

Optimisation Différentiable
Théorie et Algorithmes
Partie I

Exemple de résumé du cours

J. Ch. GILBERT

14 novembre 2020

Informations pratiques

- 14 séances, échappatoire possible à mi-parcours.
- Objectif du cours : l'optimisation
 - aspects théoriques : convexité, CO, dualité, ... ,
 - aspects pratiques : algorithmes.
- Organisation :
 - Partie I : 7 séances, dont 1/2 pour l'examen.
 - CM : 6 séances d'1h15++,
 - TD + TP : 4+3 séances d'2h00--,
 - TP : projet d'optimisation (Matlab),
 - travail personnel.
- Supports de cours
 - syllabus [site] : ne pas voir les sections avec \ominus ,
 - planches [pdf] : points importants du cours [§],
 - notes manuscrites [SP] : 1 document par séance,
 - exercices : en TD (+sol), dans le syllabus (–sol).
- Contrôle des connaissances
 - TP : rapport et code incrémental à remettre,
 - Séance 7 : résolution de problèmes (1h30).

Plan du cours I

1. Introduction : optimisation et analyse convexe
TD1 (rappels, concepts de base)
2. Conditions d'optimalité I : méthode et outils
TP1
3. Conditions d'optimalité II : égalités et inégalités
TD2 (conditions d'optimalité)
4. Conditions d'optimalité III : CO2 égalités et
Méthode de descente : RL
TP2
5. Méthodes newtoniennes : N et qN
TD3 (recherche linéaire, moindres-carrés)
6. Dualité
TD4 (dualité)
7. Contrôle des connaissances
TP3

I Introduction

Vocabulaire de l'optimisation (§ 1.1)

Le problème à résoudre :

$$(P_X) \quad \inf_{x \in X} f(x).$$

Quelques définitions et conventions :

- $f : X \rightarrow \overline{\mathbb{R}}$ est appelée **critère** ou **fonction-coût** ou **fonction-objectif**,
- X est appelé **ensemble admissible**,
- un point de X est dit **admissible**,
- $\text{val}(P_X) := \inf_{x \in X} f(x) \in \overline{\mathbb{R}}$ est la **valeur optimale**,
- (P_X) est dit **réalisable** si $X \neq \emptyset$,
- convention : $\inf_{x \in \emptyset} f(x) = +\infty$,
- $\sup_{x \in X} f(x) = -\inf_{x \in X} [-f(x)]$ (mêmes solutions),
- (P_X) est dit **non borné** si $\text{val}(P_X) = -\infty$, i.e.,
 $\exists \{x_k\} \subset X$ telle que $f(x_k) \rightarrow -\infty$.

Si $X \neq \emptyset$, il existe une **suite minimisante** $\{x_k\}$, laquelle vérifie

- $\{x_k\} \subset X$,
- $f(x_k) \rightarrow \text{val}(P_X)$.

On dit que x_* est **solution** de (P_X) si

- $x_* \in X$,
- $\forall x \in X: f(x_*) \leq f(x)$.

On dit aussi **minimum** ou **minimiseur**.

On note l'ensemble des solutions

$$\text{Sol}(P_X) \quad \text{ou} \quad \arg \min_{x \in X} f(x).$$

On dit que x_* est **solution stricte** de (P_X) si

- $x_* \in X$,
- $\forall x \in X \setminus \{x_*\}: f(x_*) < f(x)$.

Si X topologique, on dit que x_* est **solution locale** de (P_X) s'il existe un voisinage V de x_* tel que

- $x_* \in X$,
- $\forall x \in X \cap V: f(x_*) \leq f(x)$.

Si X topologique, on dit que x_* est **solution locale stricte** de (P_X) s'il existe un voisinage V de x_* tel que

- $x_* \in X$,
- $\forall x \in (X \cap V) \setminus \{x_*\}: f(x_*) < f(x)$.

Existence de solution (§ 1.2)

Le problème à résoudre ($f : X \rightarrow \mathbb{R} \cup \{+\infty\}$):

$$(P_X) \quad \begin{cases} \inf f(x) \\ x \in X. \end{cases}$$

On dit que f est **fermée** si $(\text{epi } f)$ est fermé.

Si • f est fermée sur X ,
• X est compact et non vide,
alors (P_X) a (au moins) une solution.

En dimension finie (c'est notre cas):

- X compact $\iff X$ fermé borné.
- On peut remplacer l'hypothèse

X compact

par

X fermé et f coercive sur X .

Unicité de solution (§ 3.1)

- Soient X un convexe de \mathbb{E} et $f : X \rightarrow \mathbb{R}$.

Définitions : f est **convexe** sur X si pour tout $x, y \in X$, $x \neq y$, et $t \in]0, 1[$:

$$f((1-t)x + ty) \leq (1-t)f(x) + tf(y).$$

f est **strictement convexe** si on a inégalité stricte ci-dessus.

- Le problème à résoudre :

$$(P_X) \quad \begin{cases} \min f(x) \\ x \in X. \end{cases}$$

Si • X est convexe,
• f est strictement convexe sur X ,
alors (P_X) a au plus une solution.

Différentiabilité première (§§ C.1, C.2.1)

Soient \mathbb{E} et \mathbb{F} deux espaces normés, Ω un ouvert de \mathbb{E} et $f : \Omega \rightarrow \mathbb{F}$.

1. **Différentiabilité directionnelle** suivant $h \in \mathbb{E}$:

$$f'(x; h) := \lim_{t \rightarrow 0^+} \frac{1}{t} (f(x + th) - f(x)) \text{ existe.}$$

2. **Différentiabilité au sens de Gâteaux** :

- $f'(x; h)$ existe pour tout $h \in \mathbb{E}$ et
- $h \mapsto f'(x; h)$ est linéaire (continue).

On note $f'(x)$ l'application linéaire (continue).

3. **Différentiabilité au sens de Fréchet** : il existe $L : \mathbb{E} \rightarrow \mathbb{F}$, linéaire (continue) :

$$f(x + h) = f(x) + Lh + o(\|h\|).$$

On note $f'(x) := L$ (même opérateur qu'en 2).

