

マルチメディア情報ハイディング・エンリッチメント研究会 (EMM)

知的情報処理の最前線 -スパースモデリング vs 深層学習-

東北大学大学院情報科学研究科応用情報科学専攻

大関 真之



Sparse Modeling



QUANTUM ANNEALING



MACHINE LEARNING



世の中で何が起きているのか？

世の中で何が起きているのか？
人工知能？

世の中で何が起きているのか？

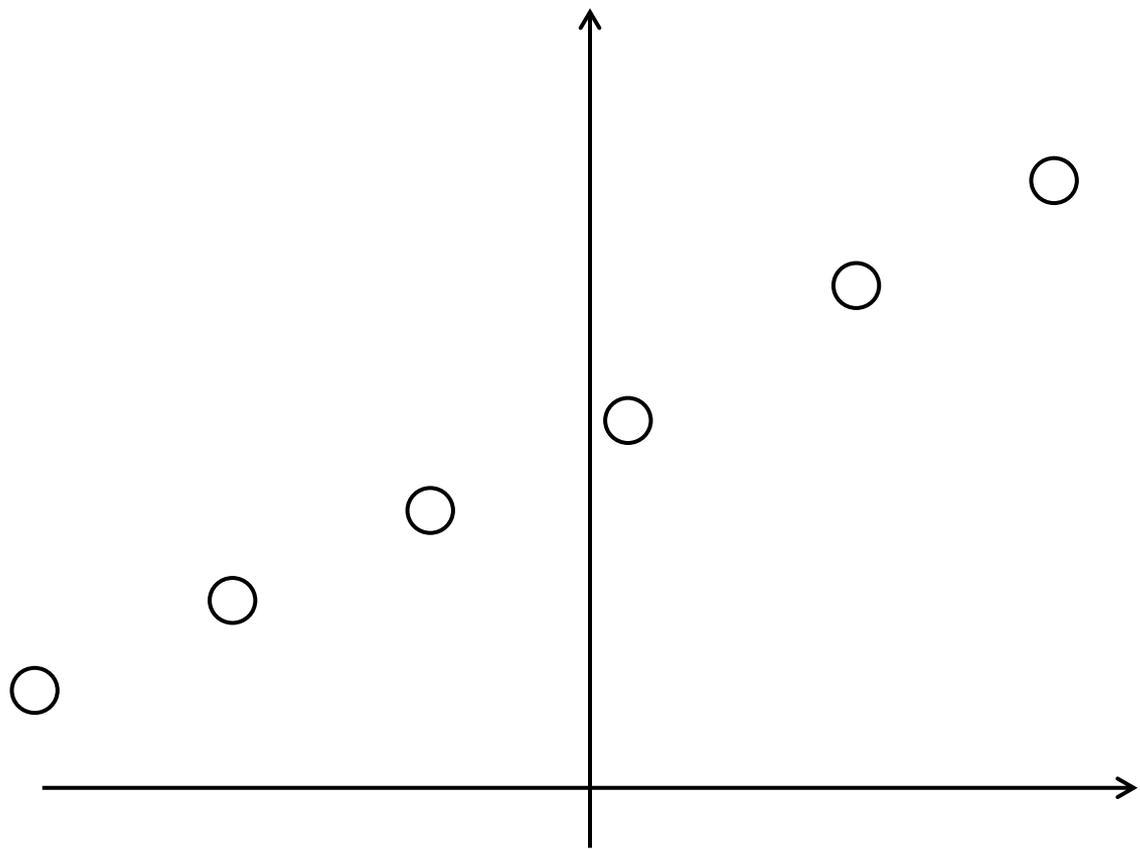
逆問題の解決

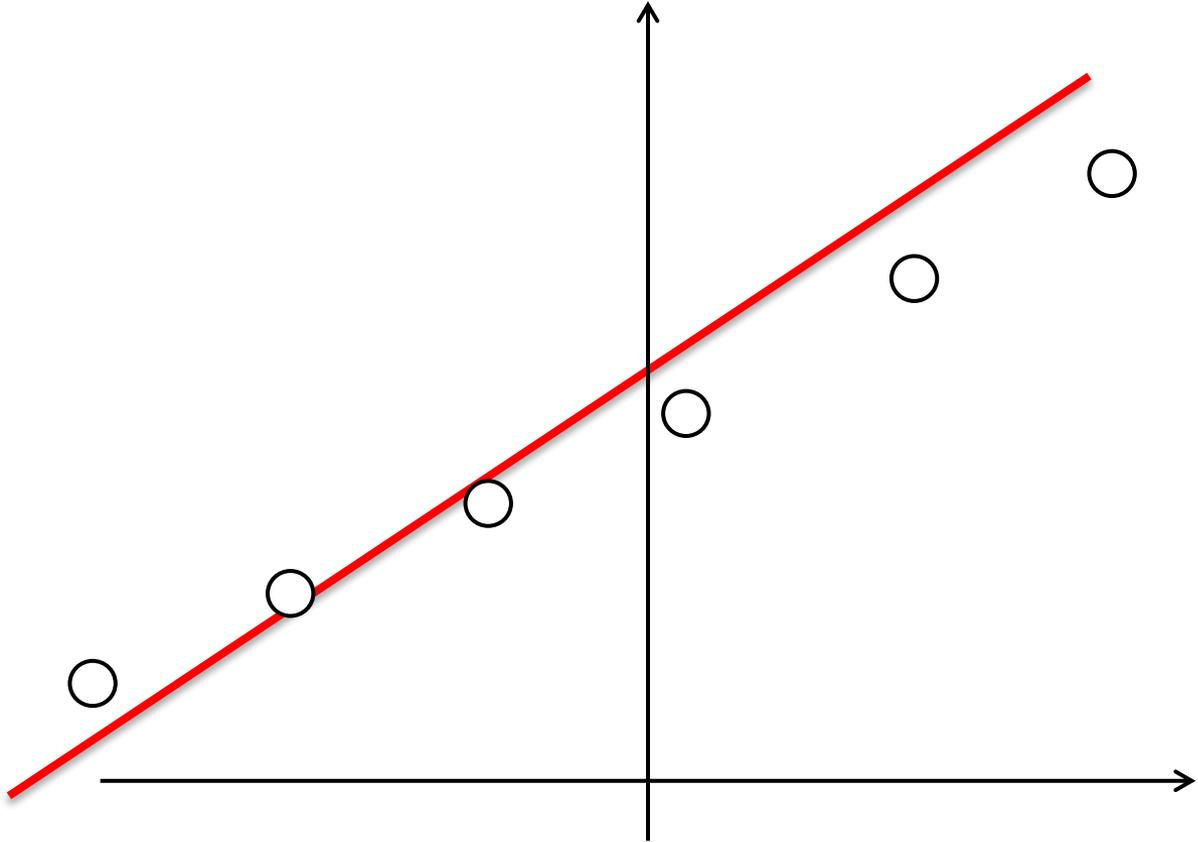
$$y = f(\mathbf{x})$$

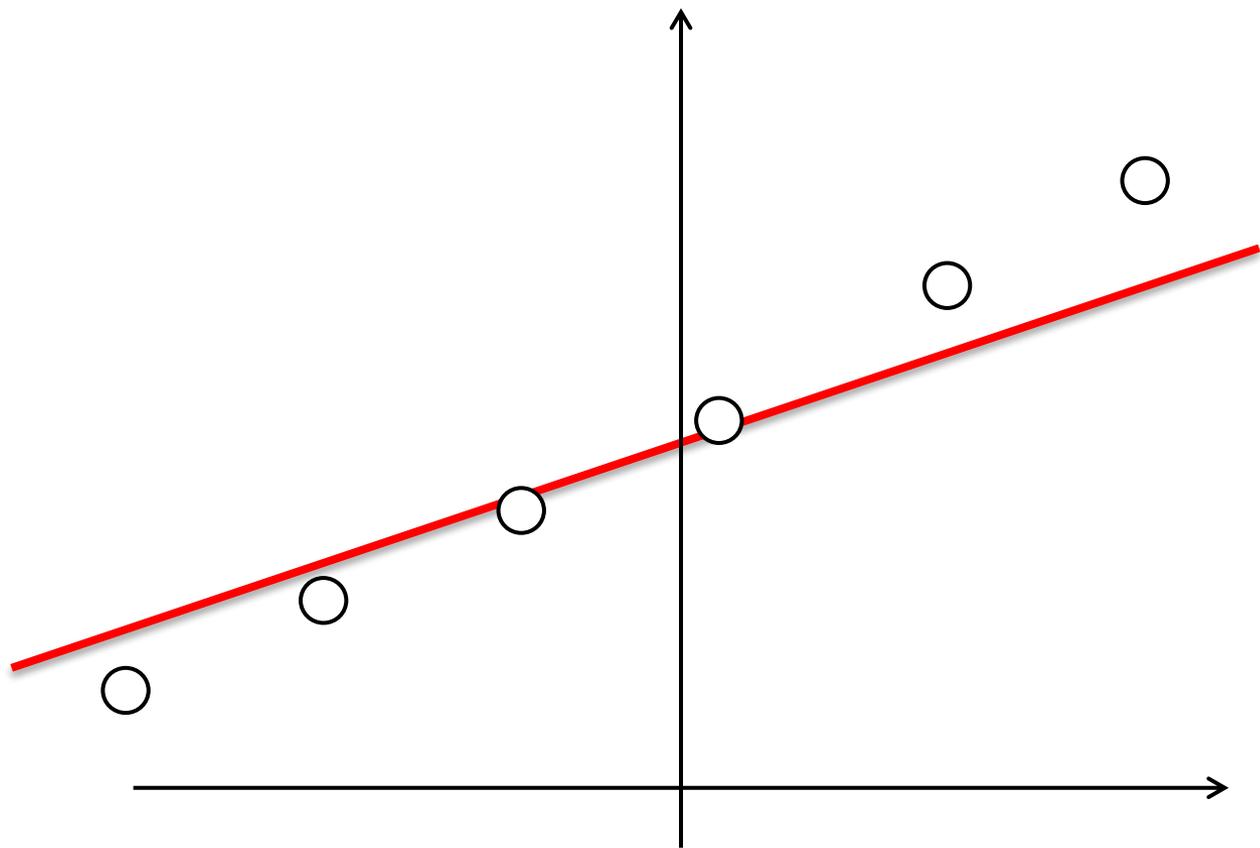
世の中で何が起きているのか？

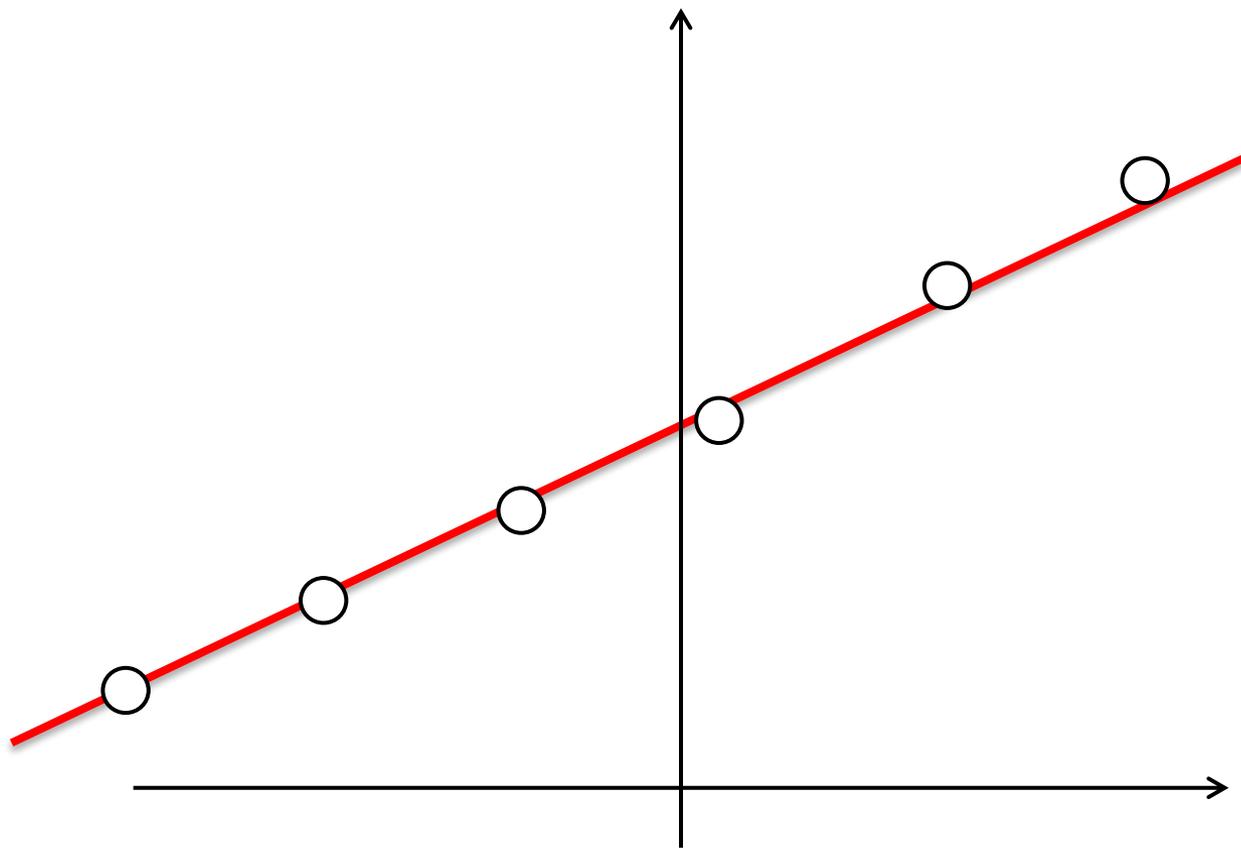
逆問題の解決

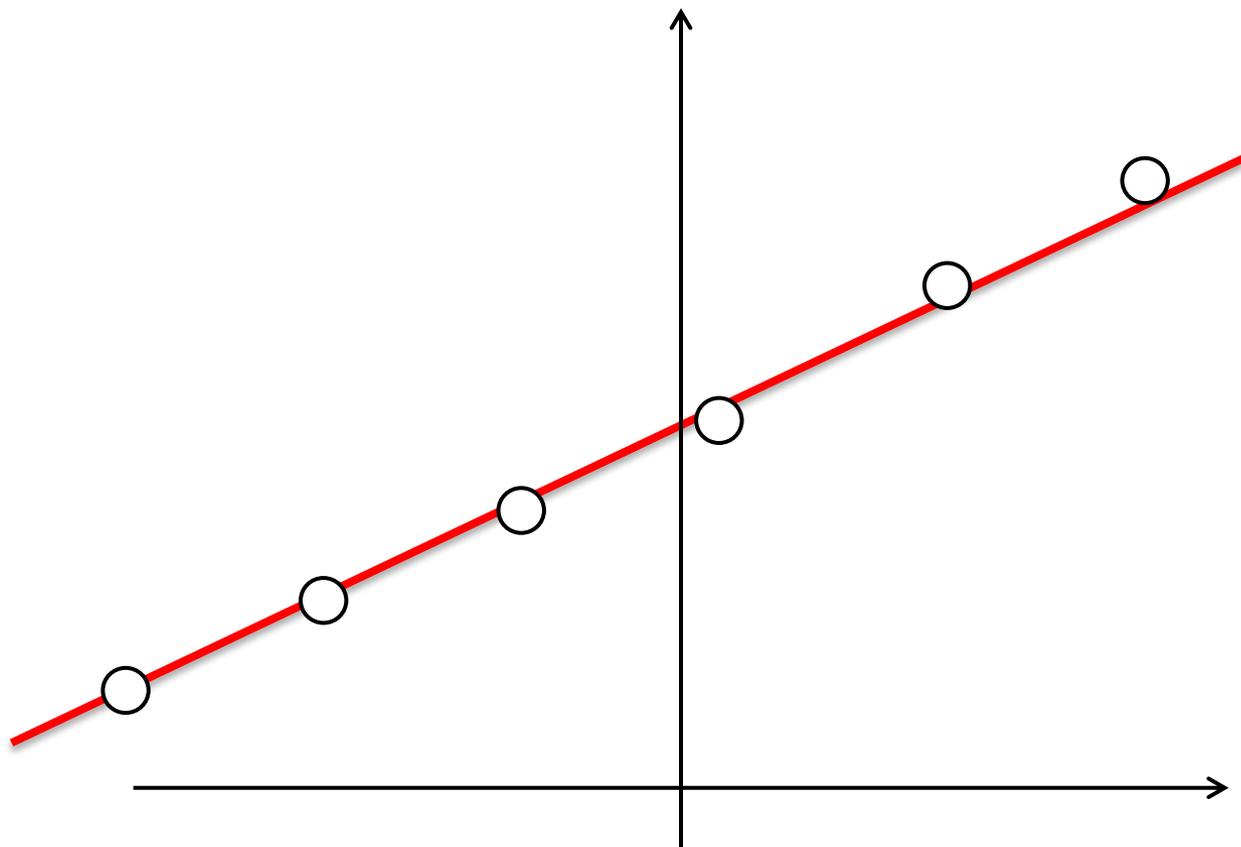
$$y = f(\mathbf{x})$$





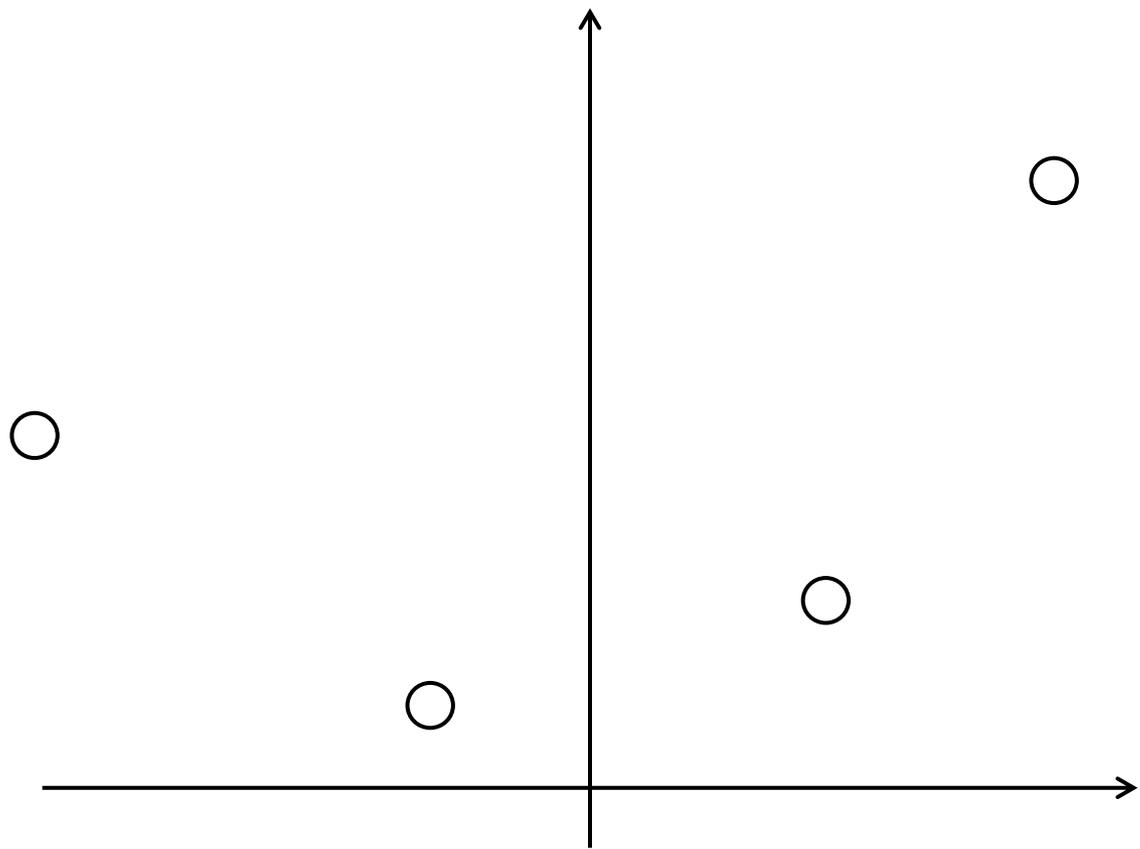


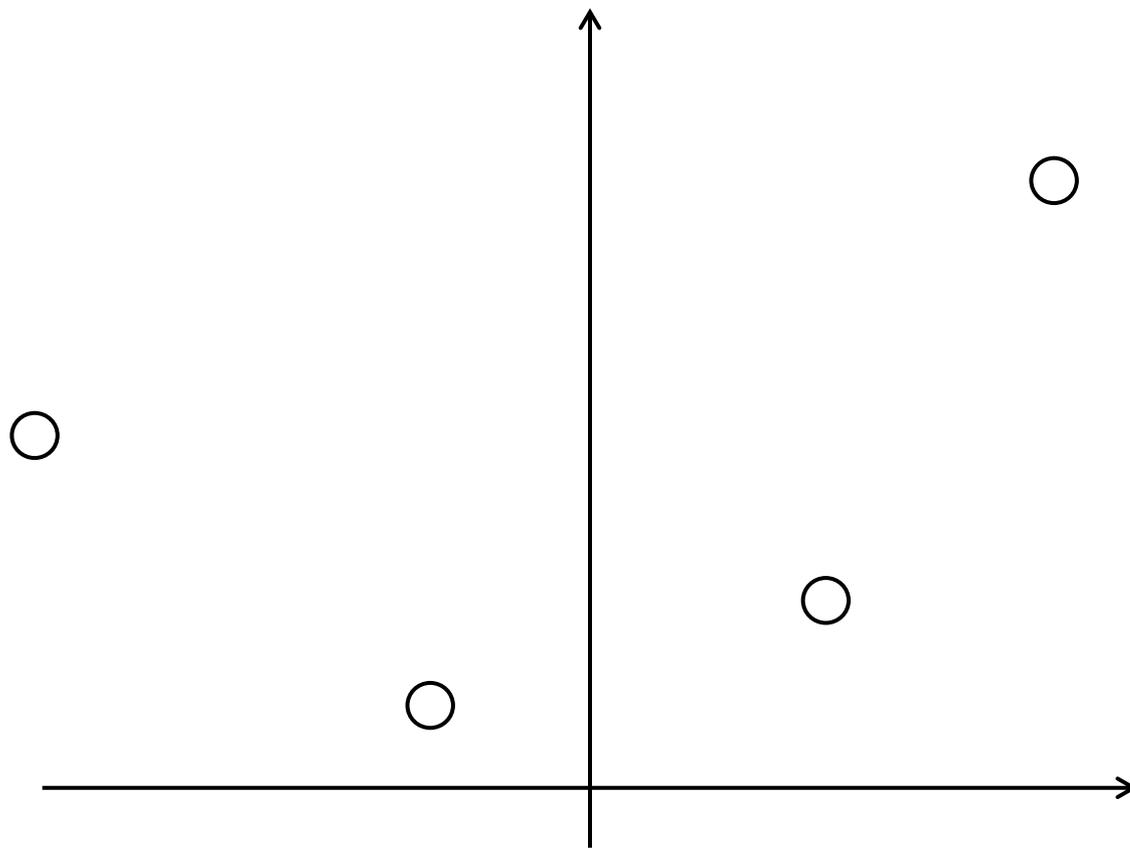




