

Une promenade informelle dans le monde de l'optimisation mathématique

Namur Center for Complex Systems (naXys), University of Namur, Belgium

Collège Belgique, Namur, Octobre 2013



Mes objectifs :

- Montrer (par l'exemple) que l'optimisation est un langage dans lequel s'expriment et se résolvent naturellement un grand nombre de problèmes complexes et intéressants.
- Partager enthousiasme et émerveillement devant la variété de son champ d'application.
- Brosser un portrait large du domaine et de sa structure
- Faire passer quelques moments intellectuellement stimulants. . .

- 1 Concepts et exemples
- 2 Un premier aperçu des méthodes et moyens
- 3 Une discipline ancrée dans l'histoire
- 4 L'optimisation en action
 - dans l'industrie et la technologie
 - dans les sciences
 - dans la société humaine
- 5 Les grands types de problèmes en variables continues
- 6 Les grands types d'algorithmes
- 7 Convergence et complexité
- 8 Conclusions et perspectives

Concepts et exemples

Qu'est-ce que l'optimisation mathématique ?

Utiliser les mathématiques pour

effectuer le meilleur choix sous contraintes

- meilleur \Rightarrow critère, **fonction objective** (**maximiser/minimiser**)
- choix \Rightarrow **variables** dont on peut choisir la valeur
- contraintes \Rightarrow **restrictions** sur les valeurs admissibles des variables

La nature optimise





Les humains optimisent (tous les jours)





Un premier aperçu des méthodes et moyens

Les méthodes : une vision montagnarde ...



Les méthodes : le chemin vers le lac



Les moyens

De puissants ordinateurs :



IBM Blue Gene

Une discipline ancrée dans l'histoire


Les pionniers de l'optimisation

“Nous sommes comme des nains juchés sur des épaules de géants, de telle sorte que nous puissions voir plus de choses et de plus éloignées que n'en voyaient ces derniers. Et cela, non point parce que notre vue serait puissante ou notre taille avantageuse, mais parce que nous sommes portés et exhaussés par la haute stature des géants.”

Bernard de Chartres (1130-1160)


Euclide (300 BC)

Al-Khwarizmi (783-850)



Isaac Newton (1642-1727)

Leonhard Euler (1707-1783)




J. de Lagrange (1735-1813)

Friedrich Gauss (1777-1855)




Augustin Cauchy (1789-1857) George Dantzig (1914-2005)




L'optimisation en action

La conception de structures pour l'aéronautique

minimiser le poids du fuselage en maintenant l'intégrité structurale



SAMTECH (2009)




réduction de la masse
en cours d'optimisation

Le design des verres progressifs (1)

Mise au point des lentilles progressives modernes :



varier la puissance optique de la lentille en minimisant l'astigmatisme



Loos, Greiner, Seidel (1997)

Le design des verres progressifs (2)

Ce qu'on peut réaliser :



sans correction
longue distance

courte distance
verres progressifs

Le design des verres progressifs (3)

Ce problème est-il non linéaire (\approx difficile) ?

Si la surface de la lentille est $z = z(x, y)$, la **puissance optique** est

$$p(x, y) = \frac{N^3}{2} \left[\left(1 + \left[\frac{\partial z}{\partial x} \right]^2 \right) \frac{\partial^2 z}{\partial y^2} + \left(1 + \left[\frac{\partial z}{\partial y} \right]^2 \right) \frac{\partial^2 z}{\partial x^2} - 2 \frac{\partial z}{\partial x} \frac{\partial z}{\partial y} \frac{\partial^2 z}{\partial x \partial y} \right]$$

où

$$N = N(x, y) = \frac{1}{\sqrt{1 + \left[\frac{\partial z}{\partial x} \right]^2 + \left[\frac{\partial z}{\partial y} \right]^2}}$$

L'**astigmatisme de la surface** est alors

$$a(x, y) = -2 \sqrt{p(x, y) - N^4 \left(\frac{\partial z}{\partial x} \frac{\partial z}{\partial y} - \left[\frac{\partial^2 z}{\partial x \partial y} \right]^2 \right)}$$

