


- 教師が学習の問題設定




特徴量の例:

画像データ: SIFT, SURF, HOG, Bag-of-words

バイオデータ: マイクロRNAデータ, mRNA発現量

特徴抽出後は統計の問題:



目的関数 = y を予測する関数 $f(x)$ をデータから学習した。

例: 最小二乗法

$$\min_{\beta} \sum_{i=1}^n (y_i - x_i^T \beta)^2$$

- ロス関数 (損失関数)

予測値 $f(x)$ がどれだけ y に近いか

$$l(y, f(x))$$

* ロス関数は目的に合, 右側の l を選ぶ

・ 回帰: $y \in \mathbb{R}$


- 二乗ロス

$$l(y, f) = (y - f)^2$$

- τ 分位ロス

$$l(y, f) = (1 - \tau) \max(f - y, 0) + \tau \max(y - f, 0)$$


(分位点回帰に用いる)



- 判別: $y \in \{\pm 1\}$


◦ ロジスティックロス

$$l(y, f) = \log(1 + \exp(-yf))$$




◦ ヒンジロス

$$l(y, f) = \max(1 - yf, 0)$$



◦ 0-1 ロス

$$l(y, f) = \mathbb{1}[y \neq \text{sign}(f)]$$



- 経験誤差と汎化誤差

n 個のサンプル $\{(x_i, y_i)\}_{i=1}^n$ が与えられるとする。

データをよく説明する関数を求めたい。

任意の可測関数から選ぶことは適当でない。(複雑すぎる)


好適な関数のクラス \mathcal{F} (モデル) を用意

例: $\mathcal{F} = \{f(x) = x^T \beta \mid \beta \in \mathbb{R}^D\}$ (線形モデル)

◦ 経験誤差最小化

$$\hat{f} = \underset{f \in \mathcal{F}}{\text{argmin}} \sum_{i=1}^n l(y_i, f(x_i)) \quad (= \hat{L}(f))$$

* \mathcal{F} が複雑な場合、「過学習」を招くことがある。



サンプルを増やしても収束しない。

◦ 汎化誤差

$$L(f) = \mathbb{E}_{x, y} [l(y, f(x))]$$

"未知のデータ (未知のデータ) への適合性の良さ."
本当の値を求めたい。

$L(f)$ と $\hat{L}(f)$ はほぼ別物 \leftarrow 異なる次元

正則化学習法

$$\min_{f \in \mathcal{F}} \sum_{i=1}^n \ell(y_i, f(x_i)) + R(f)$$

f の "複雑さ" に対する $\lambda + \lambda \sqrt{p}$ の過学習を防ぐ。

・ L_1 -正則化

$$\min_{\beta \in \mathbb{R}^p} \sum_{i=1}^n \ell(y_i, x_i^T \beta) + \lambda \|\beta\|_1$$

ただし、 $\|\beta\|_1 = \sum_{j=1}^p |\beta_j|$

・ カーネル法

$$\min_{f \in \mathcal{H}} \sum_{i=1}^n \ell(y_i, f(x_i)) + \lambda \|f\|_{\mathcal{H}}^2$$

ただし、 \mathcal{H} は "再生核ヒルベルト空間"

L_1 -正則化, L_1 学習

- 変数選択

線形モデル (カーネルモデル)

$$y_i = x_i^T \beta^* + \varepsilon_i \quad (i=1, \dots, n)$$

$$Y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}, \quad X = \begin{bmatrix} x_1^T \\ \vdots \\ x_n^T \end{bmatrix}, \quad \beta^* \in \mathbb{R}^p: \text{真の係数}$$

$$\varepsilon = \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}: \text{ノイズ}, \quad \varepsilon_i \sim N(0, \sigma^2) \text{ i.i.d.}$$

↑
後でカーネル法に使う

$$\Leftrightarrow Y = X\beta^* + \varepsilon$$

n が p に比べて十分大きくないときは

最小乗法だとうまく推定できない: $\|\beta - \beta^*\|_2^2 = O_p\left(\frac{p}{n}\right)$

今、 β^* が L_1 -2 だとする。

かつ、 $k := |\{j \mid \beta_j^* \neq 0\}| \ll p$ とする。

\Rightarrow 十分な情報を削り取る \Rightarrow 変数選択

Marrow's Cp:

$$\min_{\beta} \underbrace{\|Y - X\beta\|^2}_{\text{Fitting}} + 2\sigma^2 \underbrace{\|\beta\|_0}_{\text{Sparsity}}$$

total. $\|\beta\|_0 = |\{j \mid \beta_j \neq 0\}|$.