Soit $\langle \cdot, \cdot \rangle$ un produit scalaire sur \mathbb{E} et $\mathbb{F} = \mathbb{R}$. On définit le **gradient** de f en x comme l'unique vecteur $\nabla f(x) \in \mathbb{E}$:

$$\langle \nabla f(x), h \rangle = f'(x) \cdot h, \quad \forall h \in \mathbb{E}.$$

Différentiabilité seconde (§ C.2.2)

Supposons que $f : \Omega \rightarrow \mathbb{F}$ soit 2 fois différentiable (pour une définition rigoureuse, voir le syllabus).

Propriétés :

- $f''(x) \cdot (h, k)$ est la dérivée directionnelle de $x \mapsto f'(x) \cdot h$ dans la direction k :

$$f''(x) \cdot (h, k) = \lim_{t \rightarrow 0^+} \frac{1}{t} (f'(x + tk) \cdot h - f'(x) \cdot h).$$

- l'application

$$(h, k) \mapsto f''(x) \cdot (h, k)$$

est bilinéaire symétrique.

Soit $\langle \cdot, \cdot \rangle$ un produit scalaire sur \mathbb{E} et $\mathbb{F} = \mathbb{R}$. On définit le **hessien** de f en x comme l'unique opérateur linéaire symétrique $\nabla^2 f(x)$ sur \mathbb{E} tel que

$$\langle \nabla^2 f(x)h, k \rangle = f''(x) \cdot (h, k), \quad \forall (h, k) \in \mathbb{E}^2.$$

II Analyse convexe

Ensemble convexe (§ 2.1)


Soit \mathbb{E} un espace vectoriel.

- **Dfn.** Soient $x, y \in \mathbb{E}$. Un **segment** de \mathbb{E} :


$$[x, y] := \{(1-t)x + ty : t \in [0, 1]\}.$$

- **Dfn.** Un ensemble $C \subset \mathbb{E}$ est **convexe** si


$$\forall x, y \in C \implies [x, y] \subset C.$$




convexe



non convexe



convexe



non convexe

Aspects topologiques (§ 2.3)

- **Dfn.** L'**enveloppe affine** d'une partie $P \subset \mathbb{E}$ est le *plus petit espace affine* contenant P . On le note

$$\text{aff } P = \bigcap \{A : A = \text{espace affine contenant } P\}.$$

- **Dfn.** L'**intérieur relatif** d'une partie $P \subset \mathbb{E}$ est son intérieur dans $\text{aff } P$ (muni de la topologie induite de celle de \mathbb{E}). On le note

$$\text{intr } P \quad \text{ou} \quad P^\circ.$$

Polyèdre convexe (§ 2.4)

Soient \mathbb{E} et \mathbb{F} des espaces vectoriels ($\mathbb{E} = \mathbb{R}^n$ et $\mathbb{F} = \mathbb{R}^m$ parfois).

- **Dfn.** **Description primale** d'un polyèdre convexe :

$$P := \text{co}\{x_1, \dots, x_p\} + \text{cone}\{y_1, \dots, y_q\},$$

où les x_i et $y_j \in \mathbb{E}$.

Description duale d'un polyèdre convexe :

$$P := \{x \in \mathbb{E} : Ax \leq b\},$$

où $A : \mathbb{F} \rightarrow \mathbb{F}$ linéaire et $b \in \mathbb{F}$.

- **Prop.**

Si P polyèdre convexe et $L : \mathbb{F} \rightarrow \mathbb{F}$ linéaire, alors $L(P)$ polyèdre convexe.

Projection sur un convexe fermé (§ 2.5.2)

\mathbb{E} muni d'un produit scalaire $\langle \cdot, \cdot \rangle = \|\cdot\|^2$.

Si $C \subset \mathbb{E}$ convexe fermé non vide et $x \in \mathbb{E}$, alors le problème

$$\min \{\|y - x\| : y \in C\} \quad (1)$$

a une unique solution.

- **Dfn** : l'unique solution de (1) est appelée **projection/projeté de x sur C** et est notée $P_C x$.

- **Prop** : Soit $\bar{x} \in C$. Alors

$$\bar{x} = P_C x \iff \forall y \in C, \langle y - \bar{x}, \bar{x} - x \rangle \geq 0$$

$$\iff \forall y \in C, \langle y - \bar{x}, y - x \rangle \geq 0$$

$$\iff \forall y \in C, \langle y - x, \bar{x} - x \rangle \geq \|\bar{x} - x\|^2.$$

Séparation des convexes (§ 2.5.4)

\mathbb{E} muni d'un produit scalaire $\langle \cdot, \cdot \rangle$.

- **Dfn** : On peut **séparer** $C_1, C_2 \subset \mathbb{E}$ s'il existe $\xi \in \mathbb{E}$ **non nul** tel que

$$\sup_{x_1 \in C_1} \langle \xi, x_1 \rangle \leq \inf_{x_2 \in C_2} \langle \xi, x_2 \rangle.$$

La séparation est **stricte** si l'inégalité ci-dessus est stricte (alors ξ est nécessairement non nul).

- **Théor (Hahn-Banach)** :

Si • C_1 et C_2 convexes, non vides, disjoints,
 • $\dim \mathbb{E} < \infty$,
alors on peut séparer C_1 et C_2 .

Si • C_1 et C_2 convexes, non vides, disjoints,
 • C_1 ou C_2 est d'**intérieur non vide**,
alors on peut séparer C_1 et C_2 .

Si • C_1 et C_2 convexes, non vides, disjoints,
 • l'un est **fermé**, l'autre est **compact**,
alors on peut séparer C_1 et C_2 **strictement**.

Cône dual (§ 2.5.6)

\mathbb{E} muni d'un produit scalaire $\langle \cdot, \cdot \rangle$.

- **Dfn** : Le **cône dual** de $P \subset \mathbb{E}$ est défini par

$$P^+ := \{y \in \mathbb{E} : \langle y, x \rangle \geq 0, \forall x \in P\}.$$

C'est un cône, convexe, fermé, non vide.

- **Lemme de Farkas (généralisé)**

Si • \mathbb{E} et \mathbb{F} deux espaces euclidiens,
 • K un cône convexe $\neq \emptyset$ de \mathbb{E} ,
 • $A : \mathbb{E} \rightarrow \mathbb{F}$ linéaire,
alors $\{y \in \mathbb{F} : A^*y \in K^+\}^+ = \overline{A(K)}$.

