

MSIA

MDI 720 : Ridge / Tikhonov

François Portier
Télécom ParisTech

Some of the contents were provided by Joseph Salmon <http://josephsalmon.eu>

Plan

Définitions de l'estimateur Ridge

- Point de vue par pénalisation

- Analyse du biais par la SVD

- Analyse de la variance par la SVD

Choix du paramètre de régularisation

- Notion de chemin de régularisation

- Validation Croisée (CV)

Algorithmes et aspects computationnels

Sommaire

Définitions de l'estimateur Ridge

- Point de vue par pénalisation

- Analyse du biais par la SVD

- Analyse de la variance par la SVD

Choix du paramètre de régularisation

- Notion de chemin de régularisation

- Validation Croisée (CV)

Algorithmes et aspects computationnels

Ridge / Tikhonov : la définition pénalisée

$$\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = \arg \min_{\boldsymbol{\theta} \in \mathbb{R}^p} \left(\underbrace{\|\mathbf{y} - X\boldsymbol{\theta}\|_2^2}_{\text{attache aux données}} + \underbrace{\lambda \|\boldsymbol{\theta}\|_2^2}_{\text{régularisation}} \right)$$

- ▶ Noter que l'estimateur *Ridge* est **unique** pour un λ fixé
- ▶ On retrouve de nouveau les cas limites :

$$\lim_{\lambda \rightarrow 0} \hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = \hat{\boldsymbol{\theta}}^{\text{MCO}} \text{ (solution de norme } \|\cdot\|_2 \text{ minimale)}$$

$$\lim_{\lambda \rightarrow +\infty} \hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = \mathbf{0} \in \mathbb{R}^p$$

- ▶ Lien des deux formulations par les CNO : pour

$$f(\boldsymbol{\theta}) = \frac{\|\mathbf{y} - X\boldsymbol{\theta}\|_2^2}{2} + \frac{\lambda \|\boldsymbol{\theta}\|_2^2}{2}$$

$$\nabla f(\boldsymbol{\theta}) = X^{\top}(X\boldsymbol{\theta} - \mathbf{y}) + \lambda\boldsymbol{\theta} = 0 \Leftrightarrow (X^{\top}X + \lambda \text{Id}_p)\boldsymbol{\theta} = X^{\top}\mathbf{y}$$

Régulariser simplifie le problème quand il est mal conditionné




FIGURE: OLS (left) and Ridge (right)

Régulariser simplifie le problème quand il est mal conditionné



FIGURE: OLS (left) and Ridge (right)

Régulariser simplifie le problème quand il est mal conditionné



FIGURE: OLS (left) and Ridge (right)

Régulariser simplifie le problème quand il est mal conditionné



FIGURE: OLS (left) and Ridge (right)

Régulariser simplifie le problème quand il est mal conditionné




FIGURE: OLS (left) and Ridge (right)

Interprétation contrainte

Un problème de la forme “Lagrangienne” suivante :

$$\arg \min_{\boldsymbol{\theta} \in \mathbb{R}^p} \left(\underbrace{\frac{1}{2} \|\mathbf{y} - X\boldsymbol{\theta}\|_2^2}_{\text{attache aux données}} + \underbrace{\frac{\lambda}{2} \|\boldsymbol{\theta}\|_2^2}_{\text{régularisation}} \right)$$

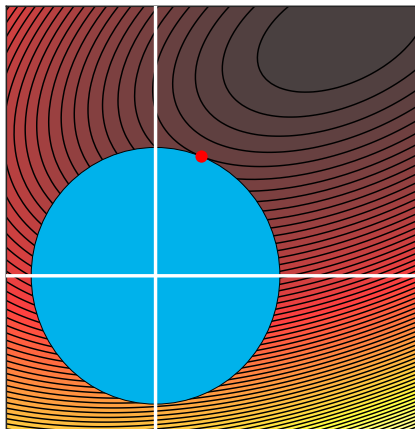
admet pour un certain $T > 0$ la même solution que :

$$\begin{cases} \arg \min_{\boldsymbol{\theta} \in \mathbb{R}^p} \|\mathbf{y} - X\boldsymbol{\theta}\|_2^2 \\ \text{t.q. } \|\boldsymbol{\theta}\|_2^2 \leq T \end{cases}$$

Rem: le lien $T \leftrightarrow \lambda$ n'est pas explicite !

