

LARS 最適化の方法

池田 思朗

統数研

4 August 2009



- 二次計画法と Lasso
- Lasso と Elastic net
- LARS-Lasso
- 線形計画法と Compressed Sensing



二次計画法

$\mathbf{x} = (x_1, \dots, x_n)^t$ を実数ベクトルとして, この \mathbf{x} に関する次のような最適化問題を考えるとき, これを二次計画問題 (Quadratic Programming) と呼ぶ.

基本形式

$$\begin{aligned} \min_{\mathbf{x}} \quad & \frac{1}{2} \mathbf{x}^t H \mathbf{x} + \mathbf{f}^t \mathbf{x} \\ \text{subject to} \quad & \\ & A \mathbf{x} \leq \mathbf{b}. \end{aligned}$$

ただし, H は n 次の半正定値対称行列, \mathbf{f} は n 次の実ベクトルである.



二次計画法

二次計画法を解く数値処理パッケージは沢山存在する。問題や計算機環境に応じて適切なものが選択できる。

これを用いて Lasso の問題を解く。

Lasso の問題 (再掲)

$$\min_{\beta_1, \dots, \beta_p} \left(y_i - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_j |\beta_j|$$
$$\min_{\beta_1, \dots, \beta_p} \|\mathbf{y} - X\boldsymbol{\beta}\|_{\ell_2}^2 + \lambda \|\boldsymbol{\beta}\|_{\ell_1}$$



Lasso 再考

$\mathbf{y} = (y_1, \dots, y_n)^t$, $X = \{x_{ij}\}$, $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)^t$ として

Lasso の問題 (再掲)

$$\begin{aligned} & \min_{\beta_1, \dots, \beta_p} \|\mathbf{y} - X\boldsymbol{\beta}\|_{\ell_2}^2 + \lambda \|\boldsymbol{\beta}\|_{\ell_1} \\ & = \mathbf{y}^t \mathbf{y} + \min_{\boldsymbol{\beta}} (\boldsymbol{\beta}^t X^t X \boldsymbol{\beta} - 2\mathbf{y}^t X \boldsymbol{\beta}) + \lambda \sum_{j=1}^p |\beta_j| \end{aligned}$$



Lasso と拡張した問題

ここで $\beta_j = \beta_j^+ - \beta_j^-$ とふたつの成分に分ける. ただし, $\beta_j^+, \beta_j^- \geq 0$.

Lasso の問題

$$\min_{\beta^+, \beta^-} \left[(\beta^+ - \beta^-)^t X^t X (\beta^+ - \beta^-) - 2\mathbf{y}^t X (\beta^+ - \beta^-) \right] + \lambda(\beta^+ + \beta^-)$$

subject to

$$\beta_j^+, \beta_j^- \geq 0 \quad j = 1, \dots, p.$$

$\beta_j = \beta_j^+ - \beta_j^-$ となる正の β_j^+, β_j^- の組は無数にあるが, そのうちで $\beta_j^+ + \beta_j^-$ を最小にするのはどちらかが 0 となる場合に限る.



Lasso を二次計画法の基本問題へ

$\gamma = (\beta_1^+, \dots, \beta_p^+, \beta_1^-, \dots, \beta_p^-)^t$ を $2p$ の長さのベクトルとおくと

Lasso の問題

$$\min_{\gamma} \left[\gamma^t \begin{pmatrix} X^t X & -X^t X \\ -X^t X & X^t X \end{pmatrix} \gamma + \begin{pmatrix} -2X^t \mathbf{y} + \lambda \mathbf{1}_p \\ 2X^t \mathbf{y} + \lambda \mathbf{1}_p \end{pmatrix}^t \gamma \right]$$

subject to

$$-E_{2p} \gamma \leq \mathbf{0}_{2p}.$$

$\mathbf{0}_n, \mathbf{1}_n$ はそれぞれ n 次元の $0, 1$ を成分とするベクトル, E_n は $n \times n$ の単位行列である.



