

# Sixième cours

- DM1 en ligne à rendre pour le 6 Octobre (en main propre ou par email: thomas.schatz@univ-amu.fr)
- DM2 en ligne mercredi prochain
- Scribes : Rémi Gauchotte et Anas Ouled Sbouria (rendu = fichier .tex)
- Aujourd’hui
  - Fin de l’optimisation début des probabilités

# Descente de gradient

**‘Backtracking’ avec la règle d’Armijo**

Input:  $x_0 \in \mathbf{R}^n, f : \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1.$

Iteration :  $x_{k+1} = x_k - \alpha_k \nabla f(x_k)$

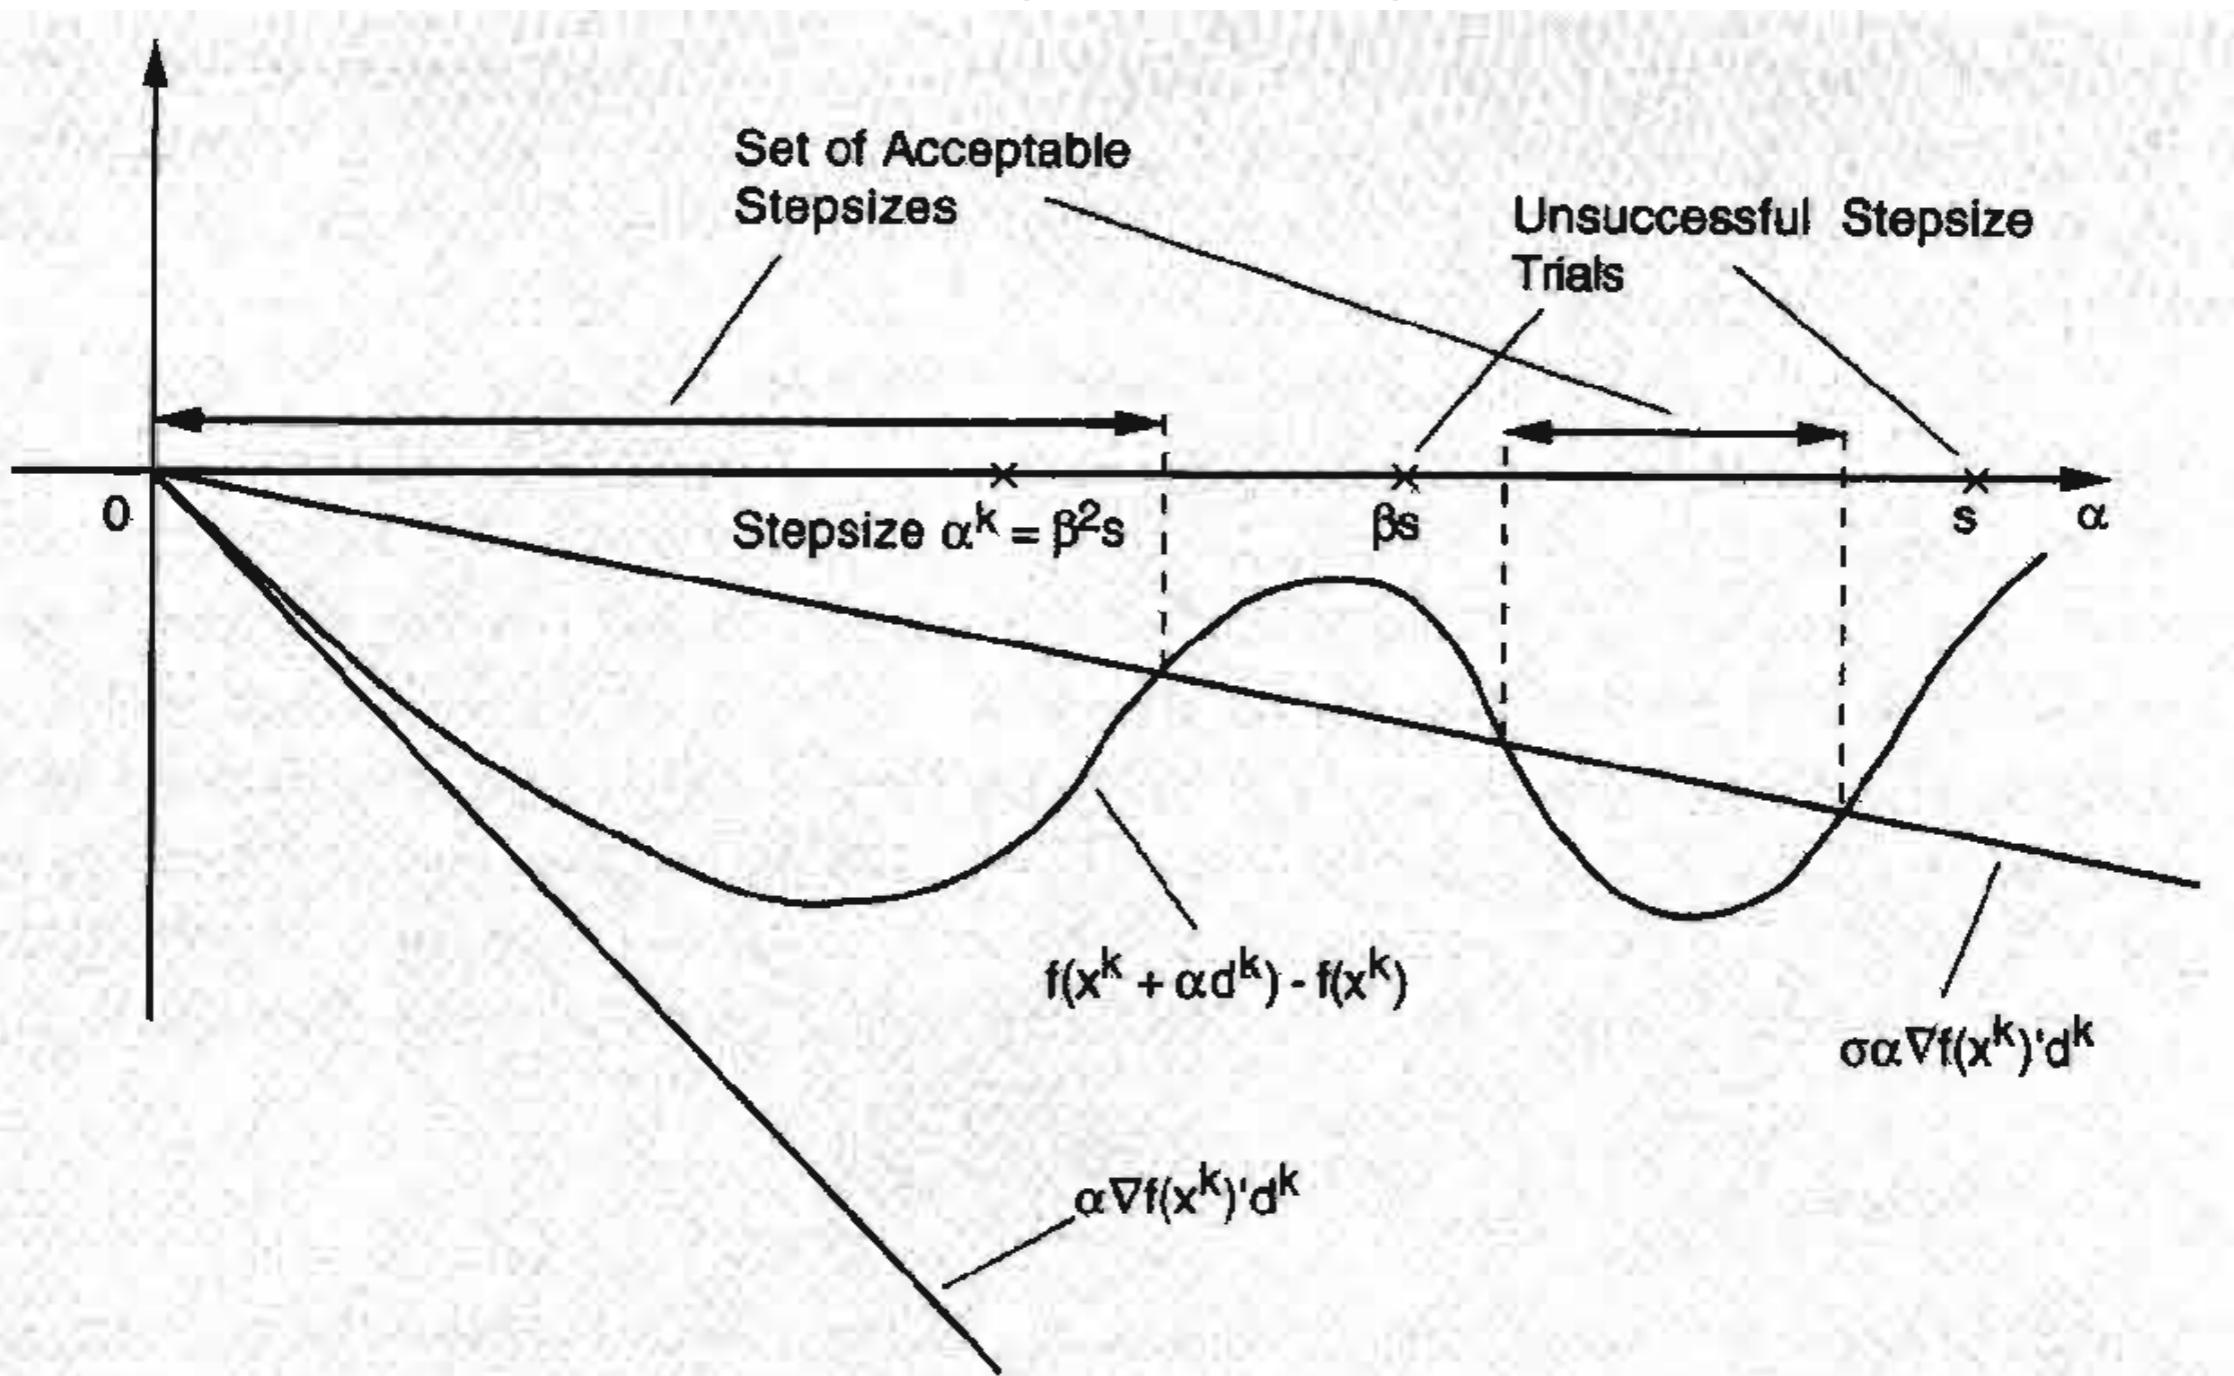
$$\alpha_k = \beta^{m_k} s$$

$m_k$  plus petit entier positif tel que

$$f(x_k) - f(x_{k+1}) \geq \sigma \beta^{m_k} s \nabla f(x_k)^T \nabla f(x_k)$$

# Descente de gradient

‘Backtracking’ avec la règle d’Armijo



# Descente de gradient

**‘Backtracking’ avec la règle d’Armijo**

Input:  $x_0 \in \mathbf{R}^n, f : \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1.$

Iteration :  $x_{k+1} = x_k - \alpha_k \nabla f(x_k)$

$$\alpha_k = \beta^{m_k} s$$

$m_k$  plus petit entier positif tel que

$$f(x_k) - f(x_{k+1}) \geq \sigma \beta^{m_k} s \nabla f(x_k)^T \nabla f(x_k)$$

# Descente de gradient

**‘Backtracking’ avec la règle d’Armijo**

Input:  $x_0 \in \mathbf{R}^n, f : \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1.$

Iteration :  $x_{k+1} = x_k - \alpha_k \nabla f(x_k)$

$$\alpha_k = \beta_{m_k} s$$

$m_k$  plus petit entier positif tel que

$$f(x_k) - f(x_k - \beta_{m_k} s \nabla f(x_k)) \geq \sigma \beta_{m_k} s \nabla f(x_k)^T \nabla f(x_k)$$