- ▶ Si $T \rightarrow 0$ on retrouve le vecteur nul : $0 \in \mathbb{R}^p$
- ▶ Si $T \rightarrow \infty$ on retrouve $\hat{\boldsymbol{\theta}}^{\text{MCO}}$ (non contraint)

Lignes de niveau et ensemble de contraintes



Optimisation sous contraintes ℓ_2

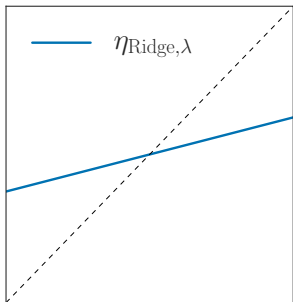
Le cas orthogonal

Retour sur un cas simple $X^T X = \text{Id}_p$

$$\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = (\lambda \text{Id}_p + X^T X)^{-1} X^T \mathbf{y}$$

$$\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = (\lambda \text{Id}_p + \text{Id}_p)^{-1} X^T \mathbf{y} = \frac{1}{\lambda + 1} X^T \mathbf{y}$$

$$\hat{\mathbf{y}} = \frac{1}{\lambda + 1} \mathbf{y} = (\eta_{\text{rdg},\lambda}(\mathbf{y}_i))_{i=1,\dots,n}$$



Rem: la fonction réelle $\eta_{\text{rdg},\lambda}$ est une contraction linéaire (shrinkage)

Prédiction associée


Partant du coefficient *Ridge* :

$$\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = (\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} \mathbf{y}$$

la prédiction associée s'obtient ainsi :

$$\hat{\mathbf{y}} = X \hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = X (\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} \mathbf{y}$$

Rem: l'estimateur $\hat{\mathbf{y}}$ est toujours linéaire en \mathbf{y}

Rem: l'équivalent de la matrice chapeau ( : *hat matrix*) est


$$H_{\lambda} = X (\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} = \sum_{j=1}^{\text{rg}(X)} \frac{s_j^2}{s_j^2 + \lambda} \mathbf{u}_j \mathbf{u}_j^{\top}$$

Attention : si $\lambda \neq 0$, on n'a plus $H_{\lambda}^2 = H_{\lambda} = \sum_{j=1}^{\text{rg}(X)} \mathbf{u}_j \mathbf{u}_j^{\top}$, i.e., H_{λ}

n'est donc pas un projecteur

Point normalisation et centrage

Rappel : normaliser les p variables de la même manière pour que la pénalisation contraigne de manière similaire toutes les variables

- ▶ centrer l'observation et les variables explicatives \Rightarrow pas de coefficient pour la variable constante (donc pas de contrainte)
- ▶ ne pas centrer les variables explicatives \Rightarrow ne pas mettre de contrainte sur la variable constante ( : *bias/intercept*),

$$\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}} = \arg \min_{\boldsymbol{\theta} \in \mathbb{R}^p} \|\mathbf{y} - X\boldsymbol{\theta} - \theta_0 \mathbf{1}_n\|^2 + \lambda \sum_{j=1}^p \theta_j^2$$

Alternative (si l'on n'a pas normalisé) : changer la pénalité en

$$\arg \min_{\boldsymbol{\theta} \in \mathbb{R}^p} \|\mathbf{y} - X\boldsymbol{\theta}\|^2 + \lambda \sum_{j=1}^p \alpha_j \theta_j^2 \quad (\text{e.g., } \alpha_j = \|\mathbf{x}_j\|^2)$$

Rem: pour la validation croisée on utilisera plus naturellement $\frac{\|\mathbf{y} - X\boldsymbol{\theta}\|^2}{2n}$ que $\frac{\|\mathbf{y} - X\boldsymbol{\theta}\|^2}{2}$ pour conserver l'amplitude de λ

Sommaire

Définitions de l'estimateur Ridge

Point de vue par pénalisation

Analyse du biais par la SVD

Analyse de la variance par la SVD

Choix du paramètre de régularisation

Notion de chemin de régularisation

Validation Croisée (CV)

Algorithmes et aspects computationnels

Le biais dans le cas général

Sous l'hypothèse de bruit "blanc" $\mathbf{y} = X\boldsymbol{\theta}^* + \boldsymbol{\varepsilon}$ avec $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$:

$$\begin{aligned}\mathbb{E}(\hat{\boldsymbol{\theta}}_{\lambda}^{\text{rdg}}) &= \mathbb{E}((\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} \mathbf{y}) \\ &= \mathbb{E}((\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} X \boldsymbol{\theta}^* + (\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} \boldsymbol{\varepsilon}) \\ &= (\lambda \text{Id}_p + X^{\top} X)^{-1} X^{\top} X \boldsymbol{\theta}^* \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^2}{s_i^2 + \lambda} \mathbf{v}_i \mathbf{v}_i^{\top} \boldsymbol{\theta}^*\end{aligned}$$

Rem: on retrouve $\mathbb{E}(\hat{\boldsymbol{\theta}}^{\text{MCO}}) = \sum_{i=1}^{\text{rg}(X)} \mathbf{v}_i \mathbf{v}_i^{\top} \boldsymbol{\theta}^*$ quand $\lambda \rightarrow 0$

