

Optimisation

1. Optimisation sans contraintes
2. Optimisation sous contraintes
3. Analyse convexe et dualité

Optimisation sous contraintes

$$\min_{x \in \mathbf{R}^n} f(x) \text{ subject to } \begin{cases} c_i(x) = 0, & i \in \mathcal{E} \\ c_i(x) \leq 0, & i \in \mathcal{I} \end{cases}$$

$$\Omega = \{x \in \mathbf{R}^n \mid \text{pour tout } i \in \mathcal{E}, c_i(x) = 0, \text{ pour tout } j \in \mathcal{I}, c_j(x) \leq 0\}$$

x^* est une solution locale du problème ssi $x^* \in \Omega$ et il existe un ensemble ouvert $U \subset \mathbf{R}^n$ contenant x^* tel que pour tout $x \in U \cap \Omega$, $f(x^*) \leq f(x)$

Condition nécessaire d'optimalité: intuition

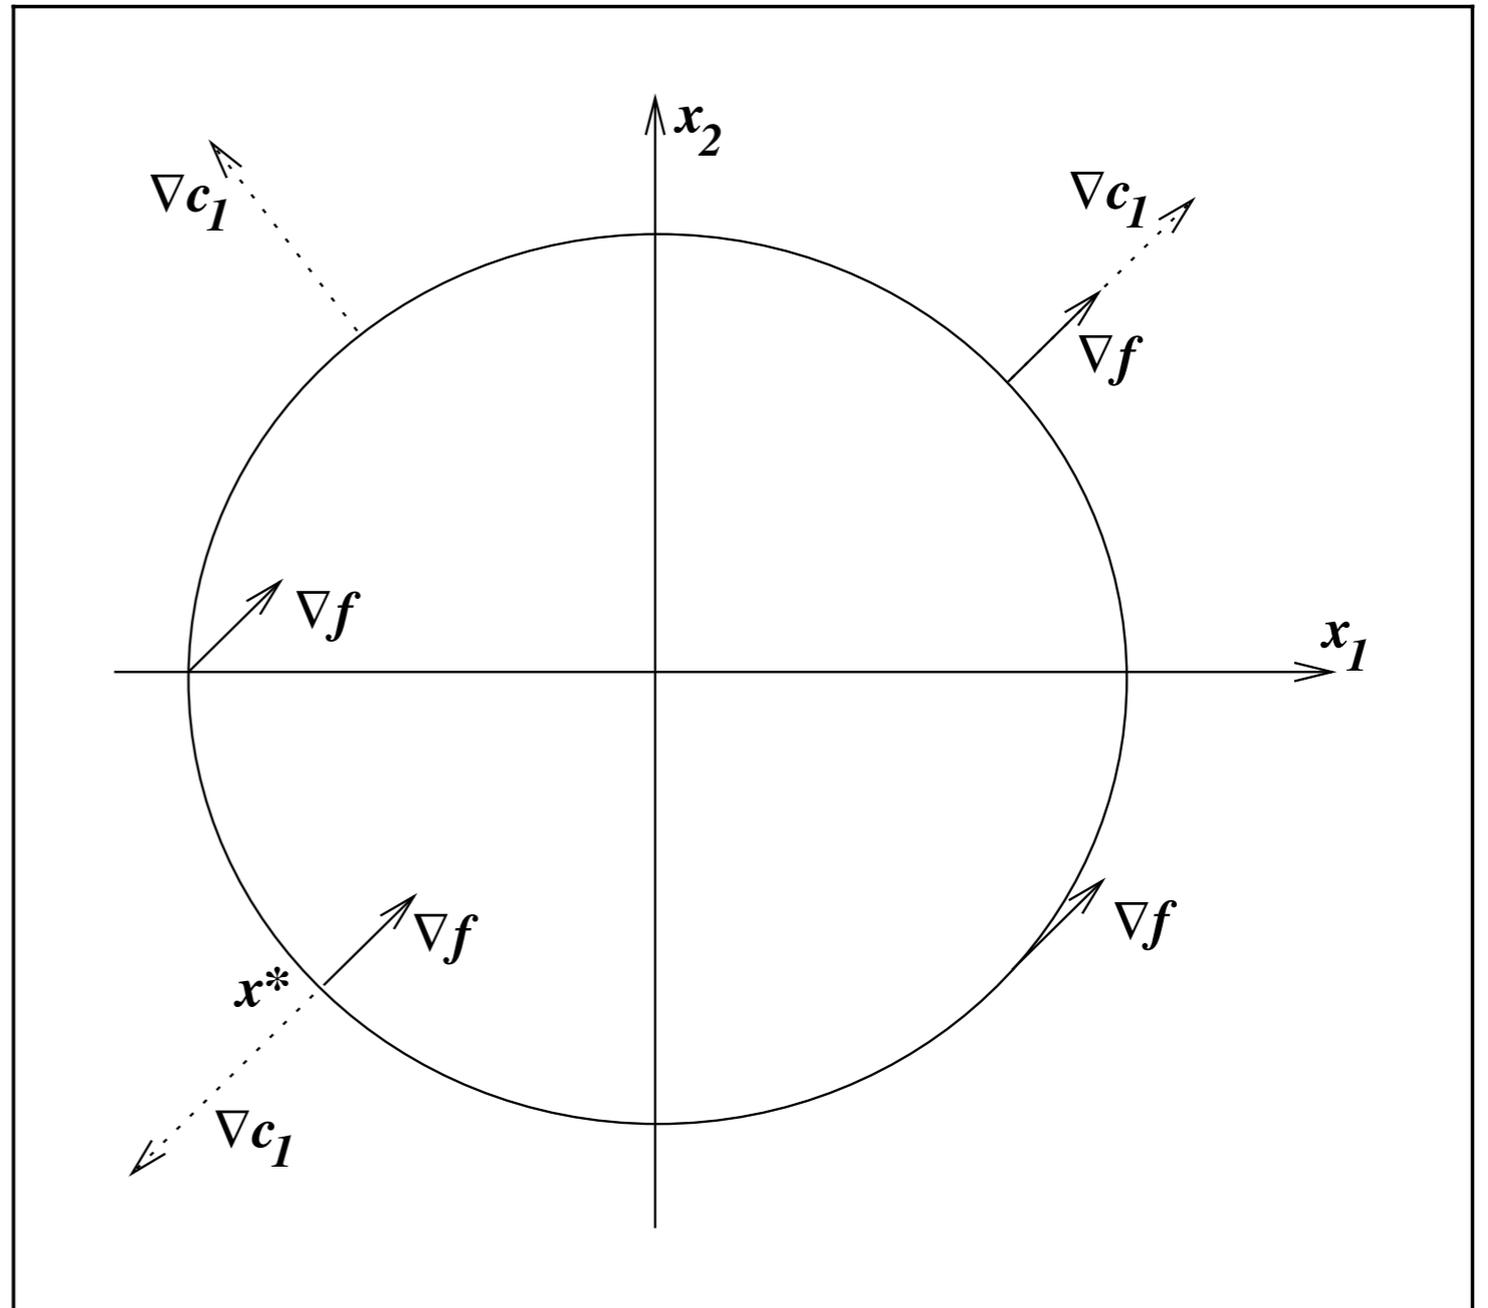
$$f : x_1, x_2 \mapsto x_1 + x_2$$

**Cas d'une seule
contrainte d'égalité**

$$x_1^2 + x_2^2 = 2$$

**Condition nécessaire
d'optimalité**

$$\nabla f(x^*) = \lambda_1^* \nabla c_1(x^*).$$



Condition nécessaire d'optimalité: intuition

$$f : x_1, x_2 \mapsto x_1 + x_2$$

**Cas d'une seule
contrainte d'inégalité**

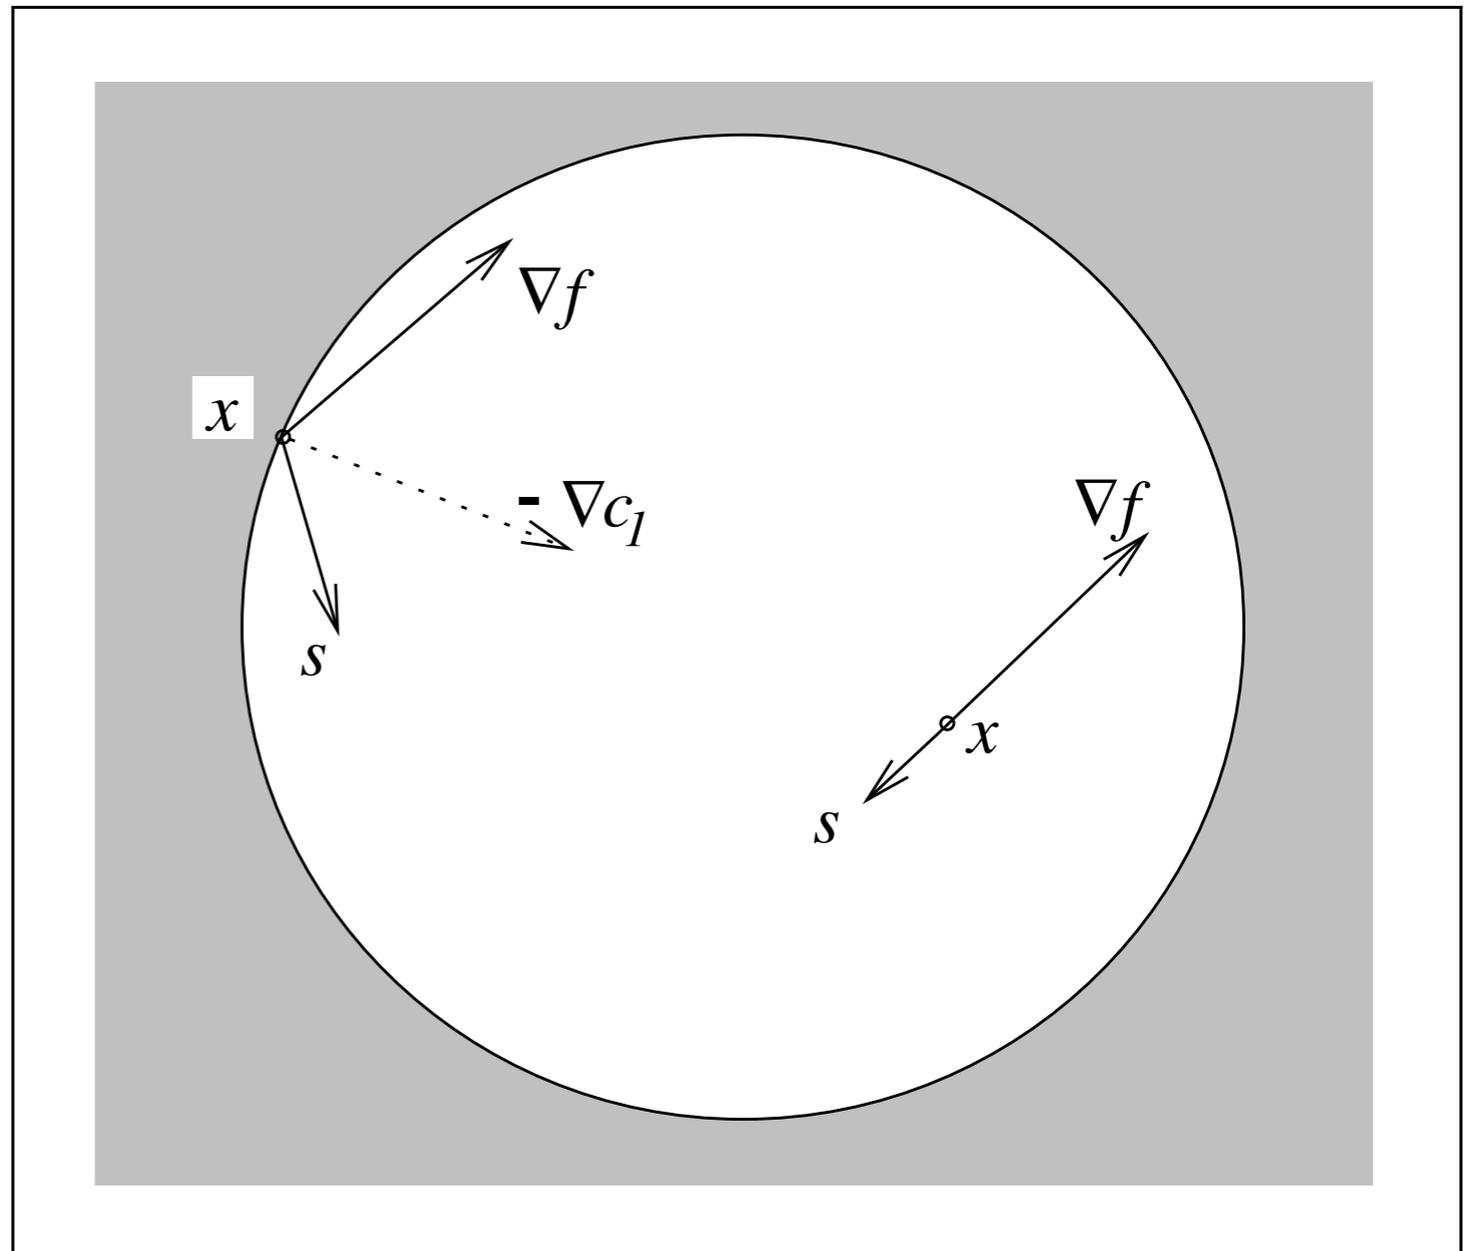
$$x_1^2 + x_2^2 \leq 2$$

**Condition nécessaire
d'optimalité**

$$\nabla f(x^*) = -\lambda_1^* \nabla c_1(x^*)$$