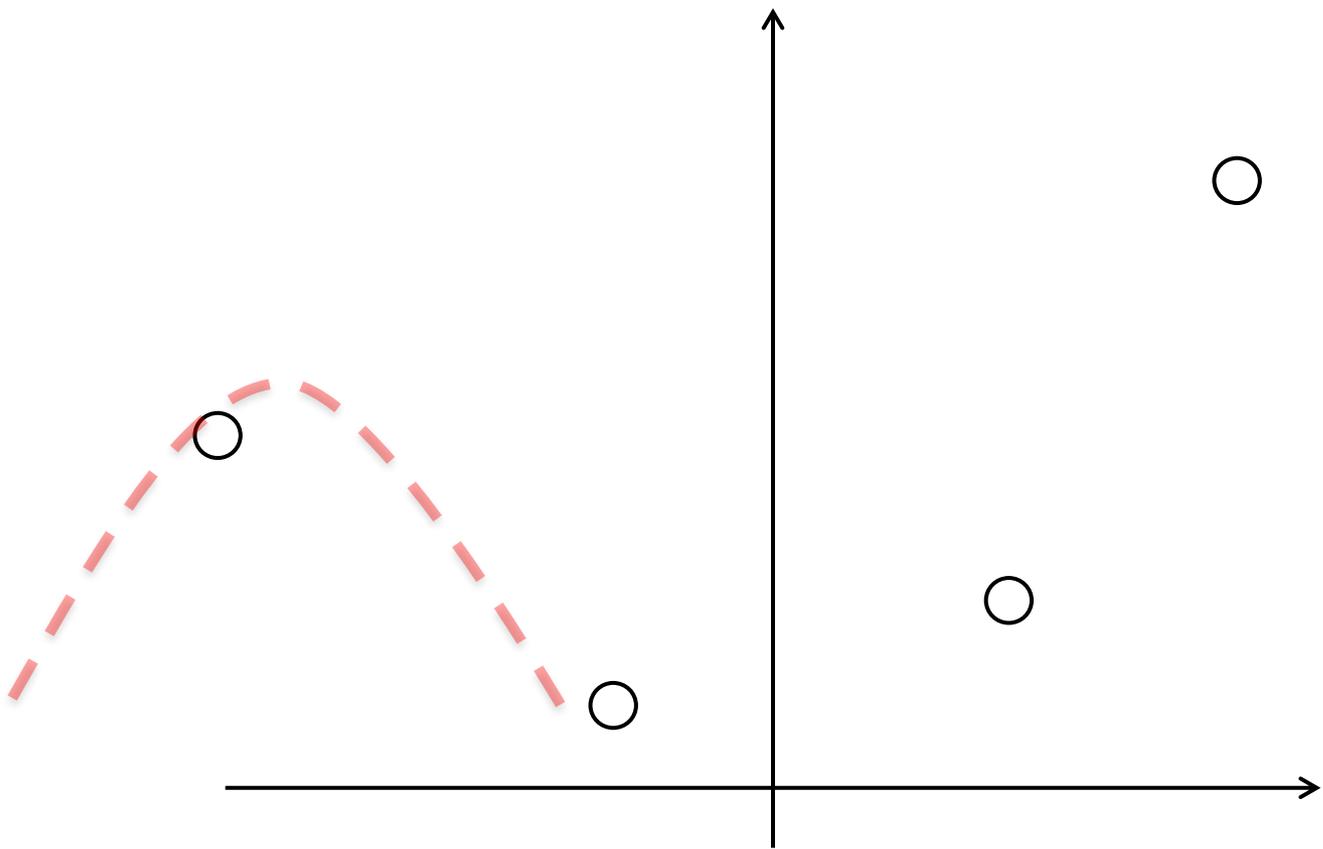
$$\min_{\mathbf{a}} \left\{ \sum_{d=1}^D \left(y^{(d)} - ax^{(d)} - b \right)^2 \right\}$$

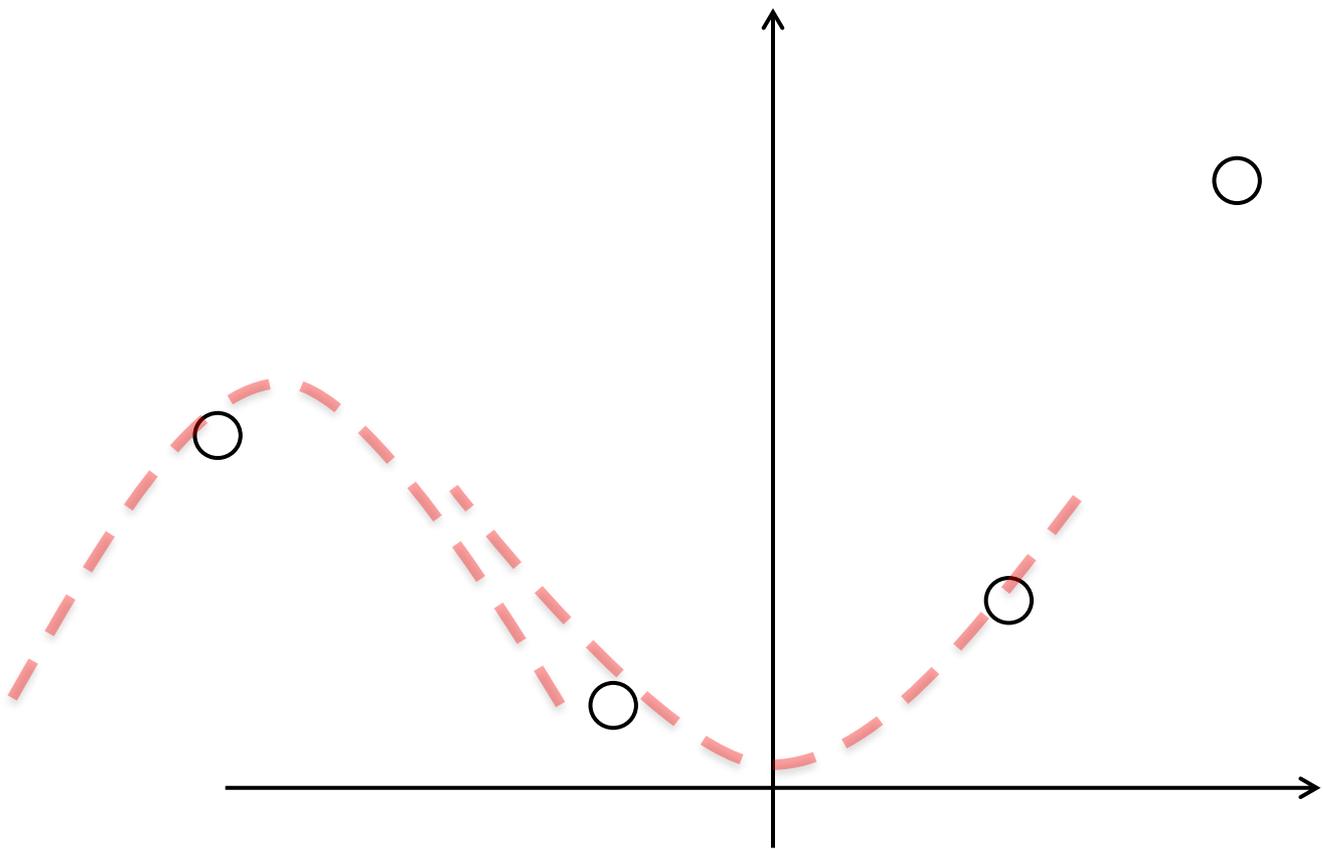
複雑になったら??

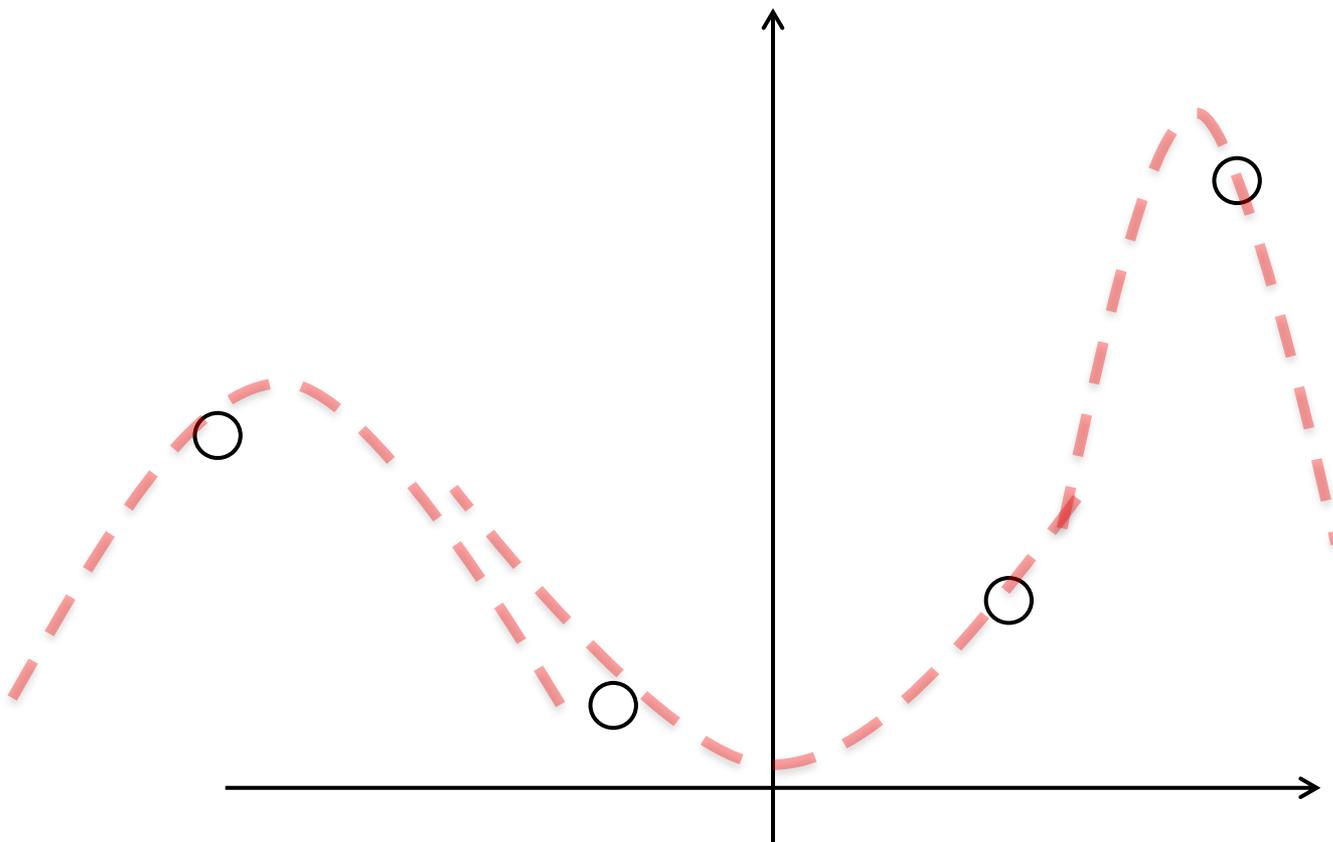


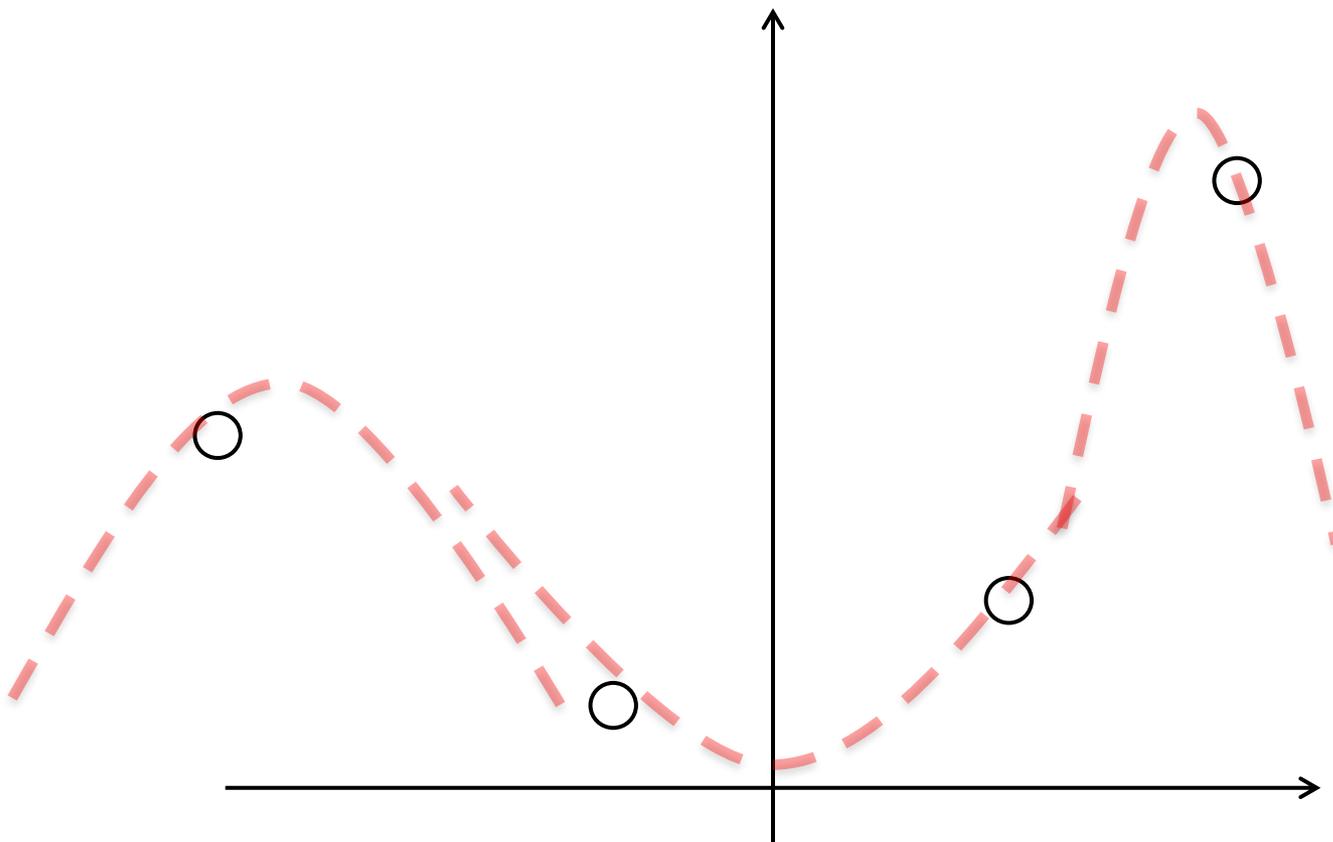


直線？曲線？何次関数？？

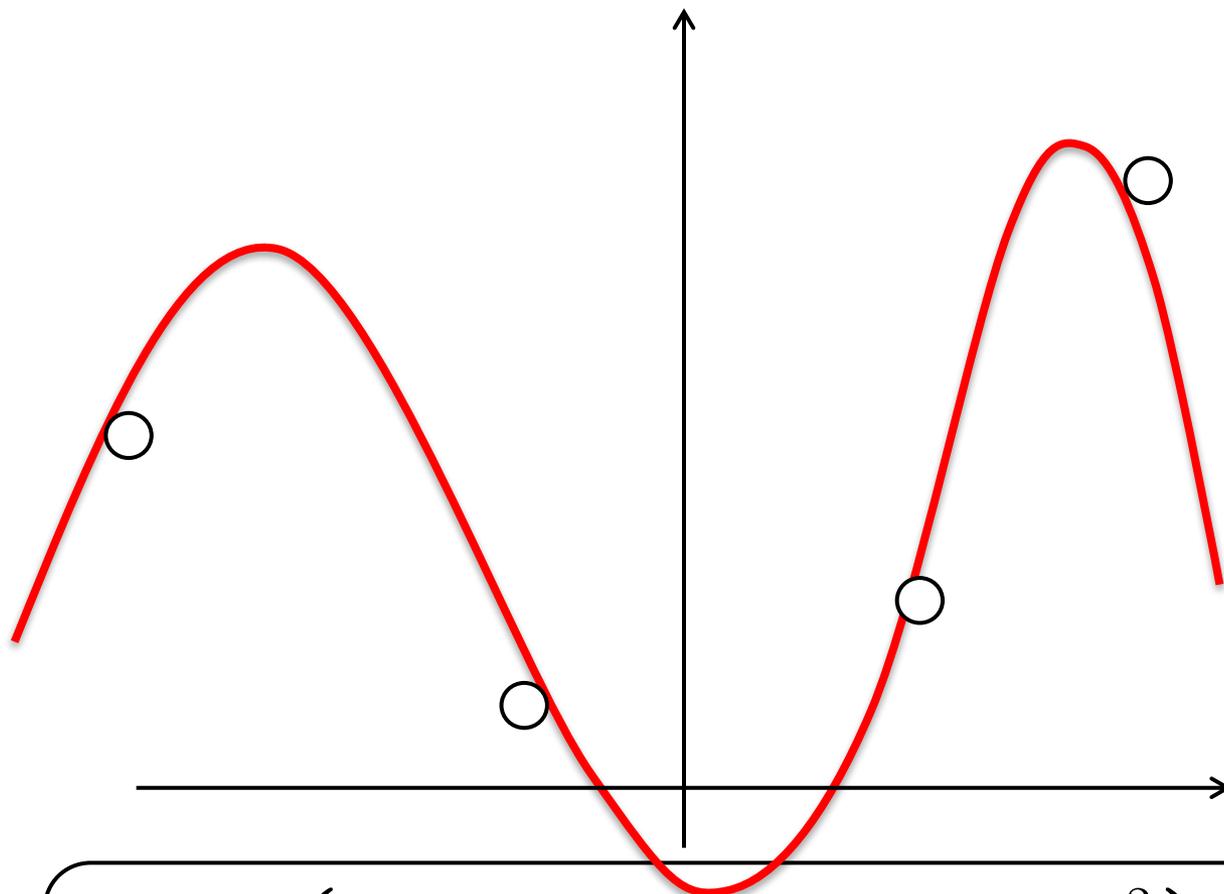








$$\min_{\mathbf{a}} \left\{ \sum_{d=1}^D \left(y^{(d)} - \sum_{k=0}^N a_k f_k(x^{(d)}) \right)^2 \right\}$$



$$\min_{\mathbf{a}} \left\{ \sum_{d=1}^D \left(y^{(d)} - \sum_{k=0}^N a_k f_k(x^{(d)}) \right)^2 \right\}$$

