

近似的劣モジュラ性を用いた 局所探索法の近似保証

藤井 海斗 (国立情報学研究所)

OPTA 第 14 回研究会

2021/1/8

すべての部分集合に実数値を割り当てる関数



$$f: 2^N \rightarrow \mathbb{R}$$

N は要素全体の集合
(台集合と呼ぶ)

$$n \triangleq |N|$$

$$N = \left\{ \text{🍝}, \text{🍡}, \text{🥦}, \text{🍕}, \text{🍱}, \text{🍞}, \text{🍜}, \text{🍫}, \text{🍔}, \text{🍩}, \text{🍌}, \text{🍞}, \text{🌙}, \text{🍙} \right\}$$

すべての部分集合に実数値を割り当てる関数

$$f(\{\text{🥦}, \text{🍔}, \text{🍌}\}) = 50$$



$$f: 2^N \rightarrow \mathbb{R}$$

N は要素全体の集合
(台集合と呼ぶ)

$$n \triangleq |N|$$

$$N = \{\text{🍜}, \text{🍡}, \text{🥦}, \text{🍕}, \text{🍱}, \text{🍔}, \text{🍜}, \text{🍩}, \text{🍌}, \text{🍞}, \text{🌧️}, \text{🍱}\}$$

すべての部分集合に実数値を割り当てる関数

$$f(\{\text{🍝, 🍔}\}) = 20$$



$$f: 2^N \rightarrow \mathbb{R}$$

N は要素全体の集合
(台集合と呼ぶ)

$$n \triangleq |N|$$

$$N = \{\text{🍝, 🍷, 🥦, 🍕, 🍱, 🍔, 🍜, 🍫, 🍔, 🍩, 🍌, 🍞, 🌂, 🏠}\}$$

実行可能な集合を集合族 $\mathcal{I} \subseteq 2^N$ で表現

例 要素数の制約

要素数 k 以下の集合はすべて実行可能

$$\mathcal{I} = \{X \in 2^N \mid |X| \leq k\}$$

例 予算の制約 (ナップサック制約)

各要素 $v \in N$ の価格が c_v 円するとき,

合計金額が B 円以下の集合はすべて実行可能

$$\mathcal{I} = \{X \in 2^N \mid \sum_{v \in X} c_v \leq B\}$$

関数値が最大となる部分集合を見つける問題

Maximize $f(X)$ 目的関数

subject to $X \in \mathcal{I}$ 制約

- ※ $X \subseteq N$ を入力すると $f(X)$ の値と $X \in \mathcal{I}$ かどうかを出力する
オラクルを使えると仮定

解の候補は指数的に多い

→ 全部を調べると天文学的な時間がかかる

Q f と \mathcal{I} がどんな条件を満たせば効率的に解けるか？

1 劣モジュラ最大化

2 近似的劣モジュラ性による貪欲法の近似保証

3 近似的劣モジュラ性による局所探索の近似保証

手元にある要素が増えると新しい要素による増分が減る

$$f(v|A) \triangleq f(A \cup \{v\}) - f(A)$$

$A \subseteq N$ に対して $v \in N$ を追加したときの増分



f が劣モジュラ

\triangleq
 $\Leftrightarrow A \subseteq B$ を満たす任意の $A, B \subseteq N$ と $v \in N \setminus B$ について

$f(v|A) \geq f(v|B)$ が成り立つ

$A = \{\text{🍝}\}, B = \{\text{🍝}, \text{🍷}\}, v = \text{🍷}$ のとき

$$f(\{\text{🍷}, \text{🍝}\}) - f(\{\text{🍝}\}) \geq f(\{\text{🍷}, \text{🍝}, \text{🍷}\}) - f(\{\text{🍝}, \text{🍷}\})$$

要素を追加すると関数値が増える（減らない）

$$f(v|A) \triangleq f(A \cup \{v\}) - f(A)$$

$A \subseteq N$ に対して $v \in N$ を追加したときの増分

f が単調

\triangleq
 \Leftrightarrow 任意の $A \subseteq N$ と $v \in N$ について $f(v|A) \geq 0$ が成立

