

# Apprentissage statistique multi-tâches

Matthieu Solnon<sup>1</sup>

Directeurs de thèse : Sylvain Arlot et Francis Bach


Équipe Sierra  
Département d'Informatique de l'École normale supérieure  
(CNRS/ENS/INRIA UMR 8548)

Lundi 25 novembre 2013


---

1. <http://www.di.ens.fr/~solnon/>


# Lissage par des *splines* cubiques.




## Lissage par des *splines* cubiques.




# Lissage par des *splines* cubiques.




## Lissage par des *splines* cubiques.




# Lissage par des *splines* cubiques.



# Lissage par des *splines* cubiques.




## Lissage par des *splines* cubiques.












## Lissage par des *splines* cubiques.







But du multi-tâches.



# But du multi-tâches.



## But du multi-tâches.



# Construction d'un estimateur multi-tâches

## Modèle.

*Design* :  $n$  points  $(X_i)_{i=1}^n \in \mathcal{X}^n$ .

*Cible* :  $p$  fonctions  $(F^j)_{j=1}^p \in \mathcal{F}^p$ .

*Design fixe* : On veut estimer  $(F^j(X_i))_{i,j} = (f_i^j)_{i,j}$ , comme si les  $(X_i)_{i=1}^n$  étaient fixés.

*Observations* :  $Y_i^j = F^j(X_i) + \varepsilon_i^j, \forall i (\varepsilon_i^j)_{j=1}^p \sim \mathcal{N}(0, \Sigma)$ .

*Risque quadratique* : On voudrait minimiser, sur  $(G^j)_{j=1}^p \in \mathcal{F}^p$ ,

$$\begin{aligned} \mathbb{E} \left[ \frac{1}{np} \sum_{i,j} (F^j(X_i) - G^j(X_i))^2 \right] &= \mathbb{E} \left[ \frac{1}{np} \sum_{i,j} (f_i^j - g_i^j)^2 \right] \\ &= \mathbb{E} \left[ \frac{1}{np} \|f - g\|^2 \right] \end{aligned}$$

## Modèle.

*Design* :  $n$  points  $(X_i)_{i=1}^n \in \mathcal{X}^n$ .

*Cible* :  $p$  fonctions  $(F^j)_{j=1}^p \in \mathcal{F}^p$ .

*Design fixe* : On veut estimer  $(F^j(X_i))_{i,j} = (f_i^j)_{i,j}$ , comme si les  $(X_i)_{i=1}^n$  étaient fixés.

*Observations* :  $Y_i^j = F^j(X_i) + \varepsilon_i^j, \forall i$   $(\varepsilon_i^j)_{j=1}^p \sim \mathcal{N}(0, \Sigma)$ .

*Risque quadratique* : On voudrait minimiser, sur  $(G^j)_{j=1}^p \in \mathcal{F}^p$ ,

$$\begin{aligned} \mathbb{E} \left[ \frac{1}{np} \sum_{i,j} (F^j(X_i) - G^j(X_i))^2 \right] &= \mathbb{E} \left[ \frac{1}{np} \sum_{i,j} (f_i^j - g_i^j)^2 \right] \\ &= \mathbb{E} \left[ \frac{1}{np} \|f - g\|^2 \right] \end{aligned}$$

## Notation des vecteurs.

- ▶ Pour chaque tâche  $j \in \{1, \dots, p\}$ , on note

$$f^j = \begin{pmatrix} f^j(X_1) \\ \vdots \\ f^j(X_n) \end{pmatrix} = \begin{pmatrix} f_1^j \\ \vdots \\ f_n^j \end{pmatrix}, \text{ de taille } n \times 1 .$$

- ▶ On note

$$f = \begin{pmatrix} f^1 \\ \vdots \\ f^p \end{pmatrix}, \text{ de taille } np \times 1 .$$

- ▶ Idem pour  $y, \hat{f}_M, \varepsilon$ , etc.



## Procédure simple-tâche.

$\mathcal{F}$  est un RKHS, avec une matrice de noyau  $K$ .

L'estimateur *ridge* en régression.