機械学習の躍進

- ▶ データに潜む関係性を暴く

$$y = f(\mathbf{x})$$

- ▶ x : 入力、 y : 出力、これらをつなぐ関数 f を知りたい

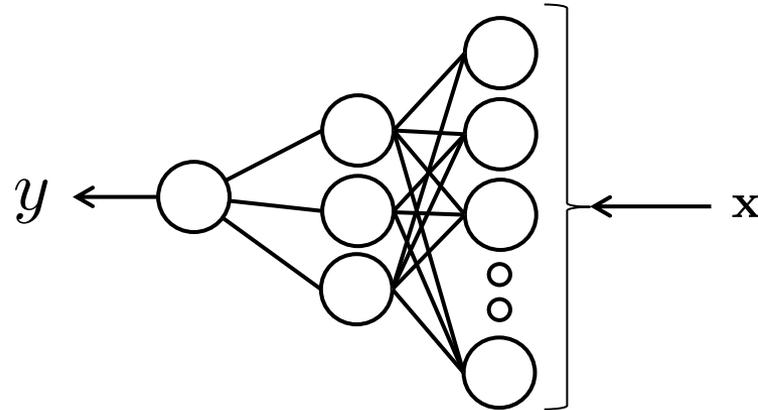
機械学習の躍進

- ▶ データに潜む関係性を暴く

$$y = f(\mathbf{x})$$

- ▶ x : 入力、 y : 出力、これらをつなぐ関数 f を知りたい
- ▶ 単純だけど繰り返しによる複雑さの極致=深層学習

How to 深層学習?



▶ 関数のモデリングの放棄 = とことん楽をする

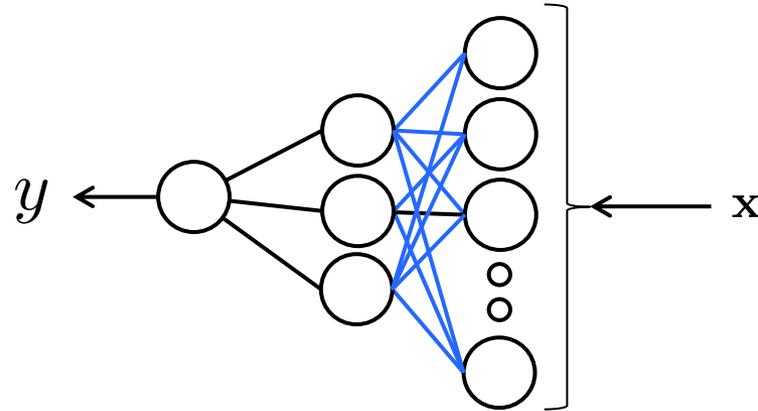
▶ 線形変換

$$\mathbf{v} = W\mathbf{x}$$

▶ 非線形変換

$$\mathbf{x}' = \phi(\mathbf{v})$$

How to 深層学習?



- ▶ 関数のモデリングの放棄 = とことん楽をする

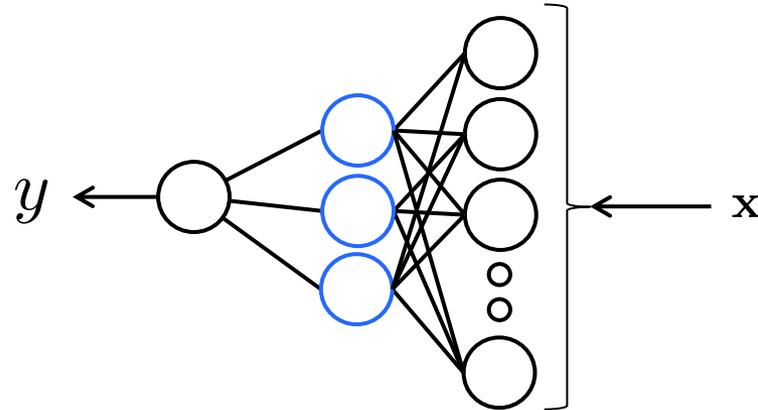
- ▶ 線形変換

$$\mathbf{v} = W \mathbf{x}$$

- ▶ 非線形変換

$$\mathbf{x}' = \phi(\mathbf{v})$$

How to 深層学習?



▶ 関数のモデリングの放棄 = とことん楽をする

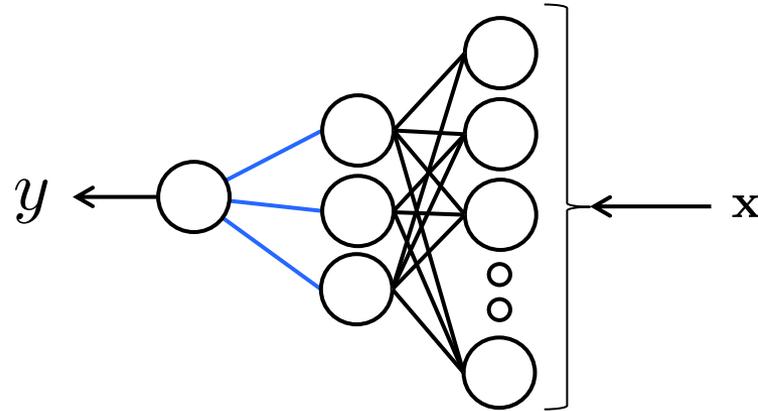
▶ 線形変換

$$\mathbf{v} = W \mathbf{x}$$

▶ 非線形変換

$$\mathbf{x}' = \phi(\mathbf{v})$$

How to 深層学習?



- ▶ 関数のモデリングの放棄 = とことん楽をする

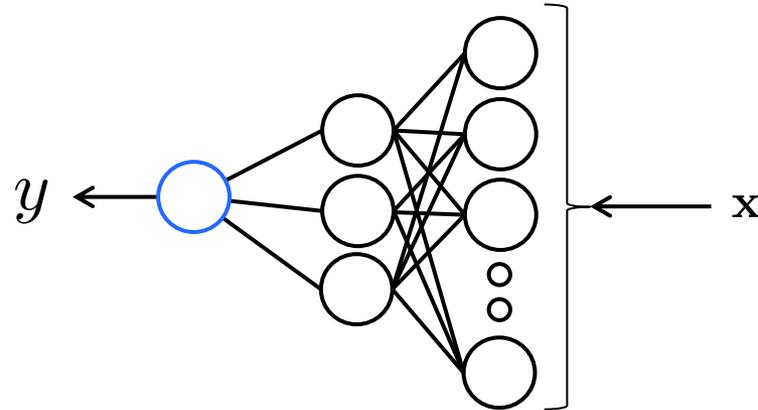
- ▶ 線形変換

$$\mathbf{v} = W \mathbf{x}$$

- ▶ 非線形変換

$$\mathbf{x}' = \phi(\mathbf{v})$$

How to 深層学習?



▶ 関数のモデリングの放棄 = とことん楽をする

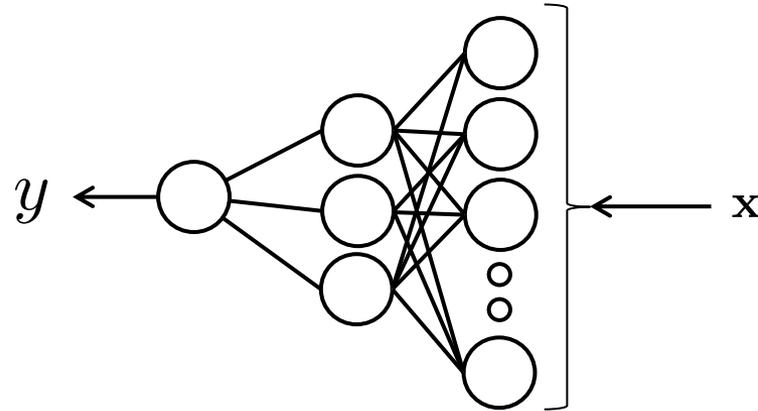
▶ 線形変換

$$\mathbf{v} = W\mathbf{x}$$

▶ 非線形変換

$$\mathbf{x}' = \phi(\mathbf{v})$$

How to 深層学習?



- ▶ 関数のモデリングの放棄 = とことん楽をする

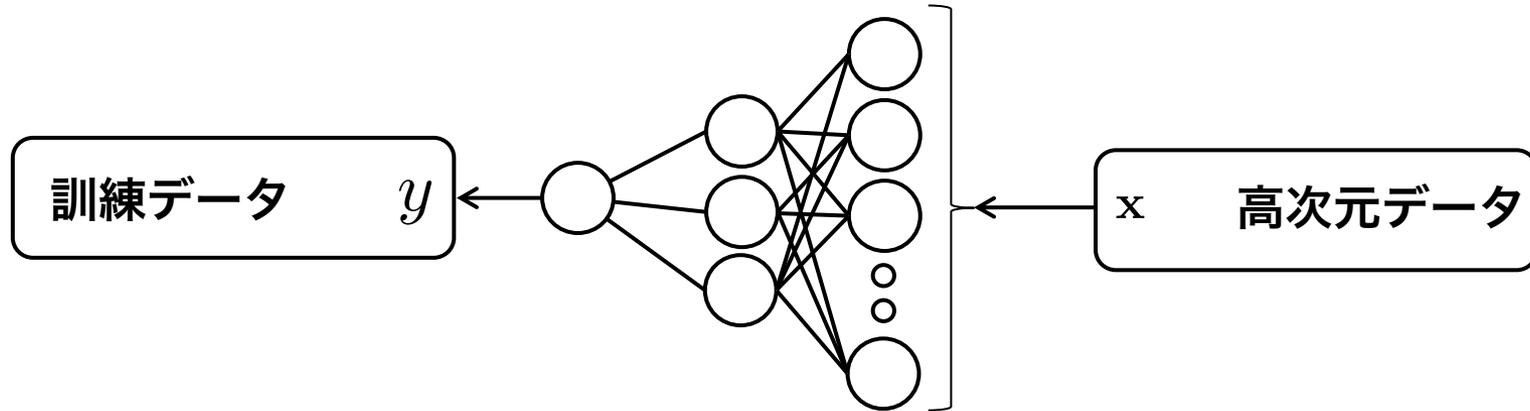
- ▶ 繰り返し構造の関数を用意

$$f_k[\mathbf{x}] = \phi_k(W_k \mathbf{x})$$

$$y = f(\mathbf{x}) = f_n[f_{n-1}[\cdots f_1[\mathbf{x}]]]$$

- ▶ 多層ニューラルネットワーク

How to 深層学習?



- ▶ 正解データに合わせる**最適化**を実行する
 - ▶ 損失関数の例:連続値を出力とする場合

$$E_f(\mathbf{y}^{(1:D)}, \mathbf{x}^{(1:D)}) = \frac{1}{2} \sum_{d=1}^D \left\| \mathbf{y}^{(d)} - f(\mathbf{x}^{(d)}) \right\|^2$$

