

Network Lasso によるクラスタリングについて

–A Study of Clustering Based on the Network Lasso–

経営システム工学専攻 柳下翔太郎

1 はじめに

データ解析において、平均や回帰などの構造とクラスター構造を同時に推定したいという状況がしばしば生じる。近年、Hallac ら [1] が提案した Network Lasso (NL) はそれを実現する方法の 1 つであり、スパースモデリングのテクニックを利用した方法である。 $\mathcal{V} = [n] := \{1, \dots, n\}$ をサンプルのインデックスの集合、 $\mathcal{E} \subset \{\{i, j\} : i, j \in [n]; i \neq j\}$ をサンプル間の隣接の有無を表す集合、 $W = (w_{\{i,j\}})_{\{i,j\} \in \mathcal{E}} \in \mathbb{R}_{\geq 0}^{|\mathcal{E}|}$ を隣接したサンプル間の類似度を表す重みとし、重み付き無向グラフ $\mathcal{G} = (\mathcal{V}, \mathcal{E}, W)$ を考える。 $f_i : \mathbb{R}^p \rightarrow \mathbb{R}$ をサンプル $i \in [n]$ に対する損失関数とし、NL は以下のように定式化される。

$$\underset{x_1, \dots, x_n \in \mathbb{R}^p}{\text{minimize}} \sum_{i \in \mathcal{V}} f_i(x_i) + \gamma \sum_{\{i,j\} \in \mathcal{E}} w_{\{i,j\}} \|x_i - x_j\|_2. \quad (1)$$

ただし、 $\gamma > 0$ は定数、 $\|\cdot\|_2$ は l_2 ノルムである。直感的には、第 1 項はサンプルごとのフィッティングを強め、第 2 項は隣接したサンプルのパラメータを重みが大きいほど近づける効果を持つ。このことから、重み W はサンプル間の類似度に関する事前情報と解釈できる。さらに、Group Lasso のもつスパース性から、最適解 (x_1^*, \dots, x_n^*) において多くの $\{i, j\} \in \mathcal{E}$ に対して $x_i^* = x_j^*$ となることを期待し、そうなったとき、 i と j が同じクラスターに属していると判定する。たとえば、 $b_i \in \mathbb{R}$ を目的変数、 $a_i \in \mathbb{R}^p$ を説明変数とし、 $f_i(x_i) = \frac{1}{2}(b_i - a_i^\top x_i)^2$ とすれば、回帰構造とクラスター構造の同時推定、




図 1 \mathbb{R}^2 上での Network Lasso によるクラスタリングの失敗例 (左) と提案する Network Trimmed Lasso による成功例 (右). 三角の点がデータ点 a_i , 細い曲線が x_i^* の軌跡, すなわちクラスターパスを表している。

$a_i \in \mathbb{R}^p$ をデータ点とし、 $f_i(x_i) = \frac{1}{2}\|x_i - a_i\|_2^2$ とすれば、平均構造とクラスター構造の同時推定を考慮することができる。 $\gamma \rightarrow \infty$ とし正則化パスを考慮することで、階層クラスタリングにおけるデンドログラムのようなクラスターパスを生成できる (図 1)。

本稿ではまず、NL が潜在的な真のクラスターを復元するための十分条件を与える。次に、NL の持つ弱点を克服するような定式化を提案する。さらに、それに対して交互方向乗数法 (ADMM) (たとえば [2]) を適用しその収束性を示す。最後に、その定式化の有効性を数値実験により検討する。

2 Network Lasso のクラスター復元

この節では、NL が真のクラスターを復元するための十分条件を与える。これは Sun ら [3] が CC に対して与えた十分条件の NL に対する拡張である。

この節では、各サンプル $i \in \mathcal{V}$ が N 個の真のクラスター $C_1, \dots, C_N (C_i \cap C_j = \emptyset, C_1 \cup \dots \cup C_N = \mathcal{V})$ のうちの 1 つに入っていることを仮定する。

定義 1. $\mathcal{P} := \{C_1, \dots, C_N\}$ と $\bar{\mathcal{P}} := \{\bar{C}_1, \dots, \bar{C}_M\}$ を \mathcal{V} の分割とする.