Rem: le biais vaut $-\lambda(X^{\top} X + \lambda \text{Id}_p)^{-1} \boldsymbol{\theta}^*$ (grâce à la 3^e ligne)

Sommaire

Définitions de l'estimateur Ridge

Point de vue par pénalisation

Analyse du biais par la SVD

Analyse de la variance par la SVD

Choix du paramètre de régularisation

Notion de chemin de régularisation

Validation Croisée (CV)

Algorithmes et aspects computationnels

Variance dans le cas général

Sous l'hypothèse de bruit "blanc" (i.e., $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$) et de modèle homoscédastique : $\mathbb{E}(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^\top) = \sigma^2 \text{Id}_n$

Variance / Covariance

$$V_\lambda^{\text{rdg}} = \mathbb{E} \left((\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}})) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}))^\top \right)$$

Calcul explicite :

$$\begin{aligned} V_\lambda^{\text{rdg}} &= \mathbb{E} \left((\lambda \text{Id}_p + X^\top X)^{-1} X^\top \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top X (\lambda \text{Id}_p + X^\top X)^{-1} \right) \\ &= (\lambda \text{Id}_p + X^\top X)^{-1} X^\top \mathbb{E}(\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top) X (\lambda \text{Id}_p + X^\top X)^{-1} \end{aligned}$$

Variance dans le cas général

Sous l'hypothèse de bruit "blanc" (*i.e.*, $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$) et de modèle homoscédastique : $\mathbb{E}(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^\top) = \sigma^2 \text{Id}_n$

Variance / Covariance

$$V_\lambda^{\text{rdg}} = \mathbb{E} \left((\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}})) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}))^\top \right)$$

Calcul explicite :

$$\begin{aligned} V_\lambda^{\text{rdg}} &= \mathbb{E} \left((\lambda \text{Id}_p + X^\top X)^{-1} X^\top \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top X (\lambda \text{Id}_p + X^\top X)^{-1} \right) \\ &= (\lambda \text{Id}_p + X^\top X)^{-1} X^\top \mathbb{E}(\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top) X (\lambda \text{Id}_p + X^\top X)^{-1} \\ &= \sigma^2 (\lambda \text{Id}_p + X^\top X)^{-2} X^\top X \end{aligned}$$

Variance dans le cas général

Sous l'hypothèse de bruit "blanc" (*i.e.*, $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$) et de modèle homoscédastique : $\mathbb{E}(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^\top) = \sigma^2 \text{Id}_n$

Variance / Covariance

$$V_\lambda^{\text{rdg}} = \mathbb{E} \left((\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}})) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}))^\top \right)$$

Calcul explicite :

$$\begin{aligned} V_\lambda^{\text{rdg}} &= \mathbb{E} \left((\lambda \text{Id}_p + X^\top X)^{-1} X^\top \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top X (\lambda \text{Id}_p + X^\top X)^{-1} \right) \\ &= (\lambda \text{Id}_p + X^\top X)^{-1} X^\top \mathbb{E}(\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top) X (\lambda \text{Id}_p + X^\top X)^{-1} \\ &= \sigma^2 (\lambda \text{Id}_p + X^\top X)^{-2} X^\top X \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^2 \sigma^2}{(s_i^2 + \lambda)^2} \mathbf{v}_i \mathbf{v}_i^\top \end{aligned}$$

Variance dans le cas général

Sous l'hypothèse de bruit "blanc" (i.e., $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$) et de modèle homoscédastique : $\mathbb{E}(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^\top) = \sigma^2 \text{Id}_n$

Variance / Covariance

$$V_\lambda^{\text{rdg}} = \mathbb{E} \left((\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}})) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}))^\top \right)$$

Calcul explicite :

$$\begin{aligned} V_\lambda^{\text{rdg}} &= \mathbb{E} \left((\lambda \text{Id}_p + X^\top X)^{-1} X^\top \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top X (\lambda \text{Id}_p + X^\top X)^{-1} \right) \\ &= (\lambda \text{Id}_p + X^\top X)^{-1} X^\top \mathbb{E}(\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top) X (\lambda \text{Id}_p + X^\top X)^{-1} \\ &= \sigma^2 (\lambda \text{Id}_p + X^\top X)^{-2} X^\top X \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^2 \sigma^2}{(s_i^2 + \lambda)^2} \mathbf{v}_i \mathbf{v}_i^\top \end{aligned}$$

Rem: on retrouve $V^{\text{MCO}} = \sum_{i=1}^{\text{rg}(X)} \frac{\sigma^2}{s_i^2} \mathbf{v}_i \mathbf{v}_i^\top$ quand $\lambda \rightarrow 0$