Lasso を二次計画法の基本問題へ

基本形式: 再掲

$$\begin{aligned} \min_{\mathbf{x}} \quad & \frac{1}{2} \mathbf{x}^t H \mathbf{x} + \mathbf{f}^t \mathbf{x} \\ \text{subject to,} \quad & A \mathbf{x} \leq \mathbf{b}, \end{aligned}$$

拡張した Lasso の問題: 再掲

$$\begin{aligned} \min_{\boldsymbol{\gamma}} \quad & \left[\boldsymbol{\gamma}^t \begin{pmatrix} X^t X & -X^t X \\ -X^t X & X^t X \end{pmatrix} \boldsymbol{\gamma} + \begin{pmatrix} -2X^t \mathbf{y} + \lambda \mathbf{1}_p \\ 2X^t \mathbf{y} + \lambda \mathbf{1}_p \end{pmatrix}^t \boldsymbol{\gamma} \right] \\ \text{subject to} \quad & -E_{2p} \boldsymbol{\gamma} \leq \mathbf{0}_{2p}. \end{aligned}$$

$$H = 2 \begin{pmatrix} X^t X & -X^t X \\ -X^t X & X^t X \end{pmatrix}, \mathbf{f} = \begin{pmatrix} -2X^t \mathbf{y} + \lambda \mathbf{1}_p \\ 2X^t \mathbf{y} + \lambda \mathbf{1}_p \end{pmatrix}, A = -E_{2p}, \mathbf{b} = \mathbf{0}_{2p}$$



- 二次計画法と Lasso
- Lasso と Elastic net
- LARS-Lasso
- 線形計画法と Compressed Sensing



Elastic net

Elastic net の問題 (再掲)

$$\begin{aligned} & \min_{\beta_1, \dots, \beta_p} \|\mathbf{y} - X\boldsymbol{\beta}\|_{\ell_2}^2 + \lambda_2 \|\boldsymbol{\beta}\|_{\ell_2}^2 + \lambda_1 \|\boldsymbol{\beta}\|_{\ell_1} \\ & = \mathbf{y}^t \mathbf{y} + \min_{\boldsymbol{\beta}} (\boldsymbol{\beta}^t (X^t X + \lambda_2 E_p) \boldsymbol{\beta} - 2\mathbf{y}^t X \boldsymbol{\beta}) + \lambda_1 \|\boldsymbol{\beta}\|_{\ell_1} \end{aligned}$$

よって、 $X^t X$ を $X^t X + \lambda_2 E_p$ によって置き換えることで、Lasso と同様に扱うことができる。



- 二次計画法と Lasso
- Lasso と Elastic net
- **LARS-Lasso**
- 線形計画法と Compressed Sensing





Lasso の解を求める

ある λ に対して Lasso の解を求める場合は以上のように二次計画法を用いれば良い。

しかし、以下のような場合、各 λ に対して二次計画法を適用するのは手間である。

- λ を様々な値に設定しながら lasso を解きたい
- 大規模な問題を解きたい。

LARS-lasso と呼ばれるアルゴリズムを説明する。

-  Efron, Hastie, Johnstone, & Tibshirani, (2004). "Least angle regression," *The Annals of Statistics*, 32(2), 407-499.
-  Rosset & Zhu, (2007). "Piecewise linear regularized solution paths," *The Annals of Statistics*, 35(3), 1012-1030.



二次計画法

ある λ に対する Lasso の解を $\hat{\beta}(\lambda)$ と書くことにする.

