

大阪市立大学電子・物理工学特別講義

今日からできる スパースモデリング

京都大学大学院情報学研究科システム科学専攻

大関 真之

QUANTUM
ANNEALING



MACHINE
LEARNING

Sparse Modeling



京都大学
KYOTO UNIVERSITY

圧縮センシング実践編

スパース解推定

- ▶ L0ノルム最小化によるスパース解推定
 - ▶ 以下の最小化問題でスパース解を探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 非零成分の個数が小さい（スパース）で方程式を満たすものを探す
 - ▶ 残念ながら計算量的に困難
- ▶ L1ノルム最小化によるスパース解推定
 - ▶ 代わりに次の最小化問題でスパース解を探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 零が多ければ小さくなる + **大きさも小さくなりがち**
 - ▶ 計算量は非常に軽い（Nの3乗程度）





ノルムについて注意

- ▶ Lpノルムの定義


$$\|\mathbf{x}\|_p = \sqrt[p]{|x_1|^p + |x_2|^p + \dots + |x_N|^p}$$


- ▶ L0「ノルム」はちょっと変
 - ▶ p->0の極限で定義.
- ▶ L1ノルムは絶対値の和

$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \dots + |x_N|$$

- ▶ L2ノルムはユークリッド距離


$$\|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_N^2}$$





- ▶ L1ノルム最小化で
スパース解は確かに得られる。

- ▶ L1ノルムは尖っている
- ▶ L2ノルムは丸い
- ▶ L_p ノルムでも良い。



$$0 < p \leq 1$$

- ▶ L2ノルム最小化でも劣決定系の
方程式の解が得られる。
- ▶ ノルム最小化による解選択
 - ▶ L1ノルムはスパース解
 - ▶ L2ノルムは大きさが小さい解





- ▶ **L1** ノルム最小化によるスパース解推定法
 - ▶ 基底追跡 (Basis Pursuit)

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = \mathbf{A}\mathbf{x}$$

$$\frac{1}{\alpha} = 1 + \sqrt{\frac{\pi}{2}} t e^{\frac{t^2}{2}} \{1 - 2Q(t)\}$$

$$\frac{\rho}{1 - \rho} = 2 \left(\frac{e^{\frac{t^2}{2}}}{t\sqrt{2\pi}} - Q(t) \right)$$

$$Q(t) = \int_t^{\infty} \frac{e^{-\frac{x^2}{2}}}{\sqrt{2\pi}} dx$$





ノイズ有り圧縮センシング

- ▶ 観測結果にはノイズがつきもの？！
 - ▶ 加法的ノイズが混入した場合


$$\mathbf{y} = \mathbf{A}\mathbf{x} + \sigma_0 \mathbf{w}$$

- ▶ 等式制約はもはや成立しない
 - ▶ LASSO (Least Absolute Shrinkage and Selection Operators)

$$\min_{\mathbf{x}} \left\{ \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2^2 \right\} \quad \text{s.t.} \quad \|\mathbf{x}\|_1 \leq a$$

- ▶ ラグランジュ未定乗数法により等価な最適化問題

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - \mathbf{A}\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$





例題

以下の最小化問題を解け.

$$\min_x \left\{ |x| + \frac{1}{2\lambda} (y - x)^2 \right\}$$

ここで λ, y は適当な実数である.





正解

- ▶ 絶対値関数は場合分けすれば良い
 - ▶ $X > 0$ のときについて平方完成すると以下のようなになる.

$$\frac{1}{2\lambda} \{x - (y - \lambda)\}^2 + y - \frac{\lambda}{2}$$

- ▶ 2次関数の最小値は頂点！？
 - ▶ 頂点の正負により最小値が変わる.




- ▶ 軟判定しきい値関数の導入

$$\min_x \left\{ |x| + \frac{1}{2\lambda} (y - x)^2 \right\}$$

- ▶ この最小化問題の解は、以下の軟判定しきい値関数で与えられる。

$$S_\lambda(y) = \begin{cases} y - \lambda & (y > \lambda) \\ 0 & (-\lambda \leq y \leq \lambda) \\ -y - \lambda & (y < -\lambda) \end{cases}$$




多変数であっても同様

- ▶ L1ノルム、L2ノルムの分離性により

$$\min_{\mathbf{x}} \left\{ |\mathbf{x}| + \frac{1}{2\lambda} \|\mathbf{y} - \mathbf{x}\|_2^2 \right\}$$