Rem: on retrouve une variance nulle quand $\lambda \rightarrow \infty$

Variance dans le cas général

Sous l'hypothèse de bruit "blanc" (*i.e.*, $\mathbb{E}(\boldsymbol{\varepsilon}) = 0$) et de modèle homoscédastique : $\mathbb{E}(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^\top) = \sigma^2 \text{Id}_n$

Variance / Covariance

$$V_\lambda^{\text{rdg}} = \mathbb{E} \left((\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}})) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \mathbb{E}(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}))^\top \right)$$

Calcul explicite :

$$\begin{aligned} V_\lambda^{\text{rdg}} &= \mathbb{E} \left((\lambda \text{Id}_p + X^\top X)^{-1} X^\top \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top X (\lambda \text{Id}_p + X^\top X)^{-1} \right) \\ &= (\lambda \text{Id}_p + X^\top X)^{-1} X^\top \mathbb{E}(\boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^\top) X (\lambda \text{Id}_p + X^\top X)^{-1} \\ &= \sigma^2 (\lambda \text{Id}_p + X^\top X)^{-2} X^\top X \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^2 \sigma^2}{(s_i^2 + \lambda)^2} \mathbf{v}_i \mathbf{v}_i^\top \end{aligned}$$

Rem: on retrouve $V^{\text{MCO}} = \sum_{i=1}^{\text{rg}(X)} \frac{\sigma^2}{s_i^2} \mathbf{v}_i \mathbf{v}_i^\top$ quand $\lambda \rightarrow 0$

Rem: on retrouve une variance nulle quand $\lambda \rightarrow \infty$

Risque de prédiction

Hypothèse de modèle homoscedastique : $\mathbb{E}(\varepsilon\varepsilon^\top) = \sigma^2 \text{Id}_n$

Risque (quadratique) de prédiction $\mathbb{E}\|X\theta^* - X\hat{\theta}_\lambda^{\text{rdg}}\|^2$

Sous l'hypothèse de modèle homoscedastique :

$$R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) = \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right]$$

Calcul explicite (début identique) :

$$\begin{aligned} R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) &= \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right] \\ &= \mathbb{E} \left[(X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon)^\top (X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon) \right] \\ &\quad + \theta^{*\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \theta^* \end{aligned}$$

Risque de prédiction

Hypothèse de modèle homoscédastique : $\mathbb{E}(\varepsilon\varepsilon^\top) = \sigma^2 \text{Id}_n$

Risque (quadratique) de prédiction $\mathbb{E}\|X\theta^* - X\hat{\theta}_\lambda^{\text{rdg}}\|^2$

Sous l'hypothèse de modèle homoscédastique :

$$R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) = \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right]$$

Calcul explicite (début identique) :

$$\begin{aligned} R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) &= \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right] \\ &= \mathbb{E} \left[(X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon)^\top (X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon) \right. \\ &\quad \left. + \theta^{*\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \theta^* \right] \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^4 \sigma^2}{(s_i^2 + \lambda)^2} + \theta^{*\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \theta^* \end{aligned}$$

Risque de prédiction

Hypothèse de modèle homoscédastique : $\mathbb{E}(\varepsilon\varepsilon^\top) = \sigma^2 \text{Id}_n$

Risque (quadratique) de prédiction $\mathbb{E}\|X\theta^* - X\hat{\theta}_\lambda^{\text{rdg}}\|^2$

Sous l'hypothèse de modèle homoscédastique :

$$R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) = \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right]$$

Calcul explicite (début identique) :

$$\begin{aligned} R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) &= \mathbb{E} \left[(\hat{\theta}_\lambda^{\text{rdg}} - \theta^*)^\top (X^\top X) (\hat{\theta}_\lambda^{\text{rdg}} - \theta^*) \right] \\ &= \mathbb{E} \left[(X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon)^\top (X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \varepsilon) \right. \\ &\quad \left. + \theta^{*\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \theta^* \right] \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^4 \sigma^2}{(s_i^2 + \lambda)^2} + \theta^{*\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \theta^* \end{aligned}$$

Rem: $\lim_{\lambda \rightarrow 0} R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) = \text{rg}(X)\sigma^2$, $\lim_{\lambda \rightarrow \infty} R_{\text{pred}}(\theta^*, \hat{\theta}_\lambda^{\text{rdg}}) = \|X\theta^*\|_2^2$

Risque de prédiction

Hypothèse de modèle homoscedastique : $\mathbb{E}(\varepsilon\varepsilon^\top) = \sigma^2 \text{Id}_n$

Risque (quadratique) de prédiction $\mathbb{E}\|X\boldsymbol{\theta}^\star - X\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}\|^2$