世の中で何が起きているのか？

逆問題の解決

$$y = f(\mathbf{x})$$

世の中で何が起きているのか？

逆問題の解決

$$y = f(\mathbf{x})$$

関数は分かっているとして…

- ▶ データの本質を暴く

$$y = f(\mathbf{x})$$

- ▶ x : 入力、 y :出力、出力が出てきた原因・要因・本質 x を知りたい

関数は分かっているとして…

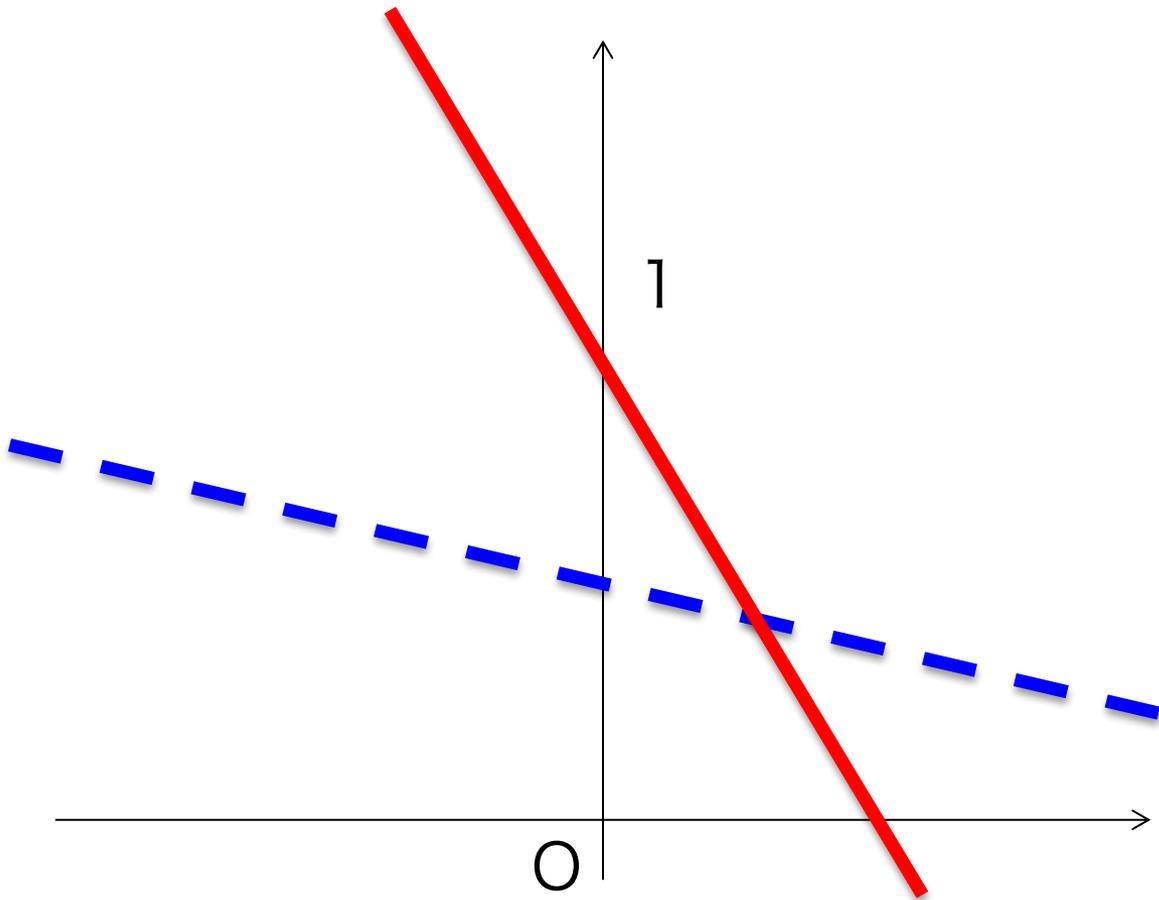
▶ データの本質を暴く

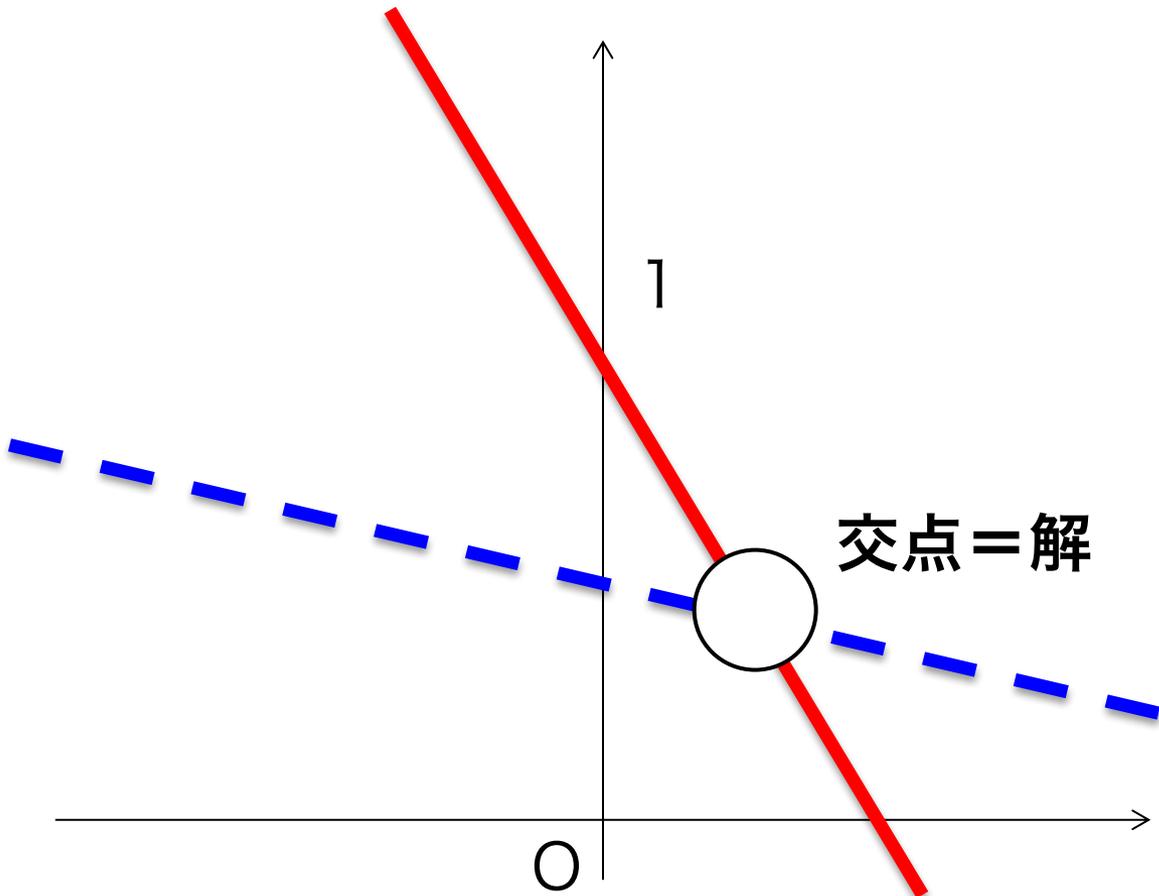
$$y = f(\mathbf{x})$$

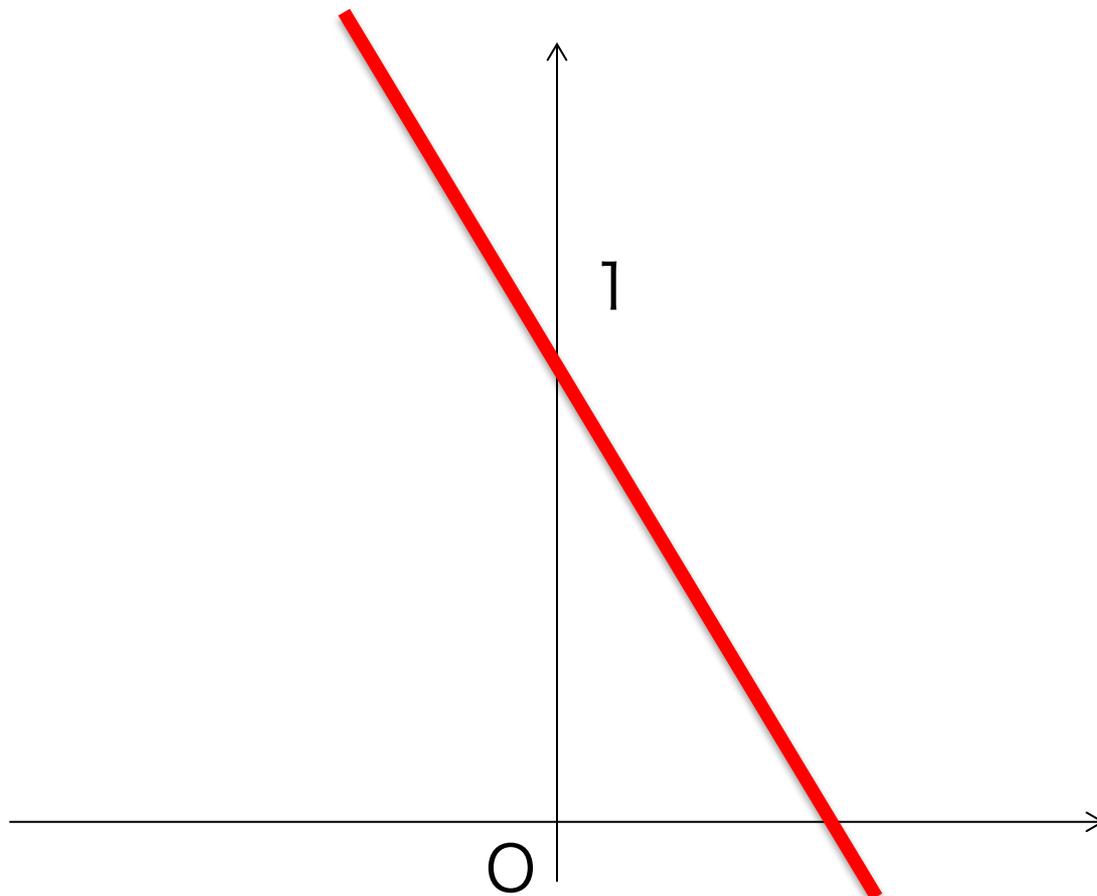
- ▶ x: 入力、y:出力、出力が出てきた**原因・要因・本質**xを知りたい
- ▶ 本質を探るために必要な方法論=**スパースモデリング**

要するに
Xを求める話

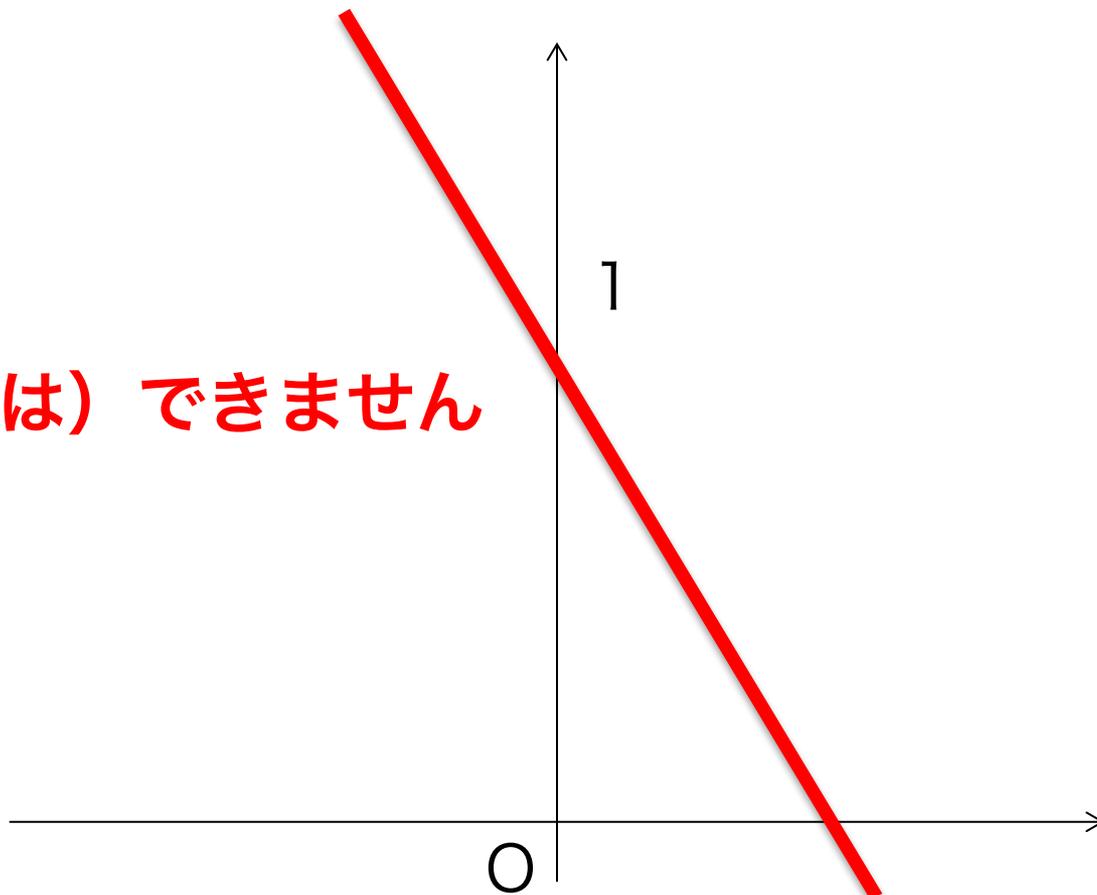
要するに
Xを求める話
連立方程式



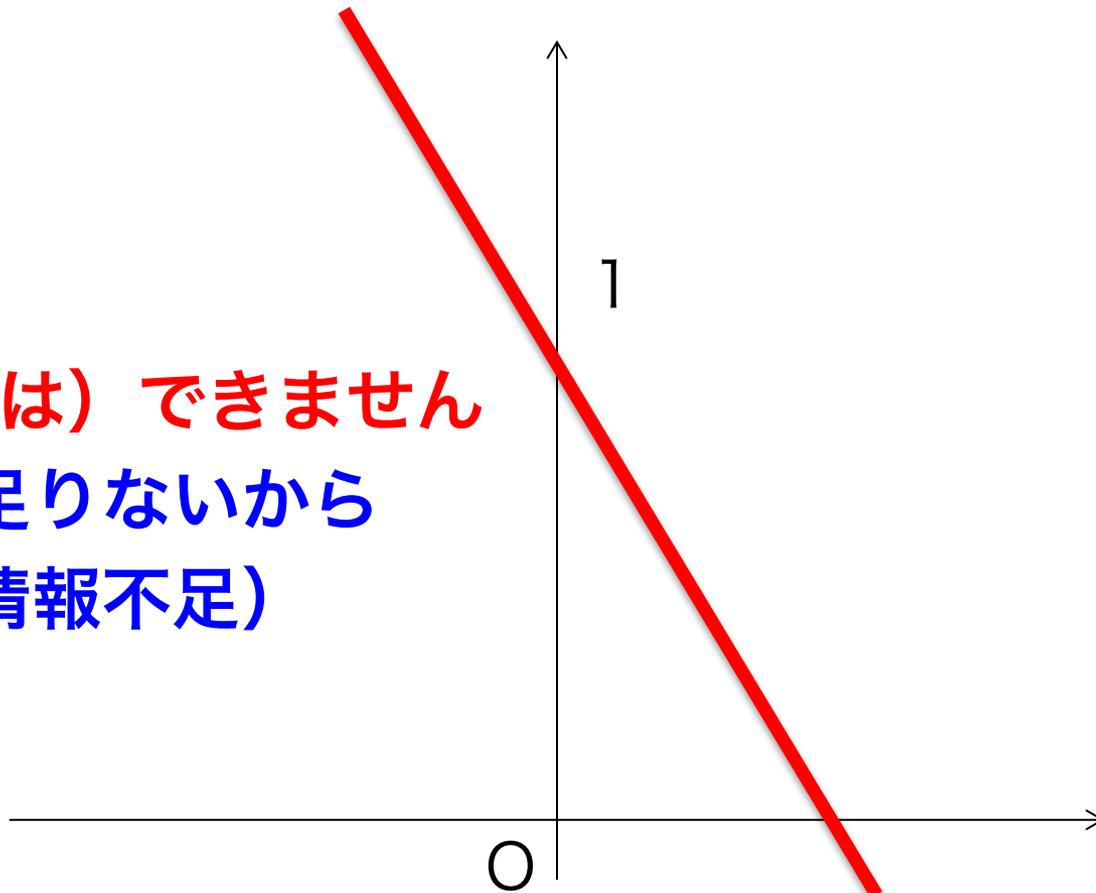




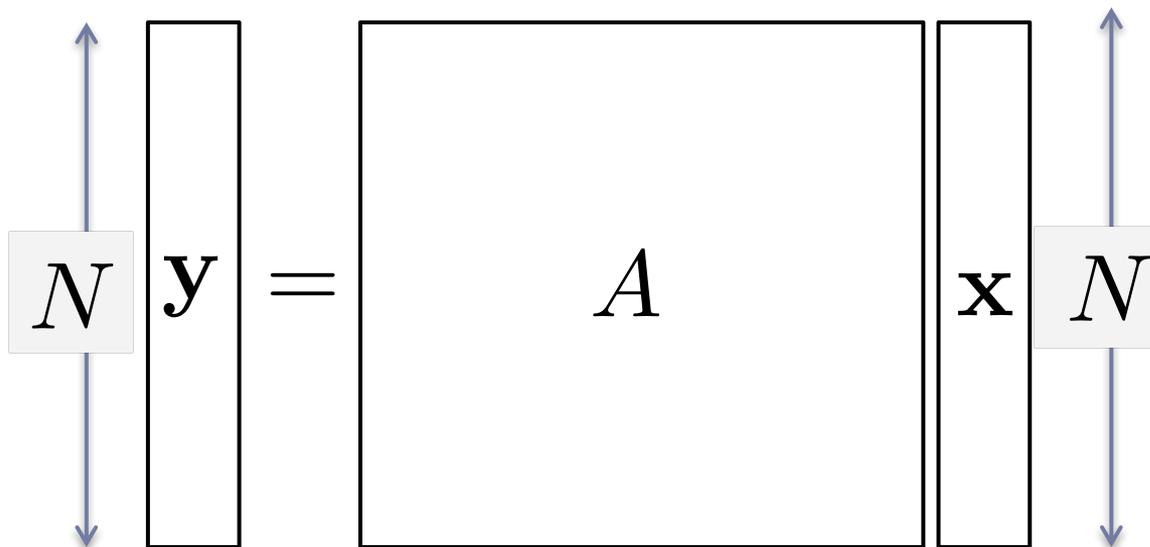
(一意には) できません



(一意には) できません
式が足りないから
(情報不足)