- **Cas particulier** : Soit A une matrice. Alors

$$\begin{aligned} \{Ax : x \geq 0\} &= \text{cône, convexe, fermé, } \neq \emptyset \\ \{y : A^T y \geq 0\}^+ &= \{Ax : x \geq 0\}. \end{aligned}$$

$(\cdot)^+ = \text{dual pour le produit scalaire euclidien.}$
 [c'est une généralisation de $N(A^T)^\perp = R(A)$]

Fonction convexe (§ 3.1)

Soient \mathbb{E} un espace vectoriel et $f : \mathbb{E} \rightarrow \overline{\mathbb{R}}$.

- **Dfn.** Le **domaine** de f est l'ensemble

$$\text{dom} f := \{x \in \mathbb{E} : f(x) < +\infty\}.$$

On peut avoir $f(x) = -\infty$ pour $x \in \text{dom} f$.

- **Dfn.** L'**épigraphe** de f est l'ensemble

$$\text{epi} f := \{(x, \alpha) \in \mathbb{E} \times \mathbb{R} : f(x) \leq \alpha\}.$$

- **Dfn.** f est **convexe** \iff $\text{epi} f$ est convexe.

$$f \text{ est convexe} \iff \forall x, y \in \text{dom} f, \forall t \in]0, 1[:$$

$$f((1-t)x + ty) \leq (1-t)f(x) + tf(y).$$

Différentiabilité directionnelle (§ 3.3.2)

Soient $f \in \text{Conv}(\mathbb{E})$, $x \in \text{dom} f$ et $d \in \mathbb{E}$.

- 1) $t \in]0, +\infty[\mapsto \frac{f(x+td)-f(x)}{t}$ est croissante,
- 2) $f'(x; d)$ existe dans $\overline{\mathbb{R}}$,
- 3) $f'(x; d) = +\infty \iff f(x + td) = +\infty, \forall t > 0$,
- 4) $f'(x; -d) \geq -f'(x; d)$,
- 5) $f'(x; \cdot)$ est convexe,
- 6) $x \in (\text{dom} f)^\circ \implies \begin{cases} f'(x; \cdot) \in \mathbb{R}, \\ f'(x; \cdot) \text{ Lipschitz}, \\ f'(x; \cdot) \in \overline{\text{Conv}}(\mathbb{E}). \end{cases}$

Reconnaitre une fonction convexe
par ses dérivées (§ 3.3.3)

Enveloppe supérieure (§ 3.4.2)

- **Enveloppe supérieure** d'une famille de $f_i : \mathbb{E} \rightarrow \overline{\mathbb{R}}$,
 $i \in I$ (quelconque) :

$$\left(\sup_{i \in I} f_i \right) (x) := \sup_{i \in I} \left(f_i(x) \right).$$

- $\text{epi}(\sup_{i \in I} f_i) = \bigcap_{i \in I} (\text{epi } f_i)$.
- f_i convexes $\implies \sup_{i \in I} f_i$ convexe.
- f_i fermées $\implies \sup_{i \in I} f_i$ fermée.

Soient X un convexe de \mathbb{E} et $f : X \rightarrow \mathbb{R}$.

- Si f est 1 fois dérivable et X ouvert

Les propriétés suivantes sont équivalentes :

- f est convexe sur X
[resp. strictement convexe],

- $\forall x, y \in X, x \neq y$:

$$f(y) \geq f(x) + f'(x) \cdot (y - x)$$

[resp. >],

- $\forall x, y \in X, x \neq y$:

$$(f'(y) - f'(x)) \cdot (y - x) \geq 0$$

[resp. >].

- Si f est 2 fois dérivable et X ouvert :

- f est convexe sur $X \iff$
 $\forall x \in X, \forall h \in \mathbb{E}, f''(x) \cdot h^2 \geq 0,$
- f est strictement convexe sur $X \iff$
 $\forall x \in X, \forall h \in \mathbb{E} \text{ non nul}, f''(x) \cdot h^2 > 0.$

Contre-exemple: $f(x) = x^4$.

III Conditions d'optimalité (CO)

Le problème à résoudre :

$$(P_X) \begin{cases} \min f(x) \\ x \in X, \end{cases}$$

où $X \subset E$ (espace euclidien, produit scalaire $\langle \cdot, \cdot \rangle$).

- **But.** L'optimalité s'exprime par un nombre **infini** de conditions $x_* \in X$ et $\forall x \in X : f(x_*) \leq f(x)$. Peut-on exprimer cela avec un nombre **fini** de conditions ?
- **Qu'est-ce ?** Des $=$ et \leq décrivant les solutions de (P_X) .
- **Utilité** des CO :
 - donner des renseignements sur (P_X) ,
 - vérifier qu'un point est solution,
 - calculer la solution analytiquement (parfois),
 - définir des algorithmes de résolution.
- Il y a des CO **nécessaires** (notées CN) et des CO **suffisantes** (notées CS).
- Il y a des CO du 1^{er} ordre (CN1, CS1) et des CO du 2^{ième} ordre (CN2, CS2).

CO sans contrainte (rappel, § 4.2)

Le problème à résoudre :

$$\begin{cases} \min f(x) \\ x \in \mathbb{E}. \end{cases}$$

On note $\nabla f(x)$ et $\nabla^2 f(x)$ les gradient et hessien de f en x pour $\langle \cdot, \cdot \rangle$.

- **CN1 :**

$$x_* \text{ min local} \implies \nabla f(x_*) = 0.$$

(Si f est convexe, c'est une **CS1 globale**.)

- **CN2 :**

$$x_* \text{ min local} \implies \begin{cases} \nabla f(x_*) = 0 \\ \nabla^2 f(x_*) \succ 0. \end{cases}$$

- **CS2** pour un minimum local strict :

$$\begin{cases} \nabla f(x_*) = 0 \\ \nabla^2 f(x_*) \succ 0 \end{cases} \implies x_* \text{ min local } \underline{\text{strict}}.$$


CN1 de Peano-Kantorovitch (§ 4.1)

Le problème à résoudre :

$$(P_X) \begin{cases} \min f(x) \\ x \in X. \end{cases}$$

Dfn. Cône tangent : $d \in T_x X \iff$

$$\exists \{x_k\} \subset X, \quad \exists \{t_k\} \downarrow 0 : \quad \frac{x_k - x}{t_k} \rightarrow d.$$



Prop

- $T_x X$ est fermé.
- X convexe et $x \in X \implies T_x X$ convexe.

