

Restauration d'image : approches convexes

— Pénalisations et contraintes —

Jean-François Giovannelli
Giova@IMS-Bordeaux.fr

Groupe Signal – Image
Laboratoire de l'Intégration du Matériau au Système
Université de Bordeaux – CNRS

- Déconvolution
 - Motivation par l'exemple
 - Caractère mal-posé, information manquante, régularisation

- Trois types d'inversion régularisée
 - Solution linéaire et pénalisation quadratique
 - Algorithme de gradient
 - Pénalisation non-quadratique et préservation des contours
 - Approche semi-quadratique
 - Prise en compte de contraintes : positivité
 - Lagrangien augmenté et ADMM

Interferometer : principles of measurements


Physical principle [Thompson, Moran, Swenson, 2001]

- Antenna array \rightsquigarrow large aperture
- Frequency band, e.g., 164 MHz
- Couple of antennas interference \rightsquigarrow one measure in the Fourier plan

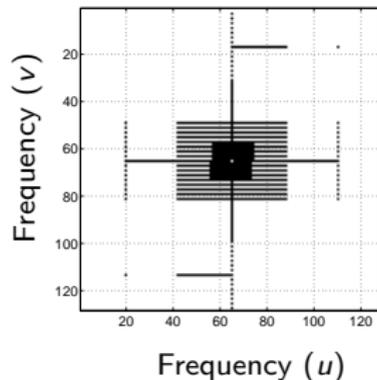
Picture site (NRH)



Antenna positions




Fourier plane




- Connaissance du Soleil, activité magnétique, taches et éruptions
- Prévision des intempéries et de leur impact,...

Interferometer : True map – Dirty beam – Dirty map


True map ES




True map PS




Dirty beam




Dirty map ES



Dirty map PS



Dirty map PS + ES




Principe physique [Alaux 92]


- Champ magnétique intense $\mathbf{B} \rightsquigarrow$ précession des spins, $f \propto \|\mathbf{B}\|$
- Gradient $\mathbf{B} = \mathbf{B}_0 + B(x) \rightsquigarrow$ codage de espace - fréquence
- Densité de proton \rightsquigarrow amplitude de signal



Fantôme GE



Couverture fréquentielle




Autres schémas acquisition

- Imagerie médicale, morphologique et fonctionnelle, neurologie,...
- IRM rapide, applications cardiovasculaires, imagerie de flux,...


Fantôme (vrai)



Réponse instrument





Reconstruction naïve



Tomographie à rayons X (scanner)

Principe physique


- Absorption de rayons X \rightsquigarrow radiographie
- Rotation autour de l'objet \rightsquigarrow série de radiographie (sinogramme)
- Transformée de Radon



- Analyse de matériau, sécurité aéroportuaire, . . .
- Imagerie médicale : diagnostic, suivi thérapeutique

Principe physique

- Interaction : onde ultrasonore \leftrightarrow milieu d'intérêt
- Impédance acoustique : inhomogénéité, changement de milieu





- Contrôle non-destructif, e.g., fissures (nucléaire, aéronautique, ...)
- Caractérisation des tissus, imagerie médicale, ...

Sismique réflexion

Principe physique

- Interaction : onde mécanique \leftrightarrow milieu d'intérêt
- Impédance acoustique : inhomogénéité, changement de milieu



- Prospection minière et pétrolière
- Connaissance des sols et des phénomènes géologiques

Principe physique


- Optique de base (géométrique et physique) \rightsquigarrow tache image
 - Capteur CCD ou bolomètres \rightsquigarrow réponse spatiale et temporelle
-
- Astronomie, surveillance (lieux publics, circulation, sauvetage, . . .)
 - Satellitaire : astronomie, télédétection, surveillance, environnement
 - Vision nocturne, fumées, nuages, conditions météo dégradées

Principe physique

- Série temporelle d'images \rightsquigarrow image sur-résolue
 - Mouvement sub-pixellique \sim sur-échantillonnage
-
- Les mêmes... à résolution augmentée

Inversion : question standard

$$y = \mathcal{H}(x) + \varepsilon = \mathbf{H}x + \varepsilon = \mathbf{h} \star x + \varepsilon$$




$$\hat{x} = \hat{\mathcal{X}}(y)$$

Restauration, déconvolution-débruitage

- Problématique : problèmes inverses mal-posés, *déficit en information*
- Méthodologie : régularisation, *compensation en information*
 - Spécificité des méthodes de reconstruction / restauration, d'inversion
 - Compromis et paramètres de réglage
- Résultats de qualité limitée

Inversion : questions plus avancées

$$y = \mathcal{H}(x) + \varepsilon = \mathbf{H}x + \varepsilon = \mathbf{h} \star x + \varepsilon$$



$$\hat{x} = \hat{\mathcal{X}}(y)$$

$$\left[\hat{x}, \hat{\gamma}, \hat{\theta}, \hat{\ell} \right] = \hat{\mathcal{X}}(y)$$

Sur-problèmes d'estimation

- Hyperparamètres, paramètres de réglage : *non-supervisé*
- Paramètres instruments (resp. réponse) : *myope* (resp. *aveugle*)
- Variables cachées : contours, régions, points singuliers, ... : *augmenté*
- Modèles (bruit, objet, instrument, ...) : *sélection de modèle*

Problèmes inverses

- Modèle instrument, modèle direct
- Inclut de la physique
 - du phénomène en jeu
 - de l'instrument, de l'acquisition
- Inverser
 - défaire les dégradations, dépasser la résolution naturelle
 - remonter des conséquences vers les causes
 - restituer / reconstruire / restaurer l'entrée
- Caractère mal-posé ou mal-conditionné et régularisation

Inversion et régularisation convexe


- Modèle direct
 - linéaires et invariants, *i.e.*, convolutifs
 - à erreur (de modélisation, de mesure) additive
- Régularisation par pénalisation et contrainte
- Optimisation de critères et cadre convexe

Quelques repères historiques


- Approches quadratiques et filtrage linéaire ~ 60
 - Phillips, Twomey, Tikhonov
 - Kalman
 - Hunt (et Wiener ~ 40)
- Extension : variables cachées discrètes ~ 80
 - Kormylo & Mendel (Impulsions)
 - Geman & Geman (Lignes)
 - Besag, Graffigne, Descombes (Régions)
- Pénalisation convexe (variables cachées, aussi ...) ~ 90
 - $L_2 - L_1$, Huber, hyperbolique, : Sauer, Blanc-Féraud, Idier...
 - L_1 : Alliney-Ruzinsky, Taylor ~ 79 , Yarlagadda ~ 85 ...
 - Et boum du L_1 ~ 2005
- Retour vers des modèles plus complexes ~ 2000
 - Et non-supervisé, myope, semi-aveugle, aveugle
 - Échantillonnage stochastique (MCMC, ...)

