

1. 概要
2. Lasso の考え方
3. 実データの結果
4. シミュレーション結果
5. まとめ

## 論文紹介

nanimonaiyo

山本 藤也 (Touya Yamamoto)  
u220067@st.pu-toyama.ac.jp

富山県立大学 情報システム工学科

December 12, 2025

1. 概要

2. Lasso の考え方

3. 実データの結果

4. シミュレーション結果

5. まとめ

## 対象論文

- Regression Shrinkage and Selection via the Lasso
- Robert Tibshirani, JRSS B, 1996

## この論文がやっていること

- 回帰モデルで予測精度を保ちつつ、不要な変数を自動で 0 にする方法を提案する。
- その方法を Lasso (Least Absolute Shrinkage and Selection Operator) と呼ぶ。

1. 概要
2. Lasso の考え方
3. 実データの結果
4. シミュレーション結果
5. まとめ

## 通常回帰（最小二乗法）

- モデル：

$$y = X\beta + \varepsilon$$

- 推定：

$$\hat{\beta}^{\text{OLS}} = \arg \min_{\beta} \|y - X\beta\|_2^2$$

## 問題点

- 説明変数が多いと分散が大きくなり予測が不安定になる。
- すべての変数に係数が付くためどの変数が重要か分かりにくい。

## L1 正則化付き回帰

- Lasso は次の問題を解く：

$$\hat{\beta}^{\text{lasso}} = \arg \min_{\beta} \left\{ \frac{1}{2} \|y - X\beta\|_2^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$$

- $\lambda$  が大きいほど  $\sum_j |\beta_j|$  のペナルティが強くなり、係数が 0 に近づく。

## 特徴

- 一部の係数を 0 にする ため、重要な変数だけ残る。
- Subset selection より連続的で安定であり、Ridge 回帰よりスパースになる。

# L1 正則化が 0 を作る理由

6/13

## 直交デザインの場合の解

- $X^T X = I$  のとき、Lasso の解は

$$\hat{\beta}_j^{\text{lasso}} = \text{sign}(\hat{\beta}_j^{\text{LS}}) (|\hat{\beta}_j^{\text{LS}}| - \lambda)_+$$

- $|\hat{\beta}_j^{\text{LS}}| \leq \lambda$  なら  $\hat{\beta}_j^{\text{lasso}} = 0$ 。




図 1: 4 手法 (Subset・Ridge・Lasso・Garotte) の縮小挙動

## L1 と L2 の違い

- Ridge :  $\sum_j \beta_j^2 \leq c$  (円形の制約領域)
- Lasso :  $\sum_j |\beta_j| \leq t$  (ひし形の制約領域)
- 等高線と制約領域の最初の接点が解になる。




図 2: L1 L2 の制約領域と等高線

→ひし形の角が軸上にあり、係数が 0 の解を選びやすい。

## データとモデル

- PSA（前立腺特異抗原）の対数を目的変数とする。
- 8つの説明変数（lcavol, lweight, age, ...）を標準化して回帰。




図 3: 正則化の強さによる Lasso 係数パス



# 前立腺がんデータの結果 (2)

9/13

1. 概要
2. Lasso の考え方
3. 実データの結果
4. シミュレーション結果
5. まとめ

## Lasso が選んだ変数

- GCV により非ゼロの係数は 3 つ：
  - lcavol (がん体積)
  - lweight (前立腺重量)
  - svi (精囊浸潤)

## 係数の例 (Table1)

- lcavol : OLS 約 0.69 → Lasso 約 0.56
- lweight : OLS 約 0.23 → Lasso 約 0.10
- svi : OLS 約 0.32 → Lasso 約 0.16

# Example 1 : 少数の大きな効果

10/13

## 設定

- 真の係数 :

$$\beta = (3, 1.5, 0, 0, 2, 0, 0, 0)^T$$

- 非ゼロは 3 つだけのスパース構造。

## 結果 (Table 3)

- 中央 MSE の比較 :
  - 最小二乗 :  $\approx 2.8$
  - 部分集合選択 :  $\approx 2.4$
  - Lasso (GCV) :  $\approx 1.9$  (最良)
  - Ridge :  $\approx 3.2$
- Lasso はスパース構造に強い。

## Example 4 : 高次元の例

11/13

### 設定と結果 (Table 8)

- $N = 100, p = 40$  の高次元設定。
- Ridge が最良 (MSE 約 57.4)。
- Lasso (GCV) は MSE 約 64.9。

### ここから言えること

- 多くの小さな効果が分散している場合は Ridge が有利。
- Lasso は解釈性の高いスパース解を提供。

1. 概要
2. Lasso の考え方
3. 実データの結果
4. シミュレーション結果
5. まとめ

## Lasso のポイント

- Lasso は L1 正則化により係数の一部を 0 にする。
- Subset のスパース性と Ridge の安定性を両立する。
- スパース構造があるときに強い予測性能。

## この論文の意義

- L1 正則化モデルの基礎を確立した重要論文。
- スパース推定という概念を統計学・機械学習に広めた。

- $y$  : 目的変数 ( $N \times 1$ )
- $X$  : 説明変数行列 ( $N \times p$ )
- $\beta$  : 回帰係数 ( $p \times 1$ )
- $\hat{\beta}^{\text{LS}}$  : 最小二乗推定量
- $\hat{\beta}^{\text{lasso}}$  : Lasso 推定量
- $\lambda$  : L1 正則化パラメータ
- $(x)_+ = \max(x, 0)$  : soft-thresholding
- $\text{sign}(x)$  : 符号関数