Conditions d'optimalité

- **CN1 de Peano-Kantorovitch.** On exprime plus ou moins le fait que f croît si on se déplace “vers l'intérieur” de X :

$$f'(x_*) \cdot d \geq 0, \quad \forall d \in T_{x_*} X, \quad (2)$$

où $T_{x_*} X$ est le **cône tangent** à X en x_* , ce qui s'écrit aussi

$$\nabla f(x_*) \in (T_{x_*} X)^+, \quad (3)$$

- **CN1.** Lorsque X est convexe, la relation (2) se simplifie en :

$$f'(x_*) \cdot (x - x_*) \geq 0, \quad \forall x \in X. \quad (4)$$

- **CS1.** Si X est convexe, f est convexe et (4), alors x_* est un minimum global.

CO avec contraintes d' = (§ 4.3)

Le problème en $x \in \mathbb{E}$ (e.v. euclidien) à résoudre :

$$(P_E) \quad \begin{cases} \min f(x) \\ c(x) = 0 \in \mathbb{F} \quad (\text{e.v. euclidien}). \end{cases}$$

Ensemble admissible noté X_E .

Le lagrangien du problème :

$$\ell(x, \lambda) = f(x) + \langle \lambda, c(x) \rangle.$$

- **CN1** : si $c'(x_*)$ est surjective, il existe $\lambda_* \in \mathbb{F}$, unique, tel que

$$\begin{cases} \nabla_x \ell(x_*, \lambda_*) = 0 \\ c(x_*) = 0. \end{cases} \quad (5)$$

(Si c affine, λ_* existe, pas néc. unique.)

(Si f est convexe et X_E est convexe, ce sont des **CS1** globales.)

Si $\mathbb{F} = \mathbb{R}^m$, la première condition de (5) s'écrit

$$\nabla f(x_*) + \sum_{i=1}^m (\lambda_*)_i \nabla c_i(x_*) = 0.$$

- **CN2** : si x_* minimum local et $c'(x_*)$ est surjective, alors il existe λ_* tel que

$$\begin{cases} \nabla_x \ell(x_*, \lambda_*) = 0 \\ c(x_*) = 0 \\ \nabla_{xx}^2 \ell(x_*, \lambda_*) \succcurlyeq 0 \text{ sur } N(c'(x_*)). \end{cases}$$

- **CS2** : si (x_*, λ_*) vérifie

$$\begin{cases} \nabla_x \ell(x_*, \lambda_*) = 0 \\ c(x_*) = 0 \\ \nabla_{xx}^2 \ell(x_*, \lambda_*) \succ 0 \text{ sur } N(c'(x_*)), \end{cases}$$

alors x_* est un minimum local strict.

CO avec contraintes $d'=$ et $d' \leq$ (§ 4.4)

Le problème à résoudre en $x \in \mathbb{E}$:

$$(P_{EI}) \quad \begin{cases} \min f(x) \\ c_E(x) = 0 \in \mathbb{R}^{m_E} \\ c_I(x) \leq 0 \in \mathbb{R}^{m_I}. \end{cases}$$

Ensemble admissible noté X_{EI} .

Le lagrangien du problème ($c := (c_E, c_I)$):

$$\ell(x, \lambda) = f(x) + \lambda^\top c(x).$$

On note $I^0(x) := \{i \in I : c_i(x) = 0\}$.

- **CN1** : si les contraintes sont **qualifiées** en x_* , il existe $\lambda_* \in \mathbb{R}^m$ tel que

$$(KKT) \quad \begin{cases} \nabla_x \ell(x_*, \lambda_*) = 0 \\ c_E(x_*) = 0 \\ 0 \leq (\lambda_*)_I \perp c_I(x_*) \leq 0. \end{cases}$$

(Si f est convexe et X_{EI} est convexe, ce sont des **CS1** globales.)

Qualification des contraintes (§ 4.4.3)

- **Dfn** : on dit que les contraintes de (P_{EI}) sont **qualifiées** en x si

$$T_x X = T'_x X, \quad (6)$$

où

$$T'_x X := \{d : c'_E(x) \cdot d = 0, c'_{I^0(x)}(x) \cdot d \leq 0\}.$$

On a toujours : $T_x X \subset T'_x X$.

- **Conditions suffisantes** de qualification des contraintes. Régularité + l'une des conditions suivantes :

(QC-A) $c_{E \cup I^0(x)}$ est affine dans un voisinage de x .

(QC-S) c_E est *affine*,

$c_{I^0(x)}$ *convexe*,

$\exists \tilde{x} \in X$ tel que $c_{I^0(x)}(\tilde{x}) < 0$.

(QC-IL) les gradients $\{\nabla c_i(x)\}_{i \in E \cup I^0(x)}$ sont linéairement indépendants.

(QC-MF) $\sum_{i \in E \cup I^0(x)} \alpha_i \nabla c_i(x) = 0$ et $\alpha_{I^0(x)} \geq 0 \implies \alpha_{E \cup I^0(x)} = 0$.

(QC-MF') $c'_E(x)$ surjective et $\exists d \in \mathbb{E}$ tel que $c'_E(x) \cdot d = 0$ et $c'_{I^0(x)}(x) \cdot d < 0$.

Démarche suivie pour obtenir (KKT)

- On part de (2)
[i.e., f croît de x_* vers l'intérieur de X].
- On suppose que les contraintes sont qualifiées en x_*
(on a (6) avec $x = x_*$). Dès lors

$$\nabla f(x_*) \in (\Gamma'_{x_*} X)^+. \quad (7)$$

- Lemme de Farkas :
Données : $A : \mathbb{E} \rightarrow \mathbb{F}$ linéaire et K cône de \mathbb{E} .

$$\{y \in \mathbb{F} : A^*y \in K^+\}^+ = \overline{A(K)}.$$

C'est une généralisation de $N(A)^\perp = R(A^\top)$.

- Le lemme de Farkas permet d'exprimer (7)
autrement : $\exists \lambda_* \in \mathbb{R}^m$ tel que l'on ait (KKT).