Sous l'hypothèse de modèle homoscedastique :

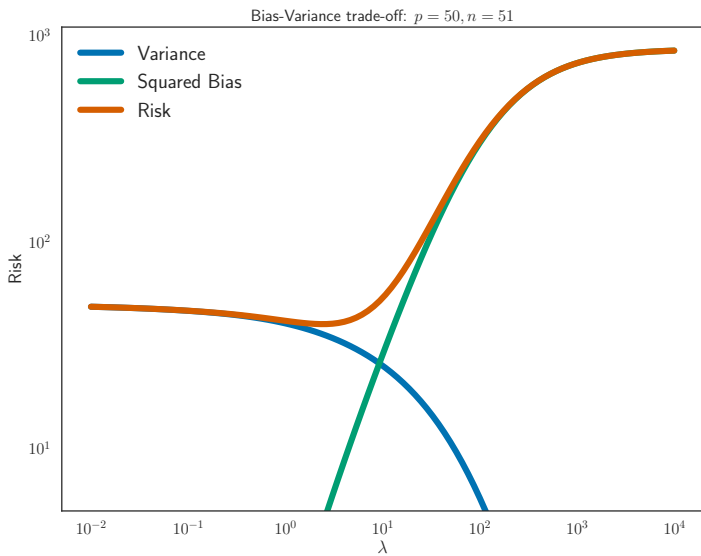
$$R_{\text{pred}}(\boldsymbol{\theta}^\star, \hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}) = \mathbb{E} \left[(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \boldsymbol{\theta}^\star)^\top (X^\top X) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \boldsymbol{\theta}^\star) \right]$$

Calcul explicite (début identique) :

$$\begin{aligned} R_{\text{pred}}(\boldsymbol{\theta}^\star, \hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}) &= \mathbb{E} \left[(\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \boldsymbol{\theta}^\star)^\top (X^\top X) (\hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}} - \boldsymbol{\theta}^\star) \right] \\ &= \mathbb{E} \left[(X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \boldsymbol{\varepsilon})^\top (X(X^\top X + \lambda \text{Id}_p)^{-1} X^\top \boldsymbol{\varepsilon}) \right. \\ &\quad \left. + \boldsymbol{\theta}^{\star\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \boldsymbol{\theta}^\star \right] \\ &= \sum_{i=1}^{\text{rg}(X)} \frac{s_i^4 \sigma^2}{(s_i^2 + \lambda)^2} + \boldsymbol{\theta}^{\star\top} \lambda^2 (X^\top X) (X^\top X + \lambda \text{Id}_p)^{-2} \boldsymbol{\theta}^\star \end{aligned}$$

Rem: $\lim_{\lambda \rightarrow 0} R_{\text{pred}}(\boldsymbol{\theta}^\star, \hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}) = \text{rg}(X)\sigma^2$, $\lim_{\lambda \rightarrow \infty} R_{\text{pred}}(\boldsymbol{\theta}^\star, \hat{\boldsymbol{\theta}}_\lambda^{\text{rdg}}) = \|X\boldsymbol{\theta}^\star\|_2^2$

Biais / Variance : exemple de simulation



$$X \in \mathbb{R}^{50 \times 50}, \boldsymbol{\theta}^* = (2, 2, 2, 2, 2, 0, \dots, 0)^\top$$

Sommaire

Définitions de l'estimateur Ridge

- Point de vue par pénalisation

- Analyse du biais par la SVD

- Analyse de la variance par la SVD

Choix du paramètre de régularisation

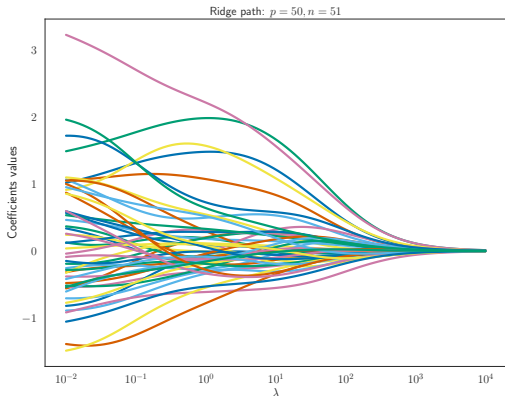
- Notion de chemin de régularisation

- Validation Croisée (CV)

Algorithmes et aspects computationnels

Choix de λ

```
n_features = 50; n_samples = 51
X = np.random.randn(n_samples, n_features)
theta_true = np.zeros([n_features, ])
theta_true[0:5] = 2.
y_true = np.dot(X, theta_true)
y = y_true + 1. * np.random.rand(n_samples,)
```