$$\lambda_1^* \geq 0$$

$$\lambda_1^* c_1(x^*) = 0.$$



Cas général : KKT conditions

$$\mathcal{L}(x, \lambda) = f(x) + \sum_{i \in \mathcal{E} \cup \mathcal{I}} \lambda_i c_i(x)$$

Conditions de Karush-Kuhn-Tucker (KKT)

$$\nabla_x \mathcal{L}(x^*, \lambda^*) = 0,$$

$$c_i(x^*) = 0, \quad \text{for all } i \in \mathcal{E},$$

$$c_i(x^*) \leq 0 \quad \text{for all } i \in \mathcal{I},$$

$$\lambda_i^* \geq 0, \quad \text{for all } i \in \mathcal{I},$$

$$\lambda_i^* c_i(x^*) = 0, \quad \text{for all } i \in \mathcal{E} \cup \mathcal{I}.$$

Condition nécessaire d'optimalité: cas général

Mangasarian-Fromovitz Constraint Qualification (MFCQ)

(Plus d'exemples de qualifications des contraintes sur la feuille d'exercice numéro 1)

The gradients of the equality constraints are linearly independent at x^* and there exists a vector $d \in \mathbf{R}^n$ such that $\nabla c_i(x^*)^T d < 0$ for all **active** inequality constraints and $\nabla e_j(x^*)^T d = 0$ for all equality constraints.

Théorème : Si x^* est une solution locale et que la qualification des contraintes de Mangasarian-Fromovitz est respectée en x^* alors les conditions KKT sont vérifiées en x^* .