Lasso の問題 (再掲)

$$\hat{\beta}(\lambda) = \arg \min_{\beta} \|\mathbf{y} - X\beta\|_{\ell_2}^2 + \lambda \|\beta\|_{\ell_1}$$



Lasso の解を求める

Lasso

$$\min_{\beta^+, \beta^-} \left[\|\mathbf{y} - X(\beta^+ - \beta^-)\|_{\ell_2}^2 + \lambda \sum_{j=1}^p (\beta_j^+ + \beta_j^-) \right]$$

subject to $\beta_j^+, \beta_j^- \geq 0 \quad j = 1, \dots, p.$

ラグランジュ関数

$$\min_{\beta^+, \beta^-} \left[L(\beta) + \lambda \sum_{j=1}^p (\beta_j^+ + \beta_j^-) - \sum_{j=1}^p \lambda_j^+ \beta_j^+ - \sum_{j=1}^p \lambda_j^- \beta_j^- \right]$$

ただし $L(\beta) = \|\mathbf{y} - X(\beta^+ - \beta^-)\|_{\ell_2}^2.$



Lasso の解を求める

Karush-Kuhn-Tucker 条件 (最適性の必要条件)

$$\begin{aligned}\partial_{\beta_j} L(\boldsymbol{\beta}) + \lambda - \lambda_j^+ &= 0 \\ -\partial_{\beta_j} L(\boldsymbol{\beta}) + \lambda - \lambda_j^- &= 0 \\ \lambda_j^+ \beta_j^+ &= 0, \quad \lambda_j^+ \geq 0 \\ \lambda_j^- \beta_j^- &= 0, \quad \lambda_j^- \geq 0 \quad j = 1, \dots, p.\end{aligned}$$

この条件を調べる。ただし

$$\partial_{\beta_j} L(\boldsymbol{\beta}) = \frac{\partial L(\boldsymbol{\beta})}{\partial \beta_j} = -2(\mathbf{y} - X\boldsymbol{\beta})^t \mathbf{x}_j$$

また, $\mathbf{x}_j = (x_{1j}, \dots, x_{nj})^t$ は X の j 番目の列ベクトルである。



Lasso の解を求める

最適値を与える β_j の満たす必要条件はいくつかの場合に分けられる.

(i) $\lambda = 0$

$$\partial_{\beta_j} L(\boldsymbol{\beta}) = 0 \quad (\lambda_j^+, \lambda_j \geq 0 \text{ より } \partial_{\beta_j} L(\boldsymbol{\beta}) = \lambda_j^+ = -\lambda_j^- = 0)$$

(ii) $\beta_j^+ > 0, \lambda > 0$

$$\partial_{\beta_j} L(\boldsymbol{\beta}) = -\lambda, \beta_j^- = 0 \quad (\lambda_j^+ = 0, \lambda_j^- > 0 \text{ より})$$

(iii) $\beta_j^- > 0, \lambda > 0$

$$\partial_{\beta_j} L(\boldsymbol{\beta}) = \lambda, \beta_j^+ = 0 \quad (\lambda_j^+ > 0, \lambda_j^- = 0 \text{ より})$$

$$|\partial_{\beta_j} L(\boldsymbol{\beta})| \leq \lambda,$$

LARS-Lasso

λ によって β_j の成分のうち “Active”, すなわち 0 でない成分が変わる.
0 でない成分の添字の集合を \mathcal{A} とおく. $\mathcal{A} = \{j : \hat{\beta}_j(\lambda) \neq 0\}$

Active な係数の満たす条件

$$j \in \mathcal{A} \Rightarrow \partial_{\beta_j} L(\hat{\beta}(\lambda)) = -\text{sgn}(\hat{\beta}_j(\lambda))\lambda$$

Active でない係数の満たす条件

$$j \notin \mathcal{A} \Rightarrow |\partial_{\beta_j} L(\hat{\beta}(\lambda))| \leq \lambda$$



LARS-Lasso

$$\begin{aligned} \partial_{\beta_A} \partial_{\beta_A} L(\hat{\beta}(\lambda)) \frac{\partial \hat{\beta}_A(\lambda)}{\partial \lambda} &= -\text{sgn}(\hat{\beta}_A(\lambda)) \\ \frac{\partial \hat{\beta}_A(\lambda)}{\partial \lambda} &= -\left(\partial_{\beta_A} \partial_{\beta_A} L(\hat{\beta}(\lambda))\right)^{-1} \text{sgn}(\hat{\beta}_A(\lambda)) \end{aligned}$$

