

第3章 机器学习与因果推断：双重Lasso

2025年7月

本讲关键问题

- (1) 线性回归中如何估计单个解释变量前的系数？
- (2) 当 p/n 较大时上述估计量是否依然奏效？
- (3) OLS与偏回归估计量为什么也是矩估计量（method of moment）？
- (4) 当控制变量维数极高时，偏回归估计量为何依旧稳健？

重点与难点

- 理解双重Lasso方法的动机，适用场景和操作步骤；
- 掌握在实际数据中正确适用Double Lasso, 计算估计量的标准差；
- 从直觉和理论角度理解为何Double Lasso能够适应高维解释变量，得到有限维系数的可靠估计。

一、回顾：线性回归中推断单个解释变量的偏效应

大多数实证研究关心单个或者极少数解释变量对 Y 产生的平均效应。假设在

$$Y = \alpha D + X'\beta + U$$

中，我们关心 D 对 Y 产生的平均效应，这等于要准确估计并推断 α 。上述问题可以通过偏回归估计量得到：

$$\hat{\alpha} = \frac{\sum_{i=1}^n \tilde{D}_i \tilde{Y}_i}{\sum_{i=1}^n \tilde{D}_i^2} \quad (3.1)$$

其中

$$\tilde{D}_i = D_i - X_i' \hat{\gamma}_D,$$

$$\tilde{Y}_i = Y_i - X_i' \hat{\gamma}_Y.$$

当 X 维数极高时，甚至超过 n 时，上述偏回归估计量(3.1)依然能够准确估计 D 的平均偏效应。这背后的原理是什么？为什么其他估计量做不到？

一、回顾：线性回归中推断单个解释变量的偏效应

从矩估计量（method of moment）视角重新理解偏回归：

$$E[(\tilde{Y}_i - \alpha \tilde{D}_i) \tilde{D}_i] = 0. \quad (3.2)$$

(3.2)可以视作估计 α 的矩条件。所谓矩条件，就是以待估参数为未知数的，各个可观测变量须满足的总体期望方程。

$$\tilde{Y} - \alpha \tilde{D} = X' \beta + U - X' \gamma_Y + X' (\alpha \gamma_D) = m(X) + U$$

$$\tilde{D} = D - E(D|X)$$

$$E[(D - E(D|X))(m(X) + U)] = 0$$

$\hat{\alpha}$ 可以视作矩条件的样本解。 $\hat{\alpha}$ 的渐近分布：

$$\sqrt{n}(\hat{\alpha} - \alpha) \rightarrow^d N\left(0, (E[\tilde{D}^2])^{-1} \sigma^2\right) = N\left(0, \left(E\left[(D - E(D|X))^2\right]\right)^{-1} \sigma^2\right).$$

思考题： OLS估计量对应的矩条件是什么？

二、双重Lasso

- 当 X 维数很高时，上述偏回归估计量是否仍然可靠？

此时数据生成过程是

$$Y = \alpha D + X' \beta + U, E(U|D, X) = 0. \quad (3.3)$$

其中 D 是一维随机变量， X 是 p 维随机变量（ p 可以很大）。

表面上看，post Lasso可以解决以上问题：首先，用Lasso估计 Y 对 (D, X) 的回归系数 (α, β) ，由于Lasso具有变量选择功能，因此 β 中某些估计值是零。记 X 前系数估计量不等于零的分量为 X_S ，然后用 Y 对 (D, X_S) 再做OLS回归，这时 D 前面系数的估计量会被认为是 α 的一致估计。

- 以上post Lasso是否真的奏效？

二、双重Lasso

在此，我们考虑四种估计 α 的方法：

α 的估计方法	具体步骤	评论
(1) Lasso $\hat{\alpha}_{lasso}$	用 Y 对 (D, X) 进行Lasso，将得到的系数估计量 $\hat{\alpha}_{lasso}$ 作为 α 的估计量。	由于惩罚项的存在，lasso估计量是系数的有偏估计（压缩估计）。
(2) post Lasso $\hat{\alpha}_{post}$	用 Y 对 (D, X) 进行Lasso，记 $\hat{\beta}_{lasso}$ 不等于零的分量是 X_{S_1} 。用 Y 对 (D, X_{S_1}) 做OLS，将得到的估计量 $\hat{\alpha}_{post}$ 作为 α 的估计量。	倘若第1步lasso能够“准确”选择变量，post lasso是一致估计。
(3) double select $\hat{\alpha}_{dlm1}$	用 D 对 X 进行Lasso，记系数不等于零的分量对应的 X 集合是 X_{S_2} 。用 Y 对 X 进行Lasso，记系数不等于零的分量是 X_{S_3} 。用 Y 对 (D, X_{S_2}, X_{S_3}) 做OLS，将得到的估计量 $\hat{\alpha}_{dlm1}$ 作为 α 的估计量。	double select比post lasso在最后一步估计中加入了更多的 X （那些对 D 具有预测能力的 X_{S_2} ，这缓解了post lasso过度依赖第1步lasso对变量选择的准确性。
(4) double lasso $\hat{\alpha}_{dlm2}$	用 D 对 X 进行Lasso，相应的残差是 $D_i - X_i' \hat{\gamma}_D = \tilde{D}_i$ 。用 Y 对 X 进行Lasso，残差是 $Y_i - X_i' \hat{\gamma}_Y = \tilde{Y}_i$ 。用 \tilde{Y}_i 对 \tilde{D}_i 做OLS回归，记 \tilde{D}_i 前面的系数是 $\hat{\alpha}_{dlm2}$ 。	Double lasso是偏回归估计量在 X 高维情形下的推广，具有良好的小样本性质。

