

## Paskovta 2

DNT veikimo mechanizmas  
(matematika, kuri generuoja  
stebuklus).

Jau Mokinio mokymuose kurse  
mes apibrėžiame technikas, leidžian-  
čias greitai sudaryti regresijos mode-  
lių tikslumą. Šis aspektas yra  
iš Matematinio modelavimo pinci-  
pinių bloky rinkimų - tik patvirtin-  
su realiais fiziciais eksperimentais  
leidžia vertinti tikrąjį modelio  
tikslumą (ar jo naudojimą).

Natūralu, kad DNT technologijoje  
suvone šviesi svarbūs (svarbiausi?)  
dėmesį prognozei (spėjimui) patikimai  
vertinimui.

O tada natūraliav genome matematinį uždavinį:

- kaip parinkti tinklo parametrus (svorius), kad modelio prognozės palankios būtų mėsaiams (arba bent mėsos, šiek tiek cėdarinis yra praktiškesnis)
- išmolti parinkti optimalių DNT architektūrų, geriausių tinkamų duotajai cėdariniui klasei

Gerųjų rūšis - jau turimi pakankamai tinkamų įrankių (matematinės technikos), kad sudarytume gerus (o kad kada ir netikėtai labai gerus DNT.

## Pakļaudes skaitļdarbus

Šiam klāsimam jau esam paskyruš  
daug daimešu vairinore studijis  
dalijkuose:

- aproksimācijas palubida
- statistiio vērtis funkciun
- masveidus uolymosi prognozes  
palubida.

Ja vairis palubides skaitļdarbus  
teheikos (normas, funkcijis, ...)

Imleuie vektors  $X = (x_1, x_2, \dots, x_m)$

u jo aproksimacijis/prognozes  $Y = (y_1, \dots, y_m)$ .

Tada palubide gelime vērtētis ēvērtis  
būdaris

1. Max palubida:  $E_\infty = \max_j |x_j - y_j|$ .  
( $L_\infty$  norma)

2. Vidutinė paklaida:

$$E_V = \frac{1}{m} \sum_{j=1}^m |x_j - y_j| \quad (L_1\text{-norma})$$

3. Kvadratinė paklaida: (jos kvadratas)

$$E^2 = \frac{1}{m} \sum_{j=1}^m (x_j - y_j)^2 \quad (L_2\text{-norma}) \\ = \sqrt{E^2}$$

Taip pat galime nagrinėti šis  
dėdžius saulyklos versijas

Prz.:

$$\tilde{E}_\infty = \max_j \frac{|x_j - y_j|}{\varepsilon + |x_j|}$$

Aptarhite skirtingų paklaidos  
vertinimų (normų) sąlygas -  $\varepsilon$   
kolius procesy būožen jos atkreipda  
dėdžiusis dėmesį)

Sabar apgalvokime, koks bus  
solmesnis mūsu analīzes etapas,  
kur jau saskaņā ar savu pakalpojumu  
(prognozes, spriedums, ...)

Aisku, jēg pakalpojumu grā māsā  
(koka pakalpojuma grā māsā?)

Ja gūstam pašnovērtēti gēnā  
prognose, rekomendācija, atpazīstināšana

Bet jēgu pakalpojuma grā didelē?  
(kaip tā zīnēti aprūpi, o ne tādā,  
kur jau daļēji jāveic veiksme?)

• Jaigi abu aspektus rezultācija  
perenti pūē mehānismu etapas -  
kurā ir mēģināts DNT, šeit ir veiktas  
rekomendācijas.

## Mokymosi etapas

Šiame etape, vyksta DNT parametru parinkimas, leidžiantis suformuoti prognozes rezultaty paklaidę.

## Matematinis apibrezimas

Parentame parametrus taip, kad tikro funkcija / funkcionalas, apibreziantis prognozes rezultaty paklaidę, būtų minimali.

