

Optimisation

Nicolas Pécheux
`nicolas.pecheux@limsi.fr`


Université Paris Sud — LIMSI

27 mars 2013

Première partie I

Qu'est ce que l'optimisation ?

Introduction



| N | Coût de possession | Coût de possession | Coût de stockage |
|----|--------------------|--------------------|------------------|
| 1 | 28 € | 600.00 € | 628 € |
| 2 | 56 € | 300.00 € | 356 € |
| 3 | 84 € | 200.00 € | 284 € |
| 4 | 112 € | 150.00 € | 262 € |
| 5 | 140 € | 120.00 € | 260 € |
| 6 | 168 € | 100.00 € | 268 € |
| 7 | 196 € | 85.71 € | 282 € |
| 8 | 224 € | 75.00 € | 299 € |
| 9 | 252 € | 66.67 € | 319 € |
| 10 | 280 € | 60.00 € | 340 € |
| 11 | 308 € | 54.55 € | 363 € |
| 12 | 336 € | 50.00 € | 386 € |

- But : minimiser une fonction (sous contraintes)

$$\begin{aligned} & \underset{x}{\text{minimiser}} && f_0(x) \\ & \text{s.c.} && x \in \mathcal{C} \end{aligned}$$

- Exemples ?

Exemple d'applications

Économie

- ▶ Minimiser le risque d'un placement financier
- ▶ Maximiser le profil...



Ingénierie

- ▶ Minimiser la taille de circuits électroniques
- ▶ Minimiser la quantité de réactifs d'une équation chimique


Apprentissage

- ▶ Minimiser le nombre d'erreur d'une méthode

Et (presque) tout le reste !

Deuxième partie II

Formalisation



But minimiser $f_0(x)$
s.c. $x \in C$

- ▶ f_0 fonction de coût (ou de perte)
 - ▶ C est l'ensemble des contraintes
-
- ▶ **Solution optimale** : x^* a la plus petit valeur de f_0 parmi les points qui satisfont les contraintes

rem : $\Leftrightarrow \max_x -f_0(x)$

Combinatoire vs numérique


Optimisation combinatoire

- ▶ $x \in \mathcal{S}$ discret (e.g. \mathbb{N})


Exemples :

- ▶ Plus court chemin dans un graph
- ▶ K -moyennes !

Souvent très compliqué (NP-dur)



Numérique (mathématique)



- ▶ $x \in \mathbb{R}^n$

minimiser $f_0(x)$
 x

s.c. $f_i(x) \leq 0, \quad i = 1, \dots, m$

$h_j(x) = 0, \quad j = 1, \dots, p$

Linéaire vs non linéaire

Programmation linéaire

$$\begin{aligned} & \underset{x}{\text{minimiser}} && c^T x \\ & \text{s.c.} && a_i^T x \leq b_i, \quad i = 1, \dots, m \\ & && c_j^T x = d_j, \quad j = 1, \dots, p \end{aligned}$$

- ▶ Pas de solution analytique
 - ▶ Mais méthodes efficaces pour la résolution
 - ▶ Faciles à reconnaître
- ⇒ Technologie (sauf si n est très grand)

Linéaire vs non linéaire

Non-linéaire

- ▶ Très difficile à résoudre
- ▶ En général besoin de compromis (approximation ou très longue attente)

Sauf...



Convexe vs non convexe

In fact the great watershed in optimization isn't between linearity and nonlinearity, ut convexity and nonconvexity.

[Rockafellar 93]


Optimisation convexe

$$\begin{aligned} & \underset{x}{\text{minimiser}} && f_0(x) \\ & \text{s.c.} && f_i(x) \leq 0, \quad i = 1, \dots, m \\ & && c_j^T x = d_j, \quad j = 1, \dots, p \end{aligned}$$

avec f_i convexes, $i = 0, \dots, m$
(et donc C convexe)

- ▶ Rappel : $f : \mathbb{R}^n \rightarrow \mathbb{R}$ est convexe ssi $\forall x, y \in \mathbb{R}^n, \alpha, \beta \in \mathbb{R}^+, \alpha + \beta = 1$

$$f(\alpha x + \beta y) \leq \alpha f(x) + \beta f(y)$$



Convexe vs non convexe


Problèmes convexes

- ▶ Sorte de généralisation de la linéarité
- ▶ Pas de solution analytique
- ▶ Mais méthodes efficaces pour la résolution
- ▶ De très nombreux problèmes peuvent s'y ramener
- ▶ Presque une technologie



Propriétés

- ▶ minimum local = minimum global
- ▶ la “courbe” est au dessus de ses “tangentes”
- ▶ stricte convexité → encore meilleures propriétés




Mais...