\Rightarrow NP-困難 \Rightarrow 凸緩和

Lasso: $\min_{\beta \in \mathbb{R}^p} \|Y - X\beta\|^2 + \lambda \|\beta\|_1$

*最近は、様々な効率的な解法が考案されている。


命題

$\| \cdot \|_1$ は $\| \cdot \|_0$ の $[-1, 1]^p$ 上でタイトな凸包絡

証明


(補題)

$$\left[\begin{array}{l} f^*(y) = \sup_x \{y^T x - f(x)\} \quad (\text{Legendre 変換}) \\ \text{ただし} \\ f^{**}(x) \text{ は } f(x) \text{ のタイトな凸包絡} \end{array} \right.$$



$$f(x) = \begin{cases} \|x\|_0 & (x \in [-1, 1]^p) \\ \infty & (\text{otherwise}) \end{cases} \quad \text{ただし}$$

$$f^{**}(x) = \begin{cases} \|x\|_1 & (x \in [-1, 1]^p) \\ \infty & (\text{otherwise}) \end{cases}$$



$[-1, 1]^p$ を 2 次元で延長して x を思い出す。

実際 $\lambda=0$ の推定値が得られる


簡単のため、 $X=I$ (単位行列) とする。

このとき、 β の最適化条件は

$$2(\hat{\beta} - Y) + \lambda \text{sign}(\hat{\beta}) = 0 \quad (\text{微分して 0 とおく})$$

$$\text{sign}(\beta) = (\text{sign}(\beta_j))_{j=1}^p \quad \text{ただし} \quad \text{sign}(\beta_j) = \begin{cases} 1 & (\beta_j > 0) \\ -1 & (\beta_j < 0) \\ [-1, 1] & (\beta_j = 0) \end{cases} \quad \text{2 あり}$$

つまり、 $\hat{\beta}_j = \text{sign}(y_j) \left(y_j - \frac{\lambda}{2} \text{sign}(y_j) \right)_+$



よす
 $|y_j| \leq \frac{\lambda}{2}$ なら $\hat{\beta}_j = 0$
 $\Rightarrow \lambda \|\cdot\|_1 - \lambda \sum$
 (原点への縮小)

Soft-Thresholding 関数

o L_1 -正則化以外の $\lambda \|\cdot\|_1 - \lambda \sum$

- ガル-70 正則化

$$\beta = \begin{bmatrix} \beta_{g_1} \\ \vdots \\ \beta_{g_M} \end{bmatrix}$$


$$\beta_{g_n} \in \mathbb{R}^{|g_n|}$$

g_n は変数の部分集合

$$\|\beta\|_G = \sum_{j=1}^M \|\beta_{g_j}\|_2$$

* ガル-70 $\beta = 0$ のとき $\beta = 0$ となる。

- 一般化 Fused-Lasso



$$G = (V, E)$$

$$V = \{1, 2, \dots, p\}$$

与えらる

$$\|\beta\|_{\text{Fused}} = \sum_{(i,j) \in E} |\beta_i - \beta_j|$$

- HL-ス / ルル 正則化

$$W \in \mathbb{R}^{M \times N}, \text{ 行列}$$

$$\|W\|_{\text{tr}} = \sum_{j=1}^{\min(M,N)} \sigma_j(W)$$

\uparrow
 W の j 番目の特異値

* \hat{W} は 低ランク に拘束する

- 逆分散選択

- 和型 vs. 量+込計型

- Lasso の収束 -

Lasso :

$$\hat{\beta} = \arg \min_{\beta} \frac{1}{n} \|Y - X\beta\|_2^2 + \lambda_n \|\beta\|_1$$

< $\|\hat{\beta} - \beta^*\|_2^2$ の収束 - を解析 >

仮定

(i) $\max_{i,j} |X_{ij}| \leq 1$

(ii) $J = \{j \mid |\beta_j^*| \neq 0\}$, $|J| = k$ ($k \ll n$ を想定)

(iii) ε_i i.i.d. ε_i $E[\varepsilon_i] = 0$ $\sigma^2 > 0$, $\exists \sigma > 0$

$$E[e^{t\varepsilon_i}] \leq e^{\sigma^2 t^2 / 2} \quad \text{for } \forall t \in \mathbb{R}$$

