

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  $\lambda, y$  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



- ▶ 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

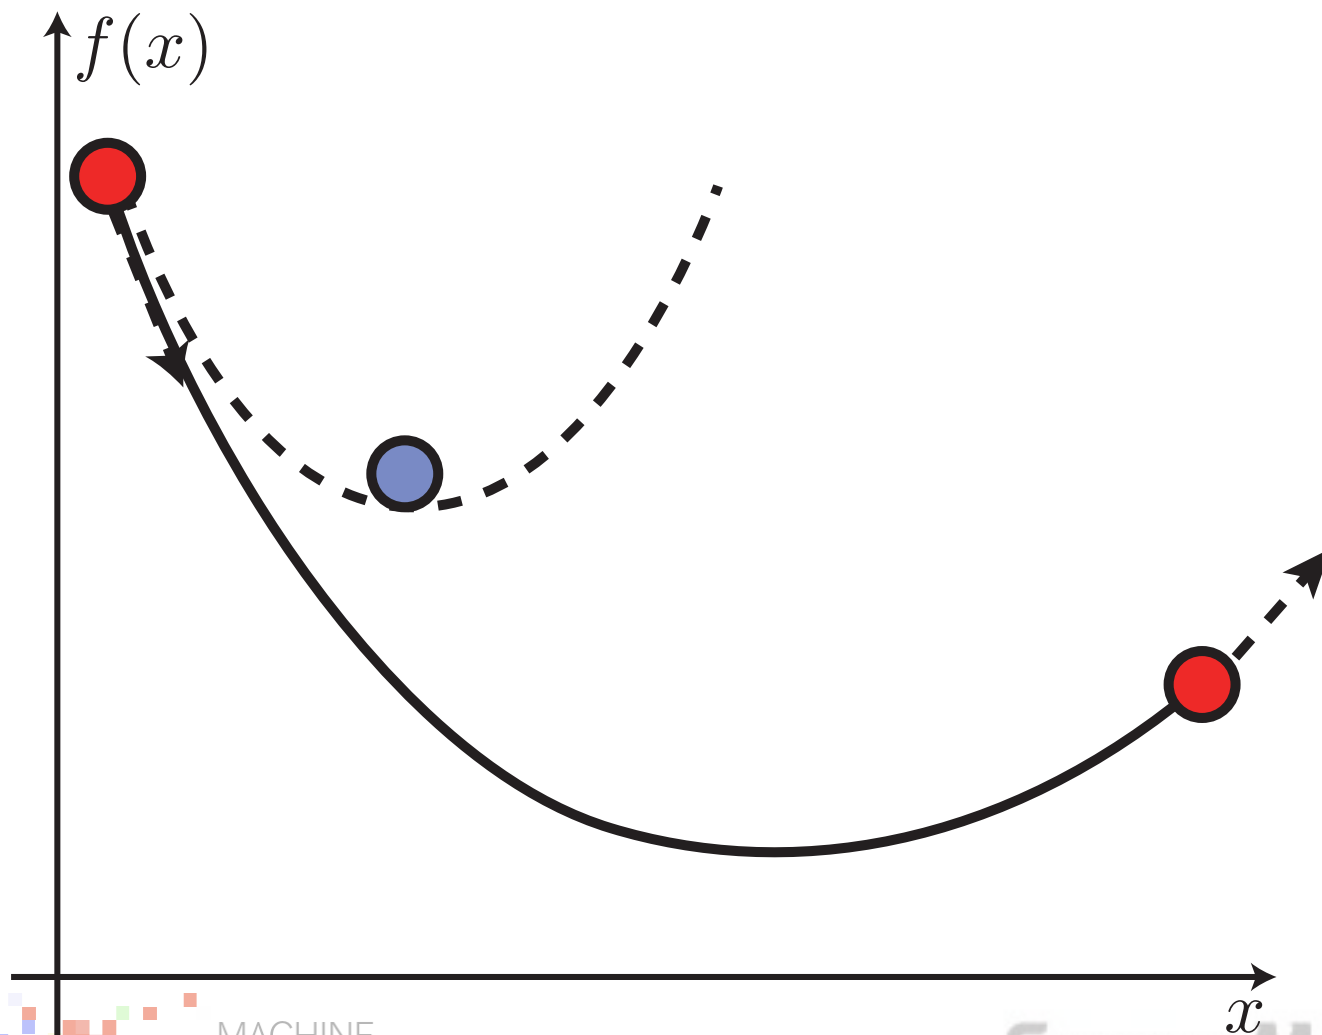


MACHINE LEARNING


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

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





# 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.

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

QUANTUM ANNEALING 6. 終了基準を満たすまでステップ 2-6 を繰り返す.  
MACHINE LEARNING

*Sparse Modeling*

# メジャライザーは存在するか？

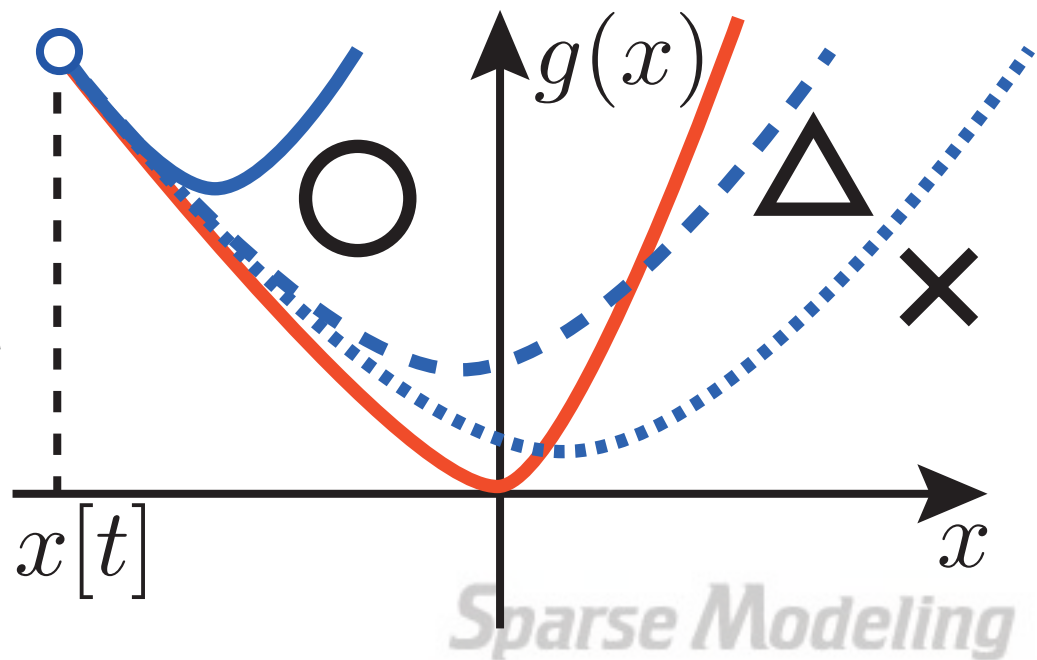
- ▶ そんな都合のいい関数あるのか？
  - ▶ メジャライザーの存在条件
    - ▶ 微分がリプシッツ定数Lのリプシッツ連続であればよい。

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

- ▶ LASSOの場合、全領域で

$$L = A^T A / \lambda \text{ が示される}$$

- ▶ 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 $\mu$ 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 $\mu$ 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**

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

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



- ▶ 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.