- ▶ この最小化問題の解は、軟判定しきい値関数で与えられる。

$$\mathbf{x}^* = S_{\lambda}(\mathbf{y})$$





多変数であっても同様

- ▶ L1ノルム、L2ノルムの分離性により

$$\min_{\mathbf{x}} \left\{ |\mathbf{x}| + \frac{1}{2\lambda} \|\mathbf{y} - \mathbf{x}\|_2^2 \right\}$$


- ▶ この最小化問題の解は、軟判定しきい値関数で与えられる。

$$\mathbf{x}^* = S_{\lambda}(\mathbf{y})$$

- ▶ 分離性は、成分毎の和に分かれること

$$\|\mathbf{x}\|_1 = \|x_1\| + \|x_2\| + \dots + \|x_N\|$$

$$\|\mathbf{x}\|_2^2 = x_1^2 + x_2^2 + \dots + x_N^2$$





問題点

- ▶ 解くべき問題はLASSO型最小化問題

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$

- ▶ ちょっとそのまま軟判定しきい値関数は利用できない





問題点

- ▶ 解くべき問題はLASSO型最小化問題

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$

- ▶ ちょっとそのまま軟判定しきい値関数は利用できない
- ▶ なんとかして分離性を持つ形にしたい。

$$\min_{\mathbf{x}} \left\{ |\mathbf{x}| + \frac{1}{2\lambda} \|\mathbf{v} - \mathbf{x}\|_2^2 \right\}$$



問題点

- ▶ 解くべき問題はLASSO型最小化問題

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$

- ▶ ちょっとそのまま軟判定しきい値関数は利用できない
- ▶ なんとかして分離性を持つ形にしたい。

$$\min_{\mathbf{x}} \left\{ |\mathbf{x}| + \frac{1}{2\lambda} \|\mathbf{v} - \mathbf{x}\|_2^2 \right\}$$

- ▶ そうすれば軟判定しきい値関数を適用できる

$$\mathbf{x}^* = S_{\lambda}(\mathbf{v})$$





メジャライザー最小化

- ▶ 最小化したい関数 $g(\mathbf{x})$ を上からふたするメジャライザーを導入

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + (\nabla g(\mathbf{v}))^T (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

$$g(\mathbf{x}) \leq q_L(\mathbf{x}, \mathbf{v})$$





メジャライザー最小化

- ▶ 最小化したい関数 $g(\mathbf{x})$ を上からふたするメジャライザーを導入

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + (\nabla g(\mathbf{v}))^T (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

$$g(\mathbf{x}) \leq q_L(\mathbf{x}, \mathbf{v})$$

- ▶ メジャライザーは2次関数なので平方完成すれば最小値は即座にわかる



メジャライザー最小化


- ▶ 最小化したい関数 $g(\mathbf{x})$ を上からふたするメジャライザーを導入

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + (\nabla g(\mathbf{v}))^T (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

$$g(\mathbf{x}) \leq q_L(\mathbf{x}, \mathbf{v})$$

- ▶ メジャライザーは2次関数なので平方完成すれば最小値は即座にわかる
- ▶ 逐次メジャライザーの最小化をすると...

$$g(\mathbf{x}[t + 1]) \leq q_L(\mathbf{x}[t + 1], \mathbf{x}[t]) \leq g(\mathbf{x}[t])$$





メジャライザー最小化

- ▶ 最小化したい関数 $g(\mathbf{x})$ を上からふたするメジャライザーを導入

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + (\nabla g(\mathbf{v}))^T (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

$$g(\mathbf{x}) \leq q_L(\mathbf{x}, \mathbf{v})$$


- ▶ メジャライザーは2次関数なので平方完成すれば最小値は即座にわかる
- ▶ 逐次メジャライザーの最小化をすると…

$$g(\mathbf{x}[t + 1]) \leq q_L(\mathbf{x}[t + 1], \mathbf{x}[t]) \leq g(\mathbf{x}[t])$$