をみたす。 (サドコフイネquality)

例: $-P(\varepsilon_i = 1) = P(\varepsilon_i = -1) = \frac{1}{2}$
 $-\varepsilon_i \sim N(0, \sigma^2)$


(iv) Restricted Eigenvalue Condition (RE(2k, 3))

$$A := \frac{X^T X}{n} = \frac{1}{n} \sum_{i=1}^n x_i x_i^T,$$

に対し

$$\phi_{RE} = \phi_{RE}(2k, 3) = \inf_{\substack{|I| \leq 2k \\ \exists \|v\|_2 \geq \|v_{I^c}\|_2}} \frac{v^T A v}{\|v\|_2^2} \quad \text{or}$$

$0 < \phi_{RE}$ をみたす。 \uparrow ほぼ λ_{\min}^2 くらい制限



補題 (Hoeffding の不等式)

ξ_1, \dots, ξ_n : 独立な (同一と仮定する) 平均 0 の確率変数

$$E[e^{t\xi_i}] \leq e^{\sigma_i^2 t^2 / 2} \quad (\forall t > 0, i=1, \dots, n) \text{ とき}$$

$$P\left(\left|\frac{1}{n} \sum_{i=1}^n \xi_i\right| \geq t\right) \leq 2 \exp\left(-\frac{nt^2}{2\left(\frac{\sum_{i=1}^n \sigma_i^2}{n}\right)}\right)$$

証明

任意の $t > 0$ の不等式より、 $t > 0$ に対し、

$$P\left(\frac{1}{n} \sum_{i=1}^n \xi_i \geq t\right) \leq \frac{E\left[e^{\frac{1}{n} \sum_{i=1}^n \xi_i \times t}\right]}{e^{t^2}} = \frac{\prod_{i=1}^n E\left[e^{\frac{t}{n} \xi_i}\right]}{e^{t^2}} \leq \frac{e^{\left(\frac{n}{n} \sigma^2\right) \frac{1}{2} \left(\frac{t}{n}\right)^2}}{e^{t^2}}$$

ここで $t = \frac{n^2 \sigma}{\sum_{i=1}^n \sigma_i^2}$ とおけば題意を得る。

補題

仮定(i)と仮定(ii)のもと、 $0 < \delta < 1$ に対し

$$P\left(\left\|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_i\right\|_{\infty} \geq \sigma \sqrt{\frac{2 \log(2P/\delta)}{n}}\right) \leq \delta$$

証明

$$\begin{aligned} P\left(\left\|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_i\right\|_{\infty} \geq r\right) &= P\left(\max_{1 \leq j \leq p} \left|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij}\right| \geq r\right) \\ &= P\left(\bigcup_{1 \leq j \leq p} \left|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij}\right| \geq r\right) \\ &\leq \sum_{j=1}^p P\left(\left|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij}\right| \geq r\right) \\ &\leq P \max_{1 \leq j \leq p} P\left(\left|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij}\right| \geq r\right) \end{aligned}$$

ここで、 $\xi_{ij} = \epsilon_i X_{ij}$ とおけば $\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij} = \frac{1}{n} \sum_{i=1}^n \xi_{ij}$ である。

今 $|X_{ij}| \leq 1$ の条件と、 ϵ_i のサトウカウラン性より、

$$E\left[e^{t \xi_{ij}}\right] \leq e^{\frac{\sigma^2 t^2}{2}} \quad (t > 0)$$

である。よって前の補題より、

$$P\left(\left|\frac{1}{n} \sum_{i=1}^n \epsilon_i X_{ij}\right| > r\right) \leq 2 \exp\left(-\frac{n r^2}{2 \sigma^2}\right)$$

である。よって $r = \sigma \sqrt{\frac{2 \log(2P/\delta)}{n}}$ とおけば題意を得る。

定理

$0 < \delta < 1$ を固定せよ。正則化係数 $\lambda_n = 4\sigma \sqrt{\frac{2 \log(2/\delta)}{n}}$ とする。

“確率”の対、ある定数 $C > 0$ が存在し、

$$\|\hat{\beta} - \beta^*\|_2^2 \leq C \frac{\sigma^2}{\phi_{RE}^2} \times \frac{k \log(2/\delta)}{n}$$