Exemple de Hunt (réponse « carré ») [1970]


- Modèle convolutif (moyennage) : $y = h \star x + \varepsilon$



Entrée (x)




Réponse (h)





Sortie (y)

Exemple du photographe photographié (réponse « carré »)

- Modèle convolutif (moyennage de pixels) : $y = h \star x + \varepsilon$
- Domaine de Fourier : $Y(f) = H(f)X(f) + E(f)$



Réponse spatiale



Réponse fréquentielle




Entrée (x)




Sortie (y)

Exemple du photographe (réponse « bougé »)

- Modèle convolutif (moyennage de pixels) : $\mathbf{y} = \mathbf{h} \star \mathbf{x} + \varepsilon$
- Domaine de Fourier : $\mathbf{Y}(f) = \mathbf{H}(f)\mathbf{X}(f) + \mathbf{E}(f)$



Réponse spatiale



Réponse fréquentielle



Entrée (x)



Sortie (y)

- Exemples de réponse



- Modèle convolutif

$$y(n) = \sum_{p=-P}^{+P} h(p) x(n-p)$$

$$y(n, m) = \sum_{p=-P}^{+P} \sum_{q=-Q}^{+Q} h(p, q) x(n-p, m-q)$$

- Réponse : $h(p, q)$ ou $h(p)$

- réponse impulsionnelle, noyau
- fonction d'étalement de point (point spread function), tache image

Écriture explicite et matricielle : convolution 1D

- Linéaire \rightsquigarrow relation matricielle : $\mathbf{y} = \mathbf{H}\mathbf{x}$
- Invariant \rightsquigarrow structure de Tœplitz
- Réponse courte \rightsquigarrow structure bande

$$\begin{array}{rcl}
 & & \vdots \\
 y_{n-1} & = & \\
 y_n & = & h_P x_{n-P} + \dots + h_1 x_{n-1} + h_0 x_n + h_{-1} x_{n+1} + \dots + h_{-P} x_{n+P} \\
 y_{n+1} & = & \\
 & & \vdots
 \end{array}$$

$$\mathbf{H} = \begin{bmatrix}
 \vdots & \vdots \\
 \dots & h_P & \dots & h_0 & \dots & h_{-P} & 0 & 0 & 0 & 0 & 0 \\
 \dots & 0 & h_P & \dots & h_0 & \dots & h_{-P} & 0 & 0 & 0 & 0 & \dots \\
 \dots & 0 & 0 & h_P & \dots & h_0 & \dots & h_{-P} & 0 & 0 & 0 & \dots \\
 \dots & 0 & 0 & 0 & h_P & \dots & h_0 & \dots & h_{-P} & 0 & 0 & \dots \\
 \dots & 0 & 0 & 0 & 0 & h_P & \dots & h_0 & \dots & h_{-P} & 0 & \dots \\
 & 0 & 0 & 0 & 0 & 0 & h_P & \dots & h_0 & \dots & h_{-P} & \\
 \vdots & \\
 \vdots &
 \end{bmatrix}$$

Cas circulant : diagonalisation

- Diagonalisation de matrices circulantes ...

$$\tilde{H} = \mathbf{F}^\dagger \Lambda_h \mathbf{F}$$

- ... dans la base de Fourier

$$\mathbf{F} = N^{-1/2} \left[e^{-2i\pi(k-1)(l-1)/N} \right]_{k,l \in 1, \dots, N}$$

- Rappel de quelques propriétés

$$\begin{aligned} \mathbf{F}^t &= \mathbf{F} \\ \mathbf{F}^\dagger \mathbf{F} &= \mathbf{F} \mathbf{F}^\dagger = \mathbf{I}_N \\ \mathbf{F}^{-1} &= \mathbf{F}^\dagger = \mathbf{F}^* \end{aligned}$$


$$\mathbf{F} \mathbf{x} = \text{FFT}(\mathbf{x})$$

Cas circulant : valeurs propres

- Valeurs propres \sim réponse en fréquence

$$\overset{\circ}{\mathbf{h}} = \begin{bmatrix} \overset{\circ}{h}_0 \\ \overset{\circ}{h}_1 \\ \vdots \\ \overset{\circ}{h}_{N-2} \\ \overset{\circ}{h}_{N-1} \end{bmatrix} = \sqrt{N} \mathbf{F} \begin{bmatrix} \cdot \\ 0 \\ h_{-P} \\ \cdot \\ h_0 \\ \cdot \\ h_P \\ 0 \\ \cdot \end{bmatrix} = \text{fft}(\mathbf{h}, N)$$

- « Lues » sur la réponse en fréquence



- Commentaire : conditionnement de \mathbf{H} et caractère passe-bas

Cas circulant : convolution par FFT


- Mise en forme matricielle de convolution par FFT

$$z = Hx = F^\dagger \Lambda_h Fx$$

$$Fz = \Lambda_h Fx$$

$$\hat{z} = \Lambda_h \hat{x}$$


$$\hat{z}_n = \hat{h}_n \hat{x}_n \quad \text{pour } n = 1, \dots, N$$



- Atténuations en fréquence, caractère passe-bas, caractère mal-posé
- Système possiblement non-inversible
- Remarque : calcul de convolution exact toujours possible, mais...

Restaurée aux moindres carrés

- Comparer observations \mathbf{y} et sortie modèle \mathbf{Hx}
 - Inconnue : \mathbf{x}
 - Connus : \mathbf{H} et \mathbf{y}



- Critère de moindres carrés : distance observation – sortie modèle

$$J_{\text{MC}}(\mathbf{x}) = \|\mathbf{y} - \mathbf{Hx}\|^2$$

- Solution des moindres carrés

$$\hat{\mathbf{x}}_{\text{MC}} = \arg \min_{\mathbf{x}} J_{\text{MC}}(\mathbf{x})$$

- Solution $\hat{\mathbf{x}}_{\text{MC}}$ la meilleure pour reproduire les données
- Faut que ça « *fitte* », que ça « colle »

Modèle linéaire + moindres carrés \rightsquigarrow Critère de quadratique

$$\begin{aligned} J_{\text{MC}}(\mathbf{x}) &= \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 &= (\mathbf{y} - \mathbf{H}\mathbf{x})^t (\mathbf{y} - \mathbf{H}\mathbf{x}) \\ & &= \mathbf{x}^t \mathbf{H}^t \mathbf{H} \mathbf{x} - 2\mathbf{y}^t \mathbf{H} \mathbf{x} + \mathbf{y}^t \mathbf{y} \end{aligned}$$

- Calcul du gradient \rightsquigarrow linéaire

$$\mathbf{g}(\mathbf{x}) = \frac{\partial J_{\text{MC}}}{\partial \mathbf{x}} = 2\mathbf{H}^t \mathbf{H} \mathbf{x} - 2\mathbf{H}^t \mathbf{y} = -2\mathbf{H}^t (\mathbf{y} - \mathbf{H}\mathbf{x})$$

- Et du hessien \rightsquigarrow constant

$$\mathbf{Q} = \frac{\partial^2 J_{\text{MC}}}{\partial \mathbf{x}^2} = 2\mathbf{H}^t \mathbf{H} \quad (\geq 0)$$

- Annulation du gradient \rightsquigarrow système linéaire \rightsquigarrow inversion matricielle

$$\begin{aligned} (\mathbf{H}^t \mathbf{H}) \hat{\mathbf{x}}_{\text{MC}} &= \mathbf{H}^t \mathbf{y} \\ \hat{\mathbf{x}}_{\text{MC}} &= (\mathbf{H}^t \mathbf{H})^{-1} \mathbf{H}^t \mathbf{y} \end{aligned}$$

- Mise en œuvre et résultats : voir plus loin
- Solution inacceptable, explosive, dominée par le bruit
 - Matrice mal-conditionnée
 - Problème mal-posé
 - Instabilité numérique
 - Pourtant non biaisée et à variance minimale
- Solutions modifiées. . .