D'un point de vue esthétique . . .

$$p(x, y) = \frac{N^3}{2} \left[\left(1 + \left[\frac{\partial z}{\partial x} \right]^2 \right) \frac{\partial^2 z}{\partial y^2} + \left(1 + \left[\frac{\partial z}{\partial y} \right]^2 \right) \frac{\partial^2 z}{\partial x^2} - 2 \frac{\partial z}{\partial x} \frac{\partial z}{\partial y} \frac{\partial^2 z}{\partial x \partial y} \right]$$

$$N = N(x, y) = \frac{1}{\sqrt{1 + \left[\frac{\partial z}{\partial x} \right]^2 + \left[\frac{\partial z}{\partial y} \right]^2}}$$

$$a(x, y) = -2 \sqrt{p(x, y) - N^4 \left(\frac{\partial z}{\partial x} \frac{\partial z}{\partial y} - \left[\frac{\partial^2 z}{\partial x \partial y} \right]^2 \right)}$$

La stérilisation des aliments pour nourrissons (1)

Un problème très courant dans l'industrie alimentaire :

garder un max de vitamines en éliminant une fraction donnée des bactéries

chauffage des aliments dans des autoclaves à vapeur ou eau chaude



Sachs (2003)

La stérilisation des aliments pour nourissons (2)

Modèle : équations aux dérivées partielles (EDP) couplées
Concentration des micro-organismes et autres nutriments :

$$\frac{\partial C}{\partial t}(x, t) = -K[\theta(x, t)]C(x, t),$$

où $\theta(x, t)$ est la température, et où

$$K[\theta] = K_1 e^{-K_2 \left(\frac{1}{\theta} - \frac{1}{\theta_r} \right)} \quad (\text{équation d'Arrhenius})$$

Evolution de la **température** :


$$\rho c(\theta) \frac{\partial \theta}{\partial t} = \nabla \cdot [k(\theta) \nabla \theta],$$

(avec **conditions limites** adéquates : refroidissant, température initiale, ...)


Une estimation de paramètres en biologie (1)

Un modèle de canal potassique dans une membrane neuronale :

Sansom (2001)



Mais où se trouvent ces neurones ? Dans un homard épineux du Pacifique (*Panulirus interruptus*) ! Simmers, Meyrand and Moulin (1995)



Une estimation de paramètres en biologie (2)

Après collection des **données expérimentales**
(application d'un courant à la cellule) :

estimer les paramètres du modèle pour reproduire les données au mieux

Le modèle (pour les biologistes) :

- Activation : p **portes** indépendantes
- Déactivation : n_h portes avec des **dynamiques** différentes
- BDF à 5-points sur ≈ 50000 pas de temps
- \Rightarrow **très non linéaire** !

L'assimilation de données en météorologie (1)




(Essayer de) prédire. . .

- le temps qu'il fera demain
- la température moyenne de l'océan le mois prochain
- le champ de gravité futur
- les prochains courants dans l'ionosphère
- . . .

L'assimilation de données en météorologie (2)


Données : température, vent, pression, ... partout et à tout moment !



Peut contenir plus de 1.000.000.000 variables !

L'assimilation de données en météorologie (3)


Le principe :



- **Situation** connue il y a 2.5 jours et prévision "de fond"

L'assimilation de données en météorologie (3)

Le principe :




- **Situation** connue il y a 2.5 jours et prévision “de fond”
- **Température** des 2.5 derniers jours

L'assimilation de données en météorologie (3)

Le principe :

Minimiser l'erreur entre modèle et observations passées




- **Situation** connue il y a 2.5 jours et prévision “de fond”
- **Température** des 2.5 derniers jours
- Faire tourner le modèle pour **minimiser** l'écart **|** entre modèle and observations

$$\min_{x_0} \frac{1}{2} \|x_0 - x_b\|_{B^{-1}}^2 + \frac{1}{2} \sum_{i=0}^N \|\mathcal{HM}(t_i, x_0) - b_i\|_{R_i^{-1}}^2.$$

L'assimilation de données en météorologie (3)

Le principe :

Minimiser l'erreur entre modèle et observations passées




- **Situation** connue il y a 2.5 jours et prévision "de fond"
- **Température** des 2.5 derniers jours
- Faire tourner le modèle pour **minimiser** l'écart **I** entre modèle and observations
- **Predire** la temperature pour demain

L'assimilation de données en météorologie (4)

Analyse du contenu de chaleur de l'océan :

CERFACS (2009)




Bien meilleur ajustement !