が、確率 $1 - \delta$ で成り立つ。

* $\frac{k \log(2/\delta)}{n}$ は $\frac{p}{n}$ より大なり小なり。

証明

$\hat{\beta}$ の定義より、

$$\frac{1}{n} \|Y - X\hat{\beta}\|_2^2 + \lambda_n \|\hat{\beta}\|_1 \leq \frac{1}{n} \|Y - X\beta^*\|_2^2 + \lambda_n \|\beta^*\|_1$$

$$\begin{aligned} \Rightarrow \frac{1}{n} \|X\hat{\beta} - X\beta^*\|_2^2 + \lambda_n \|\hat{\beta}\|_1 &\leq \frac{2}{n} \epsilon^T X (\hat{\beta} - \beta^*) + \lambda_n \|\beta^*\|_1 \quad (\because Y = X\beta^* + \epsilon) \\ &= \frac{2}{n} \sum_{i=1}^p \hat{\beta}_i \epsilon^T X_{\cdot i} - \beta_i^* \epsilon^T X_{\cdot i} \\ &\leq 2 \left\| \frac{1}{n} \epsilon^T X \right\|_\infty \|\hat{\beta} - \beta^*\|_1 + \lambda_n \|\beta^*\|_1 \end{aligned}$$

ここで前の補題より、 $P\left(\left\| \frac{1}{n} \epsilon^T X \right\|_\infty \geq \frac{\lambda_n}{4}\right) \leq \delta$ である。

以後、 $\left\| \frac{1}{n} \epsilon^T X \right\|_\infty \leq \frac{\lambda_n}{4}$ とする。

$$\Rightarrow \frac{1}{n} \|X\hat{\beta} - X\beta^*\|_2^2 + \lambda_n \|\hat{\beta}\|_1 \leq \frac{\lambda_n}{2} \|\hat{\beta} - \beta^*\|_1 + \lambda_n \|\beta^*\|_1 \quad \text{--- ①}$$

ここで、 J^c を $|\hat{\beta}_j|$ の降順に並べた：

$$|\hat{\beta}_{j_1}| \geq |\hat{\beta}_{j_2}| \geq \dots \geq |\hat{\beta}_{j_{p-j_1}}|$$

この上から j_1 個に他の j_2, \dots, j_{p-j_1} が J^c に $j_2 < j_1 < j_3 < \dots$

$$I = J \cup \{j_1, \dots, j_{j_1}\}$$

と置く。すると、 $\beta_{j_1}^* = 0$ ($\forall j_1 \in J^c$) に注意すると、 ① より

$$\frac{1}{n} \|X\hat{\beta} - X\beta^*\|_2^2 + \lambda_n \|\hat{\beta}_{I^c}\|_1 \leq \frac{\lambda_n}{2} (\|\hat{\beta}_I - \beta^*_I\|_1 + \|\hat{\beta}_{I^c} - \beta^*_{I^c}\|_1) + \lambda_n (\|\hat{\beta}_I\|_1 - \|\hat{\beta}_{I^c}\|_1)$$

$$\Rightarrow \frac{1}{n} \|X\hat{\beta} - X\beta^*\|_2^2 + \frac{\lambda_n}{2} \|\hat{\beta}_{I^c}\|_1 \leq \frac{3}{2} \lambda_n \|\hat{\beta}_I - \beta^*_I\|_1 \quad \text{--- ②}$$

よって、 $\hat{\beta} - \beta^*$ は

$$\|(\hat{\beta} - \beta^*)_{I^c}\|_1 \leq 3 \|(\hat{\beta} - \beta^*)_I\|_1$$

が成り立つ。

$$\begin{aligned} &\|\hat{\beta}_I - \beta^*_I\|_1 \\ &\leq \underbrace{\|\hat{\beta}_I - \hat{\beta}_{I^c}\|_1}_{\leq 0} + \|\hat{\beta}_{I^c}\|_1 \end{aligned}$$

よって、 $\hat{\beta} - \beta^*$ は仮定 (iv) の条件を満たすので

9

$$\phi_{RE} \|\hat{\beta}_I - \beta_I^*\|_2^2 \leq \frac{1}{n} \|X(\hat{\beta} - \beta^*)\|_2^2$$