Régularisation : généralités

- Données insuffisamment informatives
 - ↪ Prise en compte d'information *a priori*
 - 1 Notion de compromis, de compétition
 - 2 Spécificité des méthodes
 - ↪ Ici : *régularité* de l'image, idéalement *préservant les contours*
 - ↪ Explicitation des informations *a priori*
- Régularisation
 - Par **pénalisation**, **contrainte**, re-paramétrisation
 - ... ou d'autres choses ... mais régularisation de toutes façons
- Régularisation par **pénalisation**

$$J_{\text{MCP}}(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \mathcal{P}(\mathbf{x})$$

- Image restaurée

$$\hat{\mathbf{x}}_{\text{MCP}} = \arg \min_{\mathbf{x}} J_{\text{MCP}}(\mathbf{x})$$

Pénalisation quadratique

- Différences, dérivées d'ordres supérieurs, généralisations,...

$$\mathcal{P}(\mathbf{x}) = \sum_n (x_{n+1} - x_n)^2$$

$$\mathcal{P}(\mathbf{x}) = \sum_n (x_{n+1} - 2x_n + x_{n-1})^2$$

$$\mathcal{P}(\mathbf{x}) = \sum_n (\alpha x_{n+1} - x_n + \alpha' x_{n-1})^2$$

$$\mathcal{P}(\mathbf{x}) = \sum_n (\boldsymbol{\alpha}_n^t \mathbf{x})^2$$

- Combinaisons linéaires (ondelettes, truc-en-ette,...)

$$\mathcal{P}(\mathbf{x}) = \sum_n (\mathbf{w}_n^t \mathbf{x})^2 = \sum_n \left(\sum_m w_{nm} x_m \right)^2$$

- Redondante ou pas
- Lien ondelette de Haar et autres

Pénalisation quadratique

- Aspects 2D : dérivées, différences finies, approximations de gradients

$$\begin{aligned}\mathcal{P}(\boldsymbol{x}) &= \sum_{p \sim q} (x_p - x_q)^2 \\ &= \sum_{n,m} (x_{n+1,m} - x_{n,m})^2 + \sum_{n,m} (x_{n,m+1} - x_{n,m})^2\end{aligned}$$

- Norme de filtrées de l'image \sim de gradient de l'image
 - En lignes + en colonnes

$$\begin{bmatrix} 1 \\ 0 \\ -1 \end{bmatrix} + [1 \quad 0 \quad -1] \quad \text{ou} \quad \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} + \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$$

- Les deux conjointement

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

- Remarques
 - Notion de voisinages et champs de Markov
 - Tout filtre passe-haut, contour (Prewitt, Sobel, ...)
 - Combinaisons linéaires (ondelettes, truc-en-ette, ...)

- Autres possibles (un peu différent)

- Rappel à une forme connue

$$\mathcal{P}(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}})^t (\mathbf{x} - \bar{\mathbf{x}})$$

- Norme euclidienne standard (termes séparables)

$$\mathcal{P}(\mathbf{x}) = \mathbf{x}^t \mathbf{x}$$

- Forme la plus générale

$$\mathcal{P}(\mathbf{x}) = (\mathbf{x} - \bar{\mathbf{x}})^t \mathbf{\Gamma} (\mathbf{x} - \bar{\mathbf{x}})$$

- Dans le suite :

$$\mathcal{P}_1(\mathbf{x}) = \sum (x_p - x_q)^2 = \|\mathbf{D}\mathbf{x}\|^2 = \mathbf{x}^t \mathbf{D}^t \mathbf{D} \mathbf{x}$$

et $\mathbf{D} = \dots$

Restaurée aux moindres carrés pénalisés

- Rappel du critère...

$$J_{\text{MCP}}(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2$$

- ... de son gradient ...

$$\mathbf{g}(\mathbf{x}) = \frac{\partial J_{\text{MCP}}}{\partial \mathbf{x}} = -2\mathbf{H}^t(\mathbf{y} - \mathbf{H}\mathbf{x}) + 2\mu \mathbf{D}^t \mathbf{D}\mathbf{x}$$

- ... de son Hessien ...

$$\mathbf{Q} = \frac{\partial^2 J_{\text{MCP}}}{\partial \mathbf{x}^2} = 2\mathbf{H}^t \mathbf{H} + 2\mu \mathbf{D}^t \mathbf{D}$$

- ... du système d'équation normale ...

$$(\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D}) \hat{\mathbf{x}}_{\text{MCP}} = \mathbf{H}^t \mathbf{y}$$

- ... et du minimiseur ...

$$\hat{\mathbf{x}}_{\text{MCP}} = (\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D})^{-1} \mathbf{H}^t \mathbf{y}$$

- Ré-écriture du critère ...

$$\begin{aligned} J_{\text{MCP}}(\mathbf{x}) &= \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2 \\ &= \frac{1}{2} \mathbf{x}^t \mathbf{Q} \mathbf{x} + \mathbf{q}^t \mathbf{x} + q_0 \end{aligned}$$

- \mathbf{Q} est le Hessien ...

$$\mathbf{Q} = \frac{\partial^2 J_{\text{MCP}}}{\partial \mathbf{x}^2} = 2\mathbf{H}^t \mathbf{H} + 2\mu \mathbf{D}^t \mathbf{D}$$

- \mathbf{q} est le gradient à l'origine ...

$$\mathbf{q} = \mathbf{g}(0) = -2\mathbf{H}^t \mathbf{y}$$

- ... du système ...

$$\begin{aligned} (\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D}) \hat{\mathbf{x}}_{\text{MCP}} &= \mathbf{H}^t \mathbf{y} \\ \mathbf{Q} \hat{\mathbf{x}}_{\text{MCP}} &= -\mathbf{q} \end{aligned}$$

- ... et du minimiseur ...



$$\hat{\mathbf{x}}_{\text{MCP}} = (\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D})^{-1} \mathbf{H}^t \mathbf{y} = -\mathbf{Q}^{-1} \mathbf{q}$$

Nombreuses options et nombreux liens...

- Calcul direct, forme compacte, inversion matricielle
- Algorithmes de résolution de systèmes linéaires
 - Gauss, Gauss-Jordan
 - Substitution
 - Triangularisation,...
- Algorithmes de moindres carrés récurrents (surtout 1D)
- Lisseur de Kalman et ses versions rapides (surtout 1D)
- Algorithmes d'optimisation
 - descente dans la direction opposée au gradient ...
 - ... et diverses versions
- Diagonalisation
 - Approximation circulante et diagonalisation par FFT

Critère quadratique : généralités



- Une variable : $\alpha(t - \bar{t})^2 + \gamma$
- Deux variables : $\alpha_1(t_1 - \bar{t}_1)^2 + \alpha_2(t_2 - \bar{t}_2)^2 + \beta(t_2 - t_1)^2 + \gamma$



- Commentaire : convexe, concave, point selle, direction propre

Critère quadratique : généralités

- Deux variables : $\alpha_1(t_1 - \bar{t}_1)^2 + \alpha_2(t_2 - \bar{t}_2)^2 + \beta(t_2 - t_1)^2 + \gamma$



Optimalité sur \mathbb{R}^N (pas de contrainte)

- Gradient nul

$$0 = \left. \frac{\partial J}{\partial \mathbf{x}} \right|_{\bar{\mathbf{x}}} = \mathbf{g}(\bar{\mathbf{x}})$$