Signification des multiplicateurs optimaux (§ 4.6.1)

- Problème perturbé : pour $p \in \mathbb{R}^m$, on définit

$$(P_{EI}^p) \quad \begin{cases} \min f(x) \\ c_E(x) + p_E = 0 \\ c_I(x) + p_I \leq 0. \end{cases}$$

- **Dfn.** La **fonction valeur** associée à (P_{EI}^p) est
 $v : p \in \mathbb{R}^m \rightarrow \overline{\mathbb{R}}$ définie par

$$v(p) = \inf_{x \in X^p} f(x),$$

où X^p est l'ensemble admissible de (P_{EI}^p) .

$$(P_{EI}) \text{ convexe} \implies v \text{ convexe.}$$

- Cas différentiable régulier.

Si • (x_*, λ_*) solution PD de (P_{EI}) ,
 • $(\bar{x}(p), \bar{\lambda}(p))$ solution PD de (P_{EI}^p) ,
 • $p \mapsto \bar{x}(p)$ différentiable en 0, $\bar{x}(0) = x_*$,
 • $p \mapsto \bar{\lambda}(p)$ continue en 0, $\bar{\lambda}(0) = \lambda_*$,
alors $\lambda_* = \nabla v(0) = \nabla(f \circ \bar{x})(0)$.

- On note

$$\Lambda := \{\lambda \in \mathbb{R}^m : \lambda_I \geq 0\}.$$

- **Dfn.** On dit que $(x_*, \lambda_*) \in \mathbb{R}^n \times \Lambda$ est un **point-selle** de ℓ sur $\mathbb{R}^n \times \Lambda$, si $\forall (x, \lambda) \in \mathbb{R}^n \times \Lambda$:

$$\ell(x_*, \lambda) \leq \ell(x_*, \lambda_*) \leq \ell(x, \lambda_*).$$

- Cas convexe non différentiable.

Si • x_* est solution de (P_{EI}) ,
 • $v \in \text{Conv}(\mathbb{R}^m)$,

alors

$$\partial v(0)$$

$$= \{\lambda_* : (x_*, \lambda_*) \text{ est point-selle de } \ell \text{ sur } \mathbb{R}^m \times \Lambda\}.$$

Remarque : Ci-dessus, $\partial v(0)$ peut être vide ! Avec qualification de Slater : $\partial v(0) \neq \emptyset$.

- CN et CS d'existence de solution PD globale.

CN d'optimalité (cas convexe non diff.).

Si • (P_{EI}) convexe (avec f et c finies),

- (Slater) : c'_E surjective, $\exists \hat{x} \in X$ t.q. $c_I(\hat{x}) < 0$,
- x_* solution de (P_{EI}) ,

alors 1) v est loc. lipschitzienne dans un vois. de 0,
 2) $\partial v(0) \neq \emptyset$.

CS d'optimalité globale.

Peu de chance d'être applicable si (P_{EI}) non convexe.

Si • $(x_*, \lambda_*) \in \mathbb{R}^n \times \Lambda$ est un **point-selle** de ℓ sur $\mathbb{R}^n \times \Lambda$,
alors x_* solution (globale) de (P_{EI}) .

IV Méthodes à directions de descente


Schéma des algorithmes (§ 6.1)

- Dfn : d est direction de descente de f en x si

$$f'(x) \cdot d < 0.$$

$\implies f$ décroît en x le long de d .

- Algorithme à directions de descente : il génère une suite $\{x_k\} \subset \mathbb{E}$ comme suit
 - Calcul d'une direction de descente d_k ;
 - Recherche linéaire : on détermine un pas $\alpha_k > 0$ le long de d_k ;
 - Nouvel itéré : $x_{k+1} := x_k + \alpha_k d_k$.



Exemples d'algorithmes à DD (§ 6.2)

On note $g_k := \nabla f(x_k)$.

- Algorithme du gradient.

$$d_k = -g_k.$$

- Algorithme du gradient conjugué.

$$d_k = \begin{cases} -g_1 & \text{si } k = 1 \\ -g_k + \beta_k d_{k-1} & \text{si } k \geq 2. \end{cases}$$

- Algorithme de Newton.

$$d_k = -\nabla^2 f(x_k)^{-1} g_k.$$

- Algorithme de quasi-Newton.

$$d_k = -M_k^{-1} g_k.$$

- Algorithme de Gauss-Newton

pour $f(x) = \frac{1}{2} \|r(x)\|_2^2$ et $J(x) := r'(x)$ injective :

$$d_k = -(J(x_k)^* J(x_k))^{-1} J(x_k)^* r(x_k).$$

La recherche linéaire (§ 6.3)

Deux techniques souvent utilisées : RL d'Armijo et RL de Wolfe.


Soient d_k une direction de descente et

$$h_k(\alpha) := f(x_k + \alpha d_k).$$

- **RL d'Armijo** ($0 < \omega_1 < \frac{1}{2}$, $0 < \tau < 1$)

$$h_k(\alpha_k) \leq h(0) + \omega_1 \alpha_k h'_k(0), \quad \alpha_k = \tau^{i_k},$$

où i_k est le plus petit dans $\{0, 1, 2, \dots\}$.

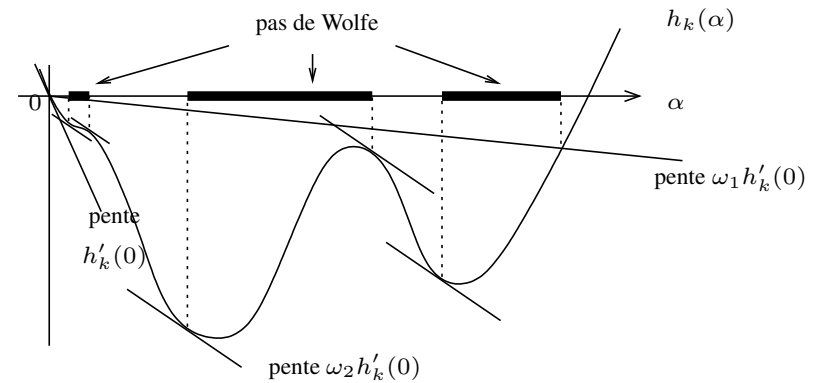


Valeurs typiques : $\omega_1 = 10^{-4}$ et $\tau = \frac{1}{2}$.

- **RL de Wolfe** ($0 < \omega_1 < \frac{1}{2}$, $\omega_1 < \omega_2 < 1$)

$$h_k(\alpha_k) \leq h(0) + \omega_1 \alpha_k h'_k(0),$$

$$h'_k(\alpha_k) \geq \omega_2 h'_k(0).$$



Valeurs typiques : $\omega_1 = 10^{-4}$ et $\omega_2 = 0.99$.