よって、よ2 (2)より

$$\begin{aligned} \|\hat{\beta}_I - \beta_I^*\|_2^2 &\leq \frac{1}{\phi_{RE}} \cdot \frac{3}{2} \lambda_n \|\hat{\beta}_I - \beta_I^*\|_1 \\ &\leq \frac{3}{2\phi_{RE}} \lambda_n \sqrt{2k} \|\hat{\beta}_I - \beta_I^*\|_2 \quad (\because |I| = 2k) \end{aligned}$$

$$\Rightarrow \|\hat{\beta}_I - \beta_I^*\|_2 \leq \frac{3}{2\phi_{RE}} \sqrt{2k} \lambda_n$$

$$\begin{aligned} \text{よって、} \quad \|\hat{\beta} - \beta^*\|_2 - \|\hat{\beta}_I - \beta_I^*\|_2 &\leq \|\hat{\beta}_{I^c} - \beta_{I^c}^*\|_2 \\ &\leq \sqrt{\|\hat{\beta}_{I^c} - \beta_{I^c}^*\|_\infty \|\hat{\beta}_{I^c} - \beta_{I^c}^*\|_2} \\ &\leq \sqrt{\frac{\|\hat{\beta}_I - \beta_I^*\|_1}{k} \|\hat{\beta}_{I^c} - \beta_{I^c}^*\|_2} \\ &\quad \uparrow \text{Iの条件(5)より} \\ &\leq \sqrt{\frac{3}{k}} \|\hat{\beta}_I - \beta_I^*\|_2 \\ &\leq \sqrt{6} \|\hat{\beta}_I - \beta_I^*\|_2 \end{aligned}$$

$$\begin{aligned} \text{よって} \quad \|\hat{\beta} - \beta^*\|_2 &\leq (1 + \sqrt{6}) \|\hat{\beta}_I - \beta_I^*\|_2 \\ &\leq (1 + \sqrt{6}) \times \frac{3}{2\phi_{RE}} \cdot \sqrt{2k} \lambda_n \end{aligned}$$

- REC 条件を満たす X の構成

X が行列 φ の場合、REC 条件は高々確率で成り立つ。

①

RI 条件 (Restricted Isometry 条件, $RI(d, \delta)$)

$$\left[\begin{array}{l} d\text{-sparse な全ての } \beta \in \mathbb{R}^p \text{ に対し } (\|\beta\|_0 \leq d) \\ (1-\delta)\|\beta\|_2 \leq \frac{\|X\beta\|_2}{\sqrt{n}} \leq (1+\delta)\|\beta\|_2 \\ \text{が成り立つ。} \end{array} \right.$$

補題

$$\left[\begin{array}{l} \forall \delta > 0, 0 < \epsilon < \gamma, b > 0 \text{ とし} \\ d = \left\lceil R \left[1 + \left(\frac{16(3b)^2(3b+1)}{\delta^2} \right) \right] \right\rceil \\ \text{とおく。このとき } X \in \mathbb{R}^{n \times p} \text{ が} \\ RI(d, \delta) \text{ を満たすならば } RE(\epsilon, b) \text{ を満たし} \\ 0 < \sqrt{1-\delta} \leq \phi_{RE}(\epsilon, b, X) \\ \text{である。} \end{array} \right.$$

(証明は省略)

よって、上で定義した $d (= d(\epsilon, b))$ において、 $RI(d, \delta)$ が成り立つのは自明。

定義 (isotropic sub-Gaussian)

\mathbb{R}^p に値を取る確率変数 Y が次の条件を満たすとき、 Y は isotropic (d) -subGaussian であるという

(1) $\forall y \in \mathbb{R}^p$ に対し、

$$E \langle Y, y \rangle^2 = \|y\|_2^2 \quad (\text{等方的})$$

(2) 定数 d が存在し、 $\forall y \in \mathbb{R}^p$ に対し

$$\| \langle Y, y \rangle \|_{\psi_2} = \inf \{ t \mid E[\exp(\langle Y, y \rangle^2 / t^2)] \leq 2 \} \leq d \|y\|_2$$

22-239-2 正しくは $E[\cdot] - 1 \leq 1$ の表示

例 (1) $Y_i \sim N(0, 1)$ (i.i.d.) のとき

isotropic subGaussian.