- ▶ Difficiles à reconnaître
- ▶ Techniques pour mettre un problème sous forme convexe

Convexe vs non convexe

Problèmes non convexes




- ▶ Minimums locaux, point selles, plateaux, ravins, etc.
- ▶ Bons et mauvais minimums locaux
- ▶ Résultats dépendent de détails subtils

- ▶ Compromis : approximation/temps de calcul
- ▶ Optimisation convexe peut jouer un rôle : initialisation, approximation, bornes, sous-problèmes convexes

Exemples

- ▶ Apprentissage non supervisées (e.g. K-moyennes !)
- ▶ Réseaux de neurones

Différentiable vs non différentiable



- ▶ Sans régularité, pas d'information locale
- ▶ Les dérivées successives peuvent ne pas exister
- ▶ Les dérivées successives peuvent être trop longues à calculer

Condition d'Euler

Si f_0 est C_1 , alors $\nabla f_0(x^*) = 0$

Si f_0 est convexe, alors $\nabla f_0(x) = 0 \Rightarrow x = x^*$

Rappel : gradient et hessienne

Idée principale : approximation locale d'une fonction (lisse)

1^{er} ordre : par une fonction linéaire (gradient)

$$f(x+h) \approx f(x) + \nabla f(x)^T h \quad \text{où } \nabla f(x) = \left(\frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_n} \right)$$

$f(x+h) \geq f(x) + \nabla f(x)^T h$ dans le cas convexe


2^e ordre : par une fonction quadratique (hessienne)

$$f(x+h) \approx f(x) + \nabla f(x)^T h + \frac{1}{2} h^T \nabla^2 f(x) h \quad \text{où } \nabla^2 f(x)_{ij} = \frac{\partial^2 f(x)}{\partial x_i \partial x_j}$$

Avec contraintes vs sans contraintes

Avec contraintes

- ▶ On n'a plus nécessairement $\nabla f_0(x^*) = 0$
- ▶ Méthodes de résolutions assez différentes
- ▶ Utilisent souvent sous-problème sans contraintes



- ▶ Mots clef : théorie lagrangienne, conditions KKT, méthode des points intérieurs, projection
- ▶ Pas aujourd'hui

Troisième partie III

Méthodes

Méthodes de descentes - intuition

Comment atteindre le minimum ? Comment le reconnaître ?

→ Fonction convexes : ouf !

Attention :

On ne “voit” pas la surface ! On ne dispose que d’information locale. Comment faire ?



Méthodes de descentes

Idée

Partir de quelque part, choisir une direction de descente Δx et l'emprunter (un peu). Puis recommencer !



Require : a starting point $x \in \text{dom } f$

1 : **repeat**

2 : Determine a descent direction Δx

3 : *Line search*. Choose a step size $t > 0$


4 : *Update*. $x := x + t\Delta x$

5 : **until** stopping criterion is satisfied.

→ méthodes itératives

Descente par coordonnées

On choisit successivement comme directions les vecteurs de la base (i.e. coordonnée par coordonnée)



- ▶ Tendance au zig-zag
- ▶ Pas besoin de calculer le gradient
- ▶ On peut choisir les coordonnées avec de l'aléa
- ▶ On peut grouper certaines coordonnées
- ▶ On peut changer de base avant (e.g. ACP)


Exemple ?

Rappel : K-moyennes

But : minimiser la qualité d'un partitionnement


$$\mathcal{E}(\mu, z) = \sum_{i=1}^n \sum_{k=1}^K z_i^k \|x_i - \mu_k\|^2$$

- ▶ μ_k est la moyenne du cluster k
- ▶ $z_i^k = 1$ si x_i est dans le cluster k et 0 sinon
- ▶ Exercice : montrer en quoi c'est une descente de gradient par coordonnées
- ▶ Question : est-ce que c'est *vraiment* une descente de gradient ?