- Hessien positif

$$\mathbf{Q} = \frac{\partial^2 J}{\partial \mathbf{x}^2} \geq 0$$

$$\bar{\mathbf{x}} = \arg \min_{\mathbf{x}} J(\mathbf{x})$$

Algorithme itératif à point fixe

- Initialisation $\mathbf{x}^{[0]}$
- Itération $\mathbf{x}^{[1]}, \mathbf{x}^{[2]}, \dots, \mathbf{x}^{[k]}, \dots$

$$\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + \tau^{[k]} \delta^{[k]}$$

- Direction $\delta \in \mathbb{R}^N$
- Pas $\tau \in \mathbb{R}_+$

$$\boxed{\mathbf{x}^{[k]} \xrightarrow[k=\infty]{} \bar{\mathbf{x}}}$$

- Condition d'arrêt, e.g., $\|\mathbf{g}(\mathbf{x}^{[k]})\| < \varepsilon$

- Direction δ
 - « Optimale » : opposé du gradient
 - Newton, inverse Hessien
 - Préconditionné
 - Directions corrigées :
 - bissectrice, Vignes, Polack-Ribière, ...
 - direction conjuguée, ...
 - ...
 - Pas τ
 - « Optimal »
 - Sur-relaxé / sous-relaxé
 - Armijo, Goldstein, Wolfe
 - ...
- ... optimal, oui, mais pas globalement...

Stratégie : direction optimale \oplus pas optimal

- Itération $\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + \tau^{[k]} \boldsymbol{\delta}^{[k]}$

- Direction $\boldsymbol{\delta} \in \mathbb{R}^N$

$$\boldsymbol{\delta}^{[k]} = -\mathbf{g}(\mathbf{x}^{[k]})$$

- Pas $\tau \in \mathbb{R}_+$

$$J_{\boldsymbol{\delta}}(\tau) = J(\mathbf{x}^{[k]} + \tau \boldsymbol{\delta}^{[k]})$$



- Que l'on peut ré-écrire \rightsquigarrow polynôme du second ordre

$$J_{\boldsymbol{\delta}}(\tau) = \dots \tau^2 + \dots \tau + \dots$$

- Et optimiser explicitement \rightsquigarrow pas optimal

$$\tau^{[k]} = \frac{\mathbf{g}(\mathbf{x}^{[k]})^t \mathbf{g}(\mathbf{x}^{[k]})}{\mathbf{g}(\mathbf{x}^{[k]})^t \mathbf{Q} \mathbf{g}(\mathbf{x}^{[k]})} = \frac{\|\mathbf{g}(\mathbf{x}^{[k]})\|^2}{\|\mathbf{g}(\mathbf{x}^{[k]})\|_Q^2}$$

Illustration



- Deux lectures :
 - optimisation directionnelle, « line-search »
 - optimisation contrainte
- Remarque : orthogonalité des directions successives

Quelques notations

$$J(x) = \frac{1}{2}x^t Q x + q^t x + q_0$$

$$g(x) = Qx + q$$

$$\bar{x} = \arg \min_x J(x) = -Q^{-1}q$$

Quelques résultats

$$J(\bar{x}) = -\frac{1}{2}q^t Q^{-1}q + q_0$$

$$J(x) - J(\bar{x}) = \frac{1}{2}g(x)^t Q^{-1}g(x)$$

$$J(x_0 + h) - J(x_0) = g(x_0)^t h + \frac{1}{2}h^t Q h$$

Éléments de preuve de convergence (1)

- Notations simplifiées : $\mathbf{x}^{[k]} = \mathbf{x}$, $\mathbf{x}^{[k+1]} = \mathbf{x}'$, $\tau^{[k]} = \tau$ et $\mathbf{g}(\mathbf{x}^{[k]}) = \mathbf{g}$

- Évolution du critère

$$\begin{aligned} J(\mathbf{x}') - J(\mathbf{x}) &= J(\mathbf{x} + \tau \boldsymbol{\delta}) - J(\mathbf{x}) \\ &= \mathbf{g}^t [\tau \boldsymbol{\delta}] + \frac{1}{2} [\tau \boldsymbol{\delta}]^t \mathbf{Q} [\tau \boldsymbol{\delta}] \\ &= \dots \\ &= -\frac{1}{2} \frac{[\mathbf{g}^t \mathbf{g}]^2}{\mathbf{g}^t \mathbf{Q} \mathbf{g}} \end{aligned}$$

puisque $\boldsymbol{\delta} = -\mathbf{g}$ et $\tau = \frac{\mathbf{g}^t \mathbf{g}}{\mathbf{g}^t \mathbf{Q} \mathbf{g}}$

- Commentaire : ça descend...

Distance à l'optimum

$$\begin{aligned} J(\mathbf{x}') - J(\bar{\mathbf{x}}) &= J(\mathbf{x}) - J(\bar{\mathbf{x}}) - \frac{1}{2} \frac{[\mathbf{g}^t \mathbf{g}]^2}{\mathbf{g}^t \mathbf{Q} \mathbf{g}} \\ &= J(\mathbf{x}) - J(\bar{\mathbf{x}}) - \frac{1}{2} \frac{[\mathbf{g}^t \mathbf{g}]^2}{\mathbf{g}^t \mathbf{Q} \mathbf{g}} \times \frac{J(\mathbf{x}) - J(\bar{\mathbf{x}})}{\mathbf{g}^t \mathbf{Q}^{-1} \mathbf{g} / 2} \\ &= [J(\mathbf{x}) - J(\bar{\mathbf{x}})] \left[1 - \frac{[\mathbf{g}^t \mathbf{g}]^2}{[\mathbf{g}^t \mathbf{Q} \mathbf{g}] [\mathbf{g}^t \mathbf{Q}^{-1} \mathbf{g}]} \right] \\ &= \dots \\ &\leq [J(\mathbf{x}) - J(\bar{\mathbf{x}})] \left(\frac{M - m}{M + m} \right)^2 \end{aligned}$$

... donc « ça converge »

- M et m : v. p. min. et max. de \mathbf{Q} ... et commentaire
- Inégalité de Kantorovitch (voir diapositive suivante)

Résultat

$$[u^t Q u] [u^t Q^{-1} u] \leq \frac{1}{4} \left(\sqrt{\frac{m}{M}} + \sqrt{\frac{M}{m}} \right)^2 \|u\|^4$$


- Q symétrique définie positive
- M et m : valeurs propres maximale et minimale de Q

Éléments de démonstration


- Un peu long et complexe
- Cas $\|u\| = 1$
- Diagonaliser Q : $Q = P^t \Lambda P$ et $Q^{-1} = P^t \Lambda^{-1} P$
- Combinaison convexe des v.p. et des v.p. inverses
- Convexité de $t \mapsto 1/t$

- $\mu = 0$, solution des moindres carrés
- μ croissant, μ qui va bien
- Approximation circulante
 - Mise en œuvre par FFT
 - Interprétation filtrage de Wiener, filtrage inverse



Solutions aux moindres carrés (Hunt et photographie)



Entrée



Données



Moindres carrés

Qualités / Défauts

- Très général, hyper-rapide, aucun paramètre à régler
- ... marche pas ... (sauf si...)
- Et pourtant : non biaisée et à variance minimale !!

$$\begin{aligned}\hat{\mathbf{x}} &= (\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D})^{-1} \mathbf{H}^t \mathbf{y} \\ &= (\tilde{\mathbf{H}}^t \tilde{\mathbf{H}})^{-1} \tilde{\mathbf{H}}^t \mathbf{y} \\ &= (\mathbf{F}^\dagger \boldsymbol{\Lambda}_h^\dagger \mathbf{F} \mathbf{F}^\dagger \boldsymbol{\Lambda}_h \mathbf{F})^{-1} \mathbf{F}^\dagger \boldsymbol{\Lambda}_h^\dagger \mathbf{F} \mathbf{y} \\ &= \mathbf{F}^\dagger \boldsymbol{\Lambda}_h^{-1} \mathbf{F} \mathbf{y}\end{aligned}$$

$$\mathbf{F} \hat{\mathbf{x}} = \boldsymbol{\Lambda}_h^{-1} \mathbf{F} \mathbf{y}$$


$$\hat{\mathbf{x}}^\circ = \boldsymbol{\Lambda}_h^{-1} \mathbf{y}^\circ$$

$$\hat{x}_n^\circ = \frac{y_n^\circ}{h_n} \quad \text{pour } n = 1, \dots, N$$

C'est du filtrage inverse !!