- ▶ Pour chaque tâche  $j \in \{1, \dots, p\}$ , minimiser

$$\underbrace{\frac{1}{n} \sum_{i=1}^n (Y_i^j - G(X_i))^2}_{\text{Risque Empirique}} + \lambda^j \|G\|_{\mathcal{F}}^2 .$$

- ▶ Estimateur linéaire :  $\forall j \in \{1, \dots, p\}, \hat{f}_\lambda^j = A_\lambda y^j$  avec  $A_\lambda = K(K + n\lambda I_n)^{-1}$ .
- ▶ La calibration du paramètre  $\lambda^j$  a été étudiée dans [AB11]<sup>2</sup>, [Wah90]<sup>3</sup>, [Gu02]<sup>4</sup>.

---

2. S. Arlot et F. Bach, Data-driven calibration of linear estimators with minimal penalties, 2011.

3. G. Wahba, Spline Models for Observational Data, 1990.

4. C. Gu, Smoothing spline ANOVA models, 2002.

## Généralisation de la pénalisation simple-tâche.

Équivalent à  $p$  problèmes simple-tâches indépendants.

Minimiser sur  $(G^j)_{j=1}^p \in \mathcal{F}^p$

$$\frac{1}{np} \sum_{i,j} (Y_i^j - G^j(X_i))^2 + \sum_{j=1}^p \lambda^j \|G^j\|_{\mathcal{F}}^2$$

## Généralisation de la pénalisation simple-tâche.

Équivalent à  $p$  problèmes simple-tâches indépendants.

$$M = \begin{pmatrix} \lambda^1 & & \\ & \ddots & \\ & & \lambda^p \end{pmatrix}$$

Minimiser sur  $(G^j)_{j=1}^p \in \mathcal{F}^p$

$$\frac{1}{np} \sum_{i,j} (Y_i^j - G^j(X_i))^2 + \underbrace{\sum_{j=1}^p \lambda^j \|G^j\|_{\mathcal{F}}^2}_{\sum_{j,k} M_{j,k} \langle G^j, G^k \rangle := \|(G_1, \dots, G_p)\|_M^2}$$

# Généralisation de la pénalisation simple-tâche.

Généralisation multi-tâches, les  $f^j$  ne sont plus estimées indépendamment.

$$M \in \mathcal{S}_p^{++}(\mathbb{R}) \text{ [EMP05]}^5$$

Minimiser sur  $(G^j)_{j=1}^p \in \mathcal{F}^p$

$$\frac{1}{np} \sum_{i,j} (Y_i^j - G^j(X_i))^2 + \underbrace{\sum_{j,k} M_{j,k} \langle G^j, G^k \rangle}_{\|(G_1, \dots, G_p)\|_M^2}$$

On obtient un estimateur linéaire :  $\hat{f}_M = A_M y$ .

Quels types de similarité entre les tâches  
peut-on exprimer ?

## Exemple de matrice $M$ n° 1.

$$M_{\text{ind}}(\lambda_1, \dots, \lambda_p) = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix}$$

Critère obtenu :

$$\underbrace{\frac{1}{np} \sum_{i,j} (Y_i^j - G^j(X_i))^2}_{\text{Risque empirique}} + \sum_{j=1}^p \lambda_j \|G^j\|_{\mathcal{F}}^2$$

Traite indépendamment les  $p$  fonctions  $\rightarrow$  simple-tâche.

## Exemple de matrice $M$ n° 2.

$$M_{SD}(\lambda, \mu) = \begin{pmatrix} \lambda + (p-1)\mu & & -\mu \\ & \ddots & \\ -\mu & & \lambda + (p-1)\mu \end{pmatrix}$$

Critère obtenu :

$$\underbrace{\frac{1}{np} \sum_{i,j} (Y_i^j - G^j(X_i))^2}_{\text{Risque empirique}} + \lambda \sum_{j=1}^p \|G^j\|_{\mathcal{F}}^2 + \frac{\mu}{2} \sum_{j,k} \|G^j - G^k\|_{\mathcal{F}}^2 .$$

## Exemple de matrice $M$ n° 2.

Il vaut mieux utiliser

$$M_{AV}(\lambda, \mu) = \frac{\lambda}{\rho} \underbrace{\frac{\mathbf{1}\mathbf{1}^\top}{\rho}}_{\text{Moyenne}} + \frac{\mu}{\rho} \underbrace{\left( I_p - \frac{\mathbf{1}\mathbf{1}^\top}{\rho} \right)}_{\text{Variance}} .$$



Peut-on en partie s'adapter à la similarité  
entre les tâches ?