Descente de gradient




Idée naturelle : choisir la direction de plus forte pente



- ▶ Celle-ci est donné par $\delta x = -\nabla f(x)$
- ▶ On peut prendre comme critère d'arrêt $\|\nabla f(x)\|_2 \leq \epsilon$

Choix du pas

- ▶ Compromis : petits pas (approximation valable localement) mais alors on avance tout doucement
- ▶ Remarque : Δx n'est pas forcément normalisé (e.g. gradient)




- ▶ Gradient à pas constant
- ▶ Gradient à pas optimal
- ▶ De toutes façon, c'est juste *un* pas, pourquoi s'embêter ?
⇒ prendre pas approché (*line search*)
- ▶ De très nombreuses méthodes : *Backtracking*, méthode de Brent, méthode de Wolfe

Analyse


- ▶ Les méthode de gradient convergent “lentement” → zig-zag
- ▶ Vitesse dépend beaucoup de l’anisotropie des courbes de niveau

$$\mathbf{cond}(C) = \frac{L_{max}^2}{L_{min}^2} = \frac{\lambda_{min}}{\lambda_{max}}$$







- ▶ Résultat de convergence (gradient à pas variable) si $\eta \leq 1m/M$
- ▶ C.f. TP

Solution : changer la géométrie ?




- ▶ i.e. faire un changement de base (matrices de passage)

Mais quelle géométrie prendre ?




La “meilleure” géométrie est donnée par la hessienne



- ▶ Correspond au changement de coordonnées $u' = P^{1/2}u$ où $P = \nabla^2 f(x)$
- ▶ On retrouve l'idée d'approximation au deuxième ordre
- ▶ C'est...

La “meilleure” géométrie est donnée par la hessienne



- ▶ Correspond au changement de coordonnées $u' = P^{1/2}u$ où $P = \nabla^2 f(x)$
- ▶ On retrouve l'idée d'approximation au deuxième ordre
- ▶ C'est la méthode de Newton

La méthode de Newton

$$\Delta x_{newton} = -\nabla^2 f(x)^{-1} \nabla f(x)$$


Exercice :

- ▶ $x + \Delta x_{newton}$ minimise l'approximation au second ordre :

$$\hat{f}(x+h) = f(x) + \nabla f(x)^T h + \frac{1}{2} h^T \nabla^2 f(x) h$$

- ▶ $x + \Delta x_{newton}$ est solution de l'équation d'Euler linéarisée :

$$\hat{f}(x+h) = 0$$



La méthode de Newton



- ▶ Convergence très rapide (quelques itérations)
- ▶ Exacte pour une fonction quadratique
- ▶ Très bonne propriétés si $\nabla^2 f$ est strictement convexe

Mais...

- ▶ Problèmes si $\nabla^2 f$ n'est pas inversible !
- ▶ Calculer $\nabla^2 f$ est très cher (souvent impossible)

Méthodes quasi-Newton

- ▶ Évitent les inconvénients de la méthode de Newton
- ▶ Mais au final se comportent à peu près de la même manière



- ▶ Méthode du gradient conjugué

Quatrième partie IV

Optimisation et apprentissage

Rappel - Fonction de perte

Données : $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{1 \leq i \leq n}$

Fonction de perte :

$$L(\mathbf{x}, y; \mathbf{w}) = \ell(h_{\mathbf{w}}(\mathbf{x}_i), y_i)$$

où

- ▶ $h_{\mathbf{w}}$ est un classifieurs paramétré par \mathbf{w}
- ▶ $\ell(y_{pred}, y_{vrai})$ le coût associé à la prédiction de y_{pred} sachant que la bonne étiquette est y_{vrai}

Risque régularisé :

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}_i, y_i; \mathbf{w}) + \frac{\lambda}{2} \|\mathbf{w}\|_2^2$$

- ▶ λ est le coefficient de régularization

Rappel - Régression linéaire

- ▶ $\ell(y_{pred}, y_{vrai}) = (y_{pred} - y_{vrai})^2$

$$f(\mathbf{w}) = ??$$

Rappel - Régression linéaire

► $\ell(y_{pred}, y_{vrai}) = (y_{pred} - y_{vrai})^2$

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n (\mathbf{w}^T \mathbf{x}_i - y_i)^2 = \|X\mathbf{w} - Y\|_2^2$$

Rappel - Régression linéaire

- ▶ $\ell(y_{pred}, y_{vrai}) = (y_{pred} - y_{vrai})^2$


$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n (\mathbf{w}^T \mathbf{x}_i - y_i)^2 = \|\mathbf{X}\mathbf{w} - \mathbf{Y}\|_2^2$$

- ▶ La solution est $\mathbf{w}^* = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$
- ▶ Solution analytique (très rare !)
- ▶ Pas besoin des algorithmes précédents
- ▶ Souvent une sous-routine de nombreuses méthodes
- ▶ C'est en gros une technologie

Classification binaire

► $\ell(y_{pred}, y_{vrai}) = \delta_{\{y_{pred} - y_{vrai}\}}$

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n \delta_{\{\text{sgn}(\mathbf{w}^T \mathbf{x}_i) = y_i\}} = \frac{1}{n} \sum_{i=1}^n \delta_{\{\text{sgn}(y_i \mathbf{w}^T \mathbf{x}_i) < 0\}}$$




► Problème ?