Une partie de chasse aux astéroïdes

trouver aujourd'hui un astéroïde dont les paramètres orbitaux coïncident le mieux avec des observations vieilles de 50 ans



Milani, Sansaturio et al. (2005)



Le débruitage d'images (1)

Considérons une **image** aléatoirement **bruitée** (noirceur des pixels incorrecte) proportionnellement à la magnitude du signal.

Comment retrouver les valeurs (noirceurs) originales ?

utiliser les valeurs des pixels le plus possible
en minimisant les transitions brutales (gradients)

Ceci donne le problème d'optimisation

$$\min_u \sum_{ij \in \Omega} (u_{ij} - z_{ij} \log(u_{ij})) + \alpha \int_{\Omega} \|\nabla u\|$$


où

$$z_{ij} = u_{ij} + n f(u_{ij})$$

et n est un bruit Gaussien.


Le débruitage d'images (2)

Quelques résultats **spectaculaires** : une image 512×512 avec **95%** de bruit



Le débruitage d'images (2)

Quelques résultats **spectaculaires** : une image 512×512 avec **95%** de bruit



Chan and Chen (2007)

La reconstruction d'objets cachés

- un objet \mathcal{O} **caché** dans un milieu opaque (sol, eau, corps, ...)
- on **illumine** cet objet par une onde (électromagnétique) plane dans "toutes" les directions

$$u^{inc}(x, d) = e^{ik\langle x, d \rangle} \quad d \in \mathcal{S}$$

- on mesure les **ondes réfléchies** $u^s(x, d)$ par l'objet dans "toutes" les directions

$$\Delta u^s + k^2 u^s = 0 \quad (\text{en dehors de } \mathcal{O})$$





avec

$$u = u^{inc} + u^s, \quad u = 0 \text{ sur } \partial\mathcal{O} \quad \text{et} \quad \lim_{r \rightarrow \infty} \frac{\partial u^s}{\partial r} = iku^s.$$

Optimiser la forme de l'objet \mathcal{O} à partir des mesures $u^s(x, d)$

Illustration : la reconstruction d'un avion

L'original et les reconstructions ($N = 1002$, $p = 5, 20, 50$)



Optimisation, transports et mobilité

Le contexte

Analyse de la mobilité quotidienne en Belgique

Modélisation des déplacements



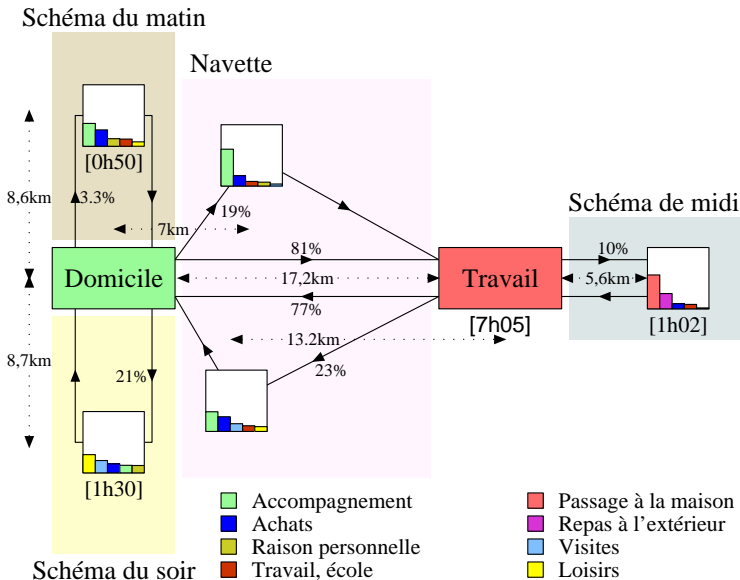
Modélisation des activités



Modélisation des individus (ou ménages)



La mobilité quotidienne : un système complexe



Comprendre les stratégies de choix en société

Contexte : simulation des choix individuels en **Mobilité**
(mode, trajet, heure de départ, ...)