Convergence avec la RL de Wolfe (§ 6.3.4)

– **Dfn :**

$$\cos \theta_k := \frac{-\langle g_k, d_k \rangle}{\|g_k\| \|d_k\|}.$$

– **Théor :**

Si • $f \in C^{1,1}$,
• RL de Wolfe
• $\exists C, \forall k \geq 0, f(x_k) \geq C$,
alors

$$\sum_{k \geq 0} \|g_k\|^2 \cos^2 \theta_k < +\infty.$$

– **Convergence :**

- * Algo du gradient : $\theta_k = 0$, donc $g_k \rightarrow 0$.
- * Plus généralement : $\cos \theta_k \geq c > 0$, donc $g_k \rightarrow 0$.

V Méthodes newtoniennes pour équations

Vitesse de convergence des suites (§ 5.1.1)

Soit $\{x_k\}$ une suite convergeant vers $x_* \in \mathbb{E}$.
 On suppose que $x_k \neq x_*$, pour tout $k \geq 1$.

- **Convergence linéaire** : il existe une norme $\|\cdot\|$, un indice k_0 et $\tau \in [0, 1[$ tels que $\forall k \geq k_0$:

$$\frac{\|x_{k+1} - x_*\|}{\|x_k - x_*\|} \leq \tau.$$

- **Convergence superlinéaire** :

$$\frac{\|x_{k+1} - x_*\|}{\|x_k - x_*\|} \rightarrow 0.$$

- **Convergence quadratique** : il existe une constante $C > 0$ telle que $\forall k \geq 1$:

$$\frac{\|x_{k+1} - x_*\|}{\|x_k - x_*\|^2} \leq C.$$

$\sigma_k =$ nombre de chiffres significatifs corrects.

k	superlinéaire		quadratique	
	x_k	σ_k	x_k	σ_k
1	2.000000000000000	0	2.000000000000000	0
2	1.500000000000000	0	0.866666666666667	1
3	0.61224489795918	1	-0.32323745064862	1
4	-0.16202797536640	1	-0.92578663808031	1
5	-0.92209500449059	1	-0.82332584261905	2
6	-0.78540447895661	1	-0.81774699537697	5
7	-0.81609056319699	3	-0.81773167400186	9
8	-0.81775774021392	5	-0.81773167388682	15
9	-0.81773165292101	8		
10	-0.81773167388656	13		
11	-0.81773167388682	15		

- Linéaire $\implies \begin{cases} \exists \underline{\sigma} > 0, \forall k \text{ grand} : \\ \sigma_{k+1} - \sigma_k \geq \underline{\sigma}. \end{cases}$
- Superlinéaire $\implies \sigma_{k+1} - \sigma_k \rightarrow \infty.$
- Quadratique $\implies \liminf_{k \rightarrow \infty} \frac{\sigma_{k+1}}{\sigma_k} \geq 2.$

Algorithme de Newton pour systèmes non linéaires

(§ 9.1.1)

Soit $F : \mathbb{E} \rightarrow \mathbb{F}$, avec $\dim \mathbb{E} = \dim \mathbb{F} < \infty$. On cherche à résoudre en x :

$$F(x) = 0.$$

• **Algorithme de Newton.** De x_k à x_{k+1} :


– Résoudre en d_k l'équation de Newton :

$$F'(x_k) d_k = -F(x_k). \quad (8)$$

– Nouvel itéré :

$$x_{k+1} = x_k + d_k.$$

• **Exemple 1D.**



• **Propriétés de l'algorithme de Newton.**

⊕⊕ Convergence quadratique *locale* :

Si • x_* vérifie $F(x_*) = 0$,

- F est $C^{1,1}$ dans un voisinage de x_* ,
- $F'(x_*)$ est inversible,

alors il existe un voisinage V de x_* tel que si $x_1 \in V$, l'algorithme de Newton (8) est bien défini et génère une suite $\{x_k\} \subset V$ qui converge *quadratiquement* vers x_* .

⊖ En général ne converge pas si x_1 n'est pas proche d'une solution.

⊖ Il faut calculer les dérivées premières de F .

Globalisation de l'algorithme de Newton
par recherche linéaire (§ 9.3.1)

- **Dfn** : « **globaliser** » = forcer la convergence lorsque x_1 n'est pas voisin d'une solution.
- Une solution miracle ?

Si $F(x) \neq 0$, la direction de Newton en x ,

$$d^N = -F'(x)^{-1}F(x),$$

est une direction de descente de

$$f(x) = \frac{1}{2}\|F(x)\|_2^2.$$

On a $f'(x) \cdot d^N = -\|F(x)\|_2^2 < 0$.

- RL sur f le long de d^N : $x_+ := x + \alpha d^N$, avec $\alpha > 0$ tel que (ici $\omega_1 \in]0, \frac{1}{2}[$)

$$f(x_+) \leq f(x) + \alpha \omega_1 f'(x) \cdot d^N.$$

- Un résultat de convergence :

Si $\{F'(x_k)\}$ et $\{F'(x_k)^{-1}\}$ sont *bornées*,
alors l'algorithme de Newton avec une RL « convenable » converge vers un point stationnaire de f :
 $\nabla f(x_k) \rightarrow 0$.

- **Cette approche ne converge pas toujours !**
 C'est la raison pour laquelle on a inventé la technique des **régions de confiance** (voir un cours plus avancé).

V'

Méthodes newtoniennes en optimisation (§ 9.1.2)

Soit le problème

$$\min_{x \in \mathbb{E}} f(x).$$

- On se déclare satisfait avec x_* vérifiant

$$\nabla f(x_*) = 0.$$

La relation $F = \nabla f$ permet d'adapter l'algorithme de Newton ($F'(x) = \nabla^2 f(x)$ est symétrique).