- ▶ 本来の最小化したい関数も小さくできる！



メジャライザー逐次最小化のイメージ




QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling

メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING

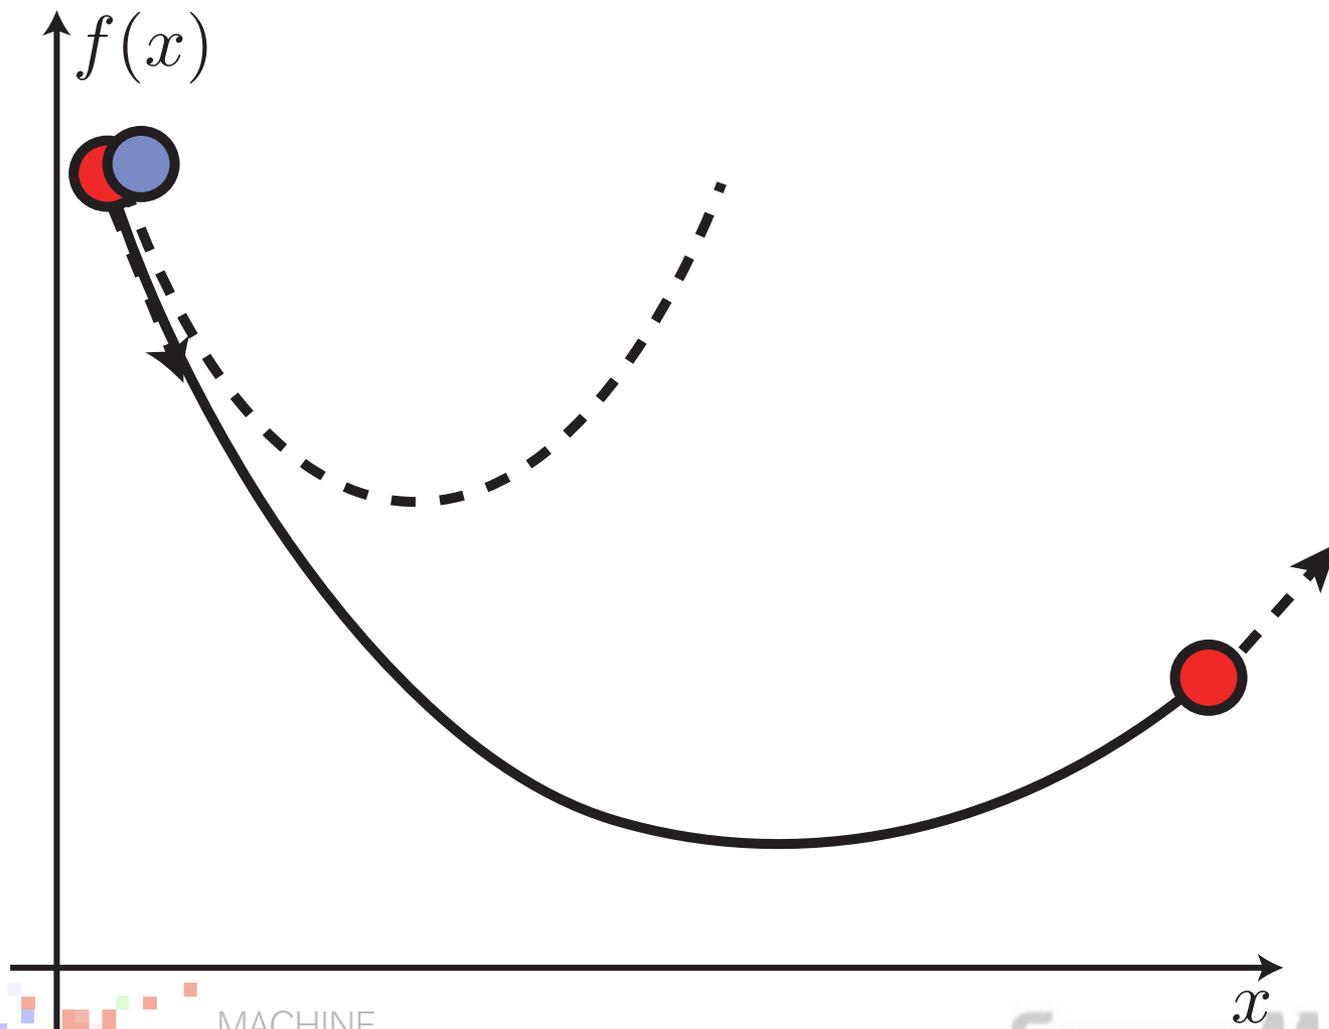


MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING




MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING




MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ




QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling

メジャライザー逐次最小化のイメージ




QUANTUM ANNEALING

MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING




MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING




MACHINE LEARNING

Sparse Modeling



メジャライザー逐次最小化のイメージ



QUANTUM ANNEALING



MACHINE LEARNING

Sparse Modeling



LASSOにメジャライザー最小化

- ▶ L1ノルムが追加されてもメジャライザーの性質は崩れない。

$$g(\mathbf{x}) + \|\mathbf{x}\|_1 \leq q_L(\mathbf{x}, \mathbf{v}) + \|\mathbf{x}\|_1$$