Théorie de l'utilité aléatoire

Un individu i assigne à l'alternative j l'“utilité”

$$U_{ij} = [\text{paramètres} \times \text{facteurs explicatifs}] + [\text{erreur aléatoire}]$$

Illustration :

$$U_{bus} = \text{distance} - 1.2 \times \text{prix du billet} - 2.1 \times \text{retard par rap. au trajet en voiture} + \epsilon$$

Les modèles de choix discrets (1)

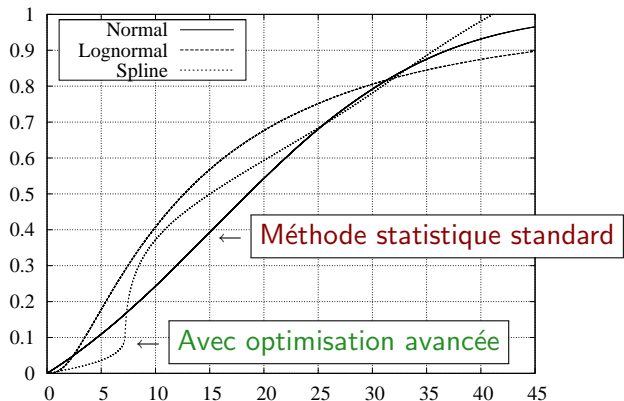
Probabilité qu'un individu i choisisse l'alternative j plutôt que l'alternative k donnée par

$$\text{prob}(U_{ij} \geq U_{ik} \text{ pour tout } k)$$

Données : enquêtes de mobilité ([MOBEL](#), [BELDAM](#), etc.)

trouver les paramètres de l'utilité qui *maximisent* la vraisemblance des comportements observés

Les modèles de choix discrets (2)



Estimation de la **valeur du temps perdu** dans les embouteillages (avec et sans optimisation avancée)

Modéliser les individus ?

Une difficulté majeure

- Données individuelles (souvent) **indisponibles/incohérentes**. . .
(coût, vie privée, sources variables)

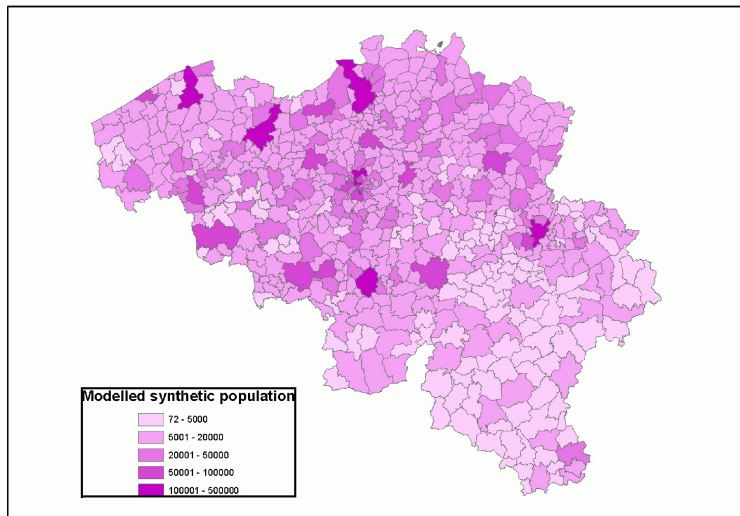
Construire une population synthétique

Méthode

- **maximiser** la vraisemblance des descriptions des individus/ménages
- en préservant les **statistiques connues** sur la population réelle


Une population synthétique pour la Belgique

Et l'on obtient $\approx 10.600.000$ individus dans 4.400.000 ménages




Une population synthétique pour la Belgique

D'où l'on peut déduire (en utilisant d'autres techniques d'optimisation)



Et en finance...