- **Algorithme de Newton.** De x_k à x_{k+1} :

- Résoudre en d_k l'équation de Newton :

$$\nabla^2 f(x_k) d_k = -\nabla f(x_k). \quad (9)$$


- Nouvel itéré :

$$x_{k+1} = x_k + d_k.$$

- **Le problème quadratique osculateur.**

Le pas de Newton d_k est aussi un point *stationnaire* du problème quadratique

$$\min_{d \in \mathbb{E}} \left(f(x_k) + \nabla f(x_k)^\top d + \frac{1}{2} d^\top \nabla^2 f(x_k) d \right).$$



• **Propriétés de l'algorithme de Newton.**

⊕⊕ Convergence quadratique *locale* :

Si • x_* vérifie $\nabla f(x_*) = 0$,
 • f est $C^{2,1}$ dans un voisinage de x_* ,
 • $\nabla^2 f(x_*)$ est inversible,
alors il existe un voisinage V de x_* tel que si $x_1 \in V$,
 l'algorithme de Newton est bien défini et génère
 une suite $\{x_k\} \subset V$ qui converge *quadratique-*
ment vers x_* .

- ⊖ En général ne converge pas si x_1 n'est pas proche d'un point stationnaire.
- ⊖ Pas de distinction entre min, max, point stationnaire.
- ⊖ Les directions ne sont pas nécessairement de descente.
- ⊖ Il faut calculer les dérivées secondes de f .

Algorithmes de quasi-Newton (§§ 10.1.1, 10.2.1, 10.2.2)

Soit le problème

$$\min_{x \in \mathbb{R}^n} f(x).$$

- Les **algorithmes de qN** génèrent 2 suites :
 $\{x_k\} \subset \mathbb{R}^n$ et $\{M_k\} \subset \mathbb{R}^{n \times n}$ sym. dfn. pos.
 - 1) $d_k := -M_k^{-1} g_k$;
 - 2) $\alpha_k > 0$ par recherche linéaire;
 - 3) $x_{k+1} := x_k + \alpha_k d_k$;
 - 4) $M_{k+1} := U(M_k, y_k, s_k)$,
 où $y_k := g_{k+1} - g_k$ et $s_k := x_{k+1} - x_k$.
 - **Mise à jour de M_k .** On cherche à ce que M_{k+1} soit proche de M_k (stabilité), tout en vérifiant :
 - l'équation de qN : $y_k = M_{k+1} s_k$;
 - la symétrie : $M_{k+1}^\top = M_{k+1}$;
 - la définie positivité : $M_{k+1} \succ 0$.
- Cela conduit à la **formule de BFGS**.

$$M_{k+1} = M_k + \frac{y_k y_k^\top}{y_k^\top s_k} - \frac{M_k s_k s_k^\top M_k}{s_k^\top M_k s_k}.$$


VI Problèmes de moindres-carrés

- Ce sont des problèmes de la forme

$$\min_{x \in \mathbb{R}^n} \|F(x)\|,$$

où $F : \mathbb{R}^n \rightarrow \mathbb{R}^m$. En général $m \gg n$.

- **Exemple** : la **régression linéaire**.



Moindres-carrés linéaire (§ 17.1)

- **Problème** : on cherche une solution de

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2, \quad (10)$$

où A est $m \times n$ et $b \in \mathbb{R}^m$.

- **Équation normale** : x est solution ssi

$$A^\top Ax = A^\top b. \quad (11)$$

- **Existence de solution** :

- Le problème (10) a **toujours** une solution.
- Solution unique $\iff A$ est injective.
- Ensemble des solutions = $x_p + N(A)$.

- **Méthodes numériques** :

- Factorisation de Cholesky de $A^\top A$.
- GC sur (11).
- Factorisation QR de A .
- Factorisation SVD de A .

Moindres-carrés non linéaire (§ 17.3)

- **Problème** : on cherche une solution de

$$\min_{x \in \mathbb{R}^n} \left(f(x) := \frac{1}{2} \|r(x)\|_2^2 \right), \quad (12)$$

où $r : \mathbb{R}^n \rightarrow \mathbb{R}^m$ est non linéaire (les **résidus**).
Jacobienne $J \equiv J(x) \equiv r'(x)$, qui est $m \times n$.

- **Algorithme de Gauss-Newton** : RL le long de

$$d_k^{\text{GN}} \in \arg \min_{d \in \mathbb{R}^n} \frac{1}{2} \|r(x_k) + J(x_k)d\|_2^2.$$

On a $f'(x_k) \cdot d_k^{\text{GN}} \leq 0$ (< 0 si $\nabla f(x_k) \neq 0$).

Résultat de convergence :

Si $\{J(x_k)\}$ est bornée et unif. injective, i.e.,

$$\exists C > 0, \forall k \geq 1, \forall v \in \mathbb{R}^n :$$

$$C\|v\|_2 \leq \|J(x_k)v\|_2 \leq C^{-1}\|v\|_2,$$

alors l'algorithme de Gauss-Newton avec RL converge vers un point stationnaire de f (c'est-à-dire $J(x_k)^\top r(x_k) \rightarrow 0$).

- **Algorithme de Levenberg-Marquardt** (révisé) : RC avec le modèle quadratique

$$\varphi_k(s) := \frac{1}{2} \|r(x_k) + J(x_k)s\|_2^2.$$

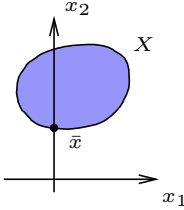
Résultat de convergence :

Si $\{J(x_k)\}$ est bornée,

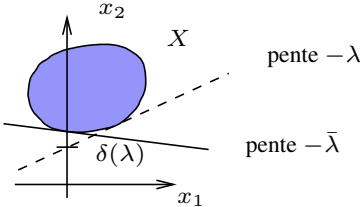
alors l'algorithme de Levenberg-Marquardt avec RC converge vers un point stationnaire de f (c'est-à-dire $J(x_k)^\top r(x_k) \rightarrow 0$).

VII Dualité (§ 13)

- **Un premier problème :**

$$(P) \begin{cases} \inf x_2 \\ x \in X \\ x_1 = 0. \end{cases}$$


- **Un second problème :**

$$(D) \sup_{\lambda \in \mathbb{R}} \delta(\lambda)$$


- (P) et (D) sont duaux l'un de l'autre.
- **Intérêts de la dualité :**
 - obtenir des propriétés sur un problème à partir des propriétés d'un pbl dual (e.g., une borne sur la valeur optimale);
 - construire des pbls duaux équivalents au pbl primal, mais plus faciles à résoudre;
 - algorithmique : recherche de point-selle, du multiplicateur optimal.