Sommaire

Définitions de l'estimateur Ridge

- Point de vue par pénalisation

- Analyse du biais par la SVD

- Analyse de la variance par la SVD

Choix du paramètre de régularisation


- Notion de chemin de régularisation

- Validation Croisée (CV)

Algorithmes et aspects computationnels

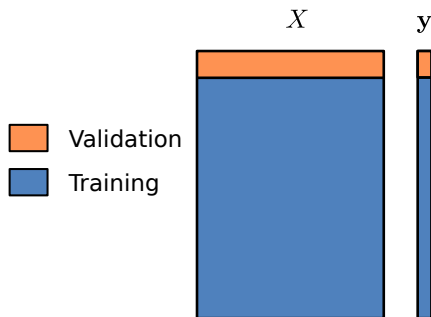
Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :

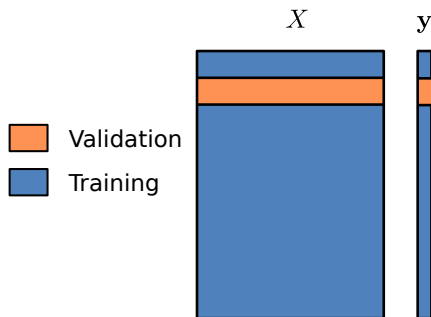


$$k = 1$$

1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

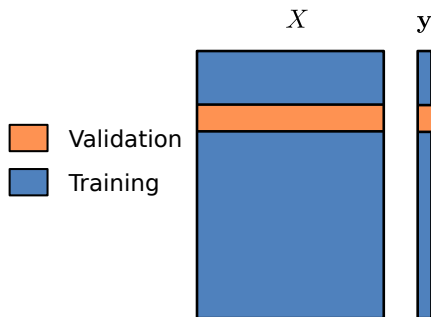
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

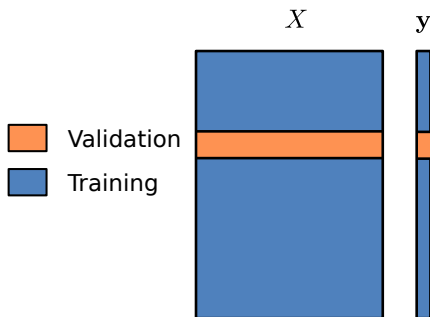
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

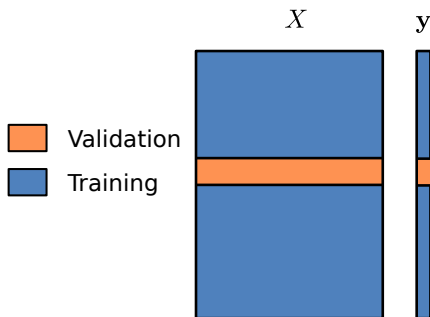
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

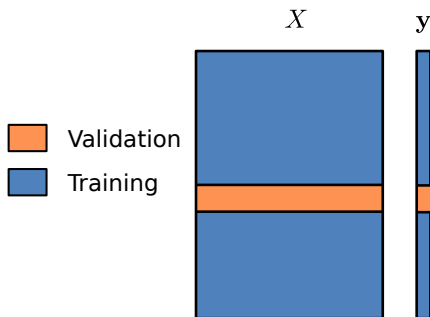
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :

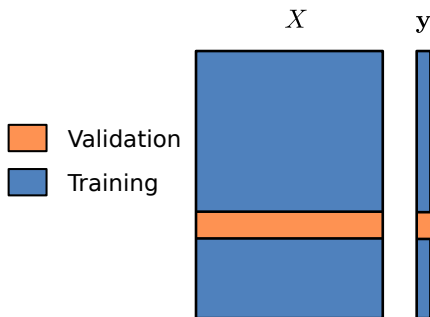


$$k = 6$$

1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

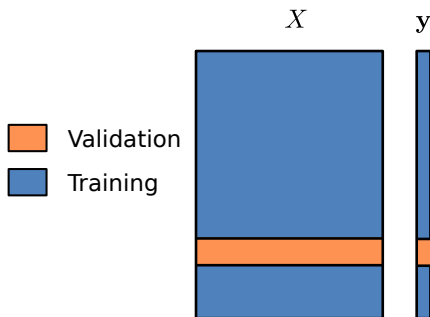
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :

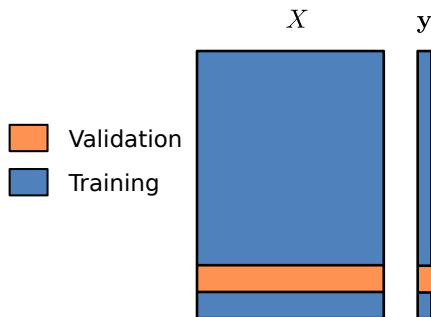


$$k = 8$$

1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :

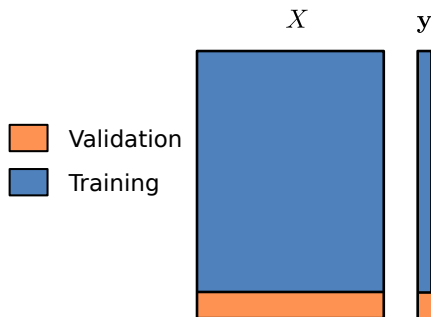


$$k = 9$$

1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

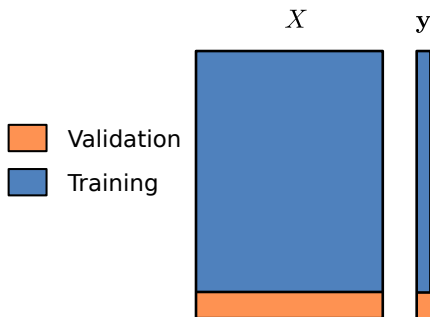
- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :



1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :

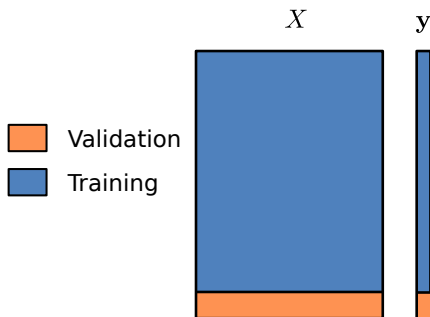


1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Choix du paramètre : calculer $\widehat{\text{Error}}_1, \dots, \widehat{\text{Error}}_r$, moyennes des erreurs et choisir $\hat{i}^{\text{CV}} \in \llbracket 1, r \rrbracket$ atteignant la plus petite

Validation croisée K -fold ($K = 10$)

- ▶ Choisir une grille de taille r de λ à tester : $\lambda_1, \dots, \lambda_r$
- ▶ Diviser (X, y) selon les observations en K blocs (🇬🇧 : *fold*) :




$$k = 10$$

1. Calculer avec les données d'entraînement les estimateurs pour $\lambda_1, \dots, \lambda_r$: $\hat{\theta}^{\lambda_1}, \dots, \hat{\theta}^{\lambda_r}$
2. Calculer les erreurs de prédiction $\text{Error}_1^k, \dots, \text{Error}_r^k$ sur l'ensemble de validation,

Choix du paramètre : calculer $\widehat{\text{Error}}_1, \dots, \widehat{\text{Error}}_r$, moyennes des erreurs et choisir $\hat{i}^{\text{CV}} \in \llbracket 1, r \rrbracket$ atteignant la plus petite

Re-calibration : calculer $\hat{\theta}^{\lambda_{i^{\text{CV}}}}$ sur toutes les observations (X, y)

CV en pratique

Cas extrême de validation croisée ( : *cross-validation*)

- ▶ $K = 1$: impossible, au moins $K = 2$
- ▶ $K = n$: stratégie “*leave-one-out*” (cf. **Jackknife**) : autant de blocs que de variables

Rem: $K = n$: calcul efficace pour Ridge mais assez instable

Conseils pratiques :

- ▶ “randomiser les observations” : observations dans un ordre aléatoire, évite des blocs de données trop similaires (chaque sous-bloc doit être représentatif de l'ensemble)
- ▶ choix habituels : $K = 5, 10$

Rem: en prédiction on peut aussi moyenner les meilleurs estimateurs obtenus plutôt que de re-calibrer sur toutes les données

Variantes de CV et sklearn

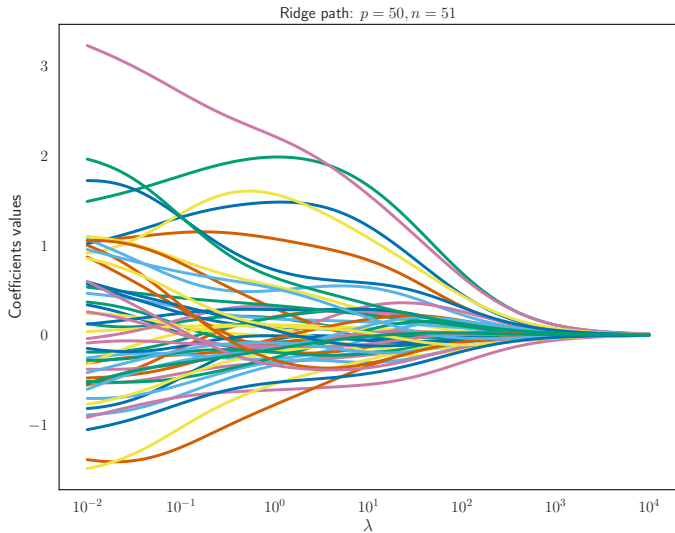
Alternatives classiques :