- 1 gestion du risque
- 2 analyse de portefeuilles
- 3 marchés des changes




Distribution des investissements de la BoJ 1991-2004

- 4 ...



Les grands types de problèmes en variables continues


Les problèmes sans contrainte



Les variables peuvent prendre n'importe quelle valeur

$$\min_{x,y} f(x, y)$$


Les problèmes avec contraintes de bornes (1)



Les variables doivent rester dans certains intervalles

$$\min_{x,y} f(x, y) \quad \text{avec} \quad 0 \leq x \leq 2 \quad \text{et} \quad 0 \leq y \leq 2$$


Les problèmes avec contraintes de bornes (2)



Les variables doivent rester dans certains intervalles

$$\min_{x,y} f(x,y) \quad \text{avec} \quad 0 \leq x \leq 2 \quad \text{et} \quad -2 \leq y \leq 2$$


Les problèmes avec contrainte(s) d'égalité (1)



Les solutions doivent satisfaire certaine(s) égalité(s)

$$\min_{x,y} f(x, y) \quad \text{avec} \quad y = \frac{1}{2}x \quad (\text{linéaire})$$


Les problèmes avec contrainte(s) d'égalité (2)



Les solutions doivent satisfaire certaine(s) égalité(s)

$$\min_{x,y} f(x, y) \quad \text{avec} \quad y = \sin x \quad (\text{non linéaire})$$


Les problèmes avec contraintes de bornes et d'égalité



Une combinaison des deux types précédents ...

$$\min_{x,y} f(x, y) \quad \text{avec} \quad 0 \leq x \leq 2, -2 \leq y \leq 2 \quad \text{et} \quad y = \sin x$$


Les problèmes avec contrainte(s) d'inégalité générales



Les solutions doivent appartenir à un ensemble ...

$$\min_{x,y} f(x, y) \quad \text{avec} \quad \left(x - \frac{1}{2}\right)^2 + (y - 1)^2 \leq 1.19$$


Le problème avec contraintes mixtes




Ou bien tous ces types de contraintes ensemble ...

$$\min_{x,y} f(x, y) \quad \text{avec} \quad 0 \leq x \leq 2, -2 \leq y \leq 2, y = \sin x, (x - \frac{1}{2})^2 + (y - 1)^2 \leq 1.19$$


Qu'est-ce qu'une solution ? (simple)




Qu'est-ce qu'une solution ? (simple)



Qu'est-ce qu'une solution ? (moins simple)



Qu'est-ce qu'une solution ? (moins simple)



Une condition nécessaire (sans contrainte)

Dans tous les cas


A une solution sans contrainte, la courbe (surface) de la fonction objective est plate

$$\nabla_x f(x_*) = 0$$

Le **gradient** $\nabla_x f(x) = g(x)$ indique la direction de **la plus grande pente** de la surface $f(x)$ en x .



Plus compliqué s'il y a des contraintes . . .

Une autre distinction fondamentale : la convexité





$$\forall x, y \forall t \in [0, 1], \quad f(tx + (1-t)y) \leq tf(x) + (1-t)f(y)$$

Convexe et non convexe



convexe



non convexe

Impact de la convexité

Si le problème est convexe, toute solution locale est globale

Si le problème est strictement convexe,
toute solution finie est unique

⇒ Les problèmes convexes sont **beaucoup** plus simples
(hélas, le monde n'est pas convexe...)