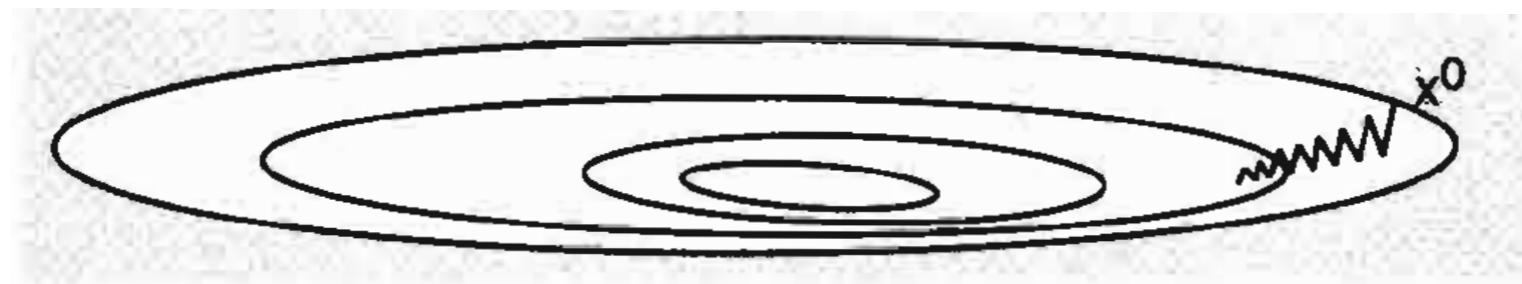
# Descente de gradient

## Convergence

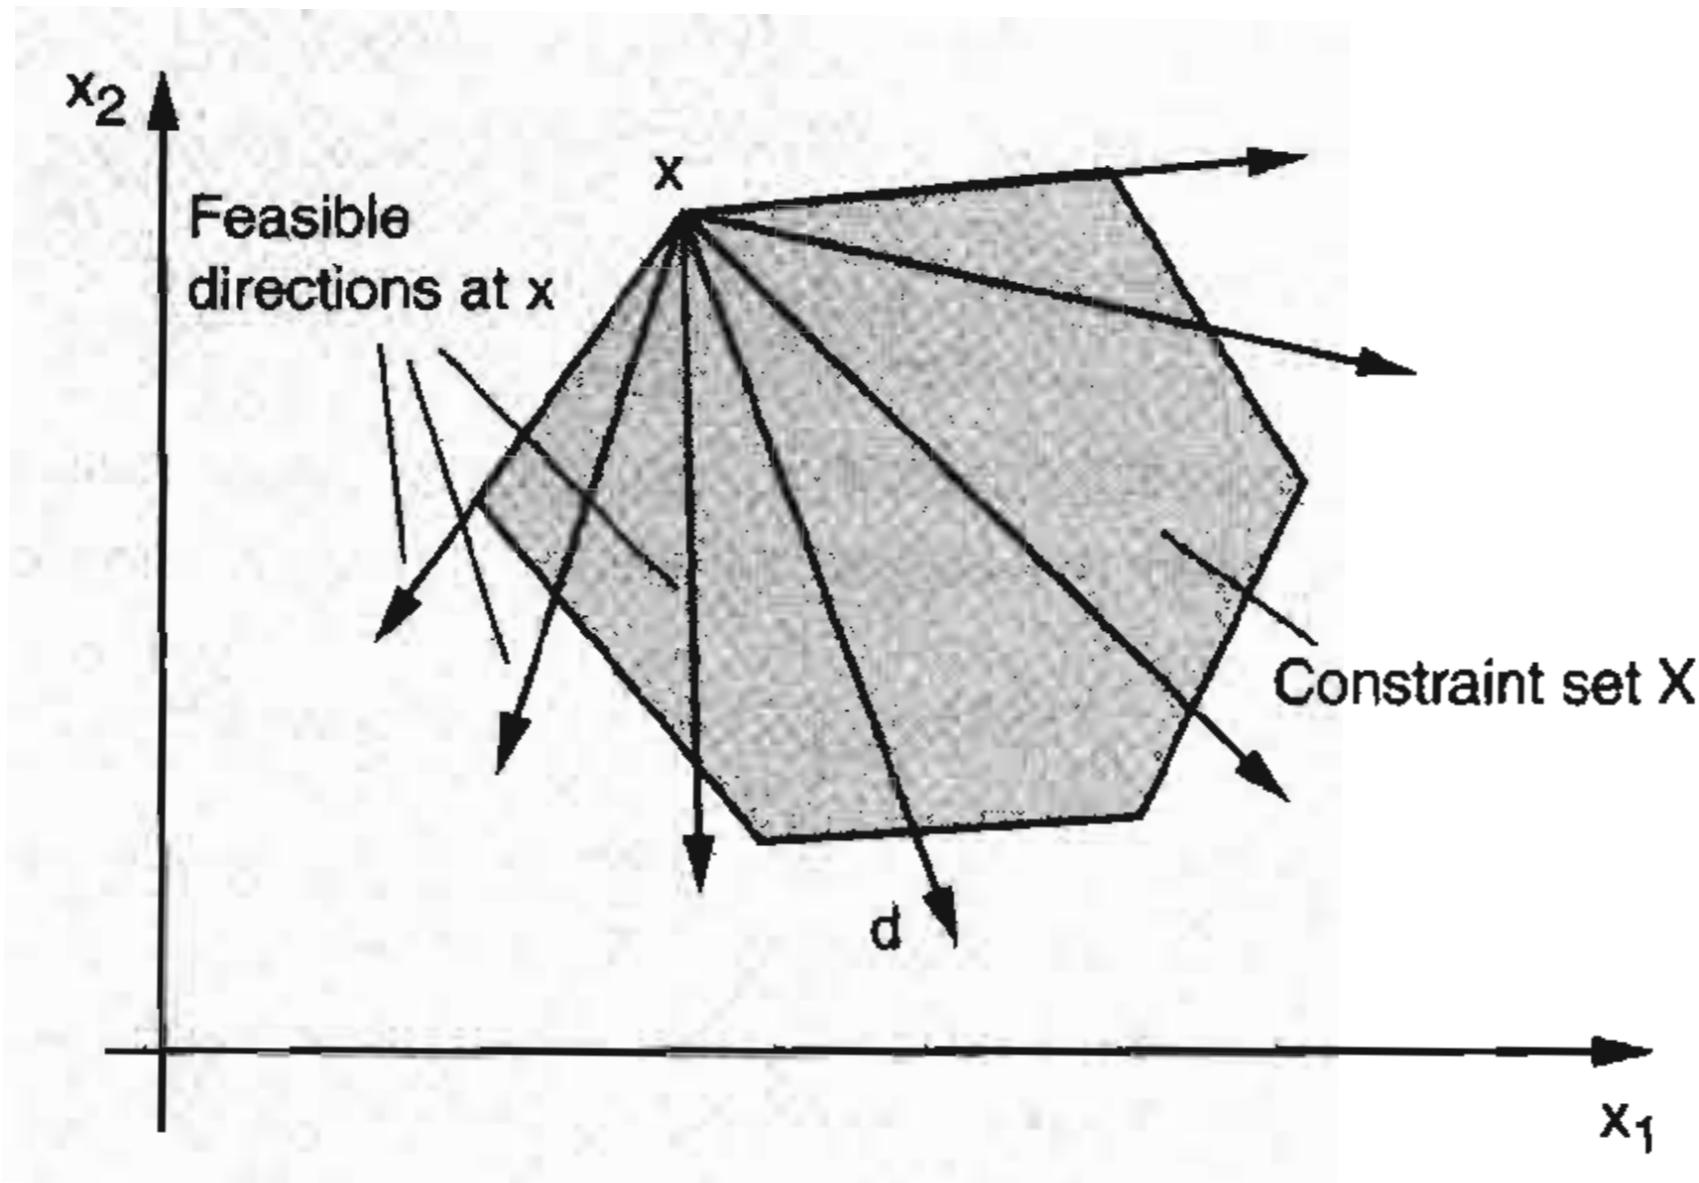
Soit  $(x_k)$  la suite des points générés par l'algorithme de descente de gradient avec pas choisi par la règle d'Armijo. Alors, tout point limite (i.e. valeur d'adhérence) de  $(x_k)$  est un point stationnaire.

