

# OUTILS D'OPTIMISATION POUR LES SCIENCES DES DONNÉES ET DE LA DÉCISION

9 novembre 2023

Aujourd'hui : → Optimisation et décomposition 1/2  
→ Fin TD 6 + début TD 7 (examen 2022-2023)

Demain : → Optimisation et décomposition 2/2  
→ Fin TD 7

# OPTIMISATION ET DÉCOMPOSITION

## Motivation

- Difficulté des problèmes modernes en optimisation : la grande dimension
  - Très grand nombre de variables et/ou
  - Fonction objectif combinaison d'un très grand nombre de termes

Ex) Apprentissage profond, réseaux d'énergie, réseaux de télécommunication

- Opportunité : Tous ces problèmes sont fortement structurés
  - Relations entre les variables (typiquement des relations linéaires)
  - Possibilité de décomposer le problème en sous-problèmes de plus petite dimension

Q) Comment exploiter la structure dans les algorithmes d'optimisation ?

## ① Optimisation sous contraintes linéaires

Problème : (P) minimiser  $f(w)$  s.c.  $Aw = b$   
 $w \in \mathbb{R}^d$

$A \in \mathbb{R}^{m \times d}$ ,  $b \in \mathbb{R}^m$ ,  $f: \mathbb{R}^d \rightarrow \mathbb{R}$

contrainte structurelle du problème (ex: contrainte physique)

Hypothèse:  $\underbrace{\{w \in \mathbb{R}^d \mid Aw = b\}}_{\text{ensemble admissible}}$  est non vide

↳ Grâce à la théorie de la dualité, on peut remplacer le problème (P) par un problème sans contraintes basé sur une fonction appelée le lagrangien du problème.

Def: Le lagrangien associé à (P) est la fonction

$$L: \mathbb{R}^d \times \mathbb{R}^m \rightarrow \mathbb{R}$$

$$(w, z) \mapsto L(w, z) = \underbrace{f(w)}_{\text{fonction objectif de (P)}} + \underbrace{z^T}_{\mathbb{R}^m} \underbrace{(Aw - b)}_{\substack{\mathbb{R}^m \\ \text{représente} \\ \text{la contrainte} \\ Aw - b = 0}}$$

variables de décision de (P)

Fonction objectif de (P)

$\mathbb{R}^m$   
représente la contrainte  $Aw - b = 0$

$z$  s'appelle le vecteur des variables duales / multiplicateurs de Lagrange

↳ Le lagrangien est une combinaison de la fonction objectif et des fonctions définissant les contraintes

↳ On peut montrer que (P) est équivalent au problème

"problème primal"

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

$$\boxed{\max_{z \in \mathbb{R}^m} L(w, z)}$$

Fonction  $w \mapsto \max_{z \in \mathbb{R}^m} L(w, z)$

## Définition

Le problème dual de (P) est le problème

$$(D) \quad \begin{array}{l} \text{maximiser} \\ z \in \mathbb{R}^m \end{array} \quad \underbrace{\min_{w \in \mathbb{R}^d} \mathcal{L}(w, z)}$$

$z \mapsto \min_{w \in \mathbb{R}^d} \mathcal{L}(w, z)$  : fonction  
dual  
du  
problème

## Propriétés:

• La fonction dual est toujours concave (son opposée est convexe)

→ (D) est équivalent à minimiser une fonction convexe sans contraintes!

• En règle générale, il y a dualité forte entre (P) et (D), c'est-à-dire que

$$1) \quad \underbrace{\min_{w \in \mathbb{R}^d} \max_{z \in \mathbb{R}^m} \mathcal{L}(w, z)}_{\text{Valeur optimale de (P)}} = \max_{z \in \mathbb{R}^m} \underbrace{\min_{w \in \mathbb{R}^d} \mathcal{L}(w, z)}_{\text{Valeur optimale en (D)}}$$

2)  $\exists (w^*, z^*) \in \mathbb{R}^d \times \mathbb{R}^m$  tels que  $w^*$  est solution de (P),  $z^*$  est solution de (D), et

$$\mathcal{L}(w^*, z^*) = \min_w \max_z \mathcal{L}(w, z) = \max_z \min_w \mathcal{L}(w, z)$$

↳ La théorie de la dualité lagrangienne permet de ramener la résolution d'un problème avec contraintes à la résolution

d'un problème convexe sans contraintes

⇒ Pour résoudre le problème (P), on va donc maximiser la fonction duale  $z \mapsto \min_{w \in \mathbb{R}^d} \mathcal{L}(w, z)$

## (2) Méthodes duales

Principe: Calculer une suite de variables duales  $\{z_k\}$  via un algorithme d'optimisation et en déduire une suite de variables primales  $\{w_k\}$

### Méthode de montée duale (dual ascent)

Initialisation:  $w_0 \in \mathbb{R}^d$ ,  $z_0 \in \mathbb{R}^m$

Pour  $k=0, 1, \dots$

• Calculer  $w_{k+1} \in \arg \min_{w \in \mathbb{R}^d} \mathcal{L}(w, z_k)$

• Poser  $z_{k+1} = z_k + \alpha_k (A w_{k+1} - b)$

avec  $\alpha_k > 0$

Calcul de  $z_{k+1}$ : Pas de sous-gradient pour la fonction

$$d: z \mapsto - \min_{w \in \mathbb{R}^d} \mathcal{L}(w, z)$$

en  $z_k$

$$(-A w_{k+1} - b) \in \partial d(z_k)$$

Calcul de  $w_{k+1}$ : Résolution d'un problème d'optimisation  
Sans contraintes

$$\mathcal{L}(w, z_k) = f(w) + z_k^T (Aw - b)$$

- Solution n'est pas forcément unique
- Contraintes ont une importance dans la minimisation