1. $\bar{\mathcal{P}} = \mathcal{P}$ のとき, $\bar{\mathcal{P}}$ は \mathcal{P} を完全に復元する, という.
2. 任意の $\bar{C} \in \bar{\mathcal{P}}$ に対して, ある $I \subset \{1, \dots, N\}$ が存在して, $\bar{C} = \cup_{l \in I} C_l$ となると, $\bar{\mathcal{P}}$ は \mathcal{P} の粗化である, という. さらに $\bar{\mathcal{P}} = \{\mathcal{V}\}$ のとき, 自明な粗化である, という. そうでないとき, 非自明な粗化である, という.

真のクラスター $\mathcal{P} = \{C_1, \dots, C_N\}$ と (1) の重み $w_{\{i,j\}}$ に対して, いくつかの記号を定義する.

$$\begin{aligned} n_k &:= |C_k|, & k \in [N], \\ w_i^{(k)} &:= \sum_{j \in C_k} w_{\{i,j\}}, & i \in \mathcal{V}, k \in [N], \\ w^{(k,k')} &:= \sum_{i \in C_k} \sum_{j \in C_{k'}} w_{\{i,j\}}, & k, k' \in [N]. \end{aligned}$$

簡単のために, $\{i,j\} \notin \mathcal{E}$ に対しては $w_{\{i,j\}} = 0$ とした.

定理 1. 任意の $i \in \mathcal{V}$ に対して, f_i は狭義凸かつ L_i -平滑であるとする. $f^{(k)} := \sum_{i \in C_k} f_i$ とし, 任意の $k \in [N]$ に対し, $f^{(k)}$ は α_k -強凸であるとし, $\bar{x}^{(k)} = \operatorname{argmin}_{x \in \mathbb{R}^p} f^{(k)}(x)$ とおく. 任意の $k \neq k'$ に対し, $\bar{x}^{(k)} \neq \bar{x}^{(k')}$ を仮定する. 任意の $i, j \in C_k, k \in [N]$ に対し

$$\mu_{ij}^{(k)} = \sum_{l \neq k} \left| w_i^{(l)} - w_j^{(l)} \right| + \frac{2(L_i + L_j)}{\alpha_k} \sum_{l \neq k} w^{(k,l)}$$

とし, $n_k w_{\{i,j\}} > \mu_{ij}^{(k)}$ を仮定する.

$$\begin{aligned} \gamma_{\max} &:= \min_{k \neq k'} \left\{ \frac{\|\bar{x}^{(k)} - \bar{x}^{(k')}\|_2}{\frac{2}{\alpha_k} \sum_{l \neq k} w^{(k,l)} + \frac{2}{\alpha_{k'}} \sum_{l \neq k'} w^{(k',l)}} \right\}, \\ \gamma_{\min} &:= \max_k \max_{i,j \in C_k} \left\{ \frac{\|\nabla f_j(\bar{x}^{(k)}) - \nabla f_i(\bar{x}^{(k)})\|_2}{n_k w_{\{i,j\}} - \mu_{ij}^{(k)}} \right\}, \end{aligned}$$

とする. ただし, $a > 0$ に対して $\frac{a}{0} = \infty$ とする.

(x_1^*, \dots, x_n^*) を (1) の最適解とし, $\bar{\mathcal{P}}$ を同値関係 $x_i^* = x_j^*$ から定まる \mathcal{V} の商集合とする.

1. $\gamma_{\min} \leq \gamma < \gamma_{\max}$ ならば, $\bar{\mathcal{P}}$ は \mathcal{P} を完全に復元する.

2. $\gamma_{\min} \leq \gamma < \max_k \frac{\|\nabla f^{(k)}(\bar{x})\|_2}{\sum_{l \neq k} w^{(k,l)}}$ ならば, $\bar{\mathcal{P}}$ は \mathcal{P} の非自明な粗化である. ただし,

$$\bar{x} := \operatorname{argmin}_{x \in \mathbb{R}^p} \sum_{k \in [N]} f^{(k)}(x) = \operatorname{argmin}_{x \in \mathbb{R}^p} \sum_{i \in \mathcal{V}} f_i(x).$$

である.

