

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

# 第一部：圧縮センシング

中学生の頃の思い出

中学生の頃の思い出  
連立方程式

$$2x_1 + x_2 = 1$$

を満たす解を求めよ

$$2x_1 + x_2 = 1$$

を満たす解を求めよ

(一意には) できません

$$2x_1 + x_2 = 1$$

を満たす解を求めよ

(一意には) できません

式が足りないから

$$2x_1 + x_2 = 1$$


を満たす解を求めよ

(一意には) できません

式が足りないから


情報が足りないから






$$y = Ax$$

を満たす解を求めよ




$$y = Ax$$

を満たす解を求めよ  
逆行列があるからOK




$$y = Ax$$

を満たす解を求めよ



$$y = Ax$$


を満たす解を求めよ  
(一意には) できません



$$y = Ax$$


を満たす解を求めよ  
(一意には) できません  
劣決定系

スパース性があるときは？



$$y = Ax$$


を満たす解を求めよ



$$y = Ax$$

を満たす解を求めよ  
できる！





$$y = Ax$$

を満たす解を求めよ  
できる！



# 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





# 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





# 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！

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



- ▶ 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）



- ▶  $L_p$ ノルムの定義

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

- ▶  $L_0$ 「ノルム」はちょっと変
  - ▶  $p \rightarrow 0$ の極限で定義.
- ▶  $L_1$ ノルムは絶対値の和

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

- ▶  $L_2$ ノルムはユークリッド距離

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





# スパース解推定?

- ▶ L2ノルム最小化によるスパース解推定は？
  - ▶ 以下の最小化問題でスパース解を探索しよう！

$$\min_{\mathbf{x}} \|\mathbf{x}\|_2 \quad \text{s.t.} \quad \mathbf{y} = A\mathbf{x}$$

- ▶ 零が多ければ小さい+大きさがかなり小さくなりがち+小さいかすが残る
- ▶ 計算量は非常に軽い (Nの2~3乗程度)



以下のふたつの最小化問題を解いてみよう。

$$\min_{x_1, x_2} \{|x_1| + |x_2|\} \quad \text{s.t.} \quad y = Ax$$

$$\min_{x_1, x_2} \left\{ \sqrt{x_1^2 + x_2^2} \right\} \quad \text{s.t.} \quad y = Ax$$

ここで観測行列  $A$  は、単なる行ベクトルに過ぎず、

$$A = ( 2 \quad 1 )$$


とする。  $y = 1$  とする。









# 正解



$$(x_1, x_2) = (1/2, 0)$$




$$(x_1, x_2) = (2/5, 1/5)$$




▶ 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。




$$0 < p \leq 1$$





- ▶ 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)

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

- ▶ L1 ノルムは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)