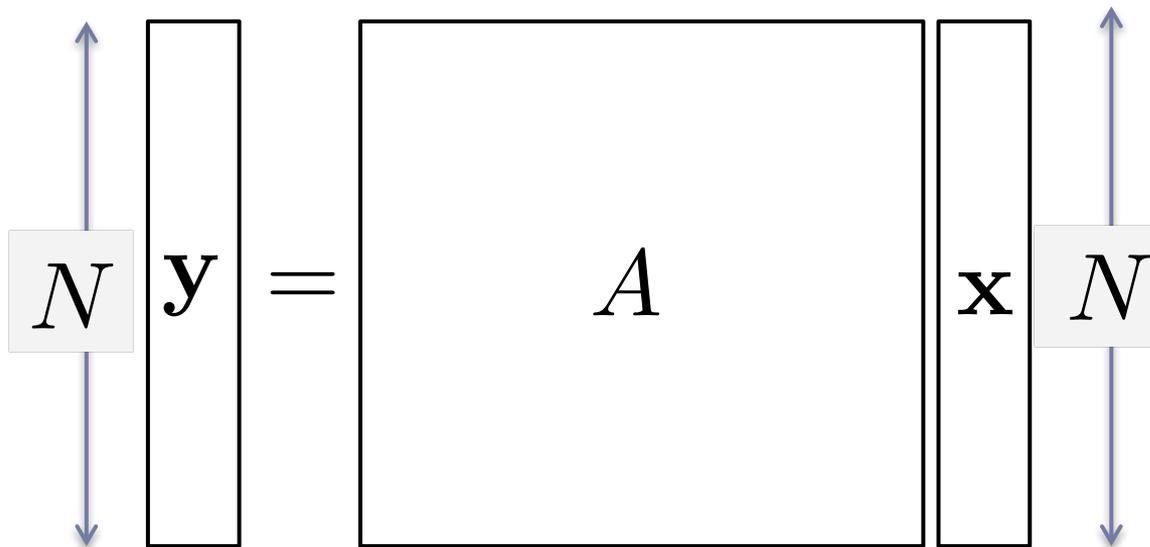


本質をつかむためには**情報**が必要
これが常識



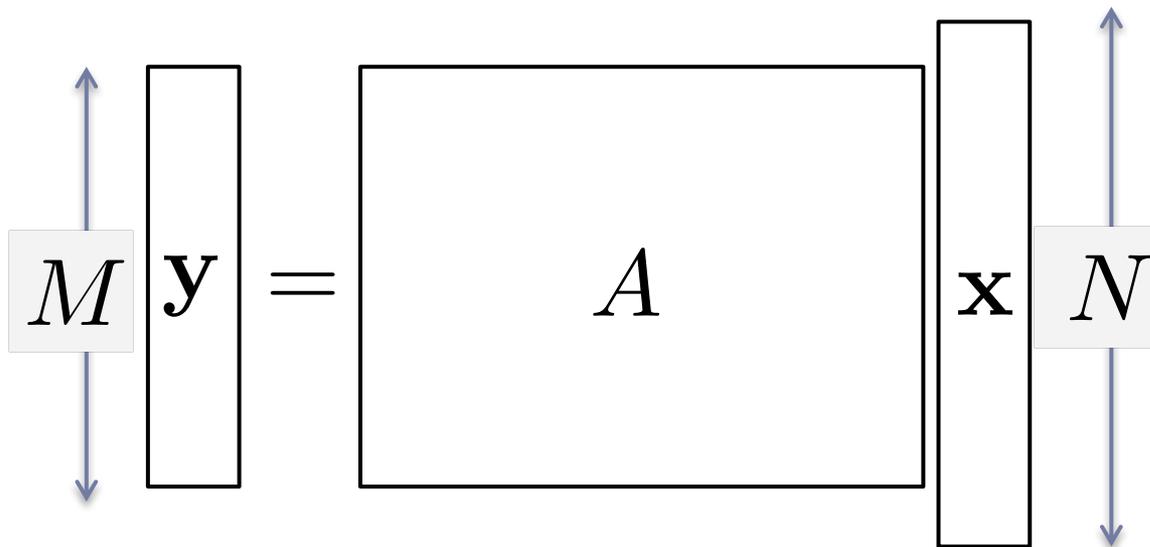
$$y = Ax$$

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

劣決定系方程式でも X を当てる技術
圧縮センシング

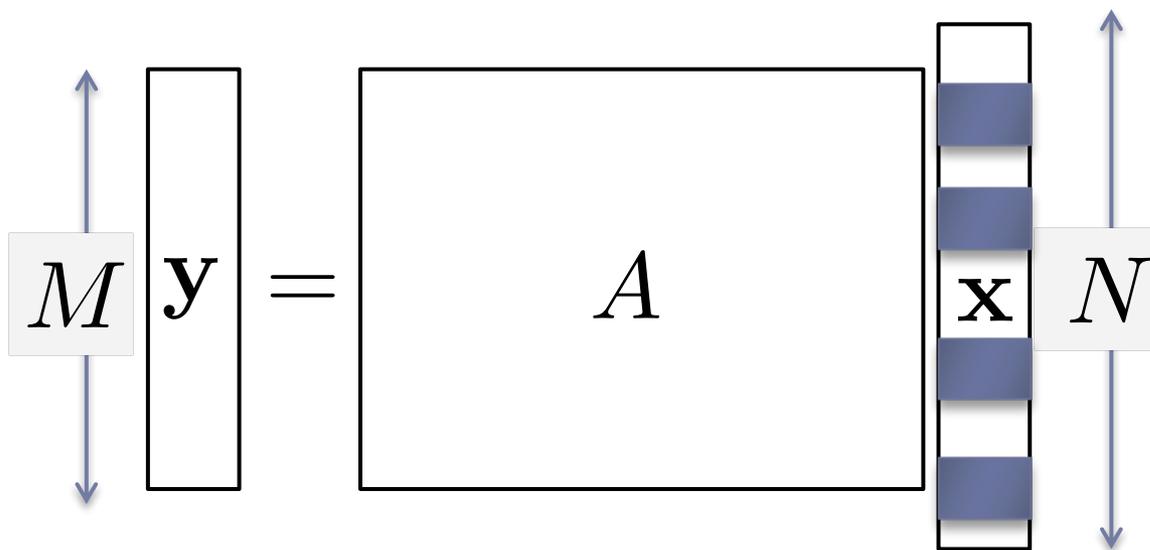
そんなことがなぜ可能か？

そんなことがなぜ可能か？
スパース性

そんなことがなぜ可能か？

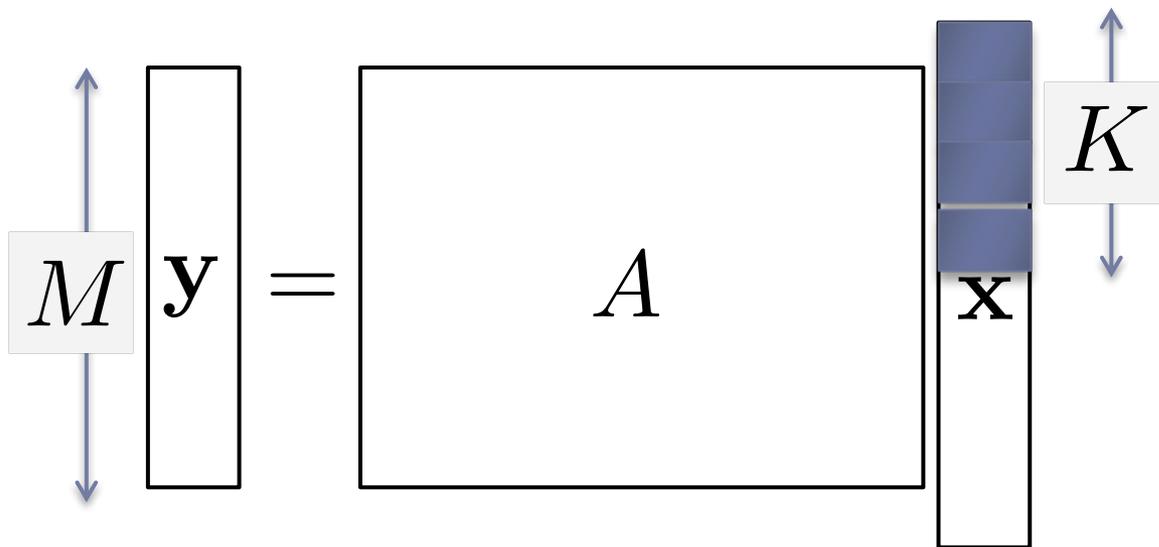
スパース性

ほとんどの要素は不要だった



$$y = Ax$$

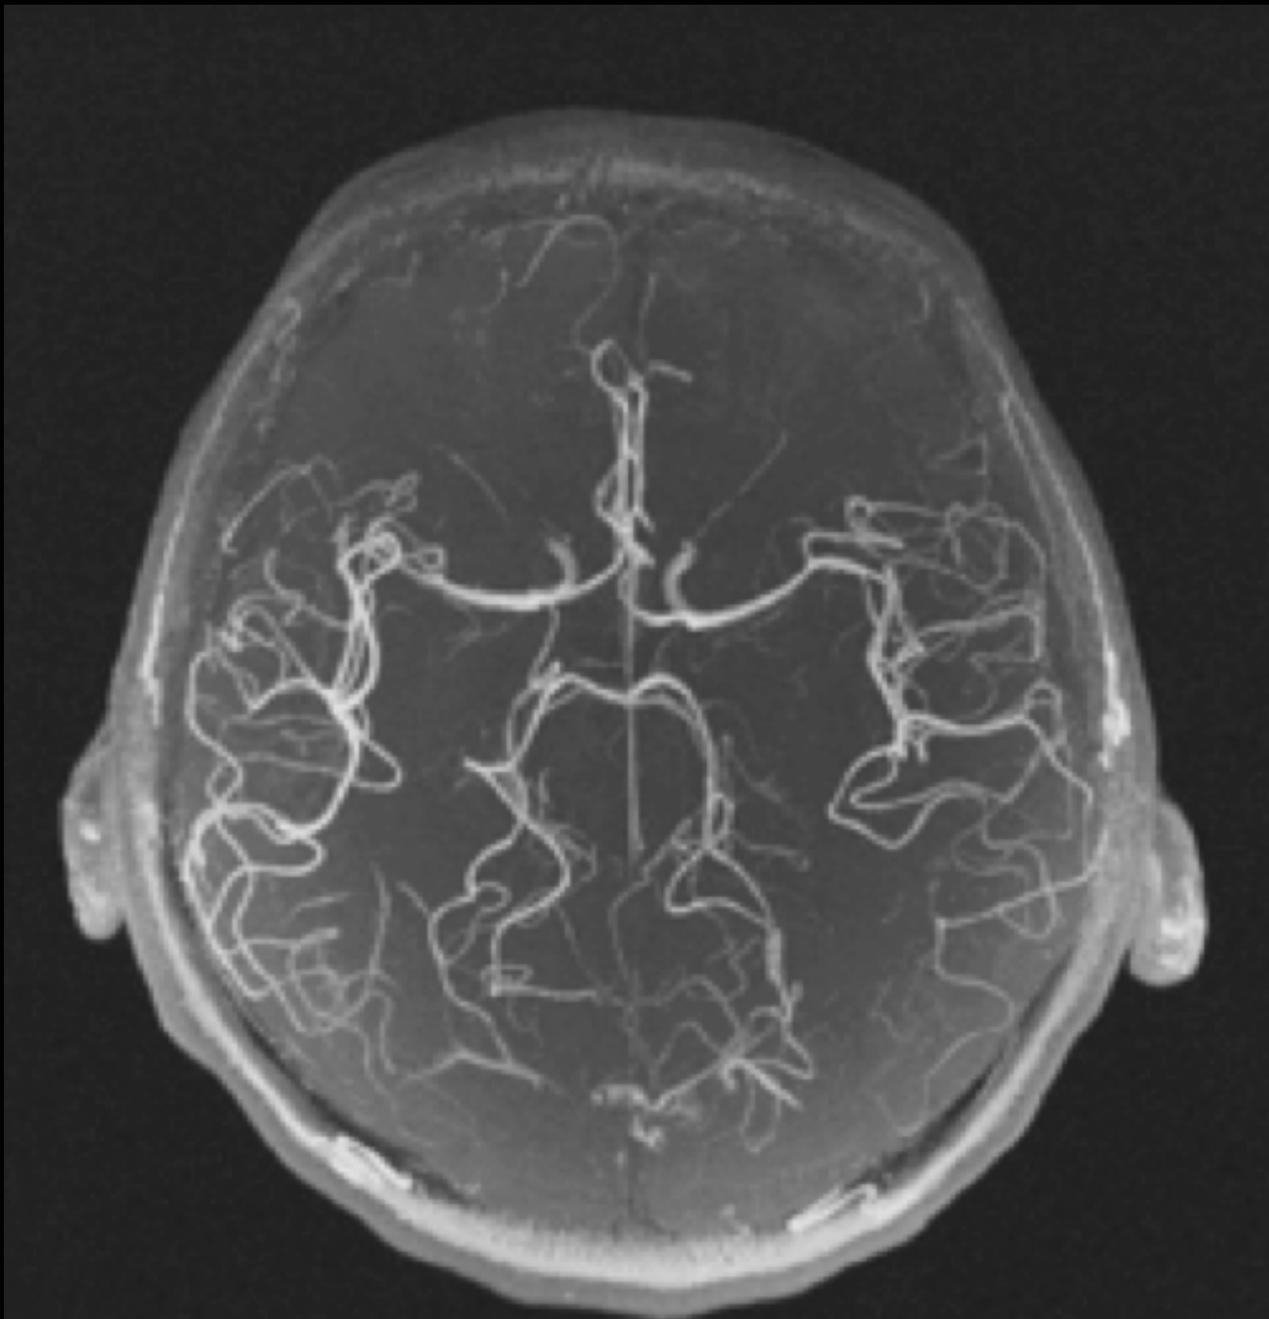
を満たす解を求めよ

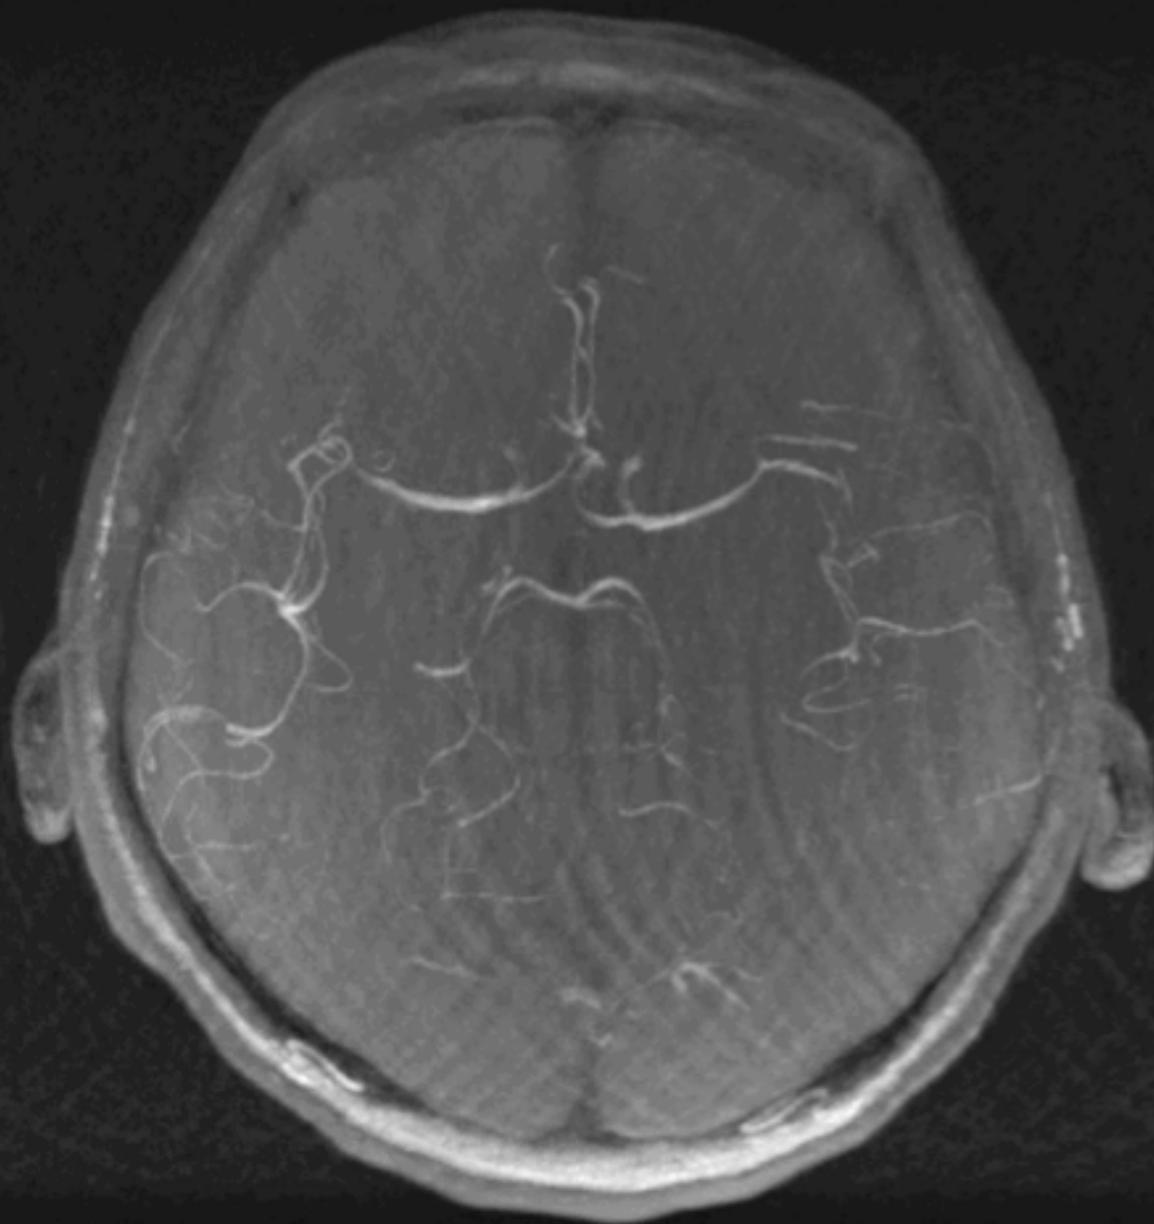


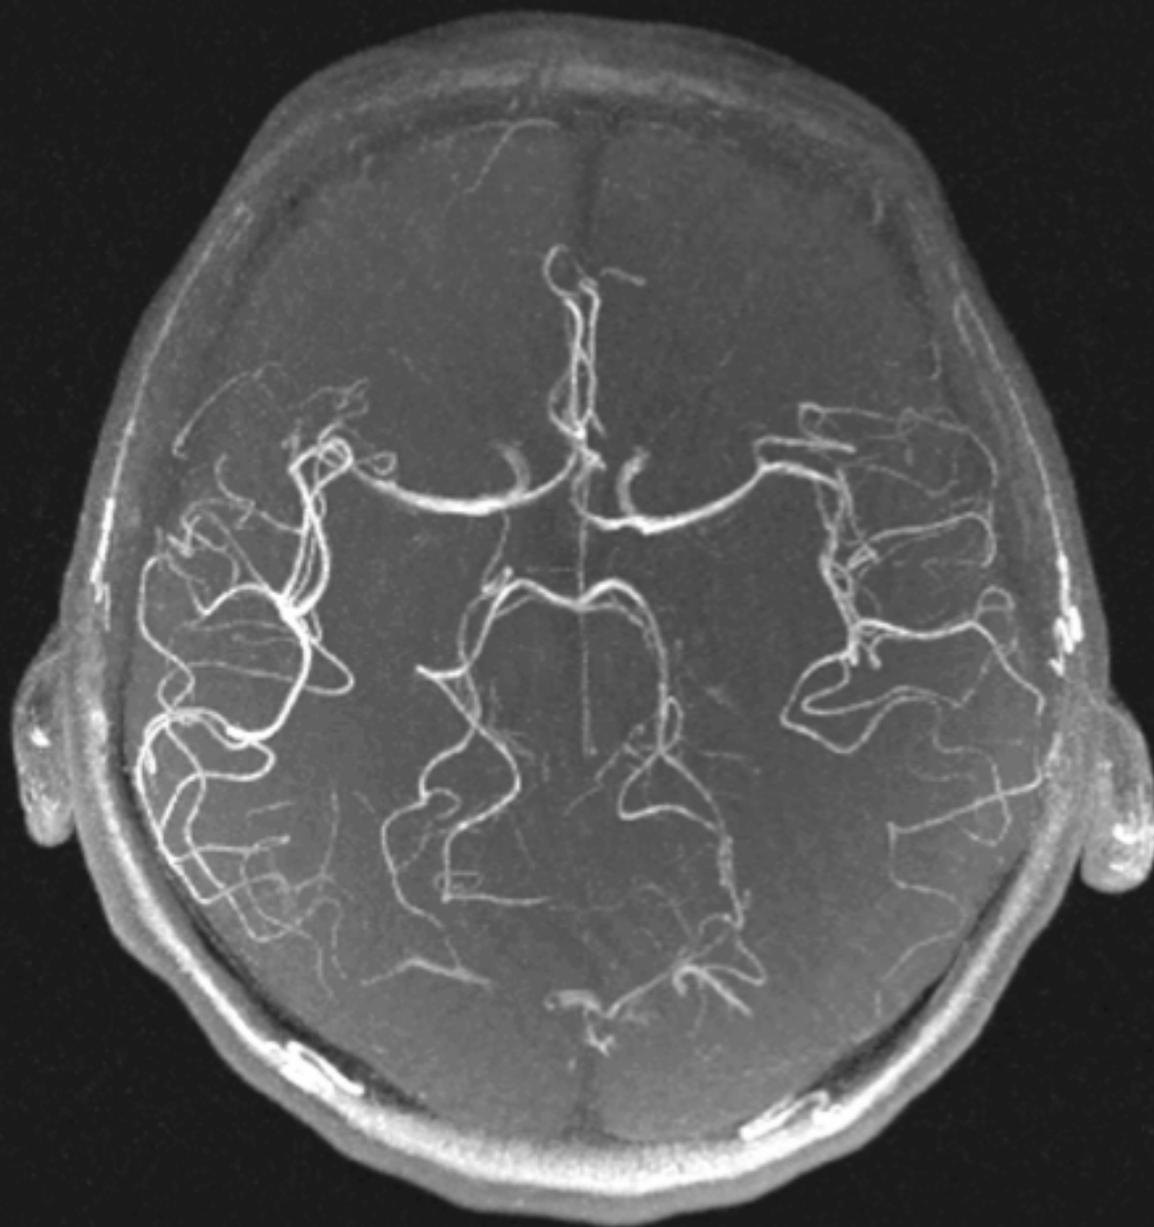
$$y = Ax$$

を満たす解を求めよ

できる！







天文学 + 圧縮センシング

K. Akiyama, et al. *Astrophys. J.* (2017)

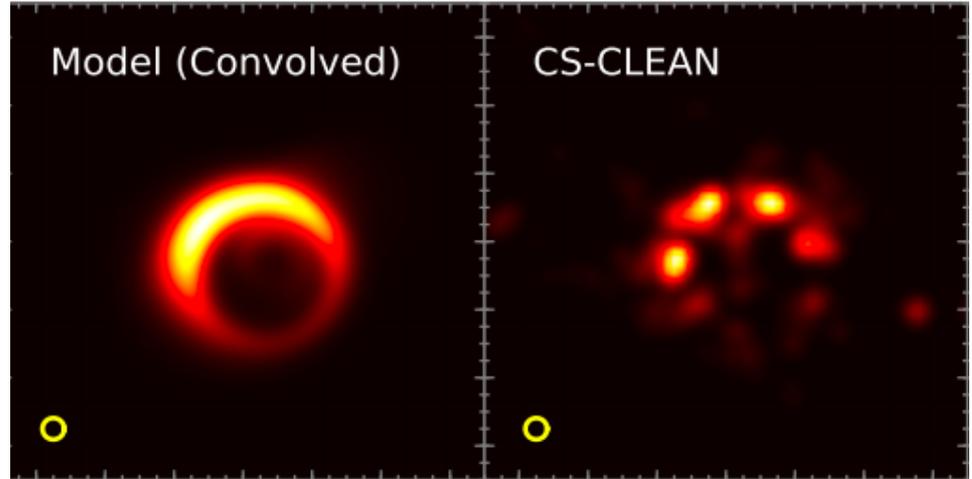
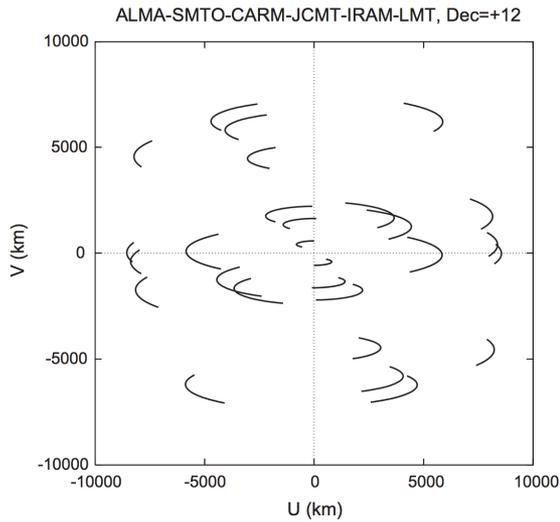
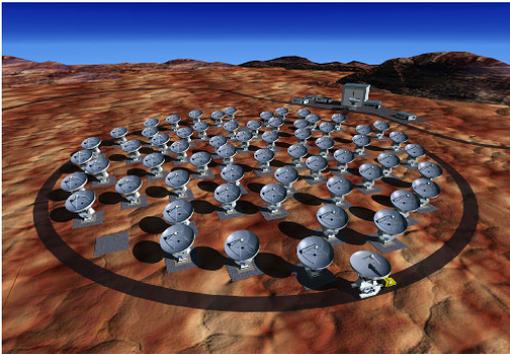


Fig. 5. Simulated UV coverage of M87 with six-station sub-mm VLBI array of EHT. Here it is assumed that observations are conducted at an elevation larger than 20° at each station.



