

ԷՄՊԻՐ ԱՒՍՈՒՅՈՒՄ / ԴԱՍ Ը

Առնակի Պաշարյան

18/08/2021

1) Հիշեցում

* $(X_1, Y_1), \dots, (X_n, Y_n)$ անկախ, P^* բաշխումներ
սովորաբար անհայտ

* $f: \mathcal{X} \rightarrow \mathcal{Y}$ շարժի արքայապարհներում
կանխարժեքի

* $f(x; \theta) = \sigma_L(W_L \dots \sigma_1(W_1 x))$ - $(L-1)$ բաժնիկ
շերտով ներքնային զանգ (Ն.Յ), որտեղ
 (L, d_0, \dots, d_L) - կառուցվածք
 $\theta = (W_1, \dots, W_L)$ - պարամետր

* մարման սխալներ (երբ $\mathcal{Y} \subset \mathbb{R}$)

$$\hat{L}_n(f) = \frac{1}{n} \sum_{i=1}^n (Y_i - f(X_i))^2$$

$$\hat{L}_n(\theta) := \hat{L}_n(f(\cdot, \theta))$$

* ERM (empirical risk minimizer)

$$\hat{\theta}_n \in \arg \min_{\theta} \hat{L}_n(\theta) \quad (*)$$

* ինչպես ցույց է տալիս $(*)$ -ը երբ $\theta \in \mathbb{R}^p$ շարժ
ժեռ p -ով է, \hat{L}_n -ը ունի միակից նվազագույն չէ:

* Առնակի սխալներ $L(f) = \mathbb{E}[(Y_i - f(X_i))^2]$:

(1)

2) հիշել է օվերֆիթինգը (overfitting)

* հոտարակալի կանխարկերը

$$f^* \in \arg \min_f L(f)$$

որպեսզի թերմոստը բոլորը հնարավոր կանխարկերից ներքին լինի է: $\mathcal{F} = \{f: X \rightarrow Y \text{ շարժելի}\}$

* շարժելի չէ՞

$$f(\cdot, \theta^*) \text{ որպեսզի } \theta^* \in \arg \min_{\theta \in \mathbb{R}^p} L(\theta)$$

Պիտարկան՝ $\{f(\cdot, \theta): \theta \in \mathbb{R}^p\} \subsetneq \mathcal{F}$,

հետևաբար $L(f^*) \leq L(\theta^*)$:

Աստիճ. $(L(\theta^*) - L(f^*))$ - ը անվանում էմք
ճարարկման սխալմեք (approximation error):

* ERM չէ՞. $\hat{f}_n(\cdot) = f(\cdot, \hat{\theta}_n)$ որպեսզի
 $\hat{\theta}_n$ -ն (*)-ի ստոմ է:

Պիտարկան՝ $L(\theta^*) \leq L(\hat{\theta}_n)$ և
 $\hat{L}_n(\hat{\theta}_n) \leq \hat{L}_n(\theta^*)$


Աստիճ. $(L(\hat{\theta}_n) - L(\theta^*))$ - ն անվանում էմք
գնահատման կամ ուսուցման սխալմեք:

Աստիճ. $|\hat{L}_n(\hat{\theta}_n) - L(\hat{\theta}_n)|$ - ը անվանում էմք
ընդհանրացման սխալմեք (generalisation error):

* Նշանակելով $\mathcal{F}_0 = \{f(\cdot, \theta) : \theta \in \mathbb{R}^p\}$:

a) երբ p -ն փոքր է, \mathcal{F}_0 բացօթյանը փոքր է, և θ^* -ը "հեղուկ" է

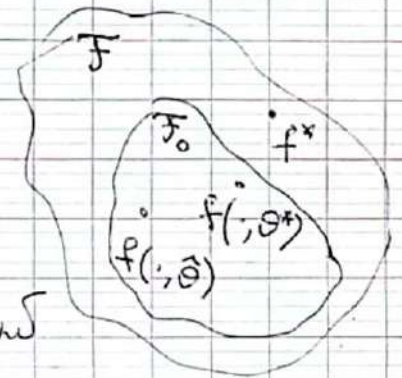
գնահատել: Անփոքարար, այդ դեպքում գնահատման սխալակետը փոքր է, բայց կարող է լինել ճորտարկման սխալակետ: Այս երևույթը անվանում են