Dualité min-max (§ 13.1)

Soient X un ensemble, $f : X \rightarrow \overline{\mathbb{R}}$ et

$$(P) \inf_{x \in X} f(x).$$

- **Réécriture du problème primal.**

On suppose que

$$f(x) = \sup_{y \in Y} \varphi(x, y),$$

où $\varphi : X \times Y \rightarrow \overline{\mathbb{R}}$. Donc

$$(P) \inf_{x \in X} \sup_{y \in Y} \varphi(x, y) = \text{val}(P).$$

- **Le problème dual :** on inverse l'inf et le sup

$$(D) \sup_{y \in Y} \inf_{x \in X} \varphi(x, y) = \text{val}(D).$$

On peut aussi l'écrire $\inf_{y \in Y} \delta(y)$, où

$$\delta(y) := - \inf_{x \in X} \varphi(x, y). \quad (13)$$

- $\delta \equiv$ **fonction duale**,
- (13) \equiv **problème interne** en $y \in Y$.

Liens entre (P) et (D)

- **Dualité faible :**

$$\text{val}(D) \leq \text{val}(P).$$

Saut de dualité := $\text{val}(P) - \text{val}(D) \geq 0$.

- **Dfn :** On dit que (\bar{x}, \bar{y}) est un **point-selle** de φ sur $X \times Y$, si $\forall x \in X$ et $\forall y \in Y$

$$\varphi(\bar{x}, y) \leq \varphi(\bar{x}, \bar{y}) \leq \varphi(x, \bar{y}).$$

- **Théor :** (\bar{x}, \bar{y}) est un point-selle de φ sur $X \times Y$ SSI

- 1) \bar{x} est solution de (P),
- 2) \bar{y} est solution de (D),
- 3) il n'y a pas de saut de dualité.

- **Coroll :** Si φ a un point-selle et $\bar{y} \in \text{Sol}(D)$:

$$\emptyset \neq \text{Sol}(P) \subset \arg \min_{x \in X} \varphi(x, \bar{y}).$$

Dualisation de contraintes fonctionnelles (§ 13.5)

On cherche à écrire un problème dual du problème d'optimisation avec contraintes :

$$(P_{X,EI}) \begin{cases} \min f(x) \\ x \in X \\ c_E(x) = 0 \\ c_I(x) \leq 0. \end{cases}$$

où $X \subset \mathbb{E}$, sans qu'il y ait de saut de dualité.

Dualité lagrangienne (problèmes convexes)

On prend pour φ , le lagrangien (ici $y \equiv \lambda$)

$$\varphi(x, \lambda) \equiv \ell(x, \lambda) = f(x) + \lambda^\top c(x),$$

$X \subset \mathbb{E}$ et $Y := \mathbb{R}^{m_E} \times \mathbb{R}_+^{m_I}$.

- **Problème primal :**

$$(P_{X,EI}) \equiv \inf_{x \in X} \sup_{\lambda \in Y} \ell(x, \lambda).$$

- **Problème dual :**

$$\sup_{\lambda \in Y} \inf_{x \in X} \ell(x, \lambda).$$

- **Résultat de dualisation :**

Si • $X = \mathbb{E}$,

- $(P_{X,EI})$ est « convexe »
(i.e., f et c_I convexes et c_E affine),
- $(\bar{x}, \bar{\lambda})$ vérifie (KKT),

alors $(\bar{x}, \bar{\lambda})$ est point-selle de ℓ sur $\mathbb{E} \times Y$.

- **Relaxation lagrangienne (Uzawa)**

On passe de λ_k à λ_{k+1} par :

1. $x_k \in \arg \min_{x \in \mathbb{E}} \ell(x, \lambda_k)$,
2. arrêt si (x_k, λ_k) est satisfaisant,
3. $\lambda_{k+1} = P_Y [\lambda_k + \alpha_k c(x_k)]$.

Explications de la formule de mise à jour de λ_k
(algorithme du gradient avec projection) :

- P_Y est le projecteur orthogonal sur Y (permet de maintenir les λ_k dans Y),
- $\alpha_k > 0$ est déterminé de manière à faire croître δ ,
- $-c(x_k)$ est un sous-gradient de δ .

Résultat de convergence :

Si • f fortement convexe, c_E affine et c_I convexe,

- $(\bar{x}, \bar{\lambda})$ vérifie (KKT),
- $\alpha_k > 0$ « petit »,

alors $x_k \rightarrow \bar{x}$.

Dualité lagrangienne augmentée

(problèmes non convexes)

On prend pour φ , le **lagrangien augmenté**

$$\begin{aligned} \ell_r(x, \lambda) = & f(x) + \sum_{i \in E} \left[\lambda_i c_i(x) + \frac{r}{2} c_i(x)^2 \right] \\ & + \sum_{i \in I} \left[\lambda_i \max \left(\frac{-\lambda_i}{r}, c_i(x) \right) + \right. \\ & \left. \frac{r}{2} \left(\max \left(\frac{-\lambda_i}{r}, c_i(x) \right) \right)^2 \right]. \end{aligned}$$

- **Problème primal :**

$$\inf_{x \in X} \sup_{\lambda \in \mathbb{R}^m} \ell_r(x, \lambda).$$

- **Problème dual :**

$$\sup_{\lambda \in \mathbb{R}^m} \inf_{x \in X} \ell_r(x, \lambda).$$

- **Résultat de dualisation :**

Si • $X = \mathbb{E}$,

- $(\bar{x}, \bar{\lambda})$ vérifie les CS2,

alors il existe un *voisinage* V de \bar{x} et un seuil $r_0 > 0$ tels que, pour tout $r \geq r_0$, $(\bar{x}, \bar{\lambda})$ est point-selle de ℓ_r sur $V \times \mathbb{R}^m$.

- **Relaxation lagrangienne augmentée (méthode des multiplicateurs)**

On passe de (λ_k, r_k) à (λ_{k+1}, r_{k+1}) par :

1. $x_k \in \arg \min_{x \in \mathbb{E}} \ell_{r_k}(x, \lambda_k)$,
2. arrêt si (x_k, λ_k) est satisfaisant,
3. $\lambda_{k+1} = P_Y [\lambda_k + r_k c(x_k)]$
(pas besoin de RL !),
4. adapter $r_k \rightsquigarrow r_{k+1}$ (heuristique).