Quelques autres distinctions . . .

la *taille* (dimension)

- le nombre de variables : de 1 à . . . plusieurs millions !
- le nombre de contraintes : de 0 à . . . plusieurs millions !

le degré de *nonlinéarité*

- fonction objective, contraintes

les *coûts d'évaluation*

- fonction objective, contraintes
- connues sous *forme analytique* ou non ?
- de “bon marché” à “tout-à-fait impossible”

la *structure*

- creux, partiellement séparable

$$\min_{x,y,z} f_1(x,y) + f_2(y,z) \text{ plus facile que } \min_{x,y,z} f(x,y,z)!$$

Les grands types d'algorithmes

Comment calculer une solution (approximative) ?

Méthode de calcul = algorithme

De quoi dépend le **design d'un algorithme** ?

- le type de problème (contraintes ?)
- le type d'**information disponible** sur le problème
- un choix de **modélisation**
- des **choix méthodologiques**


Un exemple

Un case très simple :


- pas de contraintes
- seulement les valeurs de la fonction objective sont disponibles




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock




La méthode du compas sur la fonction "banane" de Rosenbrock



La méthode du compas sur la fonction "banane" de Rosenbrock



La méthode du compas sur la fonction "banane" de Rosenbrock






Les ingrédients d'une amélioration

Malheureusement ... **très lent** !

⇒ utiliser plus d'information (que simplement la **valeur** de f)

la **pente** locale → le gradient (dérivées premières)



la **courbure** locale → le Hessien (dérivées secondes)



Comment construire des modèles locaux ?

La fonction objective f est compliquée dans le voisinage de x
⇒ construire un **modèle local**.

Revenons à notre exemple favori :





Assez facile : un modèle linéaire

Une interprétation simple :

la **pente reste constante** et il n'y a pas d'autre effet

$$\ell(u, v) = f(x, y) + g_1(x, y)(u - x) + g_2(x, y)(v - y)$$





Un peu plus complexe : un modèle quadratique

Plus précis : la **pente et la courbure restent constante** et il n'y a pas d'autre effet

$$q(u, v) = f(x, y) + g_1(x, y)(u - x) + g_2(x, y)(v - y)$$



$$+ \frac{1}{2}H_{11}(x, y)(u - x)^2 + H_{12}(x, y)(u - x)(v - y) + \frac{1}{2}H_{22}(x, y)(v - y)^2$$



Sophistiqué : un modèle cubique

On ajoute au modèle quadratique une pénalisation de la distance à (x, y)





$$c(u, v) = q(u, v) + \frac{\sigma}{3} [(u - x)^2 + (v - y)^2]^{3/2}$$



Avec le modèle linéaire : la méthode de Cauchy

Minimise la fonction objective f le long de la direction de la **plus grande pente**





recherche linéaire



Avec le modèle quadratique : la méthode de Newton (1)



Minimise la fonction objective f le long de la direction du **minimum du modèle**

recherche linéaire



Avec le modèle quadratique : la méthode de Newton (2)

Minimise la fonction objective f le long de la direction du ???





La méthode de Newton n'est pas toujours bien définie !



⇒ on ne peut pas faire confiance au modèle trop loin...

Avec le modèle quadratique : la méthode des régions de confiance



Idée : déterminer une adaptivement région (sphérique)
dans laquelle on peut faire confiance au modèle





Les itérations de la méthode de région de confiance





Les itérations de la méthode de région de confiance





Les itérations de la méthode de région de confiance





Les itérations de la méthode de région de confiance





Les itérations de la méthode de région de confiance



Les itérations de la méthode de région de confiance




Les itérations de la méthode de région de confiance




En résumé

Les itérations :





En partant d'ailleurs :



Avec le modèle cubique : la méthode ARC

Même idée, en utilisant le modèle cubique pour ne pas aller trop loin

Pour un pas :