天文学+圧縮センシング

K. Akiyama, et al. *Astrophys. J.* (2017)

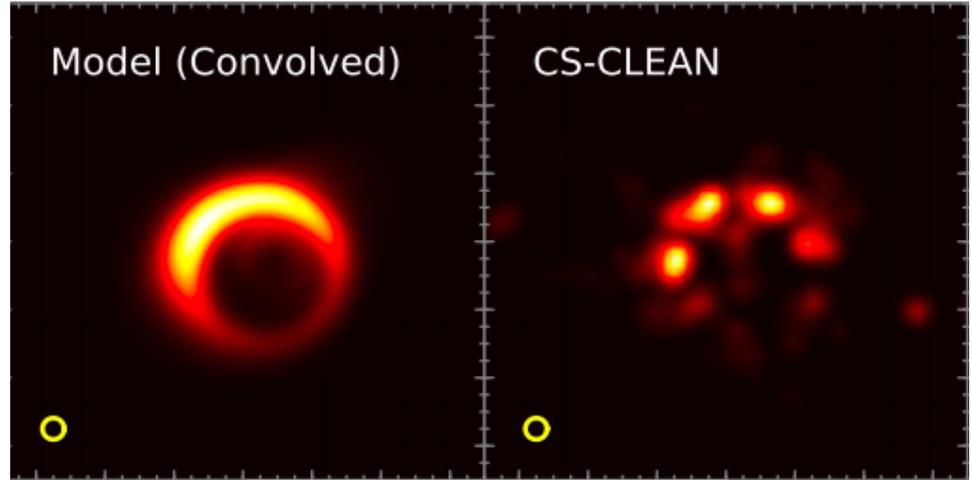
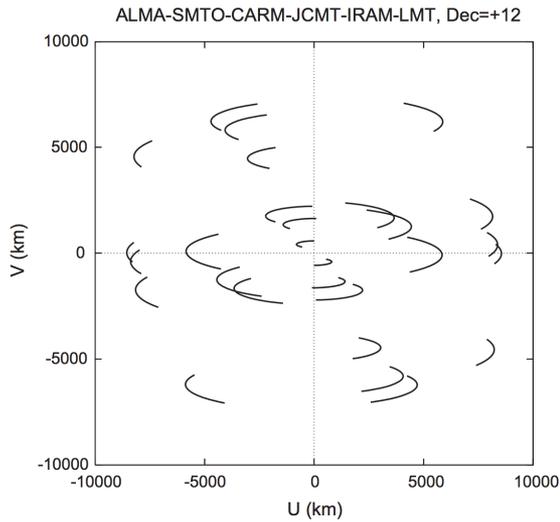
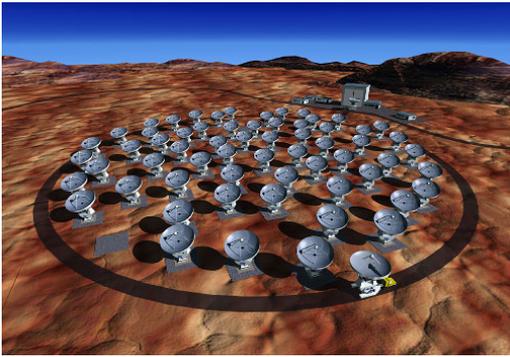
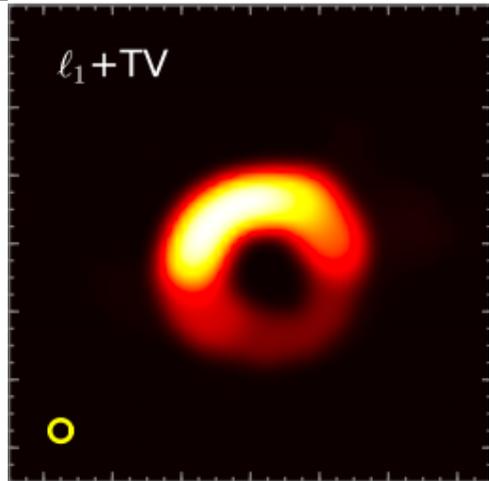


Fig. 5. Simulated UV coverage of M87 with six-station sub-mm VLBI array of EHT. Here it is assumed that observations are conducted at an elevation larger than 20° at each station.



不足した観測情報 + 推定方法
圧縮センシング

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！

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

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！

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

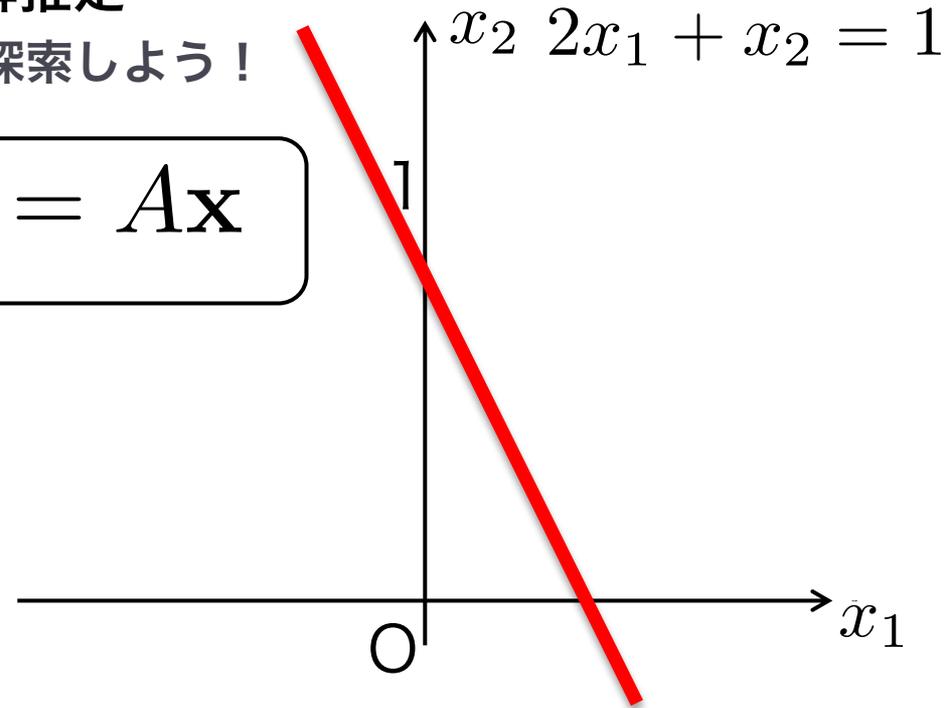
L0ノルム=非零の個数

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！

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

L0ノルム=非零の個数

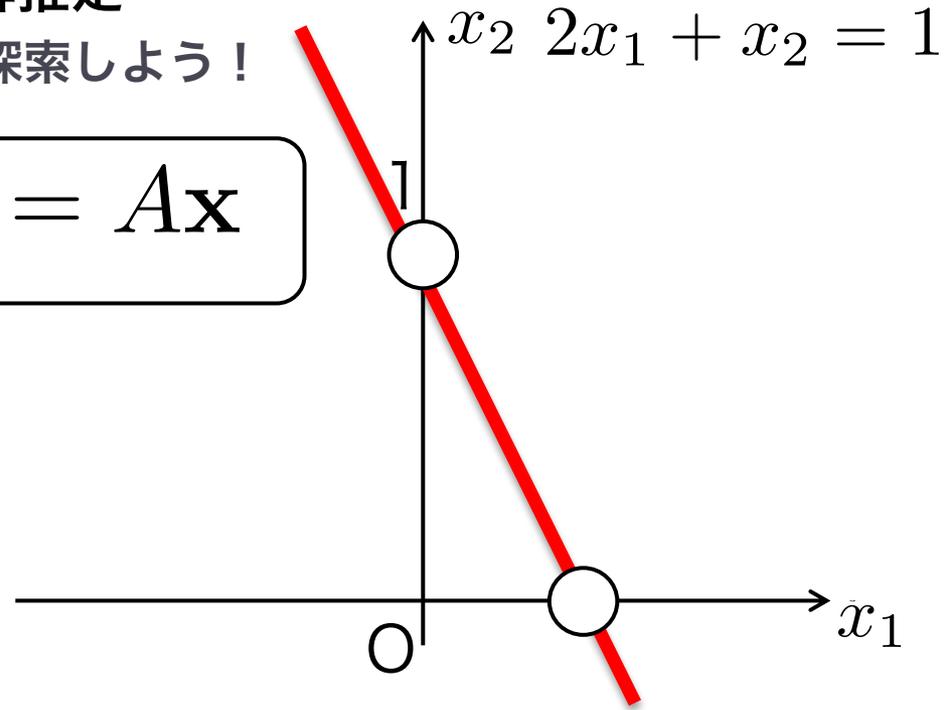


スパース解推定

- ▶ 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！

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

L0ノルム=非零の個数



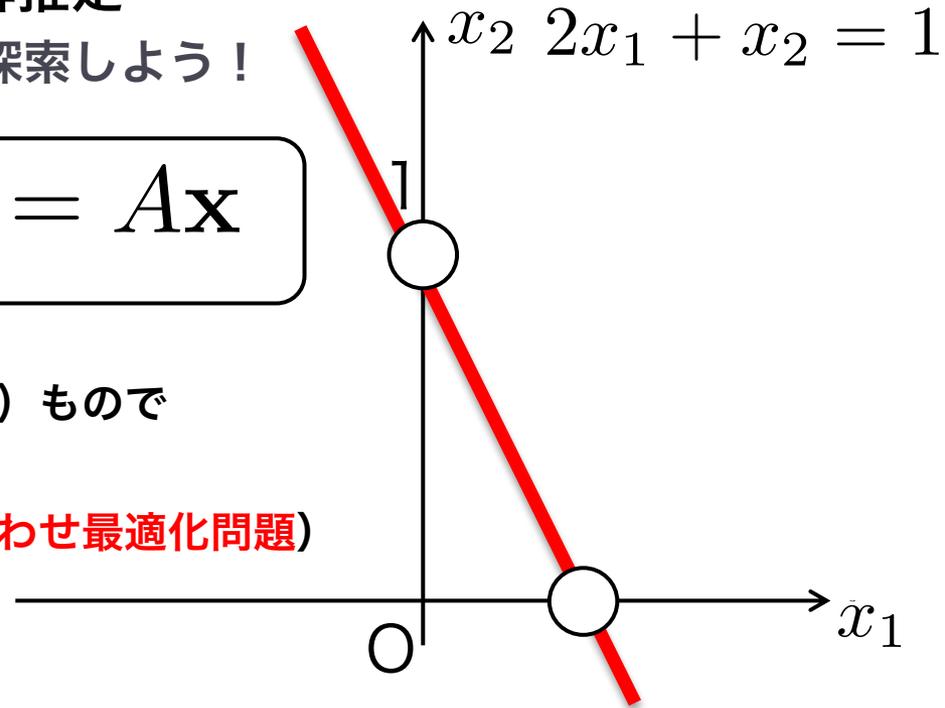
スパース解推定

- ▶ 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！

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

L0ノルム=非零の個数

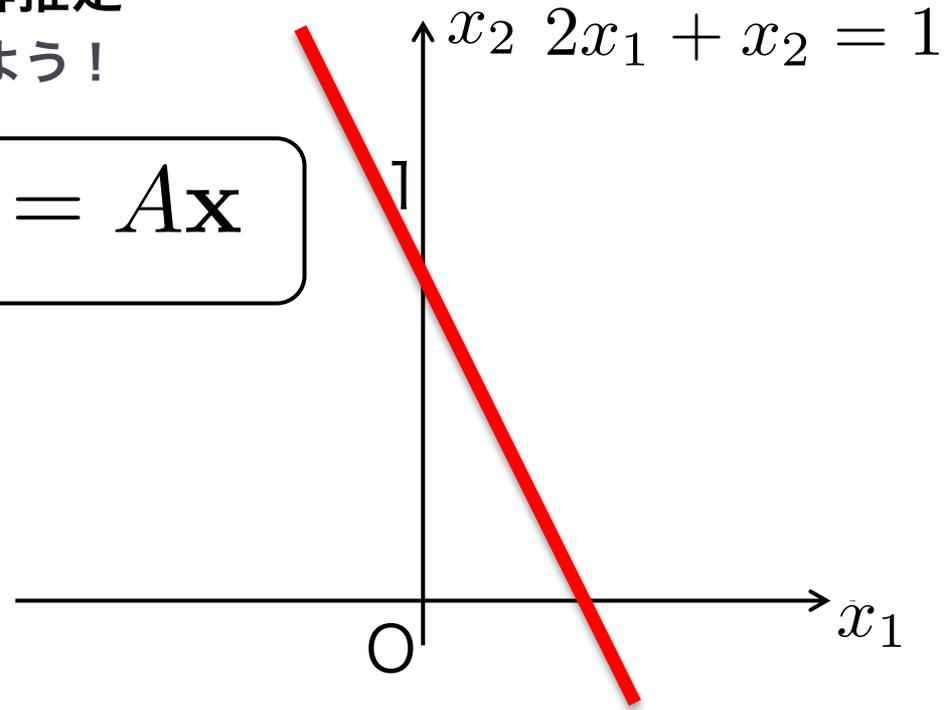
- ▶ 非零成分の個数が小さい（スパース）もので方程式を満たすものを探す
- ▶ 残念ながら計算量的に困難（組み合わせ最適化問題）



スパース解推定

- ▶ **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探索しよう！

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

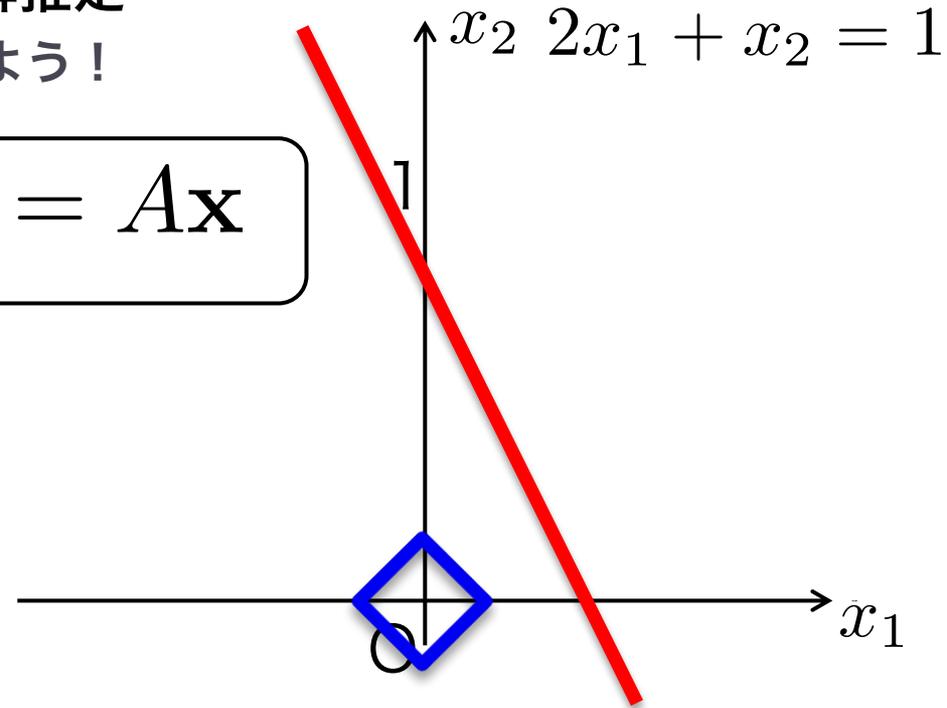


$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \dots + |x_N|$$

スパース解推定

- ▶ **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探索しよう！

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

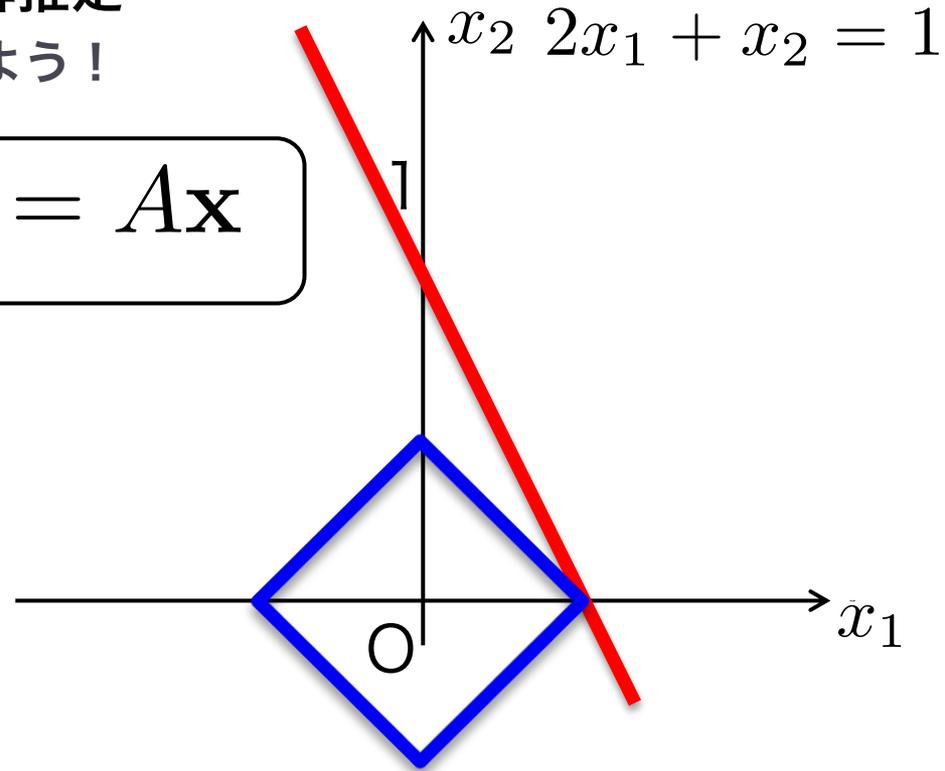


$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

スパース解推定

- ▶ **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探索しよう！

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



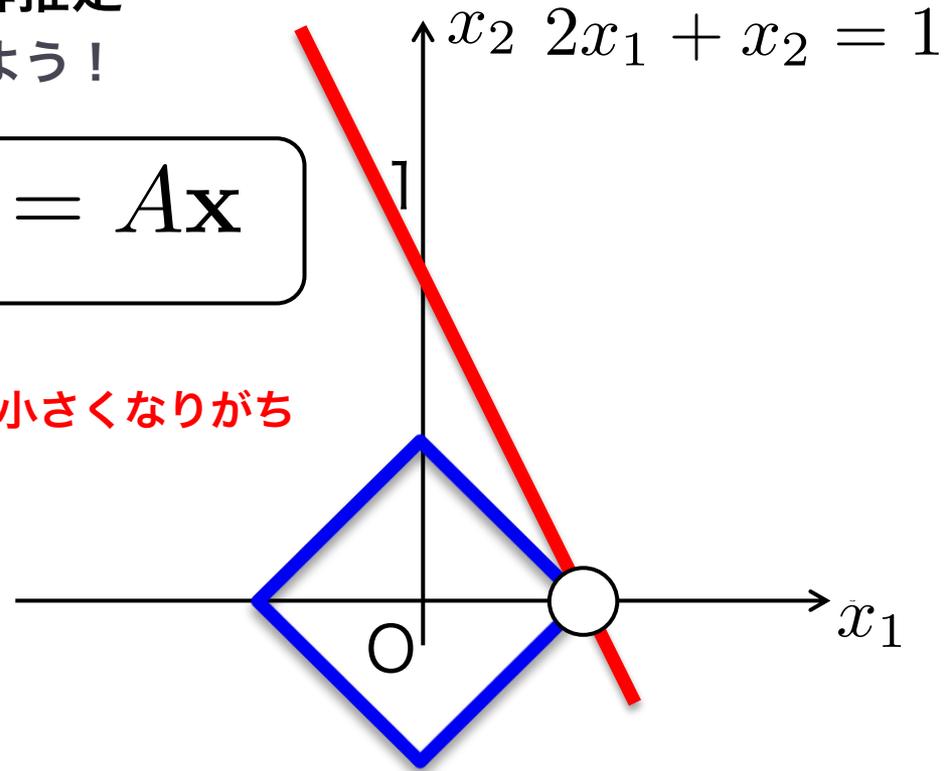
$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \cdots + |x_N|$$