De plus, si  $x^*$  est le seul point stationnaire de  $f$  dans un ensemble ouvert, il existe un ensemble ouvert  $S$  contenant  $x^*$  tel que si il existe  $k_0$  tel que  $x_{k_0} \in S$ , alors  $x_k \in S$  pour tout  $k \geq k_0$  et  $x_k \rightarrow x^*$ .

## Vitesse de convergence ?



# Présence de contraintes: Descente de gradient projeté



# Présence de contraintes: Descente de gradient projeté

**‘Backtracking’ avec la règle d’Armijo le long de l’arc de projection**

Input:  $x_0 \in \mathbf{R}^n, f : U \subset \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1.$   
 $U$  convexe, fermé, non-vide

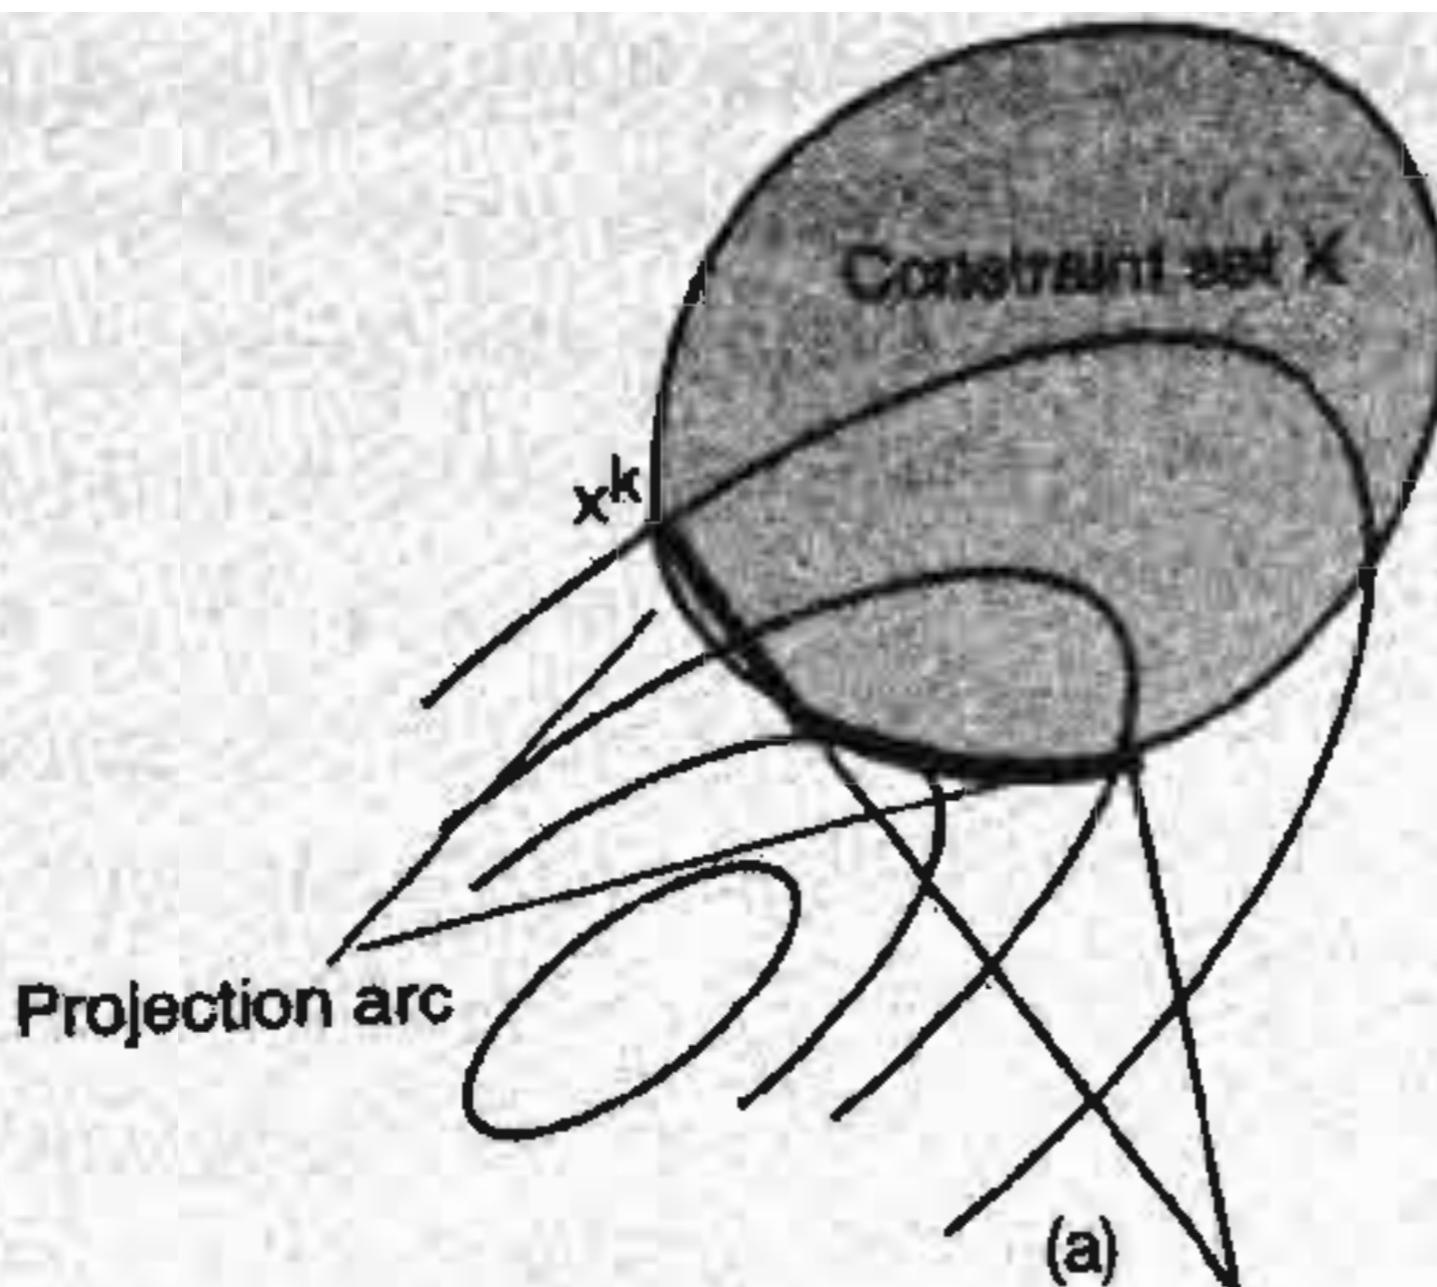
Iteration:  $x_{k+1} := p_k(\beta^{m_k} s)$