(2) $P(Y_i = 1) = P(Y_i = -1) = \frac{1}{2}$ (i.i.d.) のとき、isotropic sub Gaussian

(see Vershynin)

* Sub-Exponential だと仮定が議論が可成り

定理

$X = \begin{bmatrix} x_1^T \\ \vdots \\ x_n^T \end{bmatrix} \in \mathbb{R}^{n \times p}$ かつ、各行ベクトル $x_i \in \mathbb{R}^p$ は独立な isotropic

d -subGaussian であるとする。すなわち $d \leq p$, $0 < \delta < 1$ に対し、

$$n \geq \frac{80 d d^4}{\delta^2} \log\left(\frac{12ep}{d\delta}\right) \quad \left(n = \Omega\left(d \log\left(\frac{p}{d}\right)\right) \right)$$

$\Omega(p)$ ではない。

ならば、全ての d -norm λ に対し、

$$(1-\delta) \|p\|_2 \leq \frac{1}{n} \|Xp\|_2 \leq (1+\delta) \|p\|_2 \quad (RI(d, \delta))$$

確率 $1 - 2 \exp(-\delta^2 n / 80 d^4)$ で成り立つ。

* Johnson-Lindenstrauss の補題 とおぼえらる。距離空間の低次元 ϵ -近似的空間の等長埋め込み。

証明

補題

$Y_i \in \mathbb{R}$ ($i=1, \dots, n$) を独立な確率変数とする。

$E[Y_i^2] = 1$, $\|Y_i\|_2 \leq d$ かつ $\lambda=1, \dots, n$ で成り立つとき

$\forall t \in (0, 1)$ において、

$$P\left(\left|\frac{1}{n} \sum_{i=1}^n Y_i^2 - 1\right| > t\right) \leq 2 \exp\left(-\frac{t^2 n}{10d^4}\right)$$

である。($t > 1$ には成り立たない)

(証明は略)

RI-条件を示すには、 $\|p\|_2 = 1$ として一般性を失わない。

今 $I \subseteq \{1, 2, \dots, p\}$ に対し、 $\Pi_I := \{p \in \mathbb{R}^p \mid p_j = 0 \text{ (} j \notin I \text{)}, \|p\|_2 = 1\}$ とおす。

Π_I を有限個の点で代表させることを考える。

今 $H_I \subseteq \Pi_I$ かつ Π_I の代表 $\beta \in \Pi_I$ に対し $\exists g \in H_I$ として $\|p - g\|_2 \leq \epsilon$ とおすように H_I をとる。


$$|H_I| \leq \left(\frac{3}{\epsilon}\right)^{|I|}$$

よってこれを ϵ -ネットと知られる。(超球面のカッリンカタンク)

さらに

$$\bigcup_{|I|=d} \Pi_I = \Pi, \quad \bigcup_{|I|=d} H_I = H$$

よって、 $\forall p \in \Pi$ に対し、 $\exists g \in H$ として $\|p - g\|_2 \leq \epsilon$ である。



$$\binom{p}{d} = \frac{p \dots (p-d+1)}{d!}$$

$$\approx \frac{p^d}{d!} = \frac{p^d}{d^d \left(\frac{d}{e}\right)^d} = \left(\frac{ep}{d}\right)^d$$

total: $\frac{1}{2^d} \leq \lambda \leq \frac{1}{2^d}$
 $\Rightarrow d! \geq \left(\frac{d}{e}\right)^d$

$$\begin{aligned} \#H &\leq \left(\frac{3}{\epsilon}\right)^d \binom{p}{d} \\ &\leq \left(\frac{3}{\epsilon}\right)^d \left(\frac{ep}{d}\right)^d \\ &= \exp\left(d \log\left(\frac{3ep}{d\epsilon}\right)\right) \end{aligned}$$

まずは $H = \text{span}\{\beta\}$ は RL 条件が成り立つ $\Rightarrow \exists \epsilon > 0$ なる ϵ がある。

ある $\beta \in H \ni 1$ 固定すれば、補題より

$$\begin{aligned} & P\left(\left|\frac{1}{n}\|X\beta\|_2^2 - 1\right| \geq \epsilon\right) \\ &= P\left(\left|\frac{1}{n} \sum_{i=1}^n \langle x_i, \beta \rangle^2 - 1\right| \geq \epsilon\right) \\ &\leq 2 \exp\left(-\frac{n\epsilon^2}{10d^4}\right) \quad (\text{かつ}) \quad (\because x_i \text{ は isotropic } d\text{-subGaussian}) \end{aligned}$$

