

Compressed sensing (もしくは compressive sampling) とよばれる新しい信号復元理論の枠組み¹⁾をご存知でしょうか。これは、対象とする信号を構成する要素がほとんどゼロであるというスパース性を前提として、少ない数の観測データから元の信号を復元するもので、数学的理論に裏打ちされるとともに、さまざまな応用分野への適用が可能なことから、大変な注目を集めています。本稿では、この compressed sensing をご紹介します。

まず、compressed sensing の問題設定を明らかにしましょう。対象とする信号を N 次元ベクトル \mathbf{x} とし、 \mathbf{x} に対する M 個の線形観測 $\mathbf{y} = (y_1, \dots, y_M)^T$ が次式により得られたとします。

$$\mathbf{y} = \Phi \mathbf{x} \quad (1)$$

ここで、 Φ は $M \times N$ の行列です。観測信号 \mathbf{y} から元信号 \mathbf{x} を復元する問題は、一般に線形逆問題とよばれますが、連立方程式を解くことと同値ですので、 $M \geq N$ を満たさなければ正しい解は得られません。ここで、信号 \mathbf{x} にスパース性があるとします。つまり、 \mathbf{x} のほとんどの要素がゼロであり、 $K (< M)$ 個の要素だけがゼロでない値をもちます。この前提のもと、 $M < N$ であるときの式 (1) の逆問題を解くことが、compressed sensing の問題設定となります。ここで注意しなければならないのは、 \mathbf{x} における非ゼロの K 個の要素の位置も未知である、という点です (もし、非ゼロの要素の位置がわかっていたら、 K より大きな M 個観測から \mathbf{x} を簡単に復元できてしまいます)。

次に解き方に移りましょう。上記の問題を素直に解こうとすれば、「式 (1) を満たし、かつ、 \mathbf{x} の非ゼロの要素数ができるだけ少ない \mathbf{x} を求める」とし

て解くことが考えられます。数学的には、非ゼロの要素の個数として定義される L_0 ノルム $\|\mathbf{x}\|_0$ を用いて、次式の最適化問題として定式化することができます。

$$\text{Minimize } \|\mathbf{x}\|_0 \quad \text{Subject to } \mathbf{y} = \Phi \mathbf{x} \quad (2)$$

しかし、この問題は NP ハードとよばれ、 \mathbf{x} の次元数 N が大きい場合には現実的な計算量では解くことができません。

そこで compressed sensing では、 L_0 ノルムの代わりに L_1 ノルム (要素の絶対値の和) を用いるアプローチをとります。つまり、式 (2) の代わりに

$$\text{Minimize } \|\mathbf{x}\|_1 \quad \text{Subject to } \mathbf{y} = \Phi \mathbf{x} \quad (3)$$

を解くことにします。この問題は、線形計画法のさまざまな解法を適用して解を得ることが可能です。さらに、このようにして得られた解は、 L_0 ノルム最小化として得られる解と多くの場合一致するのです。

これを理解するために、図 1 に L_1 ノルム最小化の概念図を示します ($N=2, K=1, M=1$ の場合)。太線は L_1 ノルム一定の条件を表しており、この領域を広げていき、観測条件を満たす点線にぶつかった点が解 $\hat{\mathbf{x}}$ (○) となります。この図からおわかりのように、 L_1 ノルム最小化で得られる解は、多く




図1 L_1 ノルム最小化 (左) と L_2 ノルム最小化 (右) の概念図 ($N=2, K=1, M=1$ の場合)。縦軸と横軸は二次元ベクトル \mathbf{x} の2要素に対応し、太線は L_1 ノルムもしくは L_2 ノルム一定の条件を、点線は $\mathbf{y} = \Phi \mathbf{x}$ の条件を、○は得られる解を表す。

の場合、 L_0 ノルム最小化で得られるスパースな解（軸上の点）と一致します。図1には比較のために、 L_2 ノルム最小化の場合も示しました。 L_2 ノルム最小化は、信号のパワー（ L_2 ノルム）を最小化することでノイズを抑制する効果があることから、線形逆問題でしばしば用いられます。両者を比較すると、ずいぶんと異なる解が得られることがわかるでしょう。

では、compressed sensing はスパースな信号にしか適用できないのでしょうか。答えは、「元信号自身がスパースでなくても、スパースな信号へ線形変換可能であれば適用可能」となります。画像信号は、ウェーブレット変換や周波数変換により、高周波成分がほとんどゼロのスパースな信号へ変換できることから、このような変換と組み合わせて compressed sensing が適用されています。

次に、compressed sensing による信号復元を試してみた結果を紹介します（図2）。 \mathbf{x} の次元数は $N=500$ で、非ゼロの要素数は $K=15$ 、 \mathbf{y} の次元数は $M=75$ 、観測行列 Φ はランダムな値で構成しました。 L_1 ノルム最小化にはフリーの MATLAB ライブラリ²⁾ を用いました。比較のために、式(3)の $\|\mathbf{x}\|_1$ を $\|\mathbf{x}\|_2$ に置き換えた L_2 ノルム最小化の結果も算出しました。結果をみますと、 L_2 ノルムではほとんど正しく推定できていないのに対し、確かに L_1 ノルムを用いることで、ほぼ正確に解が求められています。また、観測データにノイズをのせても、解が大きく変わることはありませんでした。

本稿では、compressed sensing の難しい理論には立ち入らず、直観的に理解しやすいエッセンスだけをお伝えしました。実際には、どのような条件のと

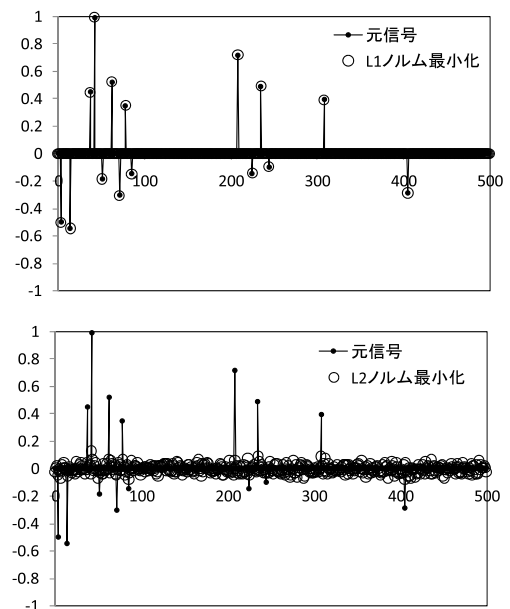


図2 スパース信号復元の例. L_1 ノルム最小化 (上), L_2 ノルム最小化 (下).

きに正しい解が得られるのか、 Φ をどのように設計すればよいのか、などのさまざまな理論的研究がなされています。一方、極限まで観測数を減らしたイメージングや、劣化した波形・画像信号の復元などの各種応用に関しても、多くの論文が発表されています。機会があれば、新しくと奥深い compressed sensing の世界をのぞかれてはいかがでしょうか。

(東京工業大学 村上百合)

文 献

- 1) E. J. Candes and M. B. Wakin: "An introduction to compressive sampling," IEEE Signal Process. Mag., **25** (2008) 21-30.
- 2) CVX: Matlab Software for Disciplined Convex Programming, <http://cvxr.com/cvx/>