- ▶ partition aléatoire entre ensemble d'apprentissage et validation ($K = 2$ en gros, cf. `train_test_split`)
- ▶ variante pour séries temporelles : `TimeSeriesSplit`
- ▶ variante pour la classification et pour les cas avec classes déséquilibrées `StratifiedKFold`

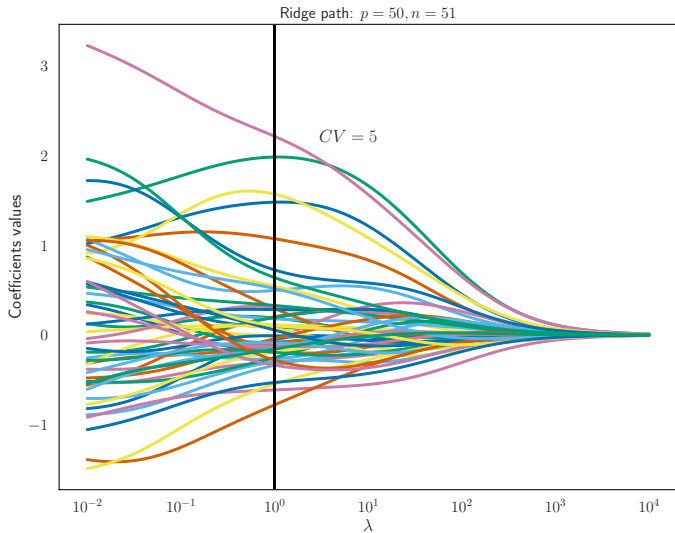
Plus de détails :

http://scikit-learn.org/stable/modules/cross_validation.html

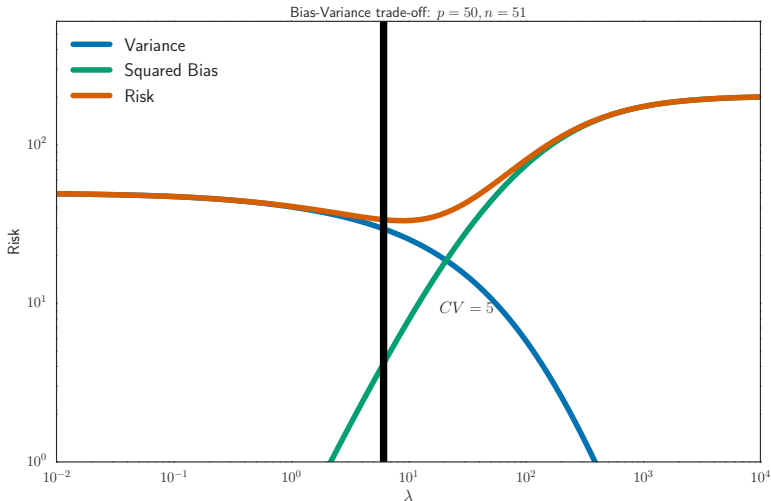
Choix de λ : exemple avec $CV = 5$ (I)



Choix de λ : exemple avec $CV = 5$ (I)



Choix de λ : exemple avec $CV = 5$ (II)




Régularisation et colonne de zéro

ATTENTION : utilisation de CV avec des données catégorielles
En effet : si on enlève toute les occurrences d'une modalité de la partie apprentissage, on crée une colonne de zéro (les MCO ne peuvent plus marcher...)

Remèdes :

- ▶ “régularisation” : on peut obtenir une solution
- ▶ faire une séparation apprentissage/test plus poussée pour équilibrer les *fold*s

Algorithmes pour la méthode *Ridge*

- ▶ 'svd' : méthode la plus stable, avantageuse pour calculer plusieurs λ car on ne "paye" la SVD qu'une fois
- ▶ 'cholesky' : décomposition matricielle proposant une formule fermée `scipy.linalg.solve`
- ▶ 'sparse_cg' : gradient conjugué utile dans les cas creux ( : *sparse*) et de grande dimension (baisser `tol/max_iter`)
- ▶ approche de type gradient stochastique si n est très grand

cf. le code des fonctions `Ridge`, `ridge_path`, `RidgeCV` dans le module `linear_model` de `sklearn`

Rem: on calcule rarement l'estimateur *Ridge* pour un λ , en général on en calcule plusieurs (10, 100, ...) et on cherche le meilleur

Rem: enjeu crucial de calculer des SVD de grandes tailles