- ▶ メジャライザー逐次最小化を用いて、LASSOを解こう！

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$



LASSOにメジャライザー最小化

- ▶ L1ノルムが追加されてもメジャライザーの性質は崩れない。

$$g(\mathbf{x}) + \|\mathbf{x}\|_1 \leq q_L(\mathbf{x}, \mathbf{v}) + \|\mathbf{x}\|_1$$

- ▶ メジャライザー逐次最小化を用いて、LASSOを解こう！

$$\min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \|\mathbf{x}\|_1 \right\}$$

▶ 方針

- ▶ メジャライザー+L1ノルムを用意する。

$$g(\mathbf{x}) + \|\mathbf{x}\|_1 \leq q_L(\mathbf{x}, \mathbf{x}[t]) + \|\mathbf{x}\|_1$$

- ▶ メジャライザー+L1ノルムの最小解を得る。

$$\mathbf{x}[t+1] = \arg \min_{\mathbf{x}} \{ q_L(\mathbf{x}, \mathbf{x}[t]) + \|\mathbf{x}\|_1 \}$$

- ▶ メジャライザーを更新する。

$$q_L(\mathbf{x}, \mathbf{x}[t+1])$$



▶ LASSOの場合 $g(\mathbf{x}) = \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2$

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + \frac{A^T A}{\lambda} (\mathbf{y} - A\mathbf{v}) (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$




LASSOにメジャライザー最小化

▶ LASSOの場合 $g(\mathbf{x}) = \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2$

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + \frac{A^T A}{\lambda} (\mathbf{y} - A\mathbf{v}) (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

▶ 平方完成してメジャライザー+L1ノルム最小解を求める

$$\mathbf{x}[t+1] = \arg \min_{\mathbf{x}} \left\{ \frac{L}{2} \left\{ \mathbf{x} - \left(\mathbf{x}[t] + \frac{1}{L\lambda} A^T (\mathbf{y} - A\mathbf{x}[t]) \right) \right\}^2 + \|\mathbf{x}\|_1 \right\}$$



LASSOにメジャライザー最小化

▶ LASSOの場合 $g(\mathbf{x}) = \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2$

$$q_L(\mathbf{x}, \mathbf{v}) = g(\mathbf{v}) + \frac{A^T A}{\lambda} (\mathbf{y} - A\mathbf{v}) (\mathbf{x} - \mathbf{v}) + \frac{L}{2} \|\mathbf{x} - \mathbf{v}\|_2^2$$

▶ 平方完成してメジャライザー+L1ノルム最小解を求める

$$\mathbf{x}[t+1] = \arg \min_{\mathbf{x}} \left\{ \frac{L}{2} \left\{ \mathbf{x} - \left(\mathbf{x}[t] + \frac{1}{L\lambda} A^T (\mathbf{y} - A\mathbf{x}[t]) \right) \right\}^2 + \|\mathbf{x}\|_1 \right\}$$

▶ 分離性を持つ形であるので軟判定しきい値関数を適用するだけ。

$$\mathbf{x}[t+1] = S_{1/L} \left(\mathbf{x}[t] + \frac{1}{L\lambda} A^T (\mathbf{y} - A\mathbf{x}[t]) \right)$$



1. $t = 0$ とする. 初期化 $\mathbf{x}[0]$. (例えば $\mathbf{x}[0] = A^T \mathbf{y}$)
2. 平方完成により $g(\mathbf{x})$ の 2 次関数近似の頂点を求める.

$$\mathbf{v}[t] = \mathbf{x}[t] + \frac{1}{L\lambda} A^T (\mathbf{y} - A\mathbf{x}[t])$$

3. 軟判定しきい値関数を適用する.

$$\mathbf{x}[t + 1] = S_{1/L} (\mathbf{v}[t])$$

4. 終了基準を満たすまでステップ 2-4 を繰り返す.