## S'adapter au problème : sélectionner une matrice.

Problème restant : Sélectionner une matrice  $M$  dans un ensemble de matrices  $\mathcal{M}$ . On peut combiner les approches précédentes.

- ▶ Ensembles paramétrés (exemples n° 1 et 2).
- ▶ Ensembles discrets.
- ▶ Unions de différents ensembles de matrices.

## Sélection de la matrice $M$ dans $\mathcal{M}$ .

But : estimer  $M^* \in \operatorname{argmin}_{M \in \mathcal{M}} \left\{ \frac{1}{np} \mathbb{E} \left[ \left\| \hat{f}_M - f \right\|^2 \right] \right\}$ .

## Sélection de la matrice $M$ dans $\mathcal{M}$ .

But : estimer  $M^* \in \operatorname{argmin}_{M \in \mathcal{M}} \left\{ \frac{1}{np} \mathbb{E} \left[ \left\| \hat{f}_M - f \right\|^2 \right] \right\}$ .

Minimiser :  $\operatorname{crit}(M) = \frac{1}{np} \left\| y - \hat{f}_M \right\|_2^2 + \operatorname{pen}(M)$ .

## Sélection de la matrice $M$ dans $\mathcal{M}$ .

But : estimer  $M^* \in \operatorname{argmin}_{M \in \mathcal{M}} \left\{ \frac{1}{np} \mathbb{E} \left[ \left\| \hat{f}_M - f \right\|_2^2 \right] \right\}$ .

Minimiser :  $\operatorname{crit}(M) = \frac{1}{np} \left\| y - \hat{f}_M \right\|_2^2 + \operatorname{pen}(M)$ .

On prend : Pénalité idéale (en espérance)

$$\begin{aligned} \operatorname{pen}_{\text{id}}(M) &:= \mathbb{E} \left[ \frac{1}{np} \left\| \hat{f}_M - f \right\|_2^2 \right] - \mathbb{E} \left[ \frac{1}{np} \left\| y - \hat{f}_M \right\|_2^2 \right] \\ &= \frac{2 \operatorname{tr} (A_M \cdot (\Sigma \otimes I_n))}{np} \end{aligned}$$

avec

$$A_M = (M^{-1} \otimes K) \left( (M^{-1} \otimes K) + np I_{np} \right)^{-1} .$$

## Estimation de variance simple-tâche par les pénalités minimales.

- ▶ Pour toute tâche  $j \in \{1, \dots, p\}$ , estimer la variance du bruit  $\varepsilon^j$ .
- ▶ On peut utiliser des pénalités minimales, [BM07]<sup>6</sup> et [AM09]<sup>7</sup>.
- ▶ Pour tout  $C > 0$ , calculer

$$\hat{\lambda}_0(C) \in \operatorname{argmin}_{\lambda \in \mathbb{R}_+} \left\{ \frac{1}{n} \left\| \hat{f}_\lambda^j - y^j \right\|^2 + C \frac{2 \operatorname{tr}(A_\lambda) - \operatorname{tr}(A_\lambda^\top A_\lambda)}{n} \right\}$$


- ▶ Si  $C > \sigma^2$ ,  $\operatorname{df}(\hat{\lambda}_0(C)) = \operatorname{tr}(A_{\hat{\lambda}_0(C)})$  est petit.
- ▶ Si  $C < \sigma^2$ ,  $\operatorname{df}(\hat{\lambda}_0(C))$  est grand.
- ▶ On estime  $\sigma^2$  en repérant un grand saut dans la courbe de  $\operatorname{df}(\hat{\lambda}_0(C))$ .

---


6. L. Birgé et P. Massart, Minimal Penalties for Gaussian Model Selection, 2007.

7. S. Arlot et P. Massart, Data-driven calibration of penalties for least-squares regression, 2009.

Estimation de  $\Sigma$ .




Estimation de  $\Sigma$ .





Estimation de  $\Sigma$ .