- Sprendziamu optimizavimo uzduoty.
- Naudojame gradientinio nuskleidimo metode (ir jo modifikacijas).

$$\min_{w_1, w_2, \dots, w_N} f(w_1, w_2, \dots, w_N)$$

$$f(w_1, \dots, w_N) :$$

set weights

$$\text{pred} = \text{input} \times \text{weights}$$

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

Darzināšanas laikā šurimā ievēroti  
keliņš atvejis prognozes.

$$\text{error} = \sum_{j=1}^M (\text{pred}_j - \text{goal}_j)^2$$

$$\boxed{\text{pred}_j = \text{input}_j \times \text{weights}}$$

Kaip sarakstā optimālās sarakstas

$w_1, \dots, w_N$  ?

Vienu  $\times$  elementāru loģisku parentu  
būdu - atbilstošas parāstus ievērotis  
kryptones

Pr. imsimė  $w_j$  ir šio parametro  
reikšmę pakėsimė

$$w_j^{new} = w_j \pm \Delta w.$$

Tada fiksuojame ar po šio pakėti-  
mo prognozei paklaida sumažėja  
(jei sumažėja abiem atvejais, tai keičis  
š atvejis leidžia sumažinti paklaidą  
labiau). Tačiau, kad tai

$$w_j^{new} = w_j + \Delta w.$$

Tada bandome šį procesą pritaikyti

$$w_j^{new} = w_j^{new} \pm \Delta w$$

ir taip gal būt atliksime kelis  
kartus.

Kaip matysime, tai ir yra gradientinio  
nuo nulio metodo esence.



-9-

$$\text{weight} = 0.5$$

$$\text{input} = 0.5$$

$$\text{goal} = 0.8$$

$$\text{stepW} = 0.001$$

(1101  
-tikulu)

for iter in range(1001):

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

$$\text{error} = (\text{prediction} - \text{goal}) \times \times 2$$

$$\text{up\_predict} = \text{input} \times (\text{weight} + \text{stepW})$$

$$\text{up\_error} = (\text{goal} - \text{up\_predict}) \times \times 2$$

$$\text{down\_predict} = \text{input} \times (\text{weight} - \text{stepW})$$

$$\text{down\_error} = (\text{goal} - \text{down\_predict}) \times \times 2$$

if (down\_error < up\_error):

$$\text{weight} = \text{weight} - \text{stepW}$$

if (down\_error > up\_error):

$$\text{weight} = \text{weight} + \text{stepW}$$

Klausimai:

a) ar šis algoritmas konverguoja  
į teisingą atsakymą (visada?)

b) jei ne - tai, kodėl? Ką  
reikia keisti?

Pagalvokite apie tai:

c) pastovūs svorio koeficientai  
žingsnis

d) kaip jie pakeičiami per  
vidurinio specifiku?

Rekomendacija (pagalba)

a) minimizuojame paklaidą!

b) prisiminkite gradientinio  
nušildymo metodus.

-10-

Kol kas nagrinėjame vieno kintamojo

$$f(x)$$

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

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

---

15 analizei keičio žinome, kad  $f$ -jis  
gradientas (vieno kintamojo atveju

$\frac{df}{dx}$  - išvestinės reikšmė taške  $\tilde{x}_0$ )

apibrėžia  $f$ -jis greičiausio didėjimo  
kryptis: Einame antigradiento kryptimi

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

$\gamma$ - parenkame teikį, kad  $f(x_{n+1}) < f(x_n)$ .

- 19 -

ĶeleiĻ kuitamujis adveji:

$$f = f(x_1, x_2, \dots, x_m)$$

Gradientas gra velitoreis:

$$\nabla f = \left( \frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \dots, \frac{\partial f}{\partial x_m} \right)$$

$$X^0 = (x_1^0, x_2^0, \dots, x_m^0)$$

$$X^{n+1} = X^n - \gamma \nabla f(X^n)$$

Mūsiņ DNT pr. 2.

$$\text{error}(\text{weight}) = (\text{input} \times \text{weight} - \text{goal}) \times 2$$

$$\frac{\partial \text{error}(\text{weight})}{\partial \text{weight}} = 2 \cdot (\text{input} \times \text{weight} - \text{goal}) \times \text{input}$$

$$\text{weight}^{n+1} = \text{weight}^n - \gamma 2 \cdot (\text{input} \times \text{weight}^n - \text{goal}) \times \text{input}$$

Mokymu pūemoneis pr.  $\gamma = 1/2$ .