注意

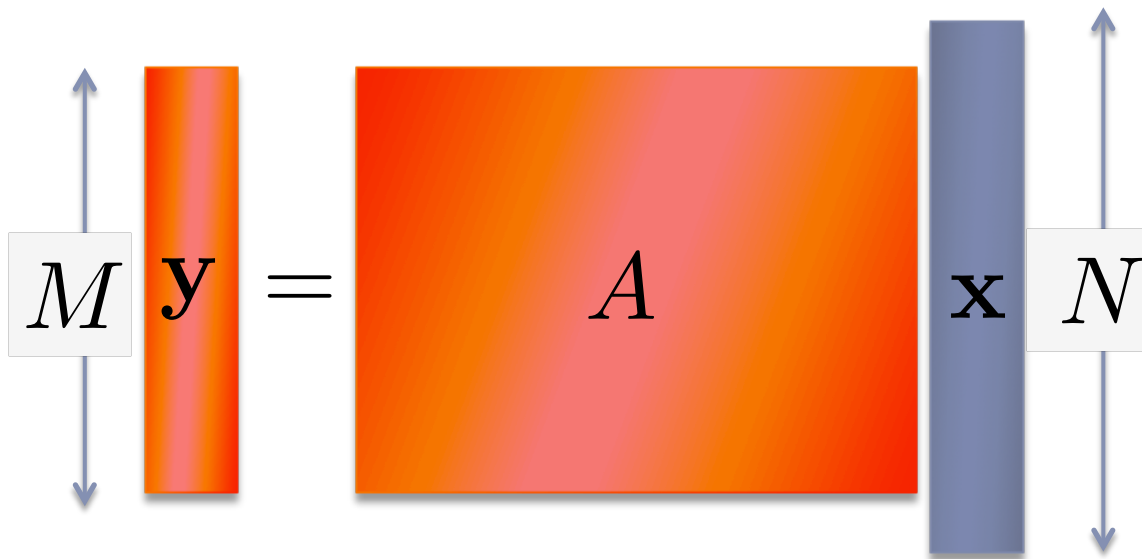
圧縮センシング = L1 ノルム最小化ではない

QUANTUM  
ANNEALING



MACHINE  
LEARNING

*Sparse Modeling*



足りない観測情報  
 $y = Ax$   
の結果から推定せよ



## 例題CS-II

スパースな原信号ベクトル  $\mathbf{x}_0^T = (1/2, 0)$  に対して、 $A = (2, 1)$  を作用して得られる  $y = A\mathbf{x}_0 = 1$  のみが得られているとする。基底追跡により、スパース解を選択することにより原信号ベクトルを推定せよ。




## 例題CS-II

スパースな原信号ベクトル  $\mathbf{x}_0^T = (1/2, 0)$  に対して、 $A = (2, 1)$  を作用して得られる  $y = A\mathbf{x}_0 = 1$  のみが得られているとする。基底追跡により、スパース解を選択することにより原信号ベクトルを推定せよ。

▶ 正解はもちろん

$$(x_1, x_2) = (1/2, 0)$$






## 例題CS-II

スパースな原信号ベクトル  $\mathbf{x}_0^T = (1/2, 0)$  に対して、 $A = (2, 1)$  を作用して得られる  $y = A\mathbf{x}_0 = 1$  のみが得られているとする。基底追跡により、スパース解を選択することにより原信号ベクトルを推定せよ。

- ▶ 正解はもちろん

$$(x_1, x_2) = (1/2, 0)$$

- ▶ では原信号ベクトルが  $(0, 1)$  だったら??
  - ▶ 外れている…




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

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

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

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



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





# 実践例


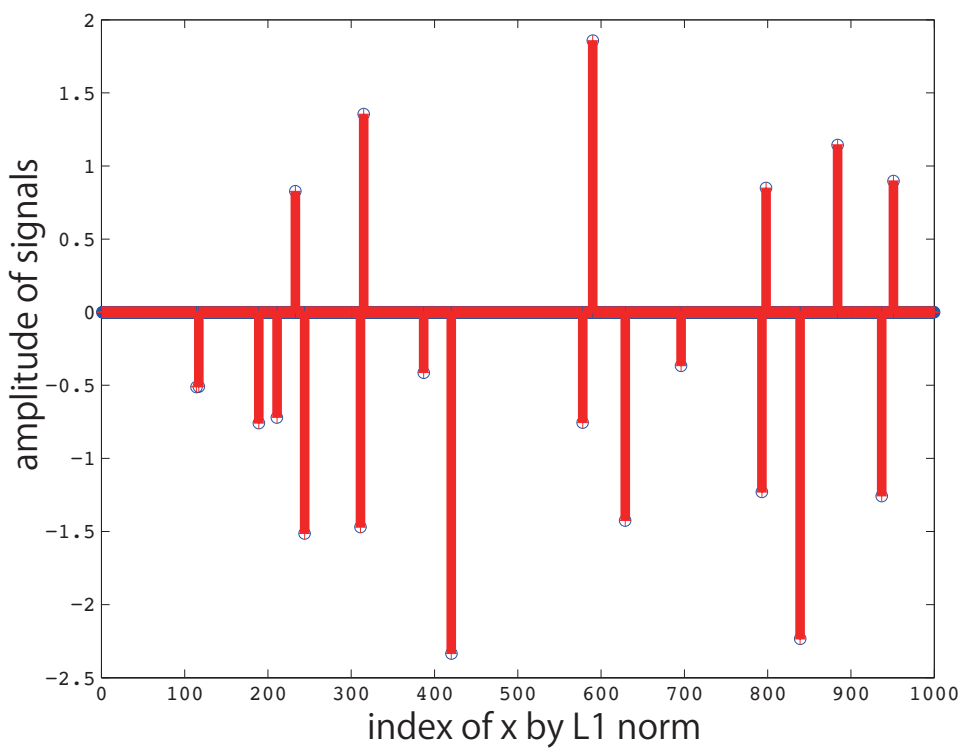
- ▶ 基底追跡 (M=100, N=1000, K=20, ガウスランダム観測行列)





