

Seminarium magisterskie 2

LASSO oraz powiązane algorytmy ścieżkowe

Magdalena Trafidło

13 kwietnia 2023

Niech Y - macierz wynikowa z K kolumnami.

$$Y_k = f(x) + \epsilon_k,$$

$$Y_\ell = f(x) + \epsilon_\ell$$

Analiza korelacji kanonicznych (CCA)

CCA znajduje sekwencję X_{v_m} - nieskorelowanych liniowych kombinacji x_j oraz odpowiadające im Y_{u_m} - nieskorelowane liniowe kombinacje y_k , tak aby

$$\text{Corr}^2(Y_{u_m}, X_{v_m})$$

było jak największe.

Do rozwiązania powyższego problemu stosuje się SVD na macierzy $Y^T X / N$, gdzie X, Y - scentrowane.

$$\hat{B}^{rr} = \arg \min_{\text{rank}(B)=m} \sum_{i=1}^N (y_i - B^T x_i)^T \Sigma^{-1} (y_i - B^T x_i), \Sigma = \text{Cov}(\epsilon).$$

Jeśli zastąpimy Σ przez estymator $Y^T Y/N$, dostaniemy rozwiązanie wyznaczone przez CCA:

$$\hat{B}^{rr}(M) = (X^T X)^{-1} X^T (Y U_m) U_m^{-1},$$

gdzie U_m jest podmacierzą rozmiaru $K \times m$ macierzy U .

Incremental Forward Stagewise Regression

Incremental Forward Stagewise Regression - przyrostowa regresja stopniowa do przodu

Algorytm FS_ϵ

- 1 Przyjmij na początku, że residua r są równe y , a $\beta_0, \dots, \beta_p = 0$. Dodatkowo, niech predyktory będą ustandaryzowane (średnia zero, norma równa 1).
- 2 Znajdź predyktor x_j najbardziej skorelowany z r .
- 3 Przypisz $\beta_j \leftarrow \beta_j + \delta_j$, $r_j \leftarrow r_j - \delta_j x_j$, gdzie $\delta_j = \epsilon \cdot \text{sign}|\langle x_j, r \rangle|$, a $\epsilon > 0$ to ustalony krok.
- 4 Powtarzaj 2-3 do momentu, w którym residua będą nieskorelowane ze wszystkimi predyktorami.

Zauważmy, że jeśli $\delta_j = \langle x_j, r \rangle$, to dostaniemy algorytm *Forward Stagewise*.

Algorytm LAR - modyfikacja FS_0



- 1 Przyjmij na początku, że $r = y - \bar{y}$, a $\beta_0, \dots, \beta_p = 0$.
Dodatkowo, niech predyktory będą ustandaryzowane (średnia zero, norma równa 1).
- 2 Znajdź predyktor x_j najbardziej skorelowany z r .
- 3 Przesuwaj β_j od zera w kierunku współczynnika $\langle x_j, r \rangle$, do momentu, w którym jakiś predyktor x_k będzie tak samo skorelowany z obecnymi residuami jak x_j .
- 4 Znajdź nowy kierunek rozwiązując następujący problem:

$$\min_b \|r - X_A b\|_2^2 \text{ z } b_j s_j \geq 0, j \in A,$$

a s_j to znak $\langle x_j, r \rangle$.

- 5 Kontynuuj tak długo, aż zostaną wykorzystane wszystkie predyktory. Po $\min(N - 1, p)$ krokach koniec.

Przykład - rak prostaty, $\epsilon = 0.01$



$\hat{\beta}(\lambda)$ - ścieżka:

$$\hat{\beta}(\lambda) = \arg \min_{\beta} [R(\beta) + \lambda J(\beta)], \text{ gdzie}$$

$$R(\beta) = \sum_{i=1}^N L \left(y_i, \beta_0 + \sum_{j=1}^p x_{ij} \beta_j \right),$$

L - funkcja straty, J - funkcja kary - wypukłe. Jeśli:

- 1 R jest kwadratową lub miejscami kwadratową funkcją β ,
- 2 J jest miejscami liniowa w β

to rozwiązanie $\hat{\beta}(\lambda)$ będzie kawałkami liniowe.

Kryterium *Dantzig Selector (DS)*:

$$\min_{\beta} \|\beta\|_1 \text{ przy warunku } \|X^T(y - X\beta)\|_{\infty} \leq s,$$

lub równoważnie:

$$\min_{\beta} \|X^T(y - X\beta)\|_{\infty} \text{ przy warunku } \|\beta\|_1 \leq t,$$

$\|\cdot\|_{\infty}$ - norma maksimum, czyli maksimum z wartości bezwzględnych elementów wektora.

Jeśli $t \rightarrow \infty$ i $N < p$, rozwiązanie zbiega do rozwiązania uzyskanego przy pomocy metody najmniejszych kwadratów, jeśli $N \geq p$ rozwiązanie zbiega do rozwiązania uzyskanego przy pomocy metody najmniejszych kwadratów z minimum normy L_1 .

L - liczba grup, na które podzielono p predyktorów,

p_ℓ - liczba predyktorów w grupie ℓ ,

X_ℓ - macierz predyktorów odpowiadająca grupie ℓ ,

β_ℓ - wektor odpowiadający X_ℓ .

$$\hat{\beta} = \min_{\beta \in \mathbb{R}^p} \left(\|y - \beta_0 \mathbf{1} + \sum_{\ell=1}^L X_\ell \beta_\ell\|_2^2 + \lambda \sum_{\ell=1}^L \sqrt{p_\ell} \|\beta_\ell\|_2 \right).$$

Smoothly clipped absolute deviation (SCAD)

Zmieniamy karę z $\lambda|\beta|_1$ na $J_a(\beta, \lambda)$, czyli szukamy $\hat{\beta}$:

$$\hat{\beta} = \arg \min_{\beta} \left\{ \frac{1}{2} \|y - X\beta\|_2^2 + J_a(\beta, \lambda) \right\},$$

gdzie

$$\frac{dJ_a(\beta, \lambda)}{d\beta} = \lambda \cdot \text{sign}(\beta) [I(|\beta| \leq \lambda) + \frac{(a\lambda - |\beta|)_+}{(a-1)\lambda} I(|\beta| > \lambda)], a \geq 2.$$

Zakładamy, że predyktory są ustandaryzowane (ze średnią 0 i normą 1). Niech $\tilde{\beta}_k(\lambda)$ oznacza obecny estymator β_k z parametrem λ . Wtedy

$$R(\tilde{\beta}(\lambda), \beta_j) = \frac{1}{2} \sum_{i=1}^N \left(y_i - \sum_{k \neq j} x_{ik} \tilde{\beta}_k(\lambda) - x_{ij} \beta_j \right)^2 + \lambda \sum_{k \neq j} |\tilde{\beta}_k(\lambda)| + \lambda \beta_j,$$

co daje

$$\beta_j(\lambda) \leftarrow S \left(\sum_{i=1}^N x_{ij} (y_i - \tilde{y}_i^{(j)}), \lambda \right),$$

$$S(t, \lambda) = \text{sign}(t) (|t| - \lambda)_+.$$