## Hypothèse sur le biais.

$$\left. \begin{aligned} \forall j \in \{1, \dots, p\}, \exists \lambda_{0,j} \in (0, +\infty), \\ \text{df}(\lambda_{0,j}) \leq \sqrt{n} \quad \text{et} \quad \frac{1}{n} \|(A_{\lambda_{0,j}} - I_n)F_{e_j}\|_2^2 \leq \Sigma_{jj} \sqrt{\frac{\ln n}{n}} \end{aligned} \right\} \text{(Hdf)}$$

avec  $\text{df}(\lambda) = \text{tr}(A_\lambda)$  et  $A_\lambda = K(K + \lambda I_n)^{-1}$ .

## Estimation consistante de $\Sigma$ .

$\widehat{\Sigma}$  : matrice obtenue en sortie de l'algorithme précédent.

**Théorème ([SAB12]<sup>8</sup>)**

Avec **(Hdf)** et pour  $n$  assez grand, avec probabilité supérieure à  $1 - p(p+1)/2 \times n^{-\delta}$ , on a

$$(1 - \eta)\Sigma \preceq \widehat{\Sigma} \preceq (1 + \eta)\Sigma ,$$

avec

$$\eta = L_1(2 + \delta)p\sqrt{\frac{\ln n}{n}}c(\Sigma)^2 .$$

---

8. M. Solnon, S. Arlot et F. Bach, Multi-task Regression using Minimal Penalties, 2012.

# Hypothèses sur la structure multi-tâches de $\mathcal{M}$ .

$\mathcal{M}$  est discret.

$$\exists (C, \alpha_{\mathcal{M}}) \in ]0, +\infty[^2, \text{card}(\mathcal{M}) < Cn^{\alpha_{\mathcal{M}}} . \quad (\mathcal{M}\text{discret})$$

Les éléments de  $\mathcal{M}$  sont co-diagonalisables dans une même base, comme dans les exemples n° 1 et 2.

$$\left. \begin{array}{l} \exists P \in O_p(\mathbb{R}) , \\ \mathcal{M} \subseteq \left\{ P^{\top} \text{Diag}(d_1, \dots, d_p)P, (d_j)_{j=1}^p \in ]0, +\infty[^p \right\} \end{array} \right\} (\mathcal{M}\text{codiag})$$

## Inégalité oracle, cas discret.

On sélectionne

$$\hat{M} \in \operatorname{argmin}_{M \in \mathcal{M}} \left\{ \frac{1}{np} \left\| \hat{f}_M - y \right\|_2^2 + \frac{2}{np} \operatorname{tr} \left( A_M \cdot (\hat{\Sigma} \otimes I_n) \right) \right\} .$$

### Théorème ([SAB12])

Avec (**Hdf**) et (**M discret**) et pour  $n$  assez grand, avec probabilité supérieure à  $1 - \kappa' p(p + C)n^{-\delta}$ , on a

$$\frac{1}{np} \left\| \hat{f}_{\hat{M}} - f \right\|_2^2 \leq \left( 1 + \frac{1}{\ln n} \right)^2 \inf_{M \in \mathcal{M}} \left\{ \frac{1}{np} \left\| \hat{f}_M - f \right\|_2^2 \right\} + \theta_n ,$$

avec

$$\theta_n = L_2 c(\Sigma)^4 \sigma_{\max}(\alpha + \delta)^2 \frac{p^4 \ln(n)^3}{np} .$$

## Inégalité oracle, cas continu et co-diagonalisable.

On a un algorithme simplifié qui donne une matrice  $\widehat{\Sigma}_{\text{HM}}$ , on sélectionne

$$\widehat{M} \in \operatorname{argmin}_{M \in \mathcal{M}} \left\{ \frac{1}{np} \left\| \widehat{f}_M - y \right\|_2^2 + \frac{2}{np} \operatorname{tr} \left( A_M \cdot (\widehat{\Sigma}_{\text{HM}} \otimes I_n) \right) \right\} .$$

### Théorème ([SAB12])

Avec **(Hdf)** et **(Mcodiag)** et pour  $n$  assez grand, avec probabilité supérieure à  $1 - \kappa'' pn^{-\delta}$ , on a

$$\frac{1}{np} \left\| \widehat{f}_{\widehat{M}} - f \right\|_2^2 \leq \left( 1 + \frac{1}{\ln n} \right)^2 \inf_{M \in \mathcal{M}} \left\{ \frac{1}{np} \left\| \widehat{f}_M - f \right\|_2^2 \right\} + \theta_n ,$$


avec

$$\theta_n = L_2 \sigma_{\max} (2 + \delta)^2 \frac{p \ln(n)^3}{np} .$$

## Comparaison entre les deux cas.


	Hypothèse ( $\mathcal{M}\mathbf{discret}$ )	Hypothèse ( $\mathcal{M}\mathbf{codiag}$ )
Coût de $\widehat{\Sigma}$	$p(p+1)/2$	$p$
Probabilité	$1 - \kappa' p(p+C)n^{-\delta}$	$1 - \kappa'' pn^{-\delta}$
Erreur $\theta_n$	$L_2 c(\Sigma)^4 \sigma_{\max}(\alpha + \delta)^2 \frac{p^4 \ln(n)^3}{np}$	$L_2 \sigma_{\max}(2 + \delta)^2 \frac{p \ln(n)^3}{np}$

# Simulations : comparaison multi-tâches - simple-tâche.






## Simulations : risque simple-tâche.



# Simulations : risque multi-tâches.



Le multi-tâches fonctionne-t-il ?

# Le multi-tâches fonctionne-t-il ?

## Petites hypothèses

- ▶ Pour simplifier :  $\Sigma = \sigma^2 I_p$ .
- ▶ Paramètres de régularisation :  
 $\mathcal{M}_{AV} = \{M_{AV}(\lambda, \mu), (\lambda, \mu) \in ]0, +\infty[^2\}$ .

## Décomposition biais-variance : le risque dépend

- ▶ des valeurs propres de la matrice de noyau  $K : (\gamma_i)_{i=1}^n$  ;
- ▶ des coefficients de la moyenne des signaux  $f^j$  sur la base qui a servi à diagonaliser  $K : \left(\frac{\mu_i}{p}\right)_{i=1}^n$  ;
- ▶ des coefficients de la « variance » des signaux  $f^j$  sur la base qui a servi à diagonaliser  $K : (\varsigma_i^2)_{i=1}^n$ .

# Hypothèses.

Régularité du noyau :

$$\forall i \in \{1, \dots, n\}, \gamma_i = ni^{-2\beta} . \quad (\text{RegNoyau})$$

Régularité du signal :

$$\forall i \in \{1, \dots, n\}, \begin{cases} \frac{\mu_i^2}{p} = C_1 ni^{-2\delta} \\ \zeta_i^2 = C_2 ni^{-2\delta} \end{cases} . \quad (\text{RegSignal})$$

## Notations

- ▶ Risque oracle multi-tâches :  $\mathfrak{R}_{\text{MT}}^*$ .
- ▶ Risque oracle simple-tâche :  $\mathfrak{R}_{\text{ST}}^*$ .

# Contrôle du risque oracle multi-tâches.

## Théorème ([Sol13]<sup>9</sup>)

Soit  $n$ ,  $p$ ,  $C_1$ ,  $C_2$ ,  $\sigma^2$ ,  $\beta$  et  $\delta$  tels que **(RegNoyau)** et **(RegSignal)** sont vérifiés et tels que  $1 < 2\delta < 4\beta + 1$ , on a

$$\mathfrak{R}_{\text{MT}}^* \leq 2^{1/(2\delta)} \left(\frac{np}{\sigma^2}\right)^{1/(2\delta)-1} \kappa(\beta, \delta) \left[ C_1^{1/(2\delta)} + (p-1)^{1-(1/2\delta)} C_2^{1/2\delta} \right].$$

De plus, il existe des constantes  $N$  et  $\alpha \in (0, 1)$  telles, si  $n \geq N$ ,  $p/\sigma^2 \leq n$  et si  $2 < 2\delta < 4\beta$ , on a

$$\mathfrak{R}_{\text{MT}}^* \geq \alpha \left(\frac{np}{\sigma^2}\right)^{1/(2\delta)-1} \kappa(\beta, \delta) \left[ C_1^{1/2\delta} + (p-1)^{1-(1/2\delta)} C_2^{1/2\delta} \right].$$

## Hypothèses pour calculer le risque oracle simple-tâche.

2 points :  $p$  est pair et

$$f^1 = \dots = f^{p/2} \text{ et } f^{p/2+1} = \dots = f^p . \quad (2\text{Points})$$

1 outlier :

$$f^1 = \dots = f^{p-1} . \quad (1\text{Out})$$

Notation

►  $r = C_2/C_1$

## Comparaison multi-tâches - simple-tâche.

Corollaire ([Sol13])

Soit  $n$ ,  $p$ ,  $C_1$ ,  $C_2$ ,  $\sigma^2$ ,  $\beta$  et  $\delta$  tels que  $2 < 2\delta < 4\beta$  et  $n\sigma^2 > p$ , si **(RegSignal)** et **(RegNoyau)** sont vérifiés, alors

avec **(2Points)** :

$$\frac{\mathfrak{R}_{\text{MT}}^*}{\mathfrak{R}_{\text{ST}}^*} \asymp \frac{p^{1/(2\delta)-1} + \left(\frac{p-1}{p}\right)^{1-(1/2\delta)} r^{1/2\delta}}{(1 + \sqrt{r})^{1/\delta} + |1 - \sqrt{r}|^{1/\delta}} ;$$

avec **(1Out)** :

$$\frac{\mathfrak{R}_{\text{MT}}^*}{\mathfrak{R}_{\text{ST}}^*} \asymp \frac{p^{1/(2\delta)-1} + \left(\frac{p-1}{p}\right)^{1-(1/2\delta)} r^{1/2\delta}}{\frac{p-1}{p} \left(1 + \sqrt{\frac{r}{p-1}}\right)^{1/\delta} + \frac{1}{p} \left|1 - \sqrt{r(p-1)}\right|^{1/\delta}} .$$




# Situations positives et négatives pour l'oracle multi-tâches.

Soit


$$\rho = \frac{\mathfrak{R}_{\text{MT}}^*}{\mathfrak{R}_{\text{ST}}^*} .$$

- ▶ Si  $r$  tend vers 0, alors  $\rho$  tend vers  $Cst \times p^{1/2\delta-1}$ .
- ▶ Quand  $r$  est grand :
  - ▶ Avec (**2Points**),  $\rho$  est borné ;
  - ▶ Avec (**1Out**),  $\rho$  tend vers  $+\infty$  quand  $r$  tend vers  $\infty$ .

# Simulations : un groupe de tâches.








# Simulations : un groupe de tâches et un *outlier*.



# Conclusion

## Références bibliographiques. I

-  Sylvain Arlot et Francis Bach: *Data-driven calibration of linear estimators with minimal penalties*, 2011.  
arXiv :0909.1884v2.
-  Sylvain Arlot et Pascal Massart: *Data-driven calibration of penalties for least-squares regression*.  
Journal of Machine Learning Research, 10 :245–279  
(electronic), 2009.
-  Lucien Birgé et Pascal Massart: *Minimal Penalties for Gaussian Model Selection*.  
Probability Theory and Related Fields, 138 :33–73, 2007.
-  Theodoros Evgeniou, Charles A. Micchelli et Massimiliano Pontil: *Learning Multiple Tasks with Kernel Methods*.  
Journal of Machine Learning Research, 6 :615–637, 2005.
-  Chong Gu: *Smoothing spline ANOVA models*.  
Springer, 2002.

## Références bibliographiques. II



Matthieu Solnon, Sylvain Arlot et Francis Bach: *Multi-task Regression using Minimal Penalties*.

Journal of Machine Learning Research, 13 :2773–2812, septembre 2012.



Matthieu Solnon: *Comparison between multi-task and single-task oracle risks in kernel ridge regression*.

2013.



Grace Wahba: *Spline Models for Observational Data*, tome 59 de *CBMS-NSF Regional Conference Series in Applied Mathematics*.

Society for Industrial and Applied Mathematics (SIAM), Philadelphia, PA, 1990.

The end.

Merci !

Et maintenant, avez-vous des questions ?

À suivre : pot en salle club !