# 実践例

▶ 基底追跡 (M=100, N=1000, K=20, ガウスランダム観測行列)



QUANTUM ANNEALING  MACHINE LEARNING

*Sparse Modeling*



# 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

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



# 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)

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



# 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

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





# そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

QUANTUM  
ANNEALING



MACHINE  
LEARNING


*Sparse Modeling*



# そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？
  - ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$



MRI画像の例

*Sparse Modeling*

# そもそも解はスパースなの？

▶ 観測したいものは本当にスパースだろうか？

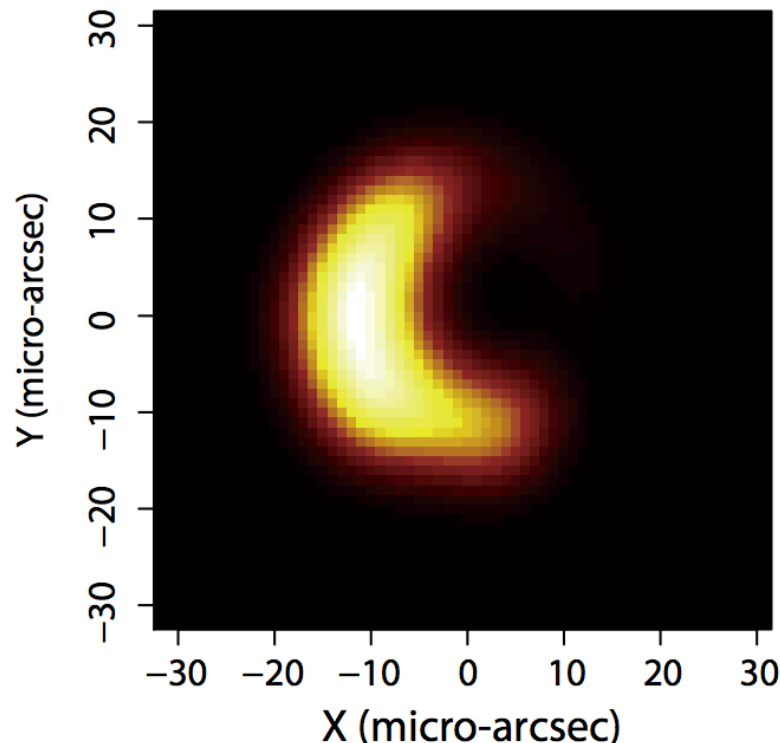
▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

▶ 隣接間差分のスパース性

$$\|\mathbf{TV}(\mathbf{x})\|_1$$

super-resolution image



ブラックホール撮像の例

M. Honma et al. Publ. Astron. Soc. Jpn. (2014)



# そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？
  - ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

- ▶ 隣接間差分のスパース性

$$\|\mathbf{TV}(\mathbf{x})\|_1$$

original image



自然画像の例

*Sparse Modeling*



# そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

- ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

- ▶ 隣接間差分のスパース性

$$\|\mathbf{TV}(\mathbf{x})\|_1$$

- ▶ ウェーブレット変換によるスパース性

$$\|\mathbf{W}(\mathbf{x})\|_1$$



自然画像の例

*Sparse Modeling*



# そもそも解はスパースなの？

▶ 観測したいものは本当にスパースだろうか？

▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$


▶ 隣接間差分のスパース性

$$\|\mathbf{TV}(\mathbf{x})\|_1$$

▶ ウェーブレット変換によるスパース性

$$\|\mathbf{W}(\mathbf{x})\|_1$$

reconstructed image



# そもそも解はスパースなの？

- ▶ 観測したいものは本当にスパースだろうか？

- ▶ 実空間でのスパース性

$$\|\mathbf{x}\|_1$$

- ▶ 隣接間差分のスパース性


$$\|\mathbf{TV}(\mathbf{x})\|_1$$

- ▶ ウェーブレット変換によるスパース性

$$\|\mathbf{W}(\mathbf{x})\|_1$$

- ▶ **スパースモデリングで獲得するスパース性**


reconstructed image




# そもそも解はスパースなの？

## ▶ 実践例


original image





reconstructed image( $\lambda=1$ )



reconstructed image( $\lambda=10$ )




reconstructed image( $\lambda=100$ )