二、双重Lasso

数据生成过程:

$$Y = D + X\beta' + U, p = \dim X = 100, n = 100.$$

$$\beta_j = \frac{1}{j^a}, j = 1, \dots, p; X \sim^d N(0, I_p); U \sim^d N(0, 1).$$

$$D = X'\gamma + V; \gamma_j = \frac{1}{(p+1-j)^a}, j = 1, \dots, p; V \sim^d N(0, 1)/4.$$

(1) 用交错验证法选择 λ :

	$a = 1$			$a = 1.5$			$a = 2$		
	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std
$\hat{\alpha}_{lasso}$	-0.1017	0.0210	0.1034	-0.2041	0.0606	0.1376	-0.2458	0.0897	0.1712
$\hat{\alpha}_{post}$	-0.0451	0.0177	0.1249	-0.1233	0.0467	0.1774	-0.1548	0.0734	0.2224
$\hat{\alpha}_{dml1}$	0.0935	0.8535	0.9192	-0.0826	0.4146	0.6386	-0.1262	0.3385	0.568
$\hat{\alpha}_{dml2}$	0.8118	1.3487	0.8305	0.274	0.3781	0.5506	0.1684	0.2733	0.495
	$a = 2.5$			$a = 3$			$a = 4$		
	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std
$\hat{\alpha}_{lasso}$	-0.2714	0.1122	0.1963	-0.2864	0.1269	0.2119	-0.2983	0.1393	0.2243
$\hat{\alpha}_{post}$	-0.1756	0.094	0.2514	-0.1884	0.1085	0.2701	-0.1989	0.1211	0.2855
$\hat{\alpha}_{dml1}$	-0.1372	0.3117	0.5412	-0.1484	0.2986	0.5259	-0.1605	0.2798	0.5041
$\hat{\alpha}_{dml2}$	0.127	0.2404	0.4736	0.0995	0.2237	0.4624	0.0632	0.2069	0.4504

二、双重Lasso

(2) 同样的数据生成过程用插值法选择 λ :

	$a = 1$			$a = 1.5$			$a = 2$		
	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std
$\hat{\alpha}_{lasso}$	-0.7531	0.584	0.1299	-0.8409	0.7251	0.1346	-0.8553	0.75	0.1363
$\hat{\alpha}_{post}$	0.0334	0.0159	0.1217	-0.0518	0.0305	0.1666	-0.0768	0.0479	0.2049
$\hat{\alpha}_{dml1}$	0.0977	0.0351	0.16	0.0070	0.0518	0.2275	-0.0027	0.0844	0.2905
$\hat{\alpha}_{dml2}$	0.0577	0.0127	0.0966	-0.0008	0.0072	0.0846	-0.0042	0.0052	0.0717

	$a = 2.5$			$a = 3$			$a = 4$		
	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std	Bias Ratio	MSE	Std
$\hat{\alpha}_{lasso}$	-0.8608	0.7599	0.1377	-0.8639	0.7655	0.1385	-0.8667	0.7705	0.1388
$\hat{\alpha}_{post}$	-0.0929	0.0642	0.2359	-0.1037	0.0769	0.2573	-0.1146	0.0892	0.2759
$\hat{\alpha}_{dml1}$	-0.0054	0.1164	0.3412	-0.0075	0.141	0.3754	-0.0102	0.1648	0.4059
$\hat{\alpha}_{dml2}$	-0.0043	0.004	0.0634	-0.0044	0.0035	0.0588	-0.0046	0.003	0.055

使用插值法估计 λ 时，double lasso方法相对于其他方法能得到偏误率更小、小样本性质更好的估计量。

三、双重Lasso为何表现良好？

➤ 为什么上述四个估计量中，只有 $\hat{\alpha}_{dml2}$ 具有良好的小样本性质？背后的理论逻辑是什么？
在模型

$$Y = \alpha D + X' \beta + U$$

中，我们感兴趣的参数是 α 。 $\hat{\alpha}_{dml2}$ 的估计步骤对应矩条件

$$E \left[\left(\tilde{Y}(\gamma) - \alpha \tilde{D}(\gamma) \right) \tilde{D}(\gamma) \right] = 0.$$

