausią rezultatą, jei ~~sub~~ <sup>sub</sup> gradientinis metodas ~~naudojamas~~ <sup>naudojamas</sup> kaskart.

$$f_{\text{best}}^{(k)} = \min \{ f_{\text{best}}^{(k-1)}, f(x^k) \}$$



Pembuktian dan sub-gradien sebagai

Ahlihi skripsi di Mulya  
 penerapan di mana Lab 6 di mana

$$f(x) = (b_1 x_1 + b_2 x_2), \quad 0 \leq x_i$$

$$y = b_1 x_1 + b_2 x_2 \quad \nabla$$