

DNT pratybas 3 paskaita
(gradientinio nusileidimo metodas)

input = 0.5
goal = 0.8

Norime išmokyti šilumą
šilumą prognozuoti
rezultatai goal.

Prognozės algoritmas

$$\text{predict} = \text{input} \times \text{weight}$$

Prognozės tikslumą vertiname atsižvelgiant į paklaidą

$$\text{error} = (\text{predict} - \text{goal})^2$$

(python `**2`)

weight = 0.5 (pradinis artinys).

MM atveju atitinku tiesinės regresijos metodą.

Šio metodo surandame

$$\text{weight} = 1.6$$

- 2 -

Apibendrinimas:

turime poras $(input_j, goal_j)$
 $j=1, \dots, M.$

$$error = \sum_{j=1}^M (input_j \times weight - goal_j)^2$$

Išvada francų regresijos kreivę
gavusiai funkcijai ir jos apmokyti
duomeniai.

DNT apmokyti metu vi
išdomi parametras weight
gavusios reikšmės.

Bet - naudojame iteracinių
algoritmų, kurių galėjome
apibūdinti daug sudėtingesni,
DNT architektūros ir
sėkmingas taikymas atvejais.

Pirmame pateiktame algoritme
(27. psl. 9) Paskaita 2.

variuojame svorio weight reikšmę,
radę geresnę reikšmę nusprendžiame
ar didiname, ar mažiname svorio
reikšmę.

- kadaugis nežinome, koki teryptum
keista parametras, weight, σ
ji didiname ir mažiname (bandymai)
- Toks algoritmas sunkiai apibūdinti
našes, bet turime daugiau
svorio parametras (o jis gali būti
daug!).

Todėl nagrinėjame gradientinio
nušleidimo metodus. Ji be paaištinimo
(uostyvacijos) pateikti ir
mokymo svorio kerygo autorius

~~14~~

Kol kas nāgrinētumē vīno kintamojō
f-ja $f(x)$

Norīme vīst $\min f(x) = f(\bar{x}_0)$

$$\arg \min f(x) = \bar{x}_0$$

15 analīzēis ķevro zīvome, kad f-jois
gradiēntas (vīno kintamojō atvejis
 $\frac{df}{dx}$ - īvesthēis vāitesme fāstke \bar{x}_0)

apbrēvīā f-jois grāvēvāesij dīdējums
kryptis: Eīvome antigradiēnta kryptis

$$x_{n+1} = x_n - \gamma \frac{df}{dx}(x_n)$$

γ -parevīvome fāleij, kad $f(x_{n+1}) < f(x_n)$.

$$\text{error}(\text{weight}) = \sum_{j=1}^M (in_j \times \text{weight} - g_j)^2$$

$$\frac{d \text{error}}{d \text{weight}} = 2 \sum_{j=1}^M (in_j \times \text{weight} - g_j) \times in_j$$

Parametru minimizojame anti gradientu kryptium (automatisku rēdame mažjku kryptu?).

$$W_{n+1} = W_n - \gamma_n \cdot 2 \sum_{j=1}^M (in_j \times W_n - g_j) in_j$$

Parametru γ_n parēhame šķē, kad

$$\text{error}(W_{n+1}) < \text{error}(W_n).$$

γ_n parināmus algoritmai gēl bēti zviris, pāpārcācēnās š j j patibit

kelvā γ vērtēnēs (1.5, 1, 0.5, 0.25) i dūtā šķē γ vērtēnē, kadā yu nēšācēnā pāhlēnā $\text{error}(W_{n+1})$.

(Mālymā pācēnā $\gamma_n = 1/2$).

Realiosse DNT atkrynusose
svorio parametrai w_1, w_2, \dots, w_k yra
daug ir reikia rasti jų tiksliausias
reikšmes, kad DNT prognozių tikrumas
būtų kiti galimi geresnis

$$E = E(w_1, w_2, \dots, w_k).$$

Tokios funkcijos gradientas

$$\nabla E = \left(\frac{\partial E}{\partial w_1}, \frac{\partial E}{\partial w_2}, \dots, \frac{\partial E}{\partial w_k} \right)$$

Naują tiklo svorių rinkinį galime
įvesti šiai algoritmu

$$W^{n+1} = W^n - \eta_n \nabla E(W^n),$$

čia

$$W^n = (w_1^n, w_2^n, \dots, w_k^n).$$