定理 1 から, 事前情報がうまく与えられれば, γ を $[\gamma_{\min}, \gamma_{\max})$ 上でとることで, NL が真のクラスター $\{C_1, \dots, C_N\}$ を復元できることがわかる.

3 Network Trimmed Lasso

NL では, 上述の十分条件が成立しない, 特に, 重み $w_{\{i,j\}}$ が「うまく」与えられていないとき, 図 1 左のように, 単純な数値例においてさえ厳密に $x_i^* = x_j^*$ とならず, 真のクラスターどころかクラスターを形成することさえできない. これを解決するために, 以下のような基数制約による定式化を考える.

$$\begin{aligned} &\text{minimize}_{x_1, \dots, x_n} \sum_{i \in \mathcal{V}} f_i(x_i) & (2) \end{aligned}$$

$$\text{subject to } \left| \left\{ \{i,j\} \in \mathcal{E} : \|x_i - x_j\|_2 > 0 \right\} \right| \leq K.$$

ただし, K は $K \leq |\mathcal{E}|$ であるような非負整数である. $x_i^* = x_j^*$ となるような制約を直接組み込むことで, クラスターが形成される. さらに, K の減少につれて, $x_i^* = x_j^*$ となるエッジが増え, クラスターパスの生成が期待できる. しかし, (2) の基数制約の左辺は (x_1, \dots, x_n) の不連続関数であり, 一般に, 問題 (2) は大域的な解を得ることが難しい. このような事情から, まず基数制約を連続関数による等価な制約に書き換える. $\mathbf{z} = (z_{\{i,j\}})_{\{i,j\} \in \mathcal{E}} \in \mathbb{R}^{p|\mathcal{E}|}$ とし, $\|z_{\{i,j\}}\|_2$ の小さいほうから $|\mathcal{E}| - K$ 個の要素の和を

$$T_K(\mathbf{z}) = \|z_{(K+1)}\|_2 + \dots + \|z_{(|\mathcal{E}|)}\|_2$$

とおく. ここで, $\|z_{(i)}\|_2$ は $(\|z_1\|_2, \dots, \|z_{|\mathcal{E}|}\|_2) \in \mathbb{R}^{|\mathcal{E}|}$ の大きいほうから i 番目の要素を表す. $\mathbf{x} := (x_i)_{i \in \mathcal{V}}$ とし, D を $z_{\{i,j\}} = x_i - x_j$ となるような

$p|\mathcal{E}| \times pn$ 行列とすれば, (2) は以下の最適化問題と等価である [4].

$$\begin{aligned} & \underset{x_1, \dots, x_n}{\text{minimize}} && \sum_{i \in \mathcal{V}} f_i(x_i) \\ & \text{subject to} && T_K(D\mathbf{x}) = 0. \end{aligned} \quad (3)$$

$T_K(D\mathbf{x})$ は非凸であるが, \mathbf{x} の連続関数である. さらに, (3) に対して, $\gamma > 0$ として, 以下の無制約問題を考える.

$$\underset{x_1, \dots, x_n}{\text{minimize}} \sum_{i \in \mathcal{V}} f_i(x_i) + \gamma T_K(D\mathbf{x}). \quad (4)$$

$T_K(D\mathbf{x}) \geq 0$ であり, $T_K(D\mathbf{x}) > 0$ と $|\{\{i, j\} \in \mathcal{E} : \|x_i - x_j\|_2 > 0\}| > K$ が等価であるので, (4) の第二項は基数制約に対するペナルティ関数の役割を果たす. 本稿では, (4) を Network Trimmed Lasso (NTL) と呼ぶ. 次に示すように, 適当な仮定の下で γ を十分大きくとれば, NTL は (3) と等価であることが示される.

定理 2. 1. 任意の $i \in \mathcal{V}$ に対し, f_i が L_i -平滑であるとし, $\mathbf{x}^\gamma := (x_1^\gamma, \dots, x_n^\gamma)$ を (4) の最適解とする. ある $C > 0$ が存在し, 任意の $i \in \mathcal{V}, \gamma > 0$ に対して $\|x_i^\gamma\|_2 \leq C$ であることを仮定する. このとき,

$$\gamma > \sum_{i \in \mathcal{V}} (\|\nabla f_i(0)\|_2 + 2L_i C) \quad (5)$$

ならば, \mathbf{x}^γ は (3) の最適解である.