Ajuster le terme cubique plutôt que le rayon de la région

Problèmes avec contraintes : la méthode des pénalités

Idée : pénaliser la violation des contraintes $e(x) = 0$


$$\min_x f(x) + \rho e(x)^2 \quad \rho = 0$$



Problèmes avec contraintes : la méthode des pénalités

Idée : pénaliser la violation des contraintes $e(x) = 0$


$$\min_x f(x) + \rho e(x)^2 \quad \rho = 10$$



Problèmes avec contraintes : la méthode des pénalités

Idée : pénaliser la violation des contraintes $e(x) = 0$


$$\min_x f(x) + \rho e(x)^2 \quad \rho = 100$$



Problèmes avec contraintes : la méthode des pénalités

Idée : pénaliser la violation des contraintes $e(x) = 0$


$$\min_x f(x) + \rho e(x)^2 \quad \rho = 1000$$



Problèmes avec contraintes : la méthode des pénalités

Idée : pénaliser la violation des contraintes $e(x) = 0$


$$\min_x f(x) + \rho e(x)^2 \quad \rho = 5000$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu \text{ inactif}$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 10$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 10$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 5$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 1$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 0.1$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$


$$\min_x f(x) - \mu \log x \quad \mu = 0.001$$



Problèmes avec contraintes d'inégalité : la méthode des points intérieurs

Idée : ériger une barrière le long des contraintes $i(x) \geq 0$

$$\min_x f(x) - \mu \log x \quad \mu = 0.00001$$



Et puis bien sûr ...

... cela peut se compliquer : on mélange les types de contraintes

⇒ un vrai zoo de méthodes :

- méthodes du lagrangien augmenté
- méthodes d'optimisation quadratique séquentielle
- méthodes des filtres
- méthode de l'entonnoir
- ...

Une autre piste : abandonner la monotonicité, etc., etc.

Convergence et complexité

Comment appliquer d'un algorithme ?

Appliquer un algorithme, c'est (en principe) :

- 1 choisir un point de départ
- 2 le laisser calculer jusqu'à ce qu'une solution satisfaisante soit trouvée

⇒ qu'est-ce qu'une solution satisfaisante ???

Choisir un critère d'optimalité approximative

$\|g(x)\| = 0$ devient $\|g(x)\| \leq \epsilon$ (sans contrainte)

Note : ϵ est un nombre positif proche de zéro.

Qu'attendre d'un algorithme ?

Les questions qui se posent alors :

convergence :

l'algorithme va-t-il s'arrêter pour
n'importe quel choix de $\epsilon \in (0, 1)$?

vitesse de convergence :

une fois "proche" la solution,
l'algorithme accélère-t-il ?

complexité :

si $\epsilon \in (0, 1)$ est choisi, combien
d'évaluations de $f(x)$ l'algorithme va-t-il
demander dans le pire des cas ?

Dans le cas sans contrainte

méthode	convergence	vitesse	complexité (évaluations de f)
Cauchy	tout juste	très lent	$O(1/\epsilon^2)$
Newton	oui (presque)	oui	$O(1/\epsilon^2)$
R. de confiance	oui	oui	$O(1/\epsilon^2)$
ARC	oui	oui	$O(1/\epsilon^{3/2})$

ϵ	0.1	0.01	0.001	0.0001
$1/\epsilon^2$	100	10000	1000000	100000000
$1/\epsilon^{3/2}$	32	1000	32622	1000000

Les surprises

Quelques résultats surprenants pour l'optimisation sans contrainte :

On peut donner une borne supérieure pour la complexité !

La méthode de Newton est aussi lente, dans le pire des cas, que la (très lente) méthode de Cauchy dans le pire des cas !

La méthode ARC est la plus rapide possible (optimale) !

Encore plus surprenant !

Pour l'optimisation avec contraintes :

La complexité est, pour chaque “classe de méthodes”, la même qu'il y ait des contraintes ou non !

La complexité ne dépend pas du type et du nombre de contrainte(s) !

Note : ces résultats sont *très* récents.

Conclusions et perspectives

Quelques conclusions

Le langage mathématique est extraordinairement *souple, adapté, élégant et efficace*.

Les mathématiques appliquées sont un domaine en plein développement.

L'optimisation est en expansion encore plus rapide.

Il reste *énormément* à comprendre et découvrir !

Merci de votre patiente attention.

(Merci aussi à N. Gould, A. Conn, C. Cartis, S. Gratton, A. Sartenaer, D. Orban, ...)