Classification binaire


► $\ell(y_{pred}, y_{vrai}) = \delta_{\{y_{pred} - y_{vrai}\}}$

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n \delta_{\{\text{sgn}(\mathbf{w}^T \mathbf{x}_i) = y_i\}} = \frac{1}{n} \sum_{i=1}^n \delta_{\{\text{sgn}(y_i \mathbf{w}^T \mathbf{x}_i) < 0\}}$$



- Problème ?
- f n'est pas convexe !
- Très difficile à minimiser


En 3D



Convexification du risque

- ▶ Comment faire quand un problème n'est pas convexe ?
- ▶ L'approcher par un problème convexe !
- ▶ Ici par une borne supérieure


Exemple :



Vous avez reconnu ?

Rappel : SVM

!2*




Rappel : SVM

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n \phi(y_i \mathbf{w}^T \mathbf{x}_i) + \frac{\lambda}{2} \|\mathbf{w}\|_2^2$$

où $\phi(u) = \max(1 - u, 0)$

- ▶ Exercice : retrouver cette formulation à partir du cours précédent



- ▶ On peut montrer que l'on “approche bien” le problème

Cinquième partie V

Large échelle ?

Rappel : optimisation et apprentissage

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}_i, y_i; \mathbf{w}) + \frac{\lambda}{2} \|\mathbf{w}\|_2^2$$

- ▶ Problème : n peut être très grand
- ▶ E.g. quelques milliards
- ▶ E.g. quelques milliers par secondes



- ▶ Les exemples sont très redondants (sinon rien à apprendre)
- ▶ Doubler le nombre d'exemple apporte un peu d'information
- ▶ À quoi ça sert au tout début de la descente ?

Descente de gradient : classique ou stochastique ?

$$f(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n L(\mathbf{x}_i, y_i; \mathbf{w}) + \frac{\lambda}{2} \|\mathbf{w}\|_2^2$$

Descente de gradient classique

Itérer : $\mathbf{w} := \mathbf{w} - \eta \left(\frac{1}{n} \sum_{i=1}^n \nabla L(\mathbf{x}_i, y_i; \mathbf{w}) + \lambda \mathbf{w} \right)$

- ▶ Tout les exemples sont nécessaires pour chaque itération (le vrai gradient)


Descente de gradient classique

Itérer :

1. Choisir au hasart (\mathbf{x}_i, y_i)
 2. $\mathbf{w} := \mathbf{w} - \eta (\nabla L(\mathbf{x}_i, y_i; \mathbf{w}) + \lambda \mathbf{w})$
- ▶ Une itération = un exemple

Descente de gradient stochastique

- ▶ À chaque descente le gradient n'est pas bon (très mal estimé)
- ▶ Mais il l'est en moyenne



En pratique

En pratique :

- ▶ On fait décroître η à chaque itération
- ▶ Beaucoup plus rapide (e.g. 1.4s vs. 6h)
- ▶ \approx Indépendant du nombre d'exemples

Rappel : le perceptron !

Exercice : montrer que l'algorithme du perceptron vu en cours est une descente de gradient stochastique. Quelle est la fonction de perte ?

Sixième partie VI

À vous...

Un problème quadratique I

$$f(x) = \frac{1}{2}(x_1^2 + \gamma x_2^2) \quad (\gamma > 0)$$

On prendra $x^{(0)} = (\gamma, 1)$ et $\gamma \in [10^{-3}, 1, 10]$

1. La fonction f est-elle convexe (strictement ?), différentiable ? Quel est son gradient, sa matrice hessienne ? En quel(s) point(s) est elle minimisée ? L'équation d'Euler est-elle vérifiée ?
2. En utilisant `mpl_toolkits.mplot3d.Axes3D`, visualisez cette fonction en 3D. Tracez ses courbes de niveaux à l'aide de `matplotlib.pyplot.contour`

Un problème quadratique II

3. Implémentez la méthode de descente par coordonnées. Pour quel(s) pas a-t-on convergence ? Dessinez les itérations successives sur le graphe des lignes de niveaux. Visualisez l'erreur en fonction du nombre d'itérations. Quelle est l'influence de γ ?
4. De même avec la méthode de gradient à pas constant.
5. De même avec la méthode de descente à pas optimal. Pour ce dernier, exprimer également analytiquement $x^{(k)}$ en fonction de k et de γ . Conclusion ?
6. Que donne la méthode de Newton ici ?