$p_k(r) = [x_k - r \nabla f(x_k)]_U$  et  $m_k$  plus petit entier  $m$  tel que

$$f(x_k) - f(x_{k+1}) \geq \sigma \nabla f(x_k)^T (x_k - x_{k+1})$$

# Présence de contraintes: Descente de gradient projeté

‘Backtracking’ avec la règle d’Armijo le long de l’arc de projection



# Présence de contraintes: Descente de gradient projeté

**‘Backtracking’ avec la règle d’Armijo le long de l’arc de projection**

Input:  $x_0 \in \mathbf{R}^n, f : U \subset \mathbf{R}^n \rightarrow \mathbf{R}$  de classe  $\mathcal{C}^1, s > 0, 0 < \beta < 1, 0 < \sigma < 1.$   
 $U$  convexe, fermé, non-vide

Iteration:  $x_{k+1} := p_k(\beta^{m_k} s)$

$p_k(r) = [x_k - r \nabla f(x_k)]_U$  et  $m_k$  plus petit entier  $m$  tel que

$$f(x_k) - f(x_{k+1}) \geq \sigma \nabla f(x_k)^T (x_k - x_{k+1})$$

# Dualité

minimize  $f(x)$

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

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

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

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

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

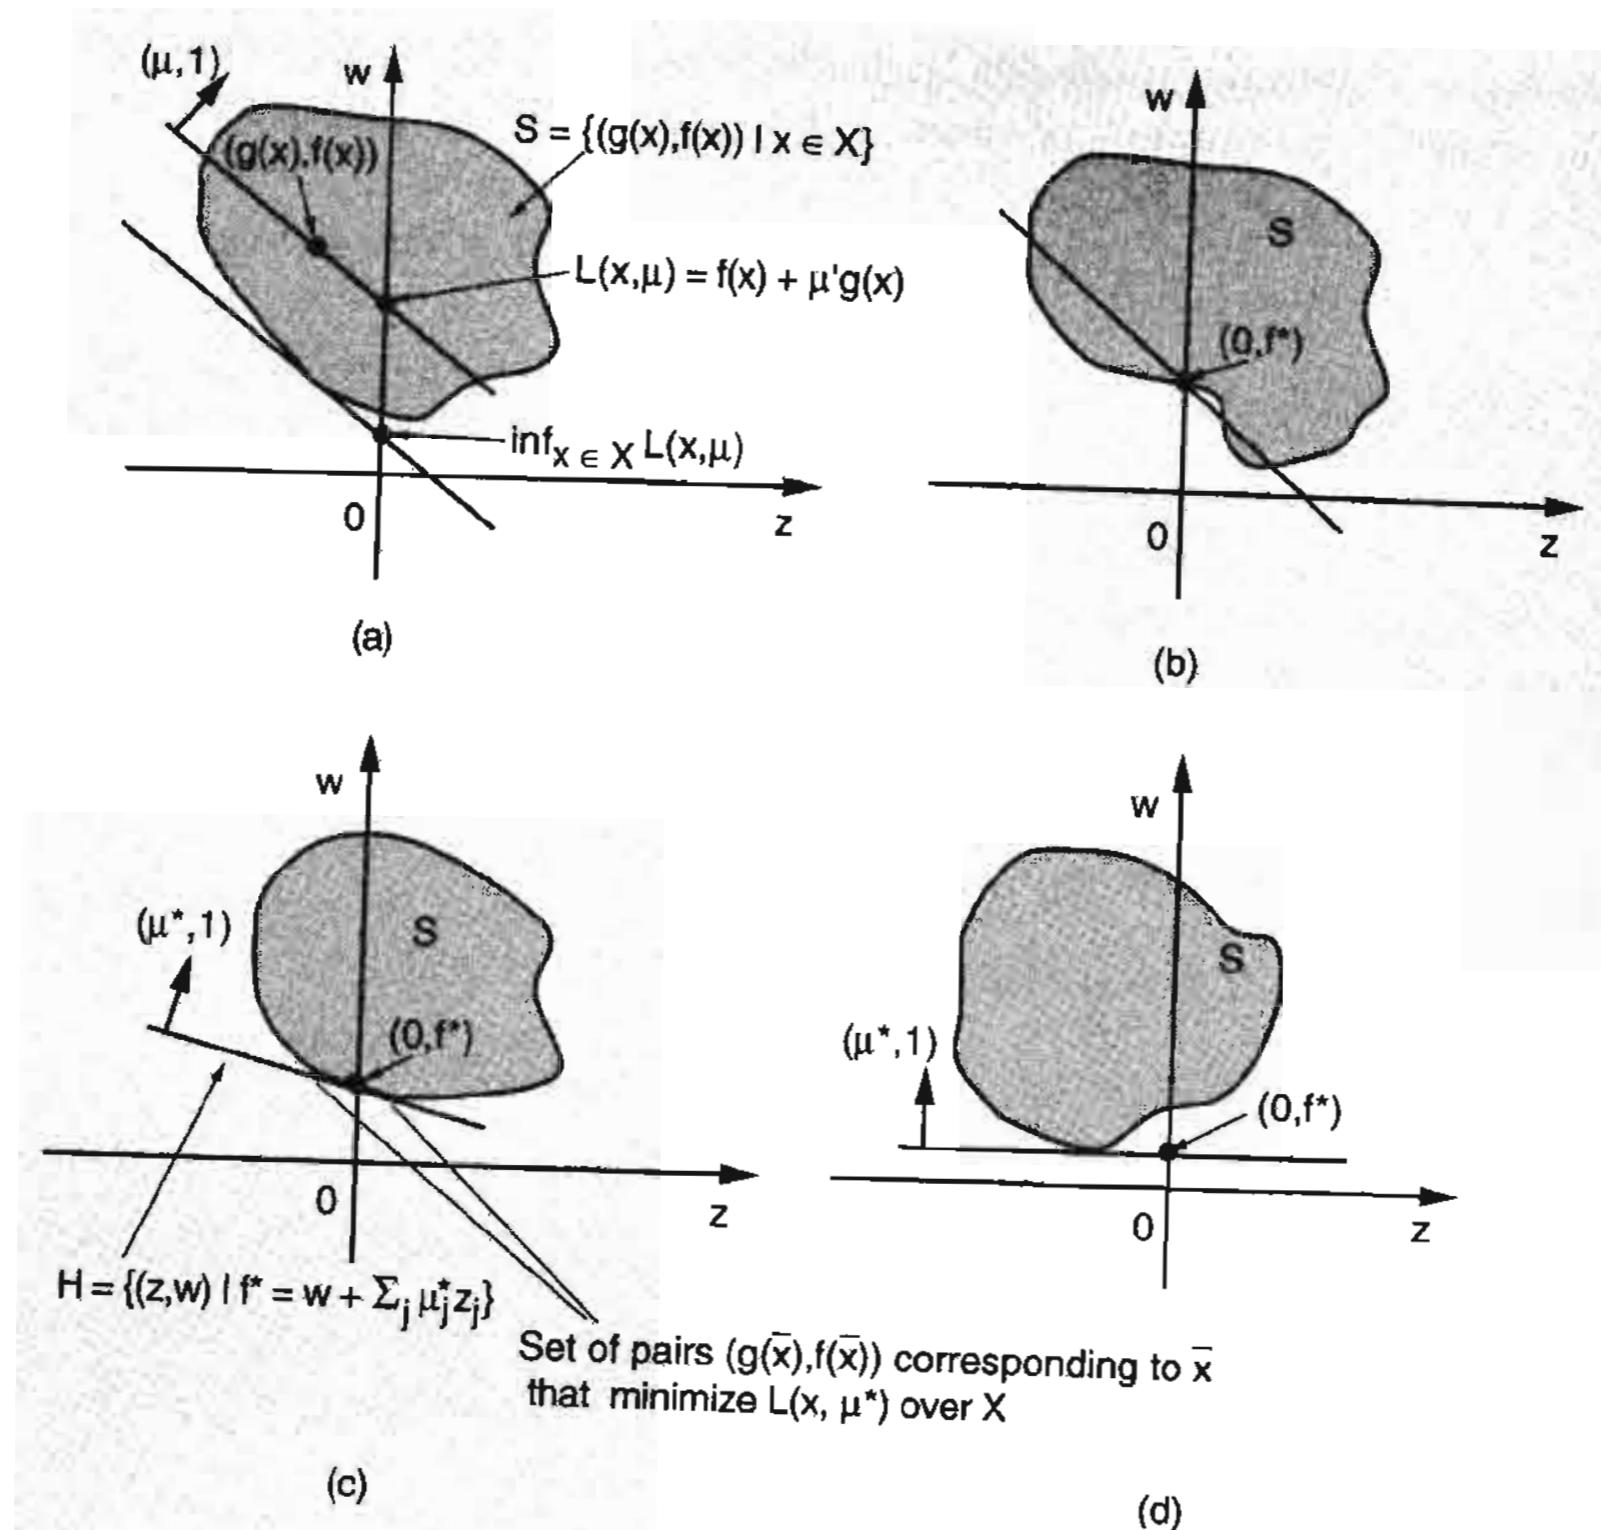
$$-\infty < f^* < +\infty$$

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

# Dualité

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

# Dualité



# Dualité

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

maximize  $q(\mu)$

subject to  $\mu \geq 0,$   
 $\mu \in D,$

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

**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**

**Example :**

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

# Dualité

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

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

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

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

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

# Crédits

Certaines figures de

- Bertsekas, nonlinear programming
- Wikipedia