

# Les méthodes de gradient réduit

J. Frédéric Bonnans

INRIA-Saclay & CMAP, Ecole Polytechnique, France

Journées en l'honneur de Pierre Huard  
JFRO, 24-25 novembre 2008, Carré des Sciences, Paris

- 1 L'optimisation au début des années 60
- 2 Premiers pas du gradient réduit
- 3 Analyse technique

# Programmation linéaire

Format standard :

$$\text{Min}_{x \in \mathbb{R}^n} c \cdot x; \quad Ax = b \quad x \geq 0. \quad (LP)$$

Base  $B$  :  $(B, N)$  partition de  $\{1, \dots, n\}$  et  $A_B$  inversible.

Solution de base :  $x_N = 0$  et  $x_B = A_B^{-1}b$  (admissible si  $x_B \geq 0$ ).

Si la valeur de  $(LP)$  est finie, il existe une solution basique.

## Algorithme du simplexe

Dantzig 1947 :

Point courant  $x$  basique,  $x_B > 0$  (pour chaque composante)

Estimations du multiplicateur et du gradient réduit

$$\lambda := -A_B^{-T} c_B; \quad g := c_N + A_n^T \lambda$$

Si  $g \geq 0$ ,  $x$  est optimal : arrêt

Soit  $i \in N$  tel que  $g_i < 0$ ;  $d_N = e_i$ ;  $d_B = -A_B^{-1} A_i$

Si  $d_B \geq 0$ ,  $\text{val}(P) = -\infty$ ; arrêt

Déplacement maximum dans la direction  $d$  pour annuler une variable de base  $k$

Pivotage : Rentrée dans la base de  $i$ , sortie de  $k$ .

## Méthodes de descente de descente

Cauchy 1847 : globalisation de la méthode de Newton pour un système "carré" d'équations non linéaires

Méthode de gradient sur le critère de moindres carrés associé

Recherche linéaire : pas optimal et heuristique

Curry 1944 : plus petit pas assurant la stationarité

Preuve de convergence

Hestenes et Stiefel 1952 : gradient conjugué (cas quadratique)

Davidon 1959, Fletcher et Powell 1963 : métrique variable (DFP)

Rosen 1960 : gradient avec projection

## Ce qui n'est pas encore connu !

Armijo 1966 : Règle de recherche linéaire

Fletcher-Reeves 1964, Polak-Ribière 1969 : Extensions du gradient conjugué

Fletcher, Powell 1969 : Lagrangien augmenté

Wolfe 1972 Conditions de recherche linéaire

Wolfe 1974, Lemaréchal 1974 : faisceaux  
(minimisation de fonctions convexes non différentiables)

Han 1976, Powell 1977 : programmation quadratique successive  
pénalisation exacte, combinaison avec métrique variable

Algorithmes polynomiaux (ellipsoïdes, points intérieurs)

## Algorithme initial du gradient réduit : P. Wolfe, 1962

$$\text{Min}_{x \in \mathbb{R}^n} f(x); \quad Ax = b \quad x \geq 0. \quad (NLP)$$

Point courant  $x$  basique,  $x_B > 0$ ,  $x_N \geq 0$ .

Estimations du multiplicateur et du gradient réduit

$$\lambda := -A_B^{-T} \nabla_B f(x); \quad g := \nabla_N f(x) + A_N^T \lambda$$

Gradient "projeté"  $g_P$  :  $g_{Pi} = g_i$  si  $x_i \neq 0$ ,  $g_{Pi} = (g_i)_-$  sinon.

Si  $g_P = 0$ ,  $x$  est optimal : arrêt

$$d_N = -g_P, \quad d_B = -A_B^{-1} d_N$$

Calcul du déplacement maximum  $\rho_{max}$  dans la direction  $d$  pour annuler une variable (de base ou non)

Choix du pas optimal  $\rho \in ]0, \rho_{max}]$ .

Pivotage si variable de base annulée

# Limitations de l'approche de P. Wolfe

Limité au gradient projeté et au pas optimal

Pas d'analyse de convergence

Pas de test numérique

## Article de P. Faure et P. Huard, 1965

**Premier article donnant une analyse théorique et des résultats théoriques sur la méthode du gradient réduit**

**Principales caractéristiques :**

Analyse de convergence

Evitement du “cyclage immédiat”

Recherche linéaire “1/4, 1/2, 3/4”

Sous relaxation, diagonalisation des directions

Conjugaison des directions

Implémentation en Fortran IV (1962) sur IBM 7094

Problèmes d'investissement : 209 variables, 61 contraintes

# Analyse de convergence de P. Faure et P. Huard, 1965

## Hypothèses

Critère convexe, minoré, " $C^2$  borné".

Pivots uniformément non nuls

Taille des pas de recherche linéaire uniformément bornés

## Résultat : alternatives suivantes

- 1) Arrêt en une solution
- 2) Sous suite convergent vers la solution, de gradient réduit projeté tendant vers 0
- 3) Gradient réduit projeté ne tendant pas vers 0 : convergence vers un point  $\bar{x}$ , et  $\rho_k \rightarrow 0$ .