Pseudo-code Matlab

```
ObjetEstMC = IFFT( FFT(Donnees,N) ./ fft(RI,N) )
```



Réponse en fréquence (2D et coupe)






Image originale




Données




Moindres carrés

Solutions par pénalisation quadratique (Hunt)


- Évolution avec μ




$\mu = 0$




$\mu = 10^{-3}$




$\mu = 10^{-2}$



$\mu = 10^{-1}$



$\mu = 1$



$\mu = 10^{+1}$

Solutions par pénalisation quadratique (photographe)



Entrée



Données



Moindres carrés pénalisés

$$\begin{aligned}\hat{\mathbf{x}} &= (\bar{\mathbf{H}}^t \bar{\mathbf{H}} + \mu \bar{\mathbf{D}}^t \bar{\mathbf{D}})^{-1} \bar{\mathbf{H}}^t \mathbf{y} \\ &= \mathbf{F}^\dagger (\mathbf{\Lambda}_h^\dagger \mathbf{\Lambda}_h + \mu \mathbf{\Lambda}_d^\dagger \mathbf{\Lambda}_d)^{-1} \mathbf{\Lambda}_h^\dagger \mathbf{F} \mathbf{y}\end{aligned}$$

$$\hat{\mathring{\mathbf{x}}} = (\mathbf{\Lambda}_h^\dagger \mathbf{\Lambda}_h + \mu \mathbf{\Lambda}_d^\dagger \mathbf{\Lambda}_d)^{-1} \mathbf{\Lambda}_h^\dagger \mathring{\mathbf{y}}$$



$$\hat{\mathring{x}}_n = \frac{\mathring{h}_n^*}{|\mathring{h}_n|^2 + \mu |\mathring{d}_n|^2} \mathring{y}_n \quad \text{pour } n = 1, \dots, N$$

C'est du filtrage de Wiener !!




Pseudo-code Matlab

```
Gain = fft(RI,N)* ./ (|fft(RI,N)|^2 + mu1*|fft([-1,1],N)|^2)
ObjetEstMCP = IFFT( FFT(Donnees,N) .* Gain )
```




Lecture fréquentielle : égalisation dans la bande






Fréquence



Fréquence




Fréquence



Fréquence


Biais / Variance (1)

Biais



Fréquence


Variance



Fréquence


Biais / Variance (2)

Biais




μ

Variance



μ

EQM



μ

Synthèse

- Déconvolution d'image
 - Aussi : modèle direct linéaire mais non-invariant
 - Et aussi : cas des signaux
- Pénalisation quadratique et régularité des solutions
 - Gradient de niveaux de gris et extensions
 - Autres décompositions
- Calcul numérique
 - Optimisation numérique (gradient, pas optimal, . . .)
 - Approximation circulante (diagonalisation) \rightsquigarrow tous calculs par FFT

Extensions

- Extension non quadratiques \rightsquigarrow résolution accrue (cours suivants)

- Solution quadratique limitée en « résolution »
- Moins de « lissage » au niveau des « discontinuités »
 - Ambivalence :
 - Lissage (zone homogène)
 - Réhaussement (discontinuités)
 - ... et nouveau compromis

Structure algorithmique

- Appuyée sur la solution quadratique
 - par FFT (Wiener-Hunt)
 - par lissage de Kalman (et ses versions rapides, factorisées, ...)
 - par optimisation numérique (gradient, pixel par pixel, ...)

- Image restaurée toujours comme minimiseur ...

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} J(\mathbf{x})$$

- ... d'un critère pénalisé ...

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \mathcal{P}(\mathbf{x})$$

- ... toujours pénalisant pour les « faibles variations »
mais moins pénalisant pour les « discontinuités »


$$\mathcal{P}(\mathbf{x}) = \sum_{p \sim q} \phi(x_p - x_q)$$

$$\phi(\delta) = \delta^2 \rightsquigarrow \phi(\delta) = \dots ?$$

- Un peu d'ambivalence : nouveau compromis
 - Lissage (zone homogène)
 - Réhaussement (discontinuités)

Potentiels typiques

- Toujours $\phi(\delta) \sim \delta^2$ pour δ petit
- Comportements pour δ grand
 - 1 Asymptote horizontale
 - 2 Branche parabolique horizontale
 - 3 Asymptotique oblique
 - 4 Branche parabolique verticale



Quatre grands types de potentiels

- 1 **Asymptote horizontale** $\phi(\delta) \sim 1$
[Blake et Zisserman (87), Geman et McClure (87)]

$$\varphi(\delta) = \alpha s^2 \min(1, (\delta/s)^2) \quad ; \quad \varphi(\delta) = \alpha s^2 \frac{(\delta/s)^2}{1 + (\delta/s)^2}$$

- 2 **Branche parabolique horizontale** $\phi(\delta) \sim \log |\delta|$
[Hebert et Leahy (89)]

$$\varphi(\delta) = \alpha s^2 \log [1 + (\delta/s)^2]$$


- 3 **Asymptotique oblique** $\phi(\delta) \sim |\delta|$
Huber, hyperbolique, Log cosinus hyperbolique, fair function

$$\varphi(\delta) = \alpha \begin{cases} \delta^2 & \text{if } |\delta| \leq s \\ 2s|\delta| - s^2 & \text{if } |\delta| \geq s \end{cases} \quad ; \quad \varphi(\delta) = 2\alpha s^2 \left(\sqrt{1 + [\delta/s]^2} - 1 \right)$$

- 4 **Branche parabolique verticale** $\phi(\delta) \sim \delta^2$
Solution de Wiener-Hunt

$$\varphi(\delta) = \alpha \delta^2$$

Potentiels à asymptote obliques (L_2 / L_1) : détails



Huber :

$$\varphi(\delta) = \alpha s^2 \begin{cases} [\delta/s]^2 & \text{if } |\delta| \leq s \\ 2|\delta|/s - 1 & \text{if } |\delta| \geq s \end{cases}$$

Hyperbolique :

$$\varphi(\delta) = 2\alpha s^2 \left(\sqrt{1 + [\delta/s]^2} - 1 \right)$$

LogCosh :

$$\varphi(\delta) = 2\alpha s^2 \log \cosh (|\delta|/s)$$

FairFunction :

$$\varphi(\delta) = 2\alpha s^2 [|\delta|/s - \log(1 + |\delta|/s)]$$

Pénalisations non-quadratiques plus générales

- Filtrées de l'image \sim gradient de l'image (lignes, colonnes, les deux)

$$\mathcal{P}(\mathbf{x}) = \sum_{p \sim q} \phi(x_p - x_q)$$

- Différences, dérivées d'ordres supérieurs, généralisations,...