# そもそも解はスパースなの？

## ▶ 実践例







# そもそも線形観測なの？

- ▶ 観測過程は線形変換で書かれるのか？

QUANTUM  
ANNEALING




MACHINE  
LEARNING

*Sparse Modeling*

# そもそも線形観測なの？

- ▶ 観測過程は線形変換で書かれるのか？
  - ▶ フーリエ変換部分行列+コイル強度

$$\mathbf{y} = \mathbf{F} \mathbf{R} \mathbf{x}_0 + \sigma_0 \mathbf{w}$$



MRI画像の例

*Sparse Modeling*

# そもそも線形観測なの？

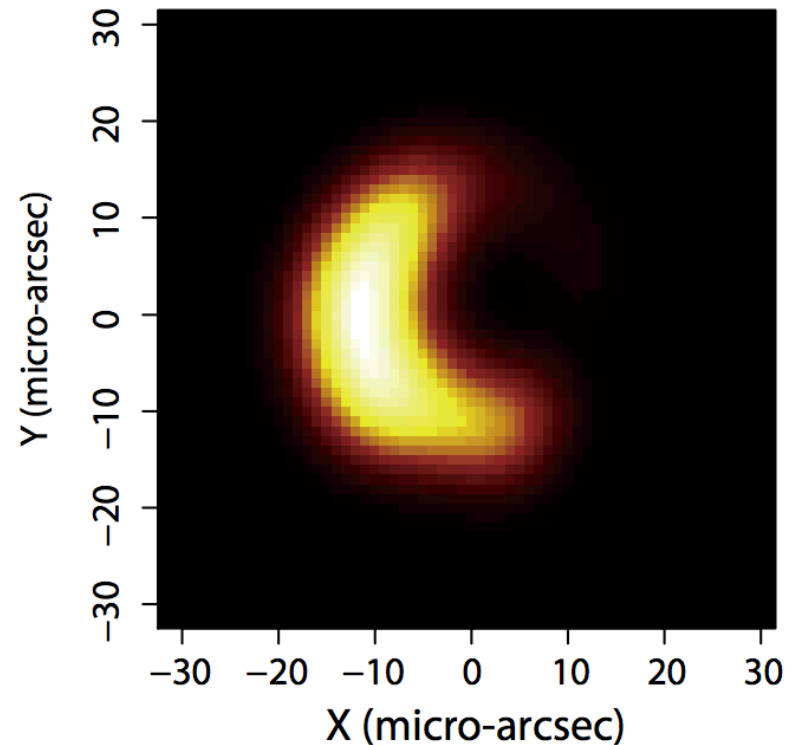
- ▶ 観測過程は線形変換で書かれるのか？
  - ▶ フーリエ変換部分行列+コイル強度

$$\mathbf{y} = F R \mathbf{x}_0 + \sigma_0 \mathbf{w}$$

- ▶ フーリエ変換部分行列+天候要素

$$\mathbf{y} = F R \mathbf{x}_0 + \sigma_0 \mathbf{w}$$

super-resolution image



ブラックホール撮像の例

*Sparse Modeling*

# そもそも線形観測なの？

▶ 観測過程は線形変換で書かれるのか？

▶ フーリエ変換部分行列+コイル強度


$$y = FRx_0 + \sigma_0 w$$

▶ フーリエ変換部分行列+天候要素

$$y = FRx_0 + \sigma_0 w$$

▶ **デザインした**観測

$$y = Ax_0 + \sigma_0 w$$



Lenseless camera

G. Huang et al: arXiv:1305.7181