«underfitting» (թերառաջում):

b) երբ p -ն լինում է, θ^* -ը ավելի

«բխված» գնահատել, բայց f^* -ը ավելի լավ է ճորտարկում $f(\cdot, \theta^*)$ -ով: Այս երևույթը անվանում են «overfitting» (գերառաջում):



c) Գերառաջման դեպքում, փակի որ լինում է պարամետրերի փակակետ (θ -ի չափողականությունը), փոքր է ճարտման սխալակետը: Խստակետ՝

$$\hat{L}_n(\hat{\theta}_n) = \min_{\theta} \frac{1}{n} \sum_{i=1}^n (Y_i - f(x_i; \theta))^2 = 0:$$

(« կարգաբաշխում - perfect fit »)

Երբ որևէ անհարմար փոքր է նաև գնահատման սխալակետ (կամ ընդհանրացման սխալակետ), ապա գերառաջումը կանխվում է «բարձրակ»: (3

Չարկամ Արտիստային գրադիենտի յերոդրու
 Չարկամ ԽՈՐԶ ՆՅ-երի դեպքում
 րտերի 5 ունենում քարքրակ գերաանան:

3) Օպտիմիզացիա

ինչպես անել $\hat{\theta}_n \in \arg \min_{\theta \in \mathbb{R}^p} \hat{L}_n(\theta)$

օպտիմիզացիայի ինդիքը:

* Գրադիենտի զայրեզգ երբ \hat{L}_n -ը դիֆերենցիալ 5

- ընտրել $\theta_0 \in \mathbb{R}^p$ և $h \in (0, +\infty)$
- հաշվել $\theta_{k+1} = \theta_k - h \nabla \hat{L}_n(\theta_k)$
 $k=0, 1, \dots, K-1$
- Էջանակել $\hat{\theta}_n^{GD} = \theta_K$

GD = Gradient Descent ; h = ուսուցման արագ
 learning rate

* Արտիստային GD

նկարագրել, որ

$$\nabla \hat{L}_n(\theta) = \frac{1}{n} \sum_{i=1}^n \nabla_{\theta} (Y_i - f(X_i, \theta))^2:$$

րել անգամ $\nabla \hat{L}_n$ -ը հաշվելու հաճաք անհրաժեշտ

5 հաշվել $\nabla_{\theta} f(\cdot, \theta)$ -ն n անգամ:

- ընտրել $\theta_0 \in \mathbb{R}^p$ և $h > 0$
- $k=0, 1, \dots, K-1$ հաճաք
 - ընտրել պարահանակներն $i_k \in \{1, \dots, n\}$
 - հաշվել $\theta_{k+1} = \theta_k - h \nabla_{\theta} (Y_{i_k} - f(X_{i_k}, \theta_k))^2$
- Էջանակել $\hat{\theta}_n^{SGD} = \theta_K$

Նկատարենք $\hat{\theta}_n^{GD}$ -ը և $\hat{\theta}_n^{SGD}$ -ը շեղումներ են

(*)-ի տեսքով $\hat{\theta}_n$ -ի հետք, այլ ժխտելով (ստատիստիկական
դիսկրետ) ճորտարկում են այն:

$|L(\hat{\theta}_n^{GD}) - L(\hat{\theta}_n)|$ -ը կորցրած է օպտիմիզացիայի
սխալում:

Նիմուշներ էրենք ցիկլի սխալում

1) ճորտարկում $L(f(\cdot, \theta^*)) - L(f^*)$

2) գնահատում $L(f(\cdot, \hat{\theta}_n)) - L(f(\cdot, \theta^*))$

3) օպտիմիզացիայի $|L(f(\cdot, \hat{\theta}_n^{GD})) - L(f(\cdot, \hat{\theta}_n))|$

Վերջին երեքում կարող ենք օգտագործել գնահատում
սխալում:

ՀԼՈՒԽ \approx ԴԱՍԱԿԱՆ, ՌԻՍԿՍԵՍԱՆ, ՏԵՍՏԻՐՈՅԻՆ

1) Վերջին բոլորի կամայական օրինակ

Պատկեր $(X_1, Y_1), \dots, (X_n, Y_n) \stackrel{iid}{\sim} P^*$ ($\mathcal{X} \times \mathcal{Y}$ -ի վրա)

iid = independent and identically distributed.

$\mathcal{F} = \{f : \mathcal{X} \rightarrow \mathcal{Y} \text{ շարժելի}\}$.

$\mathcal{F}_0 \subset \mathcal{F}$ (\mathcal{F}_0 -ն կարող է լինել չՅ-երի
բազիս)

$l : \mathcal{Y} \times \mathcal{Y} \rightarrow \mathbb{R}$ շարժելի ֆունկցիա, որը

կանխատեսելի կերպով ֆունկցիա: Օրինակ՝

$l(y, y') = (y - y')^2$ կամ $l(y, y') = |y - y'|$: