

# OPTIMISATION POUR L'APPRENTISSAGE

23 janvier 2025

Ce matin: Régularisation (Cours, illustration numérique)  
Exercice du TD 3 en ligne

# RÉGULARISATION

## Problème régularisé

minimiser  
 $w \in \mathbb{R}^d$

$$f(w) + \lambda \Omega(w)$$

↑  
Terme  
d'attachement aux  
données

→ Terme de  
régularisation  
 $\Omega: \mathbb{R}^d \rightarrow \mathbb{R}$

⇒ Modélise des propriétés  
souhaitées pour la solution

(typiquement  $f(w) = \frac{1}{m} \sum_{i=1}^m f_i(w)$ )

⇒ Exprime la tâche  
d'apprentissage à réaliser (régression, classification, etc)

## Exemples en régression linéaire

$$X \in \mathbb{R}^{m \times d}, \quad y \in \mathbb{R}^m$$
$$\begin{bmatrix} x_1^T \\ \vdots \\ x_m^T \end{bmatrix}, \quad \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}$$

Problème non régularisé:

But: Trouver  $w \in \mathbb{R}^d$  tq  $Xw \approx y$

minimiser  
 $w \in \mathbb{R}^d$

$$\frac{1}{2m} \|Xw - y\|_2^2$$

$$\|Xw - y\|_2^2 = \sum_{i=1}^m (x_i^T w - y_i)^2$$

→ Régularisation  $\ell_2$  (aka "ridge", "Tychonov", ...)

minimiser  
 $w \in \mathbb{R}^d$

$$\frac{1}{2m} \|Xw - y\|_2^2 + \lambda \|w\|_2^2$$

$$\|w\|_2^2 = \sum_{j=1}^d w_j^2$$

$\lambda = 0$  ⇒ Problème de départ

$\lambda \ll 1$  : proche du problème de départ

$\lambda \gg 1$  : poids de problème

minimiser  $w \in \mathbb{R}^d$   $\lambda \|w\|_2^2$  )  $\Rightarrow$  unique solution  $w^* = 0_{\mathbb{R}^d}$

Pourquoi régulariser avec la norme  $l_2$ ?

$\rightarrow$  Améliorer la généralisation du modèle  
 $\Rightarrow$  Eviter  $\|X^{test} w^* - y^{test}\|_2^2$

avec  $w^* \in \arg \min_{w \in \mathbb{R}^d} \frac{1}{2n} \|Xw - y\|_2^2 + \lambda \|w\|_2^2$

et  $(X^{test}, y^{test})$  provient de la même distribution de données que  $(X, y)$

$\rightarrow$  Rendre le problème fortement convexe

$w \mapsto \lambda \|w\|_2^2$   
est  $2\lambda$ -fortement convexe

⊕ Garantie d'unicité de la solution

⊕ Convergence plus rapide des algorithmes type descente de gradient / gradient stochastique

$w \mapsto \frac{1}{2n} \|Xw - y\|_2^2$   
est convexe

$\rightarrow$  Réduire la sensibilité de la solution par rapport aux données

$\rightarrow$  On souhaite que la solution varie peu si les données  $(X, y)$  sont légèrement perturbées

(ex)  $n = d = 2$

$$X = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \quad y = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

$$\text{minimiser } w \in \mathbb{R}^2 \quad \frac{1}{2n} \|Xw - y\|_2^2 = \frac{1}{4} \left( (w_1 - 1)^2 + 1 \right)$$

$$\operatorname{argmin}_{w \in \mathbb{R}^2} \frac{1}{2n} \|Xw - y\|^2 = \left\{ w = \begin{bmatrix} 1 \\ w_2 \end{bmatrix} \mid w_2 \in \mathbb{R} \right\}$$

$$\forall \lambda > 0, \operatorname{minimiser}_{w \in \mathbb{R}^2} \left\{ \frac{1}{2n} \|Xw - y\|_2^2 + \lambda \|w\|_2^2 \right\}$$

$$\frac{1}{4} w_1^2 - \frac{1}{2} w_1 + \lambda w_1^2$$

$$\frac{1}{4} \left( (w_1 - 1)^2 + 1 \right) + \lambda w_1^2 + \lambda w_2^2$$

$$\frac{1}{2} w_1 + 2\lambda w_1 - \frac{1}{2} = 0$$

$$w_1 = \frac{1}{1 + 4\lambda}$$

$$\operatorname{argmin}_{w \in \mathbb{R}^2} \left\{ \rightarrow \right\} = \left\{ \begin{bmatrix} \frac{1}{1 + 4\lambda} \\ 0 \end{bmatrix} \right\}$$

Remarque: Dans le cas général

$$\operatorname{minimiser}_{w \in \mathbb{R}^d} f(w) + \lambda \|w\|_2^2$$

avec  $f \in C^1$ , l'itération de descente de gradient sur ce problème donne

$$w_{k+1} = w_k - \alpha_k \left[ \nabla f(w_k) + 2\lambda w_k \right]$$

$$\nabla (\lambda \|w\|_2^2)(w_k) = 2\lambda w_k$$

$$= (1 - 2\lambda \alpha_k) w_k - \alpha_k \nabla f(w_k)$$

Pour  $\alpha_k < \frac{1}{2\lambda}$ , "weight decay": on réduit l'amplitude des coefficients de  $w_k$  en plus de faire un pas de gradient

# → Régularisation $l_1$ / LASSO

Pour la régression linéaire,

$$\underset{w \in \mathbb{R}^d}{\text{minimiser}} \frac{1}{2n} \|Xw - y\|_2^2 + \lambda \|w\|_1$$

$$\|w\|_1 = \sum_{j=1}^d |w_j|$$

Pourquoi la norme  $l_1$ ?

→ Favorise les solutions avec des coordonnées nulles

(cas extrême  $\lambda \gg 1$  : minimiser  $\lambda \|w\|_1$ )

$$\downarrow$$
$$w^* = 0_{\mathbb{R}^d}$$

→ Lorsque  $\lambda$  augmente, la solution du problème a de plus en plus de coordonnées nulles, et les coordonnées sont "mises à 0" par ordre croissant d'importance

Ex) minimiser  $w \in \mathbb{R}^2$   $\left[ (w_1 - 1)^2 + (w_2 - 2)^2 \right] \Rightarrow w^* = \begin{bmatrix} 1 \\ 2 \end{bmatrix}$

minimiser  $w \in \mathbb{R}^2$   $\left[ (w_1 - 1)^2 + (w_2 - 2)^2 + \lambda \|w\|_1^2 \right]$

$$2w_1 - 2 + 2\lambda w_1 = 0$$

$$w_1 = \frac{1}{1+\lambda}$$

$$\Rightarrow w^* = \begin{bmatrix} \frac{1}{1+\lambda} \\ \frac{2}{1+\lambda} \end{bmatrix} \xrightarrow{\lambda \rightarrow +\infty} \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

minimiser  $w \in \mathbb{R}^2$   $\left[ (w_1 - 1)^2 + (w_2 - 2)^2 \right] + \lambda \|w\|_1$

$$(w_1 - 1)^2 + \lambda |w_1|$$

$$2(w_1 - 1) \in \lambda \partial |w_1|$$

$$0 \leq \lambda < 2$$

$$w^* = \begin{bmatrix} 1 - \frac{\lambda}{2} \\ 2 - \frac{\lambda}{2} \end{bmatrix}$$

$$2 \leq \lambda < 4$$

$$w^* = \begin{bmatrix} 0 \\ 2 - \lambda/2 \end{bmatrix}$$

$$4 \leq \lambda$$

$$w^* = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

Q) Existe-t-il un algorithme qui s'applique à tout problème de la forme minimiser  $w \in \mathbb{R}^d$   $f(w) + \lambda \Omega(w)$  ?

- Hypothèses :
- $f \in C^1$  (mais pas forcément convexe)
  - $\Omega$  convexe (mais pas forcément dérivable)

Itération du gradient proximal:

$$w_{k+1} \in \underset{w \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \underbrace{f(w_k) + \nabla f(w_k)^T (w - w_k)}_{\approx f(w) \text{ au tour de } w_k} + \underbrace{\frac{1}{2\alpha_k} \|w - w_k\|_2^2}_{\text{Terme proximal: garantit que } w \text{ est proche de } w_k} + \underbrace{\lambda \Omega(w)}_{\text{régularisation (inchangé)}} \right\}$$

avec  $\alpha_k > 0$

Définition implicite:  $w_{k+1}$  est défini comme la solution d'un problème d'optimisation

Remarques importantes : Si  $\Omega \equiv 0$  ( $\Omega(w) = 0 \forall w$ )

alors

$$\underset{w \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ f(w_k) + \nabla f(w_k)^T (w - w_k) + \frac{1}{2\alpha_k} \|w - w_k\|_2^2 \right\}$$

$$= w_k - \alpha_k \nabla f(w_k)$$

• Dans le cas général, l'algorithme du gradient proximal n'est intéressant que si le sous-problème résolu à chaque itération est plus facile à résoudre que le problème de départ!

⇒ Pour les régularisateurs classiques ( $l_2, l_1, \dots$ ), on peut résoudre le sous-problème de manière explicite

⇒ Cas  $\Omega(w) = \|w\|_1$ : l'algorithme du gradient proximal correspond à l'algorithme ISTA (Iterative Soft-Thresholding Algorithm)

### Exo 2 TD 3

a) La régularisation sert à favoriser les vecteurs/modèles qui vérifient une propriété souhaitée (parcimonie, par exemple).

$\Leftrightarrow$  ————— pénaliser les vecteurs/modèles qui ne vérifient une propriété souhaitée.

d)

$$w_{k+1} \in \underset{w \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \phi(w_k) + \nabla \phi(w_k)^T (w - w_k) + \frac{1}{2\alpha_k} \|w - w_k\|_2^2 + \frac{\lambda_2}{2} \|w\|_2^2 + \lambda_1 \|w\|_1 \right\}$$

$$\phi(w) = \frac{1}{2m} \|Xw - y\|_2^2$$

$\Leftrightarrow$

$$w_{k+1} \in \underset{w \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \frac{1}{2m} \|Xw_k - y\|_2^2 + \frac{1}{m} (Xw_k - y)^T X (w - w_k) + \frac{1}{2\alpha_k} \|w - w_k\|_2^2 + \frac{\lambda_2}{2} \|w\|_2^2 + \lambda_1 \|w\|_1 \right\}$$

e)  $\lambda_2 = 0$

$$w_{k+1} \in \underset{w \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \phi(w_k) + \nabla \phi(w_k)^T (w - w_k) + \frac{1}{2\alpha_k} \|w - w_k\|_2^2 + \lambda_1 \|w\|_1 \right\}$$

ISTA = gradient proximal pour ce problème avec formule explicite pour  $w_{k+1}$



g) minimise  $\phi(w_k) + \nabla \phi(w_k)^T (w - w_k) + \frac{1}{2\alpha_k} \|w - w_k\|_2^2 + \frac{\lambda_2}{2} \|w\|_2^2 + \lambda_1 \|w\|_1$   
 $w \in \mathbb{R}^d$

$f(w)$

$\lambda_2 > 0 \quad \lambda_1 > 0$   
 $w_k \in \mathbb{R}^d, \alpha_k > 0$

→ Sub-gradient ✓  
 → ISTA ✓

↳ Problème : minimise  $f(w) + \lambda_1 \|w\|_1$   
 $w \in \mathbb{R}^d$

ISTA  
 $w^{(0)}, \dots, w^{(j)}, w^{(j+1)}, \dots$

↳ sous-problème :

$w^{(j+1)} \in \underset{\bar{w} \in \mathbb{R}^d}{\text{argmin}} \left\{ f(w^{(j)}) + \nabla f(w^{(j)})^T (\bar{w} - w^{(j)}) + \frac{1}{2\beta^{(j)}} \| \bar{w} - w^{(j)} \|_2^2 + \lambda_1 \| \bar{w} \|_1 \right\}$   
 avec  $\beta^{(j)} > 0$