スパース解推定

- ▶ **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探索しよう！

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

- ▶ 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**)



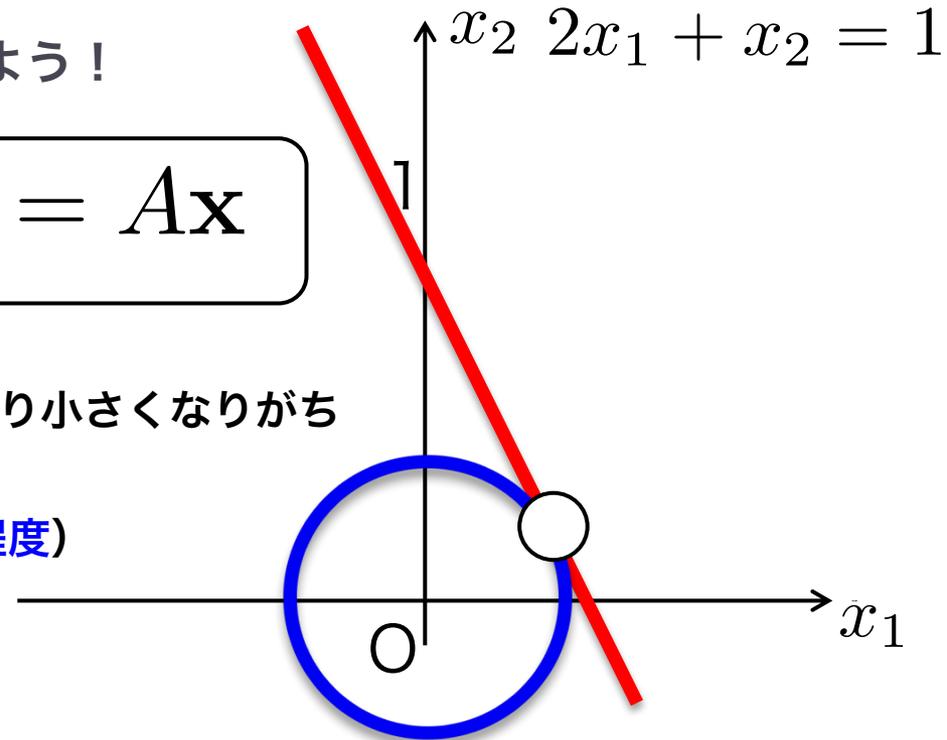
$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \dots + |x_N|$$

スパース解推定

- ▶ L2ノルムでは??
 - ▶ 代わりに次の最小化問題で探索しよう!

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

- ▶ 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)



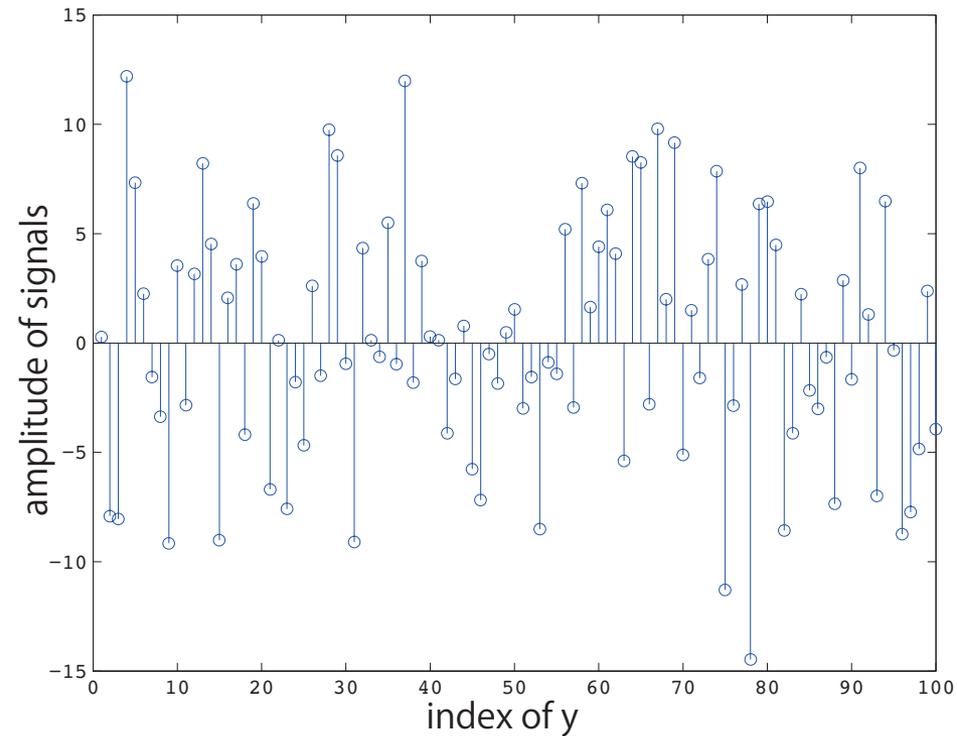
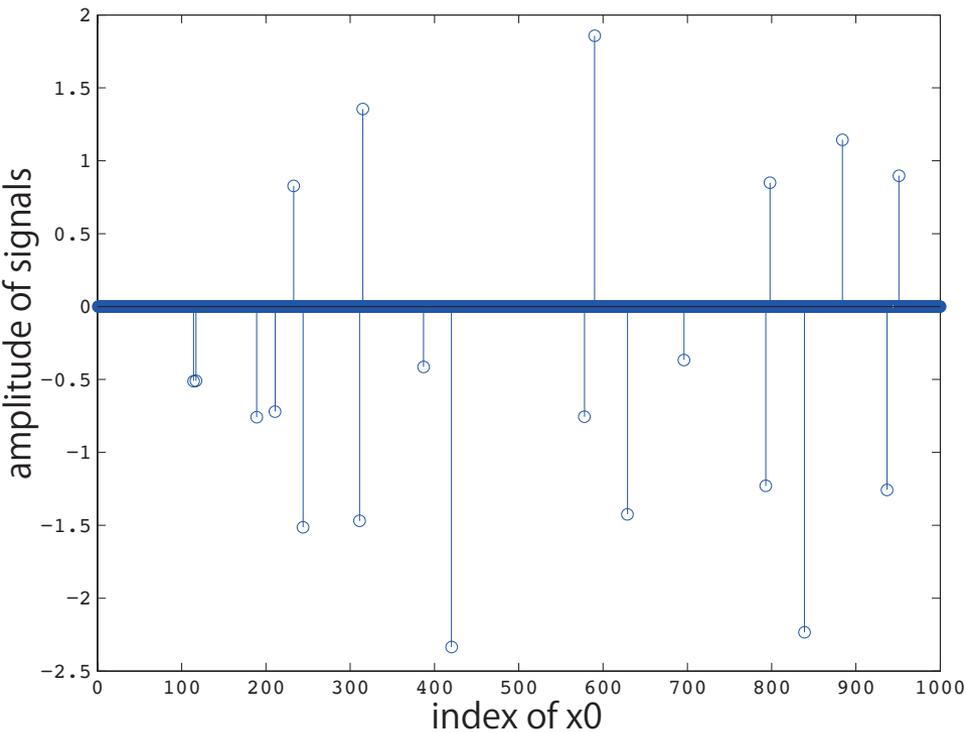
$$\|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \cdots + x_N^2}$$

L1ノルムはスパースな解の選択法

**L1ノルムはスパースな解の選択法
当たるかどうか？**

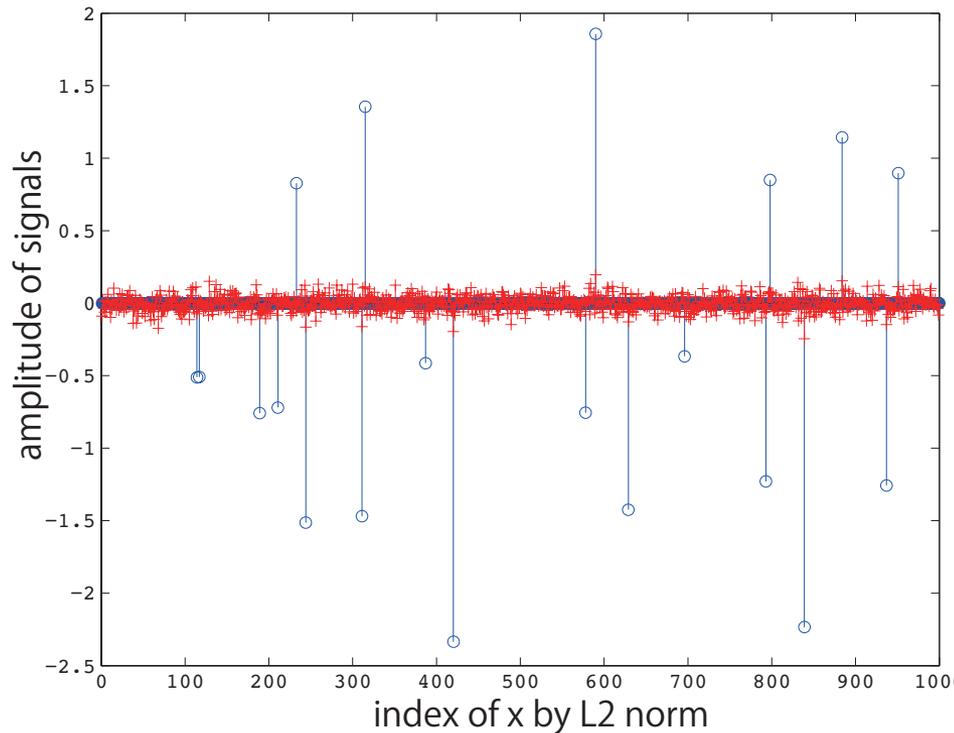
実践例

- ▶ $M=100, N=1000, K=20$, ガウスランダム観測行列の場合



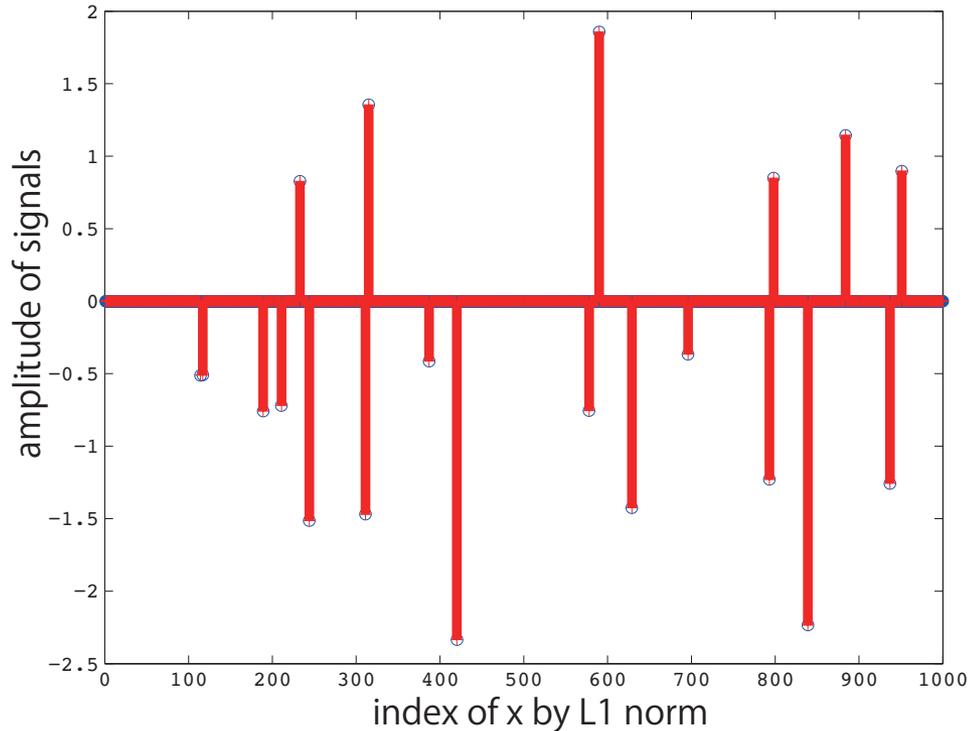
実践例

▶ L2ノルムを利用した場合



実践例

▶ L1ノルムを利用した場合



L1ノルム最小化の性能

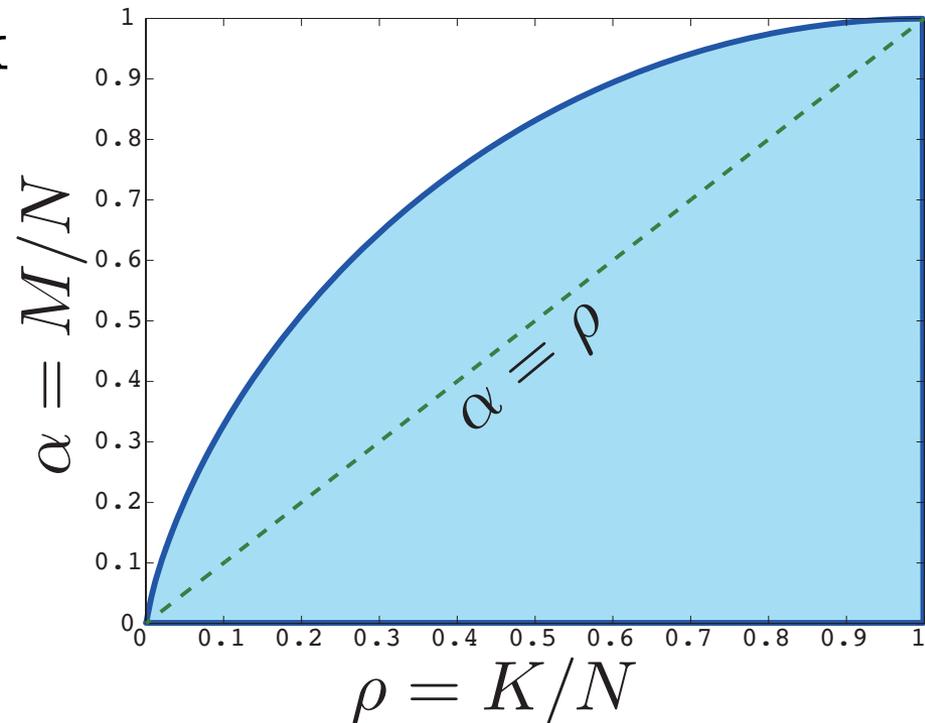
- ▶ **L1**ノルム最小化によるスパース解推定法
 - ▶ 前提：A=ガウスランダム行列、原信号はガウスランダム

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

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

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

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



- ▶ 解析方法は積分幾何学や統計力学

[D. L. Donoho and J. Tanner: Proc. Nat. Acad. Sci. 102 (2005) 9452]

[Y. Kabashima, T. Wadayama, and T. Tanaka: J. Stat. Mech.: Theor. and Exp. 09 (2009) L09003]