ここで添字の A は $j \in A$ となる添字 j をとりだしたものの。また、 $\partial_{\beta_A} \partial_{\beta_A} L(\hat{\beta}(\lambda)) = 2X_A^t X_A$ 。したがって

$$\frac{\partial \hat{\beta}_A(\lambda)}{\partial \lambda} = -\frac{1}{2} \left(X_A^t X_A\right)^{-1} \text{sgn}(\hat{\beta}_A(\lambda))$$



LARS-Lasso

Algorithm

- ① $\beta = 0$, $\mathcal{A} = \{\arg \max_j |\mathbf{y}^t \mathbf{x}_j|\}$, $\gamma_{\mathcal{A}} = -\text{sgn}(-\mathbf{y}^t \mathbf{x}_{\mathcal{A}})$, $\gamma_{\mathcal{A}^c} = 0$
- ② $\max |\partial_{\beta_j} L(\beta)| > 0$ ならば以下の手続きを行なう.
 - i $d_1 = \min\{d > 0 : |\partial_{\beta_j} L(\beta + d\gamma)| = |\partial_{\beta_{\mathcal{A}}} L(\beta + d\gamma)|, j \notin \mathcal{A}\}$
 $d_2 = \min\{d > 0 : (\beta + d\gamma)_j = 0, j \in \mathcal{A}\}$
 $d = \min(d_1, d_2)$
 - ii $\beta \leftarrow \beta + d\gamma$
 $d = d_1$ ならば d_1 として選ばれた j を \mathcal{A} に加える.
 $d = d_2$ ならば d_2 として選ばれた j を \mathcal{A} から取り除く.
 - iii $\gamma_{\mathcal{A}} = -(X_{\mathcal{A}}^t X_{\mathcal{A}})^{-1} \text{sgn}(\partial_{\beta_{\mathcal{A}}} L(\beta))$, $\gamma_{\mathcal{A}^c} = \mathbf{0}$ と更新する.
 - iv ステップ 2 へ



LARS-Lasso

① $\beta = 0, \mathcal{A} = \{\arg \max_j |\mathbf{y}^t \mathbf{x}_j|\}, \gamma_{\mathcal{A}} = -\text{sgn}(-\mathbf{y}^t \mathbf{x}_{\mathcal{A}}), \gamma_{\mathcal{A}^c} = 0$

初期値の設定: λ が無限に大きいとき, 全てのパラメータは 0 有限の大きい値のときには, β_j として $\mathbf{y}^t \mathbf{x}_j$ を最大にする j を選ぶのが良い

② $\max |\partial_{\beta_j} L(\beta)| > 0$ ならば以下の手続きを行なう.

全ての $\partial_{\beta_j} L(\beta) = 0$ ならば制約のない最適化問題となっていることを示す. このときにはさらに更新する必要はない.



LARS-Lasso

$$\begin{aligned}
 i \quad & d_1 = \min\{d > 0 : |\partial_{\beta_j} L(\boldsymbol{\beta} + d\boldsymbol{\gamma})| = |\partial_{\beta_{j \in \mathcal{A}}} L(\boldsymbol{\beta} + d\boldsymbol{\gamma})|, j \notin \mathcal{A}\} \\
 & d_2 = \min\{d > 0 : (\boldsymbol{\beta} + d\boldsymbol{\gamma})_j = 0, j \in \mathcal{A}\} \\
 & d = \min(d_1, d_2)
 \end{aligned}$$

d_1 は Active でない係数の満たす条件 $j \notin \mathcal{A} \Rightarrow |\partial_{\beta_j} L(\hat{\boldsymbol{\beta}}(\lambda))| \leq \lambda$ が破綻し、ある Active でない係数が Active となる場合がいつかを調べる。

d_2 は Active な係数の満たす条件 $j \in \mathcal{A} \Rightarrow \partial_{\beta_j} L(\hat{\boldsymbol{\beta}}(\lambda)) = -\text{sgn}(\hat{\beta}_j(\lambda))\lambda$ が係数が 0 となることで破綻する場合がいつかを調べる。