$$\mathcal{P}(\mathbf{x}) = \sum_n \phi(\alpha_n^t \mathbf{x})$$

- Combinaisons linéaires plus avancées (ondelettes,...)

$$\mathcal{P}(\mathbf{x}) = \sum_n \sum_m \pi_n \phi_n(w_{nm} x_m)$$

- Autres possibles (un peu différent)

- Rappel à une forme connue

$$\mathcal{P}(\mathbf{x}) = \sum_n \phi(x_n - \bar{x}_n)$$

- Pénalité séparable

$$\mathcal{P}(\mathbf{x}) = \sum_n \phi(x_n)$$

- Rappel du critère

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \phi_s(x_p - x_q)$$

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} J(\mathbf{x})$$

- avec ϕ_s l'un des potentiels (non-quadratique) évoqués
 - et deux hyperparamètres : μ et s
-
- Critère non-quadratique
 - Gradient non-linéaire
 - Pas de solution explicite
-
- Deux questions
 - Minimiseur : existence, unicité, ... continuité
 - Calcul pratique : algorithme d'optimisation numérique, ...

- Ensemble convexe
 - \mathbb{R}^N , \mathbb{R}_+^N , pavé de \mathbb{R}^N ,...
 - Propriétés : intersection, enveloppe convexe, projection,...
- Critère convexe (strictement)
 - $\Theta(u) = u^2$, $\Theta(u) = |u|$, $\Theta(\mathbf{u}) = \|\mathbf{u}\|^2$,...
 - Propriétés : somme de fonction convexe, lignes de niveaux,...
- Résultat clé
 - Ensemble des minimiseurs d'un convexe sur un convexe est convexe
 - Convexité stricte \rightsquigarrow minimiseur unique
- Application
 - ϕ convexe $\implies J$ convexe
- Dans la suite, potentiel ϕ_S
 - Huber ou hyperbolique : convexe (strict) \rightsquigarrow garanties
 - Autres aussi : non-convexe \rightsquigarrow pas de garantie (encore que...)

Approche semi-quadratique (début)

- Rappel du critère

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \phi(x_p - x_q)$$

- Résolution appuyée quadratique
- Jeu de variables auxiliaires b_{pq} pour que : $\phi(\delta_{pq}) \longleftrightarrow \delta_{pq}^2$
- Idée de [Geman et Yang 95], avec $\psi(b)$ bien choisie :

$$\phi(\delta) = \inf_b \left[\frac{1}{2}(\delta - b)^2 + \psi(b) \right]$$

- Critère étendu

$$\bar{J}(\mathbf{x}, \mathbf{b}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \frac{1}{2} [(x_p - x_q) - b_{pq}]^2 + \psi(b_{pq})$$

et donc bien sûr

$$J(\mathbf{x}) = \inf_{\mathbf{b}} \bar{J}(\mathbf{x}, \mathbf{b})$$

- Point algorithmique : minimisation alternée

Transformée de Legendre-Fenchel (TFL)

Conjuguée Convexe (CC)

Définition de TLF ou CC

On se donne $f : \mathbb{R} \longrightarrow \mathbb{R}$

- strictement convexe
- dérivable une fois (ou deux)

On appelle TLF ou CC la fonction notée $f^* : \mathbb{R} \longrightarrow \mathbb{R}$ définie par :

$$f^*(t) = \sup_{x \in \mathbb{R}} [xt - f(x)]$$

Remarque

$$f^*(0) = \sup_{x \in \mathbb{R}} [-f(x)] = - \inf_{x \in \mathbb{R}} [f(x)]$$

$$\forall t, x \in \mathbb{R}, \quad xt - f(x) \leq f^*(t)$$

$$\forall t, x \in \mathbb{R}, \quad f^*(t) + f(x) \geq xt$$

TFL : quelques propriétés par décalage-dilatation

$$f^*(t) = \sup_{x \in \mathbb{R}} [xt - f(x)]$$

Vertical : décalage-dilatation ($\alpha \in \mathbb{R}$ et $\beta \in \mathbb{R}_+^*$)

$$\begin{cases} g(x) = \alpha + \beta f(x) \\ g^*(t) = \beta f^*(t/\beta) - \alpha \end{cases}$$

Horizontal : décalage ($x_0 \in \mathbb{R}$) et dilatation ($\gamma \in \mathbb{R}_+^*$)

$$\begin{cases} g(x) = f(x - x_0) \\ g^*(t) = f^*(t) - tx_0 \end{cases} \quad \begin{cases} g(x) = f(\gamma x) \\ g^*(t) = f^*(t/\gamma) \end{cases}$$

Cas particuliers

$$\alpha = 0, \beta = 1 \quad / \quad x_0 = 0 \quad / \quad \gamma = 1$$

Cas quadratique ($\alpha \in \mathbb{R}$ et $\beta \in \mathbb{R}_+^*$)

On considère la fonction

$$f(x) = \alpha + \frac{1}{2}\beta(x - x_0)^2$$

On détermine la CC

$$f^*(t) = \sup_{x \in \mathbb{R}} [xt - f(x)]$$

- On pose $g_t(x) = xt - f(x) = xt - (\alpha + \beta(x - x_0)^2 / 2)$
 - En dérivant $g_t'(x) = t - \beta(x - x_0)$
 - Encore $g_t(x)'' = -\beta$
 - En annulant $g_t'(x)$, on a : $\bar{x} = x_0 + t/\beta$
 - Puis en reportant $f^*(t) = g_t(\bar{x})$

$$f^*(t) = \frac{1}{2\beta}(t + \beta x_0)^2 - \left(\alpha + \frac{1}{2}\beta x_0^2\right)$$

Formule de Legendre

$$f^*(t) = \sup_{x \in \mathbb{R}} [xt - f(x)]$$

- On pose $g_t(x) = xt - f(x)$
 - En dérivant : $g'_t(x) = t - f'(x)$
 - Encore : $g_t(x)'' = -f''(x)$
 - En annulant $g'_t(x)$:

$$t - f'(\bar{x}) = 0$$

$$\bar{x} = f'^{-1}(t) = \chi(t)$$

- Puis en reportant

$$f^*(t) = g_t(\bar{x}) = t\bar{x} - f(\bar{x}) = t\chi(t) - f[\chi(t)]$$

Dérivées

- Conjuguée convexe explicitée

$$f^*(t) = t\chi(t) - f[\chi(t)] \quad \text{avec } \chi = f'^{-1}$$

- En dérivant :

$$\begin{aligned} f^{*\prime}(t) &= \chi(t) + t\chi'(t) - \chi'(t) f'[\chi(t)] \\ &= \chi(t) \\ &= f'^{-1}(t) \end{aligned}$$

- Encore :

$$f^{*\prime\prime}(t) = \chi(t)' = \frac{1}{f''[\chi(t)]} > 0$$

- donc f^* convexe

Double conjuguée

- Transformer deux fois redonne l'originale

$$f^{**}(x) = f(x)$$

$$f^{**}(t) = \sup [xt - f^*(x)]$$

- On pose $h_t(x) = xt - f^*(x)$ et en annulant la dérivée :

$$0 = h'_t(\bar{x}) = t - f'^*(\bar{x}) = t - f'^{-1}(\bar{x}) = t - \chi(\bar{x})$$

$$\bar{x} = \chi^{-1}(t) = f'(t)$$

- On reporte

$$\begin{aligned} f^{**}(t) = h_t(\bar{x}) &= \bar{x}t - f^*(\bar{x}) \\ &= \bar{x}t - [\bar{x}\chi(\bar{x}) - f(\chi(\bar{x}))] \\ &= \bar{x}t - \bar{x}t + f(t) \\ &= f(t) \end{aligned}$$