スパースモデリング

Find x by sparsity

スパースモデリング

Find x by sparsity

Make x sparse

どうやって？

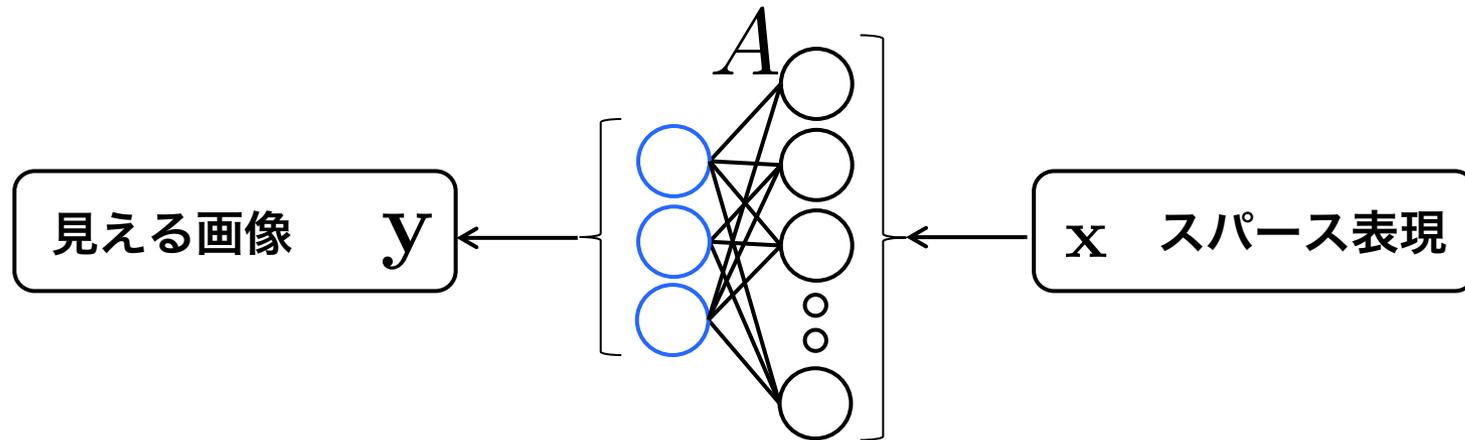
機械学習

$$y = f(\mathbf{x})$$

辞書学習でスパースな基底を

J. Mairal, F. Bach, F. Ponce, and G. Sapiro: ICML (2009)

- ▶ ノイズや抜けに対して頑強な基底を獲得



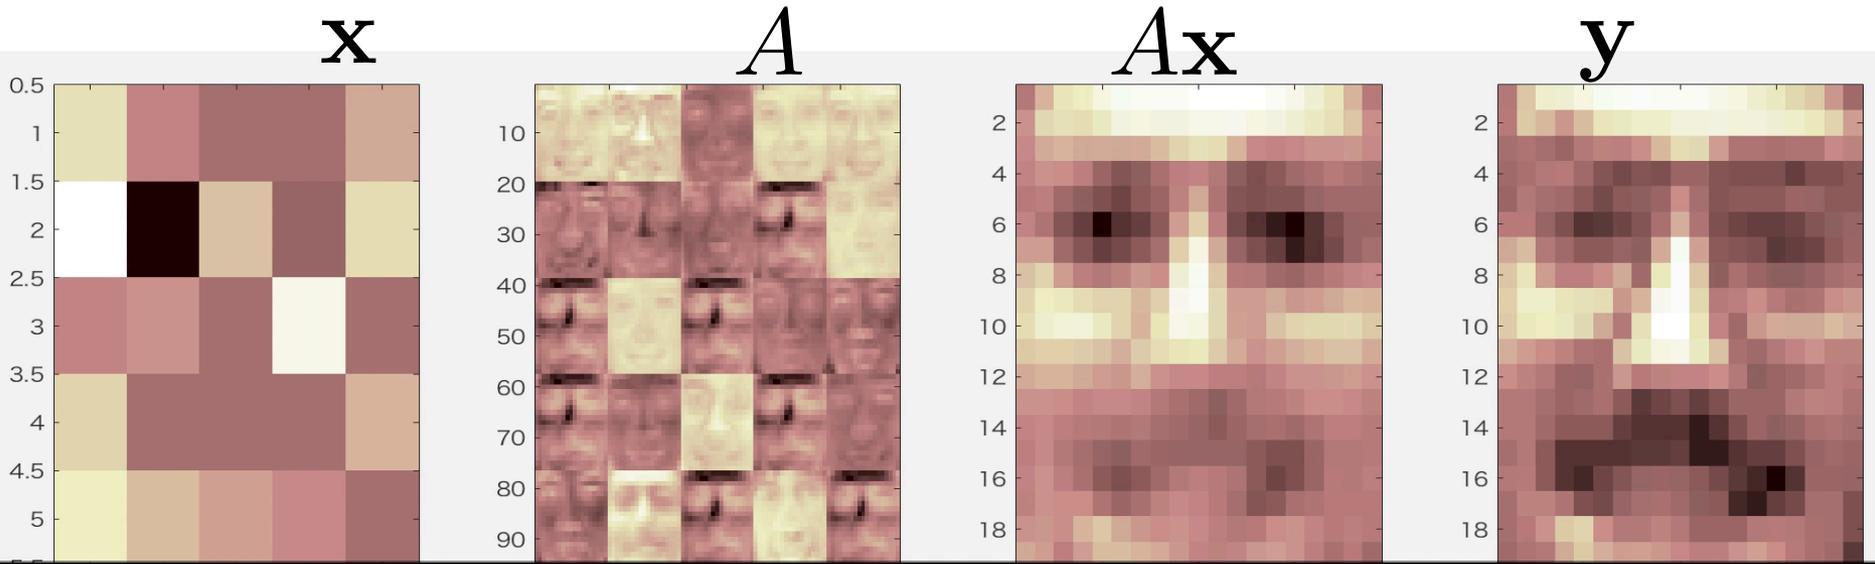
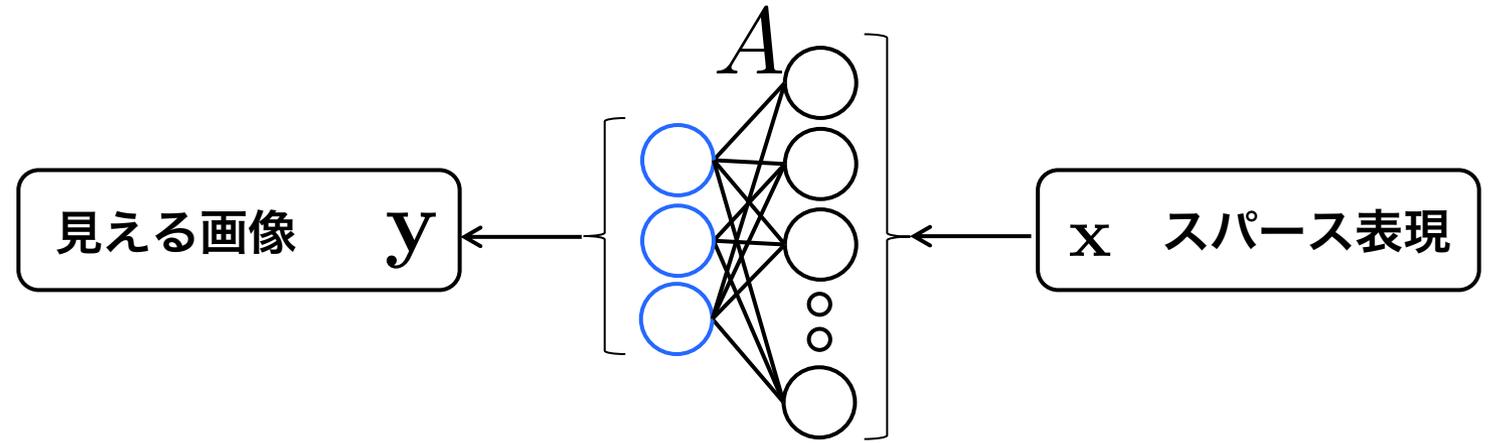
$$\min_{A, \mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \lambda \|\mathbf{x}\|_1 \right\}$$

- ▶ スパースな \mathbf{x} となるような A を求める
- ▶ \mathbf{y} が与えられているだけで良い

辞書学習でスパースな基底を

J. Mairal, F. Bach, F. Ponce, and G. Sapiro: ICML (2009)

- ▶ ノイズや抜けに対して頑強な基底を獲得



圧縮センシング実践編

何をすれば良いのか??

▶ **最適化問題**を解けば良い!

▶ 解きたい最適化問題

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

▶ **罰金法**により等価な最適化問題

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

▶ LASSO (Least Absolute Shrinkage and Selection Operators)

▶ 絶対値関数が含まれるので難しそう = **単なる印象**にすぎない

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

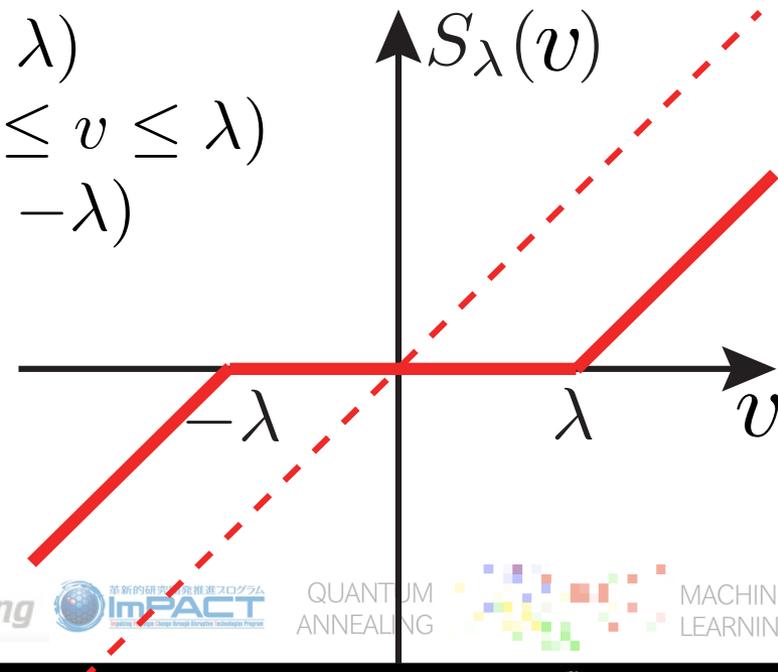
1変数なら解ける！

▶ 軟判定しきい値関数の導入

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

▶ 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。

$$x^* = S_\lambda(v) = \begin{cases} v - \lambda & (v > \lambda) \\ 0 & (-\lambda \leq v \leq \lambda) \\ v + \lambda & (v < -\lambda) \end{cases}$$



何をすれば良いのか??

▶ これなら解ける

- ▶ 仮に以下の最適化問題であれば、**微分なし**で解ける

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

- ▶ 軟判定しきい値関数の導入

$$x_i^* = S_\lambda(v_i) = \begin{cases} v_i - \lambda & (\lambda \leq v_i) \\ 0 & (-\lambda < v_i < \lambda) \\ v_i + \lambda & (v_i \leq -\lambda) \end{cases}$$

- ▶ もともとの最適化問題の代わりに**解きやすい形**にしよう

最近の進展：ADMM [Alternating Direction of Multiplier method] S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

- ▶ 勾配法に頼らない高速なアルゴリズム
 - ▶ 解きたい問題が2つ以上の関数の組み合わせとする

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

- ▶ Ex) LASSO

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

最近の進展：ADMM [Alternating Direction of Multiplier method] S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

- ▶ 勾配法に頼らない高速なアルゴリズム
 - ▶ 解きたい問題が2つ以上の関数の組み合わせとする

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

- ▶ Ex) LASSO

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

- ▶ あえてふたつの変数の問題に分割 (Spilitting)

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

最近の進展：ADMM [Alternating Direction of Multiplier method]

S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

- ▶ 勾配法に頼らない高速なアルゴリズム
 - ▶ 解きたい問題が2つ以上の関数の組み合わせとする

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

- ▶ Ex) LASSO

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

- ▶ あえてふたつの変数の問題に分割 (Spilitting)

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

- ▶ 拡張ラグランジュ法を利用する！ (未定乗数：h、罰金係数： ρ)

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

最近の進展：ADMM [Alternating Direction of Multiplier method]

S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

- ▶ 勾配法に頼らない高速なアルゴリズム
 - ▶ 解きたい問題が2つ以上の関数の組み合わせとする

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

- ▶ Ex) LASSO

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

- ▶ 交互にふたつの変数の最適化問題を解く

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

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

- ▶ ラグランジュ未定乗数を更新 $\mathbf{h} = \mathbf{h} + \rho(\mathbf{x} - \mathbf{z})$

最近の進展：ADMM [Alternating Direction of Multiplier method]

S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

- ▶ 勾配法に頼らない高速なアルゴリズム
 - ▶ 解きたい問題が2つ以上の関数の組み合わせとする

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

- ▶ Ex) LASSO

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

- ▶ 交互にふたつの変数の最適化問題を解く

$$\min_{\mathbf{x}} \left\{ \frac{1}{2} \|\mathbf{y} - A\mathbf{x}\|_2^2 + \mathbf{h}^T(\mathbf{x} - \mathbf{z}) + \frac{\rho}{2} \|\mathbf{x} - \mathbf{z}\|_2^2 \right\}$$

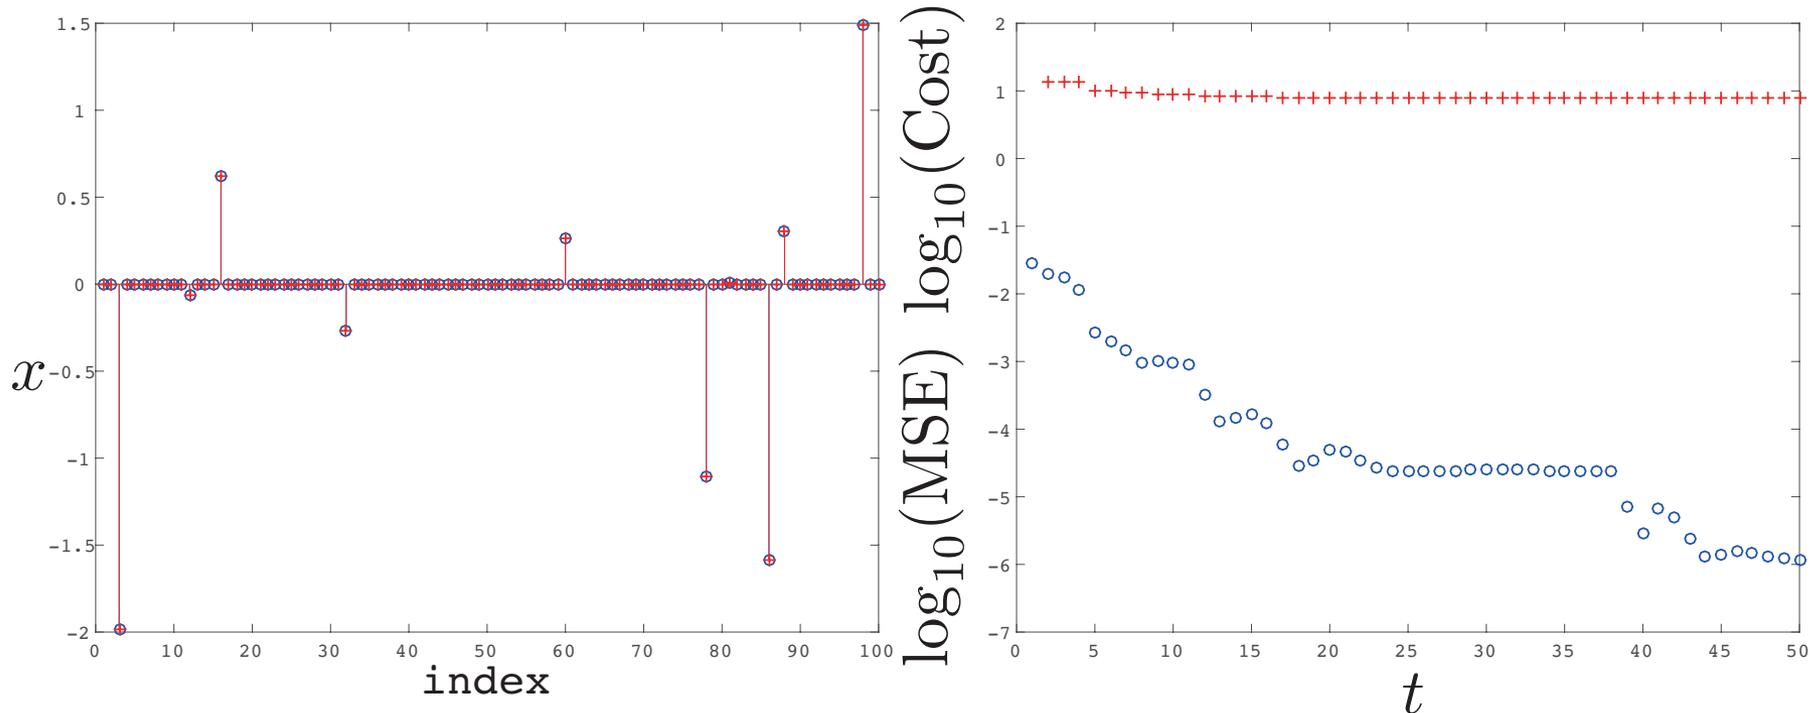
$$\min_{\mathbf{z}} \left\{ \lambda \|\mathbf{z}\|_1 + \mathbf{h}^T(\mathbf{x} - \mathbf{z}) + \frac{\rho}{2} \|\mathbf{x} - \mathbf{z}\|_2^2 \right\}$$

- ▶ ラグランジュ未定乗数を更新 $\mathbf{h} = \mathbf{h} + \rho(\mathbf{x} - \mathbf{z})$

最近の進展：ADMM [Alternating Direction of Multiplier method]

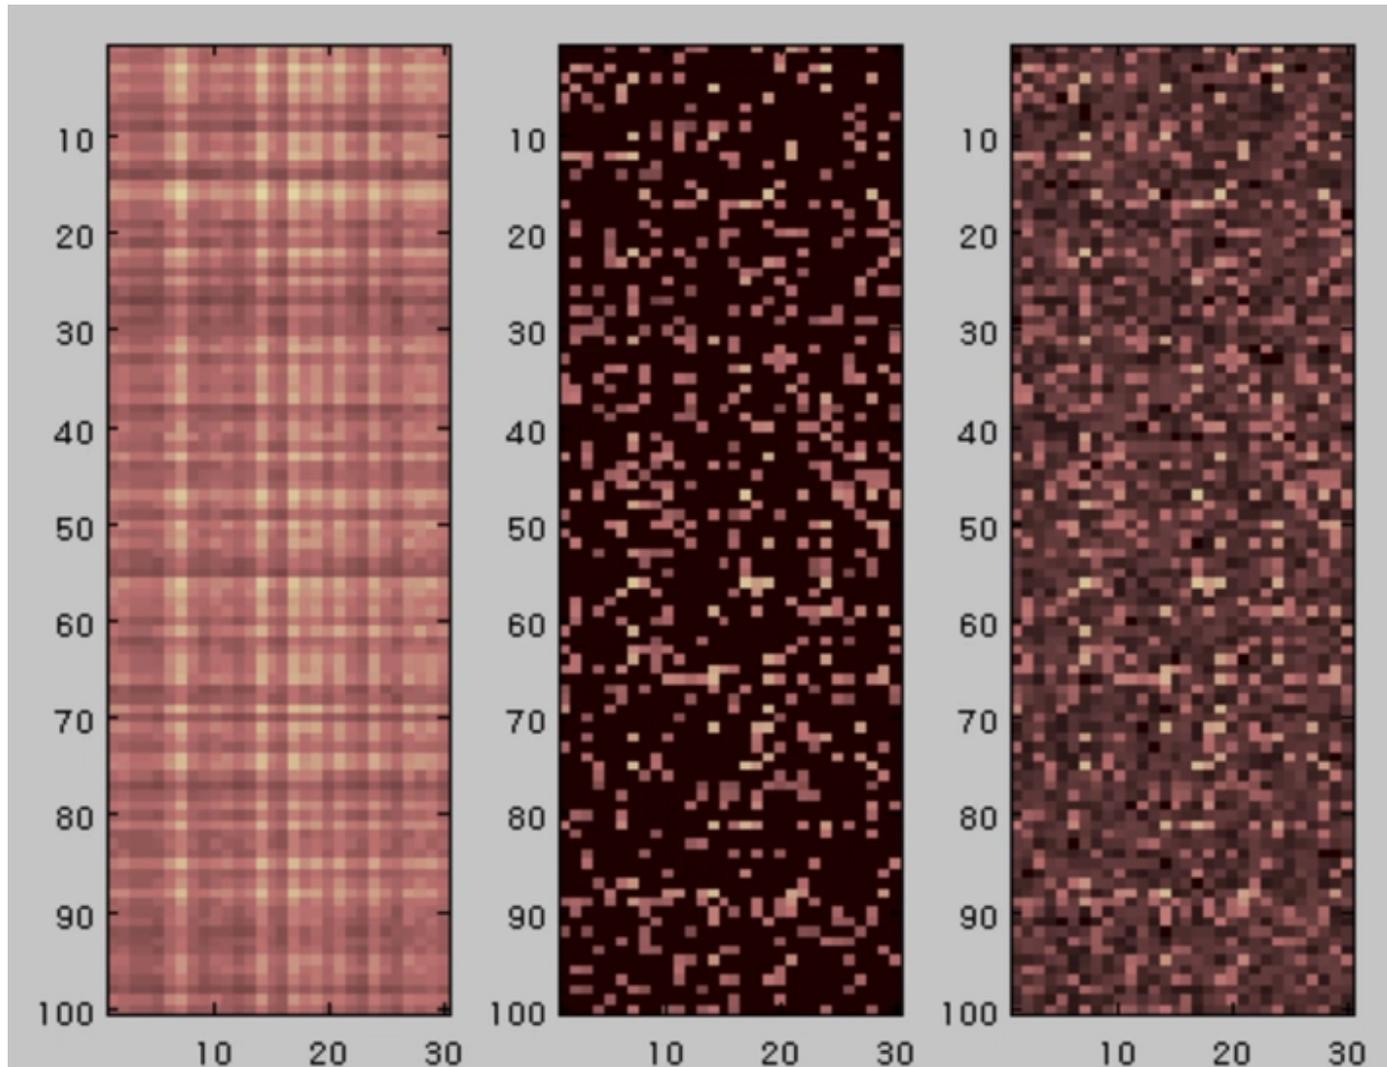
S. Boyd, et al. *Foundation and Trends in Machine Learning*, 3 (2010) 1

ADMM (コードは講義ノートに掲載中)



更なる戦略
低ランク性

サービスデータ+スパースモデリング



まとめ

- ▶ 機械学習という現代の魔法
 - ▶ 深層学習
 - ▶ 単純な繰り返しによる複雑な関数 f の近似
 - ▶ スパースモデリング
 - ▶ Find x by sparsity (圧縮センシング)
 - ▶ Make x sparse (辞書学習)
 - ▶ L1ノルム
 - ▶ スパースな解を当てることができる
 - ▶ 数学や統計物理による数理的保障がある
 - ▶ ADMM (alternating direction of multiplier method)
 - ▶ 拡張ラグランジュ法による最適化手法
 - ▶ 複数のコスト関数があっても良い
- ▶ 鍵は最適化問題
 - ▶ 世界各国で最適化専門のマシン・チップ登場