## Détails techniques : petits pas

$$x_{k+1} = x_k + \rho_k d_k$$

$$\|d_k\| = 1; \quad g^k \cdot d_N^k \leq -c \|g_P^k\|;$$

$$\begin{aligned} f(x_k + \rho d_k) &= f(x_k) + \rho g^k \cdot d_N^k + o(\rho) \\ &\leq f(x_k) - c\rho \|g_P^k\| + o(\rho) \end{aligned}$$

On choisit  $\rho_k$  assez petit pour que

$$f(x_{k+1}) \leq f(x_k) - c' \rho_k \|g_P^k\|$$

Donc  $\sum_k \rho_k \|g_P^k\| < \infty$  : Le long d'une sous suite  $\mathcal{K}$  telle que  $\liminf_{k \in \mathcal{K}} \|g_P^k\| > 0$ , on a

$$\sum_{k \in \mathcal{K}} \rho_k < \infty$$

## Détails techniques : petits pas, mais pas trop petits

**Prendre le pas assez grand** : si  $\rho_k < \rho_{max,k}$ , alors (Wolfe 1972)

$$\nabla f(x_{k+1})d_k \geq \frac{1}{2}\nabla f(x_k)d_k$$

Au voisinage de  $\hat{x}$  tel que  $g(\hat{x})_- \neq 0$ , implique

$$\rho_k > \rho(\hat{x}) \quad \text{ou} \quad \rho_k = \rho_{max,k}$$

## Points d'adhérence non stationnaires

Propriété des **paquets d'itérations locales** :

Si  $\hat{x}$  point d'adhérence non stationnaire

Sous suite associée  $k_1, k_2, \dots$  telle que  $x_{k_i} \rightarrow \hat{x}$

Alors pour tout  $\ell > 0$  :  $x_{k_i+\ell} \rightarrow \hat{x}$

On appelle **paquets d'itérations locales** des itérations successives dans un petit voisinage de  $\hat{x}$ .

Zigzagging possible seulement pour les composantes du gradient réduit nulles au point d'adhérence.

## Cyclage des variables de base ?

### Règle de Markowitz d'entrée en base (1957)

Choisir la variable hors base la plus positive sous contrainte de pivot (supérieur à une fraction du pivot maximum)

**Hyp. de non dégérescence** : Base non dégénérée associée à  $\hat{x}$

Alors (sauf dégérescence au cours des itérations) le paquet d'itérations locales finit par trouver une base non dégénérée associée à  $\hat{x}$

La base du paquet d'itérations change un nombre fini de fois.

**Ceci résout la question du cyclage des variables de base**

## Cyclage des variables hors base

### Contre exemple de P. Wolfe (1966-1972)

$$\text{Max}_{x,y,z \geq 0} f(x,y,z) = -\frac{4}{3}(x^2 - xy + y^2)^{3/4} + z$$

### Zigzagging (Zoutendijk 1960)

Pour le pas optimal,  $x_k$  et  $y_k$  s'annulent à tour de rôle, empêchant la convergence.

## Anti cyclage : P. Huard, 1982

Direction obtenue par projection du déplacement dans la direction du gradient réduit projeté.

Pour un certain  $\beta > 0$ , on projette le déplacement non basique :

$$d_N^k = -\frac{(x_N^k + \beta g_P^k)_+}{\beta} \quad d_B^k = -A_B^{-1} d_N^k$$

On a la condition de descente uniforme : pour un certain  $\alpha > 0$

$$g^k \cdot d_N^k \leq -\alpha \|g_P^k\| \|d_N^k\|$$

$\rho_{max,k} \geq \beta$  : **tout point d'adhérence est stationnaire**

De plus si  $\rho_{max,k} = \beta$  : on sature un paquet de contraintes simultanément : réduction du nombre d'itérations

## Métrieque variable I

Refs Bertsekas (1982), Bonnans (1983)

Réduction au cas de seules contraintes :  $x \geq 0$

Séparation des variables grandes et petites;  $\varepsilon > 0$  :

$$I^k := \{1 \leq i \leq n; x_i \leq \varepsilon\}; \quad J^k := \{1, \dots, n\} \setminus I^k.$$

Direction de descente telle que

$$d_i^k = -g_{P,i}^k, \quad i \in I^k;$$

Recherche linéaire par projection sur  $\mathbb{R}_+^n$

(pas maximum assurant la positivité de la base)

Possibilité de (dé)saturer simultanément plusieurs contraintes

## Métrieque variable II

Forme de métrieque variable :

$$d^k = -(M^k)^{-1} g_P^k;$$

$M^k$  bloc diagonale pour  $(I^k, J^k)$ , bloc identité sur  $I^k$

Bloc sur  $J^k$  : approximation du hessien  $\nabla^2 f(x^k)$

Amélioration possible :  $d_{J^k}^k$  solution de

$$\nabla_{J^k I^k}^2 f(x^k) d_{I^k}^k + \nabla_{J^k J^k}^2 f(x^k) d_{J^k}^k + g_{J^k} = 0$$

## Anti cyclage par blocage des variables

Blanchon, Bonnans, Dodu (1991), Bonnans (2006)

**Paquets d'itérations à l'intérieur desquelles on ne libère aucune variable**

Fin du paquet si optimalité approchée pour les variables non bloquées

## References

- 1 P. Faure et P. Huard, *Résolution de programmes mathématiques à fonction non linéaire par la méthode du gradient réduit*, Rev. Franç. de Rech. Opér., 36(1965).
- 2 P. Huard, *Convergence of the reduced gradient method*. In Nonlinear programming 2, Academic Press, 1974.
- 3 P. Huard *Un algorithme général de gradient réduit*. EDF Bull. Direction Études Rech. Sér. C Math. Inform, 1982.
- 4 J.F. Bonnans, *Optimisation Continue*, Dunod, 2006.