LARS-Lasso

$$\text{ii } \boldsymbol{\beta} \leftarrow \boldsymbol{\beta} + d\boldsymbol{\gamma}$$

$d = d_1$ ならば d_1 として選ばれた j を \mathcal{A} に加える。

$d = d_2$ ならば d_2 として選ばれた j を \mathcal{A} から取り除く。

d_1 のほうが d_2 より小さければ, Active でなかった係数を Active とする
 d_2 のほうが d_1 より小さければ, Active だった係数を Active な係数の集合から取り除く。


$$\text{iii } \boldsymbol{\gamma}_{\mathcal{A}} = -(X_{\mathcal{A}}^t X_{\mathcal{A}})^{-1} \text{sgn}(\partial_{\boldsymbol{\beta}_{\mathcal{A}}} L(\boldsymbol{\beta})), \boldsymbol{\gamma}_{\mathcal{A}^c} = \mathbf{0} \text{ と更新する.}$$

新たなパラメータの変化の方向を求める。


$$\frac{\partial \hat{\boldsymbol{\beta}}_{\mathcal{A}}(\lambda)}{\partial \lambda} = -\left(X_{\mathcal{A}}^t X_{\mathcal{A}}\right)^{-1} \text{sgn}(\partial_{\boldsymbol{\beta}_{\mathcal{A}}} L(\boldsymbol{\beta}))$$



パラメータの変化



λ と s の関係



- 二次計画法と Lasso
- Lasso と Elastic net
- LARS-Lasso
- 線形計画法と Compressed Sensing



線形計画法

$\mathbf{x} = (x_1, \dots, x_n)^t$ を実数ベクトルとして、この \mathbf{x} に関する次のような最適化問題を考えるとき、これを線形計画問題 (Linear Programming) と呼ぶ.

基本形式

$$\begin{aligned} \min_{\mathbf{x}} \quad & \mathbf{c}^t \mathbf{x} \\ \text{subject to} \quad & \\ & \mathbf{A}\mathbf{x} \leq \mathbf{b}. \end{aligned}$$

ただし、 \mathbf{c} は n 次の実ベクトルである.



線形計画法

線形計画法を解く数値処理パッケージも沢山存在する。問題や計算機環境に応じて適切なものが選択できる。

これを用いて Compressed Sensing の問題を解く。

Compressed Sensing の問題 (再掲)

$$\min_{\beta} \|\mathbf{x}\|_{\ell_1}$$

subject to

$$A\mathbf{x} = \mathbf{y}$$



線形計画法

Lasso のときと同様 $x_j = x_j^+ - x_j^-$, $x_j^+ \geq 0$, $x_j^- \geq 0$ において,

Compressed Sensing

$$\begin{aligned} & \min_{\mathbf{x}^+, \mathbf{x}^-} (\mathbf{x}^+ + \mathbf{x}^-) \\ & \text{subject to} \\ & A(\mathbf{x}^+ - \mathbf{x}^-) = \mathbf{y} \end{aligned}$$

最適な解はそれぞれの j に対して x_j^+ または x_j^- の少なくともひとつは 0 となる。



線形計画法

$\gamma = (x_1^+, \dots, x_p^+, x_1^-, \dots, x_p^-)^t$ において

Compressed Sensing

$$\min_{\gamma} \mathbf{1}_{2p}^t \gamma \quad \text{subject to} \quad \begin{pmatrix} A & -A \\ -A & A \end{pmatrix} \gamma \leq \begin{pmatrix} \mathbf{y} \\ -\mathbf{y} \end{pmatrix}, \quad -E_{2p} \gamma \leq \mathbf{0}_{2p}$$

これは線形計画法の問題になっている。

基本形式

$$\min_{\mathbf{x}} \mathbf{c}^t \mathbf{x} \quad \text{subject to} \quad A\mathbf{x} \leq \mathbf{b}.$$