FISTA: Fast Iterative Shrinkage Thresholding Algorithm

1. $t = 1$ とする. 初期化 $\mathbf{x}[0]$ 、 $\beta[1] = 0$ 、 $\mathbf{w}[1] = \mathbf{x}[0]$
2. 平方完成により $g(\mathbf{x})$ の 2 次関数近似の頂点を求める.

$$\mathbf{v}[t] = \mathbf{w}[t] + \frac{1}{L\lambda} A^T (\mathbf{y} - A\mathbf{w}[t])$$

3. 軟判定しきい値関数を適用する.

$$\mathbf{x}[t + 1] = S_{1/L} (\mathbf{v}[t])$$

4. [高速化部分] $\beta[t]$ を更新する.

$$\beta[t] = \frac{1}{2} \left(1 + \sqrt{1 + 4(\beta[t - 1])^2} \right)$$

5. [高速化部分] $\mathbf{w}[t]$ を更新する.

$$\mathbf{w}[t + 1] = \mathbf{x}[t + 1] + \frac{\beta[t] - 1}{\beta[t + 1]} (\mathbf{x}[t + 1] - \mathbf{x}[t])$$


6. 終了基準を満たすまでステップ 2-6 を繰り返す.

メジャライザーは存在するか？

- ▶ そんな都合のいい関数あるのか？
 - ▶ メジャライザーの存在条件
 - ▶ 微分がリプシッツ定数Lのリプシッツ連続であればよい。

$$\|\nabla g(\mathbf{x}) - \nabla g(\mathbf{v})\|_2 \leq L \|\mathbf{x} - \mathbf{v}\|_2$$

- ▶ LASSOの場合、全領域で
 $L = A^T A / \lambda$ が示される
- ▶ 区分的に上から押さえてもよい



▶ 罰金法

- ▶ 古典的制約つき最適化問題の解法

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + g(\mathbf{x}) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{x}[t]\|_2^2 \right\}$$

- ▶ 暫定解に近いところで最適解を探索させる.
- ▶ 罰金項の係数 μ が大きいと、制約条件に忠実





ISTAの別解釈

▶ 罰金法

▶ 古典的制約つき最適化問題の解法

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + g(\mathbf{x}) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{x}[t]\|_2^2 \right\}$$

- ▶ 暫定解に近いところで最適解を探索させる.
- ▶ 罰金項の係数 μ が大きいと、制約条件に忠実

▶ ISTA = 罰金法 + 線形近似

▶ コスト関数を暫定解付近で展開

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + g(\mathbf{x}[t]) + (\nabla g(\mathbf{x}[t]))^T (\mathbf{x} - \mathbf{x}[t]) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{x}[t]\|_2^2 \right\}$$



基底追跡の解法

- ▶ ノイズなし圧縮センシング
 - ▶ 基底追跡

$$\min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}_0$$

- ▶ 制約条件ありの最適化問題
 - ▶ ラグランジュ未定乗数

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + (\mathbf{h}[t])^T (\mathbf{y} - A\mathbf{x}) \right\}$$

- 最小化のときは正の乗数、最大化のときは負の乗数
- 未定乗数の更新と最適化にかかる変数の更新でやや不安定

- ▶ 罰金法

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + \frac{\mu}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$

- 罰金係数を徐々に大きくしていかなければならない



▶ 拡張ラグランジュ法

- ▶ ラグランジュ未定乗数と罰金法の組み合わせ

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + (\mathbf{h}^T) (\mathbf{y} - A\mathbf{x}) + \frac{\mu}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$

- ▶ ラグランジュ未定乗数の更新則

$$\mathbf{h}[t + 1] = \mathbf{h}[t] + \mu[t] (\mathbf{y} - A\mathbf{x})$$

- ▶ 罰金係数をそこまで大きくしなくてもよい。
- ▶ 未定乗数の計算が安定化する。



▶ 拡張ラグランジュ法

- ▶ ラグランジュ未定乗数と罰金法の組み合わせ

$$\min_{\mathbf{x}} \left\{ \|\mathbf{x}\|_1 + (\mathbf{h}^T) (\mathbf{y} - A\mathbf{x}) + \frac{\mu}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 \right\}$$