よって、

$$\begin{aligned} & P\left(\left|\frac{1}{n}\|X\beta\|_2^2 - 1\right| \geq \epsilon, \forall \beta \in H\right) \\ &\leq \sum_{\beta \in H} P\left(\left|\frac{1}{n}\|X\beta\|_2^2 - 1\right| \geq \epsilon\right) \\ &\leq 2|H| \exp\left(-\frac{n\epsilon^2}{10d^4}\right) \\ &\leq 2 \exp\left(\log(|H|) - \frac{n\epsilon^2}{10d^4}\right) \leq 2 \exp\left(d \log\left(\frac{3ep}{d\epsilon}\right) - \frac{n\epsilon^2}{10d^4}\right) \end{aligned}$$

$$\left[n \geq \frac{20d^4}{\epsilon^2} \log\left(\frac{3ep}{d\epsilon}\right) \quad \text{とすると} \right] \\ \leq 2 \exp\left(-\frac{n\epsilon^2}{20d^4}\right).$$

よ2. $\forall \beta \in H$ に対し.

$$1 - \epsilon \leq \frac{1}{n}\|X\beta\|_2^2 \leq 1 + \epsilon$$

$$\Rightarrow 1 - \epsilon \leq \frac{1}{n}\|X\beta\|_2 \leq 1 + \frac{\epsilon}{2} \quad (\epsilon \in (0, 1))$$

with prob $1 - 2 \exp\left(-\frac{n\epsilon^2}{20d^4}\right)$.

よ2. $\sup_{\beta \in \Pi} \frac{1}{n}\|X\beta\|_2 = \|\frac{X}{n}\|_{\infty}$ とおくと。

$\forall \beta \in \Pi$ に対し、 $\exists \beta \in H$ 且 $\|\beta - \beta\|_2 \leq \epsilon$ かつ $\frac{\beta - \beta}{\|\beta - \beta\|_2} \in \Pi$ と仮定する。

$$\begin{aligned} \frac{1}{n}\|X\beta\|_2 &= \frac{1}{n}\|X(\beta - \beta + \beta)\|_2 \leq \frac{1}{n}\|X(\beta - \beta)\|_2 + \frac{1}{n}\|X\beta\|_2 \\ &\leq \epsilon \|\frac{X}{n}\|_{\infty} + 1 + \frac{\epsilon}{2} \end{aligned}$$

よ2. 左辺の $\sup_{\beta \in \Pi}$ とおくと。

$$\|\frac{X}{n}\|_{\infty} \leq \frac{1 + \frac{\epsilon}{2}}{1 - \epsilon}$$

よってこれが成り立つ。同様にして $\frac{1}{n}\|X\beta\|_2 \geq 1 - \epsilon - \left(\frac{1 + \frac{\epsilon}{2}}{1 - \epsilon}\right)\epsilon$ 成り立つ。

$\epsilon = \frac{\delta}{1+\delta} \quad (0 < \delta < \frac{1}{2})$

$1-2\delta \leq \frac{1}{m} \|X\beta\|_2 \leq 1+2\delta \quad (\forall \beta \in \Pi)$

を得る。 $\delta = 2\epsilon$ とおくと上記を得る。

より詳しくは、

Rudelson & Zhou: Reconstruction From Anisotropic Random Measurements.

IEEE Trans. Info. Th., vol. 59, No. 6, 3434-3447.

を参照のこと。


応用例:

- 圧縮センシング

ある β^* に対し $Y = X\beta^*$ を観測

$X \in \mathbb{R}^{n \times p}$ を $n \ll p$ とおす。

→ p 次元を n 次元に"圧縮"



$\hat{\beta} = \underset{\beta \in \mathbb{R}^p}{\operatorname{argmin}} \{ \|\beta\|_1 \mid X\beta = Y \}$

定理 (Candès, 2008)

$X \in \mathbb{R}^{n \times p}$ を $\delta < \frac{1}{\sqrt{2}}$ とおくと β^* を $\|\beta^*\|_1$ とおす。

$\hat{\beta} = \beta^*$

と成す。 (Exact recovery)

$n \geq Ck \log(\frac{p}{k})$ と成す

- 大規模行列の SVD (Halko, Martinson, Tropp; 2011)

$A \in \mathbb{R}^{M \times N}$: 大規模, ほぼ低ランク or 特異値の減少が速い行列