2. f_i に L_i -平滑性に加えて凸性を仮定し, $\mathbf{x}^\gamma := (x_1^\gamma, \dots, x_n^\gamma)$ を (4) の局所最適解とする. ある $C > 0$ が存在し, 任意の $i \in \mathcal{V}, \gamma > 0$ に対して $\|x_i^\gamma\|_2 \leq C$ であることを仮定する. このとき, (5) が成立するならば, \mathbf{x}^γ は (3) の局所最適解である.

この定理に動機を得て, 基数制約付き問題 (2) の代わりに NTL (4) を解くことを考える.

4 アルゴリズム

最適化問題 (4) を解くために, ADMM の適用を考える. まず, (4) を以下の等価な線型等式制約付

きの問題に書き換える.

$$\begin{aligned} & \underset{\mathbf{x}, \mathbf{z}}{\text{minimize}} && \sum_{i \in \mathcal{V}} f_i(x_i) + \gamma T_K(\mathbf{z}) \\ & \text{subject to} && \mathbf{z} = D\mathbf{x}. \end{aligned} \quad (6)$$

双対変数を $\mathbf{y} \in \mathbb{R}^{p|\mathcal{E}|}$, $\rho > 0$ を定数として, (6) の拡張ラグランジュ関数を,

$$\begin{aligned} L_\rho(\mathbf{x}, \mathbf{z}, \mathbf{y}) = & \sum_{i \in \mathcal{V}} f_i(x_i) + \gamma T_K(\mathbf{z}) \\ & + \mathbf{y}^\top (\mathbf{z} - D\mathbf{x}) + \frac{\rho}{2} \|\mathbf{z} - D\mathbf{x}\|_2^2 \end{aligned}$$

で定義する. ADMM は各反復 t で

$$\mathbf{z}^{t+1} \in \underset{\mathbf{z}}{\text{argmin}} L_\rho(\mathbf{x}^t, \mathbf{z}, \mathbf{y}^t), \quad (7)$$

$$\mathbf{x}^{t+1} \in \underset{\mathbf{x}}{\text{argmin}} L_\rho(\mathbf{x}, \mathbf{z}^{t+1}, \mathbf{y}^t), \quad (8)$$

$$\mathbf{y}^{t+1} = \mathbf{y}^t + \rho(\mathbf{z}^{t+1} - D\mathbf{x}^{t+1})$$

のように点列を生成する反復法である. (7) は非凸であるが解析解を導出できる. (8) が解析解を持たない場合には, $L > 0$ として, (8) を以下に置き換える.

$$\mathbf{x}^{t+1} \in \underset{\mathbf{x}}{\text{argmin}} \left\{ \nabla f(\mathbf{x}^t)^\top (\mathbf{x} - \mathbf{x}^t) + \frac{L}{2} \|\mathbf{x} - \mathbf{x}^t\|_2^2 + (\mathbf{y}^t)^\top (\mathbf{z}^{t+1} - D\mathbf{x}) + \frac{\rho}{2} \|\mathbf{z}^{t+1} - D\mathbf{x}\|_2^2 \right\}.$$

ただし, $f(\mathbf{x}) = \sum_{i \in \mathcal{V}} f_i(x_i)$ である. この修正を施したものは, 近接 ADMM [5] と呼ばれる. これらのアルゴリズムの収束性に関して, 以下が成り立つ.

定理 3. 任意の $i \in \mathcal{V}$ に対して f_i は連続的微分可能かつ凸であると仮定する. ADMM (もしくは, 近接 ADMM) によって生成された点列 $(\mathbf{x}^t, \mathbf{z}^t, \mathbf{y}^t)$ が $(\mathbf{x}^*, \mathbf{z}^*, \mathbf{y}^*)$ に収束することを仮定する. このとき, \mathbf{x}^* は (4) の局所最適解である.

これらのことから, f_i が L_i -平滑かつ凸であり, ADMM (もしくは, 近接 ADMM) によって生成された点列が収束すれば, 基数制約付き問題 (2) の局所最適解を得ることができる.