Optimisation

1. Optimisation sans contraintes
2. Optimisation sous contraintes
3. Analyse convexe et dualité

Convexité

L'ensemble X est convexe ssi pour tout x, y dans X , le segment $[x, y] := \{tx + (1 - t)y \mid t \in [0, 1]\}$ est inclus dans X

Une fonction $f : X \subset \mathbf{R}^n \rightarrow R$ est convexe ssi X est convexe et pour tout x, y dans X et pour tout $t \in [0, 1]$,

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

Si l'inégalité est stricte pour $t \in]0, 1[$, la fonction est dite *strictement* convexe.

Convexité

Reconnaître une fonction convexe

- les fonctions linéaires sont convexes
- les combinaisons linéaires positives de fonctions convexes sont convexes
- le maximum (point par point) d'un ensemble de fonctions convexes est convexe
- ...

Si f est de classe C^2 , f est convexe si et seulement si $\nabla^2 f$ est semi-définie positive sur l'intérieur de X . Si $\nabla^2 f$ est définie positive sur l'intérieur de X , f est strictement convexe. ($X = \text{dom} f$)

Existence et unicité du minimum

Théorèmes

Si f est convexe et minorée, alors f admet un minimum global.

Si f est une fonction *strictement* convexe définie sur un ensemble convexe $X \subset \mathbf{R}^n$, alors f admet au plus un minimum global.

Si f est une fonction convexe définie sur un ensemble convexe $X \subset \mathbf{R}^n$, alors tout minimum local de f est aussi un minimum global de f . Si X est ouvert, alors $\nabla f(x^*) = 0$ est équivalent à x^* est un minimum global de f .

Dualité

Problème considéré

minimize $f(x)$

subject to $x \in X$, $g_j(x) \leq 0$, $j = 1, \dots, r$,

$$f : \mathbf{R}^n \rightarrow \mathbf{R}$$

$$g_j : \mathbf{R}^n \rightarrow \mathbf{R}$$

$$X \subset \mathbf{R}^n$$

$$f^* = \inf_{\substack{x \in X \\ g_j(x) \leq 0, j=1, \dots, r}} f(x).$$

$$-\infty < f^* < +\infty$$

Il existe x^* , tel que $f(x^*) = f^*$

Dualité

Lagrangien associé au problème

$$L(x, \mu) = f(x) + \sum_{j=1}^r \mu_j g_j(x) = f(x) + \mu' g(x).$$

Dualité

Fonction duale

$$q(\mu) = \inf_{x \in X} L(x, \mu).$$

Problème dual

$$\text{maximize } q(\mu)$$

$$\text{subject to } \mu \geq 0, \mu \in D,$$

$$D = \{\mu \mid q(\mu) > -\infty\}.$$

Résultats

Proposition 5.1.2: The domain D of the dual function q is convex and q is concave over D .

Proposition 5.1.3: (Weak Duality Theorem) We have

$$q^* \leq f^*.$$

Dualité

Dualité forte et qualification des contraintes

Exemple :

Si f est convexe et les contraintes g_j sont linéaires, alors il n'y a pas d'écart dual: $q^* = f^*$

Dualité

If conditions for strong duality are met and (x^*, μ^*) are such that $L(x^*, \mu^*) = f^* = q^*$, then (x^*, μ^*) is said to be an optimal solution Lagrange multiplier pair.

Proposition 5.1.5: (Optimality Conditions) (x^*, μ^*) is an optimal solution-Lagrange multiplier pair if and only if

$$x^* \in X, \quad g(x^*) \leq 0, \quad (\text{Primal Feasibility}), \quad (5.4)$$

$$\mu^* \geq 0, \quad (\text{Dual Feasibility}), \quad (5.5)$$

$$x^* = \arg \min_{x \in X} L(x, \mu^*), \quad (\text{Lagrangian Optimality}), \quad (5.6)$$

$$\mu_j^* g_j(x^*) = 0, \quad j = 1, \dots, r, \quad (\text{Complementary Slackness}). \quad (5.7)$$