Définition

On se donne $f : \mathbb{R} \rightarrow \mathbb{R}$

- strictement convexe
- dérivable une fois (ou deux)

$$f^*(t) = \sup_{x \in \mathbb{R}} [xt - f(x)]$$

Propriétés

$$f^*(t) = t\chi(t) - f[\chi(t)] \quad \text{avec } \chi = f'^{-1}$$

$$f^{*\prime} = f'^{-1} = \chi$$

$$f^{*\prime\prime}(t) = 1/f''[\chi(t)]$$

f^* est convexe

$$f^{**}(x) = f(x)$$

Théorème en action : semi-quadratique (1)

Position du problème

On se donne un potentiel ϕ , **convexe ou non**, et on veut

$$\phi(b) = \inf_{\delta \in \mathbb{R}} [(\delta - b)^2/2 + \psi(b)]$$

- On définit g de manière à ce qu'elle soit convexe strict :

$$g(\delta) = \delta^2/2 - \phi(\delta)$$

- On détermine sa CC :

$$\begin{aligned} g^*(b) &= \sup_{\delta \in \mathbb{R}} [b\delta - g(\delta)] \\ &= \sup_{\delta \in \mathbb{R}} [\phi(\delta) - (\delta - b)^2/2] + b^2/2 \end{aligned}$$

- On pose :

$$\psi(b) = g^*(b) - b^2/2 = \sup_{\delta \in \mathbb{R}} [\phi(\delta) - (\delta - b)^2/2]$$

Théorème en action : semi-quadratique (2)

- On exploite alors $g = g^{**}$

$$\begin{aligned}g(\delta) &= g^{**}(\delta) \\ \delta^2/2 - \phi(\delta) &= \sup_{b \in \mathbb{R}} [b\delta - g^*(\delta)] \\ \phi(\delta) &= \delta^2/2 - \sup_{b \in \mathbb{R}} [b\delta - g^*(\delta)] \\ &= \inf_{b \in \mathbb{R}} [(\delta - b)^2/2 + \psi(b)]\end{aligned}$$

- Cerise sur le gâteau, on a le minimiseur :

$$0 = [(\delta - \bar{b})^2/2 + \psi(\bar{b})]' = (\bar{b} - \delta) + \psi'(\bar{b}) = g^{*'}(\bar{b}) - \delta$$

d'où :

$$\bar{b} = g^{*'}{}^{-1}(\delta) = g'(\delta) = \delta - \phi'(\delta)$$

- Rappel du critère initial et du critère étendu

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \phi(x_p - x_q)$$

$$\bar{J}(\mathbf{x}, \mathbf{b}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \frac{1}{2} [(x_p - x_q) - b_{pq}]^2 + \psi(b_{pq})$$

- Point algorithmique : minimisation alternée
 - 1 Minimisation en \mathbf{x} à \mathbf{b} fixé : $\hat{\mathbf{x}}(\mathbf{b}) = \min_{\mathbf{x}} \bar{J}(\mathbf{x}, \mathbf{b})$
Problème quadratique
 - 2 Minimisation en \mathbf{b} à \mathbf{x} fixé : $\hat{\mathbf{b}}(\mathbf{x}) = \min_{\mathbf{b}} \bar{J}(\mathbf{x}, \mathbf{b})$
Mise à jour séparée et explicite

- Non-séparable mais quadratique

$$\begin{aligned}\bar{J}(\mathbf{x}) &= \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \sum_{p \sim q} \frac{1}{2} [(x_p - x_q) - b_{pq}]^2 \\ &= \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \bar{\mu} \|\mathbf{D}\mathbf{x} - \mathbf{b}\|^2\end{aligned}$$

- Système d'équations normales

$$(\mathbf{H}^t \mathbf{H} + \bar{\mu} \mathbf{D}^t \mathbf{D}) \hat{\mathbf{x}} = \mathbf{H}^t \mathbf{y} + \bar{\mu} \mathbf{D}^t \mathbf{b}$$

- Minimiseur


$$\hat{\mathbf{x}} = (\mathbf{H}^t \mathbf{H} + \bar{\mu} \mathbf{D}^t \mathbf{D})^{-1} (\mathbf{H}^t \mathbf{y} + \bar{\mu} \mathbf{D}^t \mathbf{b})$$

- Aspect numérique

- Algorithme de descente (avec sous-itérations)
- Cas circulant et FFT (sans sous-itération)

Mise à jour des variables auxiliaires

- Séparable (parallèle), explicite (pas de sous-itération), simple
- Chaque $b = b_{pq} \leftrightarrow \delta = \delta_{pq} = x_p - x_q$
- Équation de mise à jour $\bar{b} = \delta - \phi'(\delta)$
 - Huber : $\bar{b} = \delta [1 - 2\alpha \min(1; s/\delta)]$
 - Geman & McClure : $\bar{b} = \delta \left[1 - \frac{2\alpha}{(s/\delta)^2} \right]$
 - ...





Entrée



Données



Pénalité quadratique



Pénalité L2-L1

Synthèse

- Déconvolution d'image
 - Aussi : modèle direct linéaire mais non-invariant
 - Et aussi : cas des signaux
- Préservation des discontinuités et pénalisation non-quadratique
 - Gradient de niveaux de gris et autres décompositions
 - Cas convexe (et différentiable) et aussi cas non-convexe
- Calcul numérique par optimisation
 - Approche semi-quadratique
 - Technique de descente (gradient, pixel par pixel, FFT, ...)

Extensions

- Prise en compte de contraintes \rightsquigarrow résolution accrue (cours suivants)

- Restauration améliorée (résolution, physique, ...)
 - Toujours sur la base d'un critère pénalisé ...

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \mathcal{P}(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2$$

- ... image restaurée encore définie comme minimiseur ...

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} J(\mathbf{x})$$

- ... mais incluant des contraintes (sur la valeur des pixels)
- Davantage d'information \rightsquigarrow amélioration de « qualité »

Structure algorithmique

- Appuyée sur la solution quadratique
 - par FFT (Wiener-Hunt)
 - par lissage de Kalman (et ses versions rapides, factorisées, ...)
 - par optimisation numérique (gradient, pixel par pixel, ...)