5 数値実験

NTL (4) を $K \searrow 0$ として解のパスを考えることで, 図 1 右のようなクラスターパスが生成でき

る。この節では、実験結果の1つを提示する。図2は2種類の単回帰の人工データに対する、NL, NTL, NL+NTLによるクラスターパスである。クラスターパスの初期値は $(x_{i,1}^0, x_{i,2}^0) = (b_i, 0) = \operatorname{argmin}_{x \in \mathbb{R}^2} f_i(x)$ とし、NL+NTLでは途中からNLからNTLに切り替えた。NLとデータセット2に対するNTLではクラスタリングが失敗しているが、NL+NTLではどちらのデータセットに対してもクラスタリングがうまくいっている。このNTLの初期値にNLの解を用いる方法は、どのような損失関数に対しても適用できる。このほかの数値実験の結果は、論文本体を参照されたい。

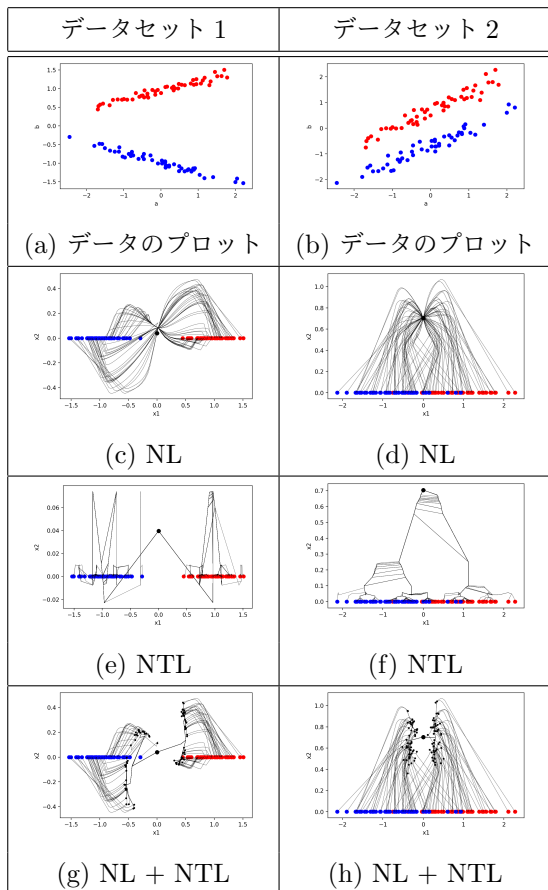


図2 単回帰データとクラスターパス。

6 まとめ

本稿ではまず、Network Lassoが真のクラスターを復元する十分条件を与え、事前情報をうまく与えられたNetwork Lassoがクラスタリングに有効であることを理論的に示した。次に、Network Trimmed Lassoを提案し、それが基数制約付き問題と等価であることを示した。さらに、ADMMに基づくアルゴリズムを提案し、その収束性を示した。最後に、数値実験によりNetwork Trimmed Lassoの有効性を示した。しかしながら、ADMMの収束性は点列の収束を仮定しており、あまり強い結果ではないので、この仮定を弱めることや、大域的収束性を示すことが今後の課題として残る。

参考文献

- [1] D. Hallac, J. Leskovec, and S. Boyd, Network lasso: Clustering and optimization in large graphs, KDD, (2015), 387–396.
- [2] S. Boyd, N. Parikh, E. Chu, B. Peleato, J. Eckstein, et al., Distributed optimization and statistical learning via the alternating direction method of multipliers, *Found. Trends Mach. Learn.*, 3 (2011), 1–122.
- [3] D. Sun, K. C. Toh, and Y. Yuan. Convex clustering: Model, theoretical guarantee and efficient algorithm. arXiv preprint 1810.02677, (2018).
- [4] J. Gottoh, A. Takeda, and K. Tono, DC formulations and algorithms for sparse optimization problems, *Math. Program.*, 169 (2018), 141–176.
- [5] G. Li and T. K. Pong, Global convergence of splitting methods for nonconvex composite optimization, *SIAM J. Optim.*, 25 (2015), 2434–2460.