- ▶ ラグランジュ未定乗数の更新則

$$\mathbf{h}[t + 1] = \mathbf{h}[t] + \mu[t] (\mathbf{y} - A\mathbf{x})$$

- ▶ 罰金係数をそこまで大きくしなくてもよい
- ▶ 未定乗数の計算が安定化する

▶ Bregman反復法と等価である





最近の進展

- ▶ ADMM(Alternating Direction Method of Multipliers)
 - ▶ ふたつのコスト関数の最適化問題を解く方法

$$\min_{\mathbf{x}} \{ f(\mathbf{x}) + g(\mathbf{x}) \}$$

- ▶ 制約条件ありの最適化問題へ敢えて変更する

$$\min_{\mathbf{x}} \{ f(\mathbf{z}) + g(\mathbf{x}) \} \quad \text{s.t.} \quad \mathbf{x} - \mathbf{z} = \mathbf{0}$$

- ▶ LASSOであれば、

$$f(\mathbf{x}) = \|\mathbf{x}\|_1 \quad g(\mathbf{x}) = \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2$$

- ▶ 拡張ラグランジュ法をちょっと適当にやる

$$\min_{\mathbf{x}, \mathbf{z}} \left\{ f(\mathbf{z}) + g(\mathbf{x}) + (\mathbf{h}^T) (\mathbf{x} - \mathbf{z}) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{z}\|_2^2 \right\}$$

$$\mathbf{h}[t + 1] = \mathbf{h}[t] + \mu (\mathbf{x} - \mathbf{z})$$

- ▶ 拡張ラグランジュ法との違い
 - 罰金係数は適当な値で**固定**
 - ふたつの変数についての最適化を**交互にやる**

$$\mathbf{x}[t + 1] = \arg \min_{\mathbf{x}} \left\{ f(\mathbf{z}[t]) + g(\mathbf{x}) + (\mathbf{h}[t])^T (\mathbf{x} - \mathbf{z}[t]) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{z}[t]\|_2^2 \right\}$$

$$\mathbf{z}[t + 1] = \arg \min_{\mathbf{z}} \left\{ f(\mathbf{z}) + g(\mathbf{x}[t + 1]) + (\mathbf{h}[t])^T (\mathbf{x}[t + 1] - \mathbf{z}) + \frac{\mu}{2} \|\mathbf{x}[t + 1] - \mathbf{z}\|_2^2 \right\}$$





ADMM for LASSO

- ▶ それぞれ解を代入するだけで求められる
 - ▶ Xについては二次関数に過ぎない=平方完成、微分

$$\mathbf{x}[t + 1] = \arg \min_{\mathbf{x}} \left\{ \frac{1}{2\lambda} \|\mathbf{y} - A\mathbf{x}\|_2^2 + (\mathbf{h}[t])^T (\mathbf{x} - \mathbf{z}[t]) + \frac{\mu}{2} \|\mathbf{x} - \mathbf{z}[t]\|_2^2 \right\}$$

- 単純更新

$$\mathbf{x}[t + 1] = \left(\mu + \frac{1}{\lambda} A^T A \right)^{-1} (A^T \mathbf{y} + \mu \mathbf{z}[t] - \mathbf{h}[t])$$

- ▶ Zについては分離性がきく=軟判定しきい値関数

$$\mathbf{z}[t + 1] = \arg \min_{\mathbf{z}} \left\{ \|\mathbf{z}\|_1 + (\mathbf{h}[t])^T (\mathbf{x}[t + 1] - \mathbf{z}) + \frac{\mu}{2} \|\mathbf{x}[t + 1] - \mathbf{z}\|_2^2 \right\}$$

- 単純更新

$$\mathbf{z}[t + 1] = S_{1/\mu} \left(\mathbf{x}[t + 1] - \frac{\mathbf{h}[t]}{\mu} \right)$$

- Hも単純更新

$$\mathbf{h}[t + 1] = \mathbf{h}[t] + \mu(\mathbf{x}[t] - \mathbf{z}[t])$$





レポート問題

- ▶ どれかのアルゴリズムを実際の実装して動作確認せよ
 - ▶ FISTAまたはISTA
 - LASSO型最適化問題なのでノイズ有り圧縮センシング
 - ▶ 拡張ラグランジュ法またはBregman反復法
 - BP型最適化問題なのでノイズなし圧縮センシング
 - ▶ ADMM
 - LASSO型最適化問題なのでノイズ有り圧縮センシング
- ▶ 実験手法 (N=1000, K=20, M=100とする)
 - ▶ X_0 の成分をK個だけ1を、それ以外0とする.
 - ▶ Aの各成分を正規分布から生成させる.
 - ▶ $Y=A*X_0$ を計算する. (ノイズ有りなら $N(0, <0.1)$ に従うノイズを印可)
 - ▶ この条件のもと、それぞれのアルゴリズムでXを計算する.