Prise en compte de contraintes : positivité et support

Contraintes explorées ici

- Positivité

$$C_p : \forall p \in \mathcal{M}, \quad x_p \geq 0$$

- Support

$$C_s : \forall p \in \bar{\mathcal{S}}, \quad x_p = 0$$

Extensions (non exploré ici)

- Gabarit

$$\forall p \in \mathcal{M}, \quad t_p^- \leq x_p \leq t_p^+$$

- Carte partiellement connue

$$\forall p \in \mathcal{D}, \quad x_p = m_p$$

Forme générale

- Égalité / Inégalité

$$Ax - a = 0 \quad \text{et} \quad Bx - b \geq 0$$

Aspect théorique

- Critère : pénalisé, quadratique, convexe strictement

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2$$



- Ensemble des contraintes convexe
- Solution : *unique minimiseur sous contrainte*

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \begin{cases} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2 \\ \text{s.c.} \begin{cases} x_p = 0 & \text{for } p \in \bar{\mathcal{S}} \\ x_p \geq 0 & \text{for } p \in \mathcal{M} \end{cases} \end{cases}$$

Aspect numérique

- Optimisation quadratique avec contraintes linéaires
- Difficultés
 - $N \sim 1\,000\,000$
 - Contraintes \oplus variables liées

- Une variable : $\alpha(t - \bar{t})^2 + \gamma$




- Solution contrainte

$$\hat{t} = \max[0, \bar{t}]$$

Positivité : dimension deux


- Deux variables : $\alpha_1(t_1 - \bar{t}_1)^2 + \alpha_2(t_2 - \bar{t}_2)^2 + \beta(t_2 - t_1)^2 + \gamma$




- Pas évident de déduire le contraint du non-contraint

Positivité : dimension deux


- Deux variables : $\alpha_1(t_1 - \bar{t}_1)^2 + \alpha_2(t_2 - \bar{t}_2)^2 + \beta(t_2 - t_1)^2 + \gamma$



1



2



3

- Solution contrainte = Solution non-contrainte (1)
- Solution contrainte \neq Solution non-contrainte
... et donc contraintes actives
 - Solution contrainte \neq Solution non-contrainte projetée (2)
 $(\hat{t}_1; \hat{t}_2) \neq (\max[0, \bar{t}_1]; \max[0, \bar{t}_2])$
 - Solution contrainte = Solution non-contrainte projetée (3)
 $(\hat{t}_1; \hat{t}_2) = (\max[0, \bar{t}_1]; \max[0, \bar{t}_2])$

Problème

- Optimisation quadratique avec contraintes linéaires
- Difficultés
 - $N \sim 1\,000\,000$
 - Contraintes \oplus variables liées

Algorithmes existants

- Outils existants *garantis convergents*
[Bertsekas 95,99 ; Nocedal 00,08 ; Boyd 04,11]
 - Gradient projeté, contraint
 - Broyden-Fletcher-Goldfarb-Shanno (L-BFGS) et *limited memory*
 - Points intérieurs
 - Descente pixel par pixel
 - Lagrangien augmenté, ADMM
 - Contraint mais non-liées + liées mais non-contraint
 - Solutions intermédiaires par FFT

Lagrangien et pénalisation

- Contrainte égalité : $x_p = 0$

$$\sum_{p \in \bar{\mathcal{S}}} \ell_p x_p + \frac{1}{2} \rho \sum_{p \in \bar{\mathcal{S}}} x_p^2$$

- Contrainte inégalité : $(x_p \geq 0) \rightsquigarrow (s_p - x_p = 0 ; s_p \geq 0)$

$$\sum_{p \in \mathcal{S}} \ell_p (x_p - s_p) + \frac{1}{2} \rho \sum_{p \in \mathcal{S}} (x_p - s_p)^2$$

- Globalement (égalité et inégalité) avec $s_p \geq 0$ ou $s_p = 0$

$$\ell^t(\mathbf{x} - \mathbf{s}) + \frac{1}{2} \rho (\mathbf{x} - \mathbf{s})^t (\mathbf{x} - \mathbf{s})$$

Lagrangien augmenté

$$\mathcal{L}(\mathbf{x}, \mathbf{s}, \ell) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2 + \ell^t(\mathbf{x} - \mathbf{s}) + \rho (\mathbf{x} - \mathbf{s})^t (\mathbf{x} - \mathbf{s})$$

$$\mathcal{L}(\mathbf{x}, \mathbf{s}, \ell) = \|\mathbf{y} - \mathbf{H}\mathbf{x}\|^2 + \mu \|\mathbf{D}\mathbf{x}\|^2 + \ell^t(\mathbf{x} - \mathbf{s}) + \rho(\mathbf{x} - \mathbf{s})^t(\mathbf{x} - \mathbf{s})$$

- Itérer trois étapes

- 1 Unconstrained minimization of \mathcal{L} w.r.t. \mathbf{x}

$$\tilde{\mathbf{x}} = (\mathbf{H}^t \mathbf{H} + \mu \mathbf{D}^t \mathbf{D} + \rho \mathbf{I}_N)^{-1} (\mathbf{H}^t \mathbf{y} + [\rho \mathbf{s} - \ell/2]) \quad (\equiv FFT)$$


- 2 Minimization of \mathcal{L} w.r.t. \mathbf{s} , s.t. $s_p \geq 0$

$$\tilde{s}_p = \begin{cases} \max(0, x_p + \ell_p/(2\rho)) & \text{for } p \in \mathcal{S} \\ 0 & \text{for } p \in \bar{\mathcal{S}} \end{cases}$$


- 3 Update ℓ

$$\tilde{\ell}_p = \ell_p + 2\rho(x_p - s_p)$$


Résultats avec contraintes




Entrée



Données



Pénalité quadratique



Solution contrainte

Synthèse

- Déconvolution d'image
 - Aussi : modèle direct linéaire mais non-invariant
 - Et aussi : cas des signaux
- Pénalisation quadratique et régularité des solutions
 - Optimisation : gradients à pas optimal
- Pénalisation non-quadratique et préservation des discontinuités
 - Optimisation : algorithmes semi-quadratiques
- Prise en compte de contraintes
 - Positivité
 - Optimisation : lagrangien augmentés et ADMM

Extensions

- Estimation d'hyperparamètres
- Estimation de paramètres instruments
- Variables cachées : détection (contours, points, . . .), segmentation, . . .
- Sélection de modèles

- Nombreux doctorants et collègues
 - François Orieux, Cornelia Vacar, Aurélien Hazart, Gilles Rochefort, Redha Boubertakh, Vincent Samson, Philippe Ciuciu
 - Guy Demoment, Jérôme Idier
 - Frédéric Champagnat, Guy Le Besnerais, Alain Herment, Thomas Rodet, Charles Soussen
 - Éric Thibaut et Laurent Mugnier
- Collaborations plus applicatives
 - EdF, ONERA
 - INSERM, IDCV, LIF, IMQ
 - IAS, IAP, RHN
 - CEA-LETI, CEA-LIST, CEA-CESTA
- Nombreux étudiants de Master

Bibliographie



P. Charbonnier, L. Blanc-Féraud, G. Aubert et M. Barlaud,
■Deterministic edge-preserving regularization in computed imaging ■,
IEEE Trans. Image Processing, vol. 6, n°2, pp. 298–311, Feb. 1997.



J. Idier, Ed.,
Approche bayésienne pour les problèmes inverses,
Traité IC2, Série traitement du signal et de l'image, Hermès, Paris, 2001.



H. W. Sorenson,
Parameter estimation, vol. 9 de *Control and system theory*,
Marcel Dekker, New York Basel, 1980.



B. R. Hunt,
■A matrix theory proof of the discrete convolution theorem ■,
IEEE Trans. Automat. Contr., vol. AC-19, pp. 285–288, 1971.



B. R. Hunt,
■Deconvolution of linear systems by constrained regression and its relationship to
the Wiener theory ■,
IEEE Trans. Automat. Contr., vol. AC-17, pp. 703–705, 1972.



G. Demoment,
■Image reconstruction and restoration : Overview of common estimation
structures and problems ■,
IEEE Trans. Acoust. Speech, Signal Processing, vol. assp-37, n°12,
pp. 2024–2036 Dec 1989