其中 $\tilde{D}(\gamma) = D - X' \gamma_D$, $\tilde{Y}(\gamma) = Y - X' \gamma_Y$, $\gamma = (\gamma_D, \gamma_Y)$, α 是 γ 的函数，即：

$$\alpha(\gamma) = E \left[\left(\tilde{D}(\gamma) \right)^2 \right]^{-1} E[\tilde{Y}(\gamma) \tilde{D}(\gamma)].$$

双重Lasso表现良好的原因在于：可以证明 $\alpha(\gamma)$ 关于 γ 的导数在真值处等于零，即

$$\frac{\partial \alpha(\gamma)}{\partial \gamma} \Big|_{\gamma=\gamma_0} = 0. \quad (3.4)$$

在用双重Lasso估计 α 时，作为中间步骤的参数 $\gamma = (\gamma_D, \gamma_Y)$ 通过lasso得到。与传统OLS不同，Lasso估计量具有较大的偏误。这是所有机器学习估计量的共同特点。(3.4)保证了 $\gamma = (\gamma_D, \gamma_Y)$ 的估计量的偏误对 α 估计量的影响（偏误）降至最低。

三、双重Lasso为何表现良好?

对 (3.4) 的验证:

$$E \left[\left(\tilde{Y}(\gamma) - \alpha(\gamma) \tilde{D}(\gamma) \right) \tilde{D}(\gamma) \right] = 0$$

记 $m(\alpha, \gamma) = E[(\tilde{Y}(\gamma) - \alpha \tilde{D}(\gamma)) \tilde{D}(\gamma)]$, 利用隐函数求导公式:

$$\frac{\partial \alpha(\gamma)}{\partial \gamma} \Big|_{\gamma=\gamma_0} = - \left[\frac{\partial E[(\tilde{Y}(\gamma) - \alpha \tilde{D}(\gamma)) \tilde{D}(\gamma)]}{\partial \alpha} \right] \Big|_{\gamma=\gamma_0}^{-1} \times \frac{\partial E[(\tilde{Y}(\gamma) - \alpha \tilde{D}(\gamma)) \tilde{D}(\gamma)]}{\partial \gamma} \Big|_{\gamma=\gamma_0}$$

$$\frac{\partial E[(\tilde{Y}(\gamma_Y) - \alpha \tilde{D}(\gamma_D)) \tilde{D}(\gamma_D)]}{\partial \gamma_D} \Big|_{\gamma=\gamma_0} = E[\tilde{Y}(\gamma_Y) X + \alpha 2 \tilde{D}(\gamma_D) X] \Big|_{\gamma=\gamma_0} = 0$$

$$\frac{\partial E[(\tilde{Y}(\gamma_Y) - \alpha \tilde{D}(\gamma_D)) \tilde{D}(\gamma_D)]}{\partial \gamma_Y} = E[X \tilde{D}(\gamma_D)] \Big|_{\gamma=\gamma_0} = 0$$

三、双重Lasso为何表现良好?

➤ 为什么post-lasso估计效果不佳?

Post-lasso对应的矩条件是

$$m(\alpha, \gamma) = E[(Y - \alpha D - X' \gamma) D] = 0$$

$$\partial_{\gamma} m(\alpha, \gamma) \Big|_{\gamma=\gamma_0} = E(DX) \neq 0$$

$\hat{\alpha}_{dml2}$ 不仅具有良好的小样本性质，它的渐进方差计算也十分简便。可以证明：

$$\sqrt{n}(\hat{\alpha}_{dml2} - \alpha) \rightarrow^d N(0, (E[\tilde{D}^2])^{-1} \sigma^2)$$

因此 $\hat{\alpha}_{dml2}$ 的渐进方差估计量是 $\frac{(\hat{E}[\tilde{D}^2])^{-1} \hat{\sigma}^2}{n}$ ，其中 $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n \hat{e}_i^2$ ， $\hat{e}_i = \hat{Y}_i - \hat{\tilde{D}}_i \hat{\alpha}_{dml2}$ ， $\hat{Y}_i = Y_i - X_i' \hat{\gamma}_Y$ ，

$$\hat{\tilde{D}}_i = D_i - X_i' \hat{\gamma}_D, \quad \hat{E}[\tilde{D}^2] = \frac{1}{n} \sum_{i=1}^n (\hat{\tilde{D}}_i)^2。$$

$$\hat{\alpha}_{dml2} X_i' \hat{Y}_Y = \hat{Y}_i$$

四、实证案例：穷国增长速率是否更快？

表3.2 用OLS、Post-Lasso和Double Lasso估计经济增长的收敛性

	估计量	标准差	置信区间
OLS	-0.0089	0.0314	[-0.0732,0.0555]
Post-Lasso	-0.0308	0.0148	[-0.0599,-0.0007]
Double Lasso	-0.0293	0.0141	[-0.0573, -0.0013]

案例中Post-Lasso和Double Lasso都使用式子 $\lambda = 2c\hat{\sigma}\sqrt{n}z_{1-a/(2p)}$ 确定 λ ，如果用CV确定Post-Lasso过程中的 λ ，估计量差不多，标准差会大一点点。

谢谢!