Si  $w_{k+1}$  est admissible pour (P) (c-à-d  $Aw_{k+1} = b$ ),

$$\text{alors } z_{k+1} = z_k + \alpha_k \underbrace{(Aw_{k+1} - b)}_{=0} = z_k$$

et  $z_k$  est une solution de (D)

$\Rightarrow w_k$  est une solution de (P)

$\hookrightarrow$  La méthode de montée duale possède des garanties théoriques proches de celles de méthodes de sous-gradient, et en particulier elle converge lentement vers une solution (et donc lentement vers un  $w_k$  qui soit admissible)

$\Rightarrow$  On peut obtenir de meilleures garanties en régularisant le problème

Def. Le lagrangien augmenté associé à (P) est la fonction

$$\mathcal{L}^a : \mathbb{R}^d \times \mathbb{R}^m \times \mathbb{R}_{++} \xrightarrow{(0, +\infty)} \mathbb{R}$$

$$(w, z, \lambda) \mapsto \mathcal{L}^a(w, z, \lambda) = f(w) + z^T (Aw - b) + \frac{\lambda}{2} \|Aw - b\|^2$$

$$\mathcal{L}^a(w, z; \lambda) = \underbrace{f(w) + z^T(Aw - b)}_{\mathcal{L}(w, z)} + \frac{\lambda}{2} \|Aw - b\|^2$$

Plus la valeur de  $\lambda$  est élevée, plus on force la solution à satisfaire les contraintes

terme de régularisation  $\lambda > 0$  qui pénalise les vecteurs  $w$  non admissibles pour (P)

Méthode du lagrangien augmenté (ou méthode des multiplicateurs)

Initialisation:  $w_0 \in \mathbb{R}^d, z_0 \in \mathbb{R}^m$

Itération k:

- Calculer  $w_{k+1} \in \underset{w \in \mathbb{R}^d}{\text{argmin}} \mathcal{L}^a(w, z_k, \lambda)$
- Poser  $z_{k+1} = z_k + \lambda (Aw_{k+1} - b)$

Commentaires

→ Version de base:  $\lambda$  utilisé comme paramètre de régularisation et comme taille de pas constante.

→ Versions avancées: • Remplacer la taille de pas  $\lambda$  par  $\alpha_k > 0$

• Faire varier  $\lambda \rightarrow \{\alpha_k\}$  (en assumant que  $\alpha_{k+1} \geq \alpha_k \forall k$ )

→ Avantage du lagrangien augmenté: Garantit une convergence plus rapide vers un point vérifiant les

contraintes

- Pour  $\lambda$  suffisamment grand, le problème minimiser  $\mathcal{L}^a(w, z_k; \lambda)$  sur  $w \in \mathbb{R}^d$  aura une unique solution (Vrai  $\forall \lambda > 0$  si  $f$  est convexe)

### ③ Décomposition

Cadre:  $\rightarrow$  minimisation sous contraintes d'égalité linéaires  
 $\rightarrow$  Structure séparable

minimiser  $f(u) + g(v)$  s.c.  $Au + Bv = c$   
 $u \in \mathbb{R}^{d_1}$   
 $v \in \mathbb{R}^{d_2}$

$f: \mathbb{R}^{d_1} \rightarrow \mathbb{R}$   
 $g: \mathbb{R}^{d_2} \rightarrow \mathbb{R}$

$A \in \mathbb{R}^{m \times d_1}$   
 $B \in \mathbb{R}^{m \times d_2}$   
 $c \in \mathbb{R}^m$

Séparable:  
• la fonction objectif est une somme d'une fonction de  $u$  et d'une fonction de  $v$   
• Les fonctions définissant les contraintes sont sommes d'une fonction de  $u$  et d'une fonction de  $v$

Approche naïve: Poser  $w = \begin{bmatrix} u \\ v \end{bmatrix} \in \mathbb{R}^{d_1+d_2}$   $d = d_1 + d_2$

$\hat{f}(w) = f(u) + g(v)$   $\hat{A} = \begin{bmatrix} A & B \end{bmatrix}$   
 $\hat{b} = c$

$\Rightarrow$  minimiser  $\hat{f}(w)$  s.c.  $\hat{A}w = \hat{b}$   
 $w \in \mathbb{R}^d$

⊖ Cette approche ne tient pas compte de la structure du problème et conduit (via les méthodes duales notamment) à résoudre des problèmes en dimension  $d_1 + d_2$  alors que les variables ont des rôles indépendants dans la fonction objectif  
 ⇒ problématique lorsque  $d \gg 1$ , on préfère donc les techniques de décomposition

Remarque : La propriété de séparabilité s'étend à plus de deux groupes de variables

$$\begin{array}{l}
 \text{minimiser} \\
 u^{(1)} \in \mathbb{R}^{d_1} \\
 \vdots \\
 u^{(m)} \in \mathbb{R}^{d_m}
 \end{array}
 \sum_{i=1}^m f_i(u^{(i)}) \quad \text{s.c.} \quad \sum_{i=1}^m A_i u^{(i)} = b$$