$A = \{\text{🍌}, \text{🍷}\}, v = \text{🍕}$ のとき

$$f(\{\text{🍕}, \text{🍌}, \text{🍷}\}) - f(\{\text{🍌}, \text{🍷}\}) \geq 0$$

Maximize $f(X)$ 目的関数（劣モジュラ関数）
subject to $X \in \mathcal{I}$ 制約

各問題設定（目的関数が単調 or 非単調、さまざまな制約）に対してアルゴリズムが研究されてきた

※ 最も単純な設定

- 単調・要素数制約 $\mathcal{I} = \{X \in 2^N \mid |X| \leq k\}$
- 非単調・制約なし

でも多項式時間で最適解を求めるのは困難

現実には効率的に最適解を求めるのが難しい問題も多い

→ **近似比**に保証のある多項式時間アルゴリズム

$\alpha = 0$ ←————→ $\alpha = 1$

任意の
アルゴリズム

最適解が
つねに求まる

$\alpha \in [0, 1]$ がアルゴリズムの**近似比** (アルゴリズムは α 近似)

\triangle
 \Leftrightarrow 任意の問題例において $\mathbb{E}[f(X)] \geq \alpha f(X^*)$

(X アルゴリズムの解, X^* 最適解)

1 貪欲法

劣モジュラ最大化アルゴリズムの多くが貪欲法に基づく
連続緩和 + 丸め、部分列挙など多様な手法

2 局所探索


マトロイド交叉、交換システムに対しては最良の近似比

3 その他

ランダムサンプリングなど

各ステップで目的関数値が最も増える要素を追加していく

$$f(\emptyset) = 0$$



貪欲法

- 1: $X_0 \leftarrow \emptyset$
- 2: **for** $i = 1, \dots, k$ **do**
- 3: $v_i \in \operatorname{argmax}_{v \in N} f(v | X_{i-1})$
- 4: $X_i \leftarrow X_{i-1} \cup \{v_i\}$
- 5: **return** X_k

各ステップで目的関数値が最も増える要素を追加していく



$$f(\{\text{🍔}\}) = 50$$

貪欲法

- 1: $X_0 \leftarrow \emptyset$
- 2: **for** $i = 1, \dots, k$ **do**
- 3: $v_i \in \operatorname{argmax}_{v \in N} f(v|X_{i-1})$
- 4: $X_i \leftarrow X_{i-1} \cup \{v_i\}$
- 5: **return** X_k

各ステップで目的関数値が最も増える要素を追加していく



$$f(\{\text{🍞, 🥦}\}) = 60$$



貪欲法

- 1: $X_0 \leftarrow \emptyset$
- 2: **for** $i = 1, \dots, k$ **do**
- 3: $v_i \in \operatorname{argmax}_{v \in N} f(v|X_{i-1})$
- 4: $X_i \leftarrow X_{i-1} \cup \{v_i\}$
- 5: **return** X_k

各ステップで目的関数値が最も増える要素を追加していく

$$f(\{\text{🍷}, \text{🍷}, \text{🍷}\}) = 65$$



貪欲法

- 1: $X_0 \leftarrow \emptyset$
- 2: **for** $i = 1, \dots, k$ **do**
- 3: $v_i \in \operatorname{argmax}_{v \in N} f(v | X_{i-1})$
- 4: $X_i \leftarrow X_{i-1} \cup \{v_i\}$
- 5: **return** X_k

各ステップで目的関数値が最も増える要素を追加していく



$$f(\{\text{🍷}, \text{🥦}, \text{🍞}\}) = 65$$

貪欲法

- 1: $X_0 \leftarrow \emptyset$
- 2: **for** $i = 1, \dots, k$ **do**
- 3: $v_i \in \operatorname{argmax}_{v \in N} f(v | X_{i-1})$
- 4: $X_i \leftarrow X_{i-1} \cup \{v_i\}$
- 5: **return** X_k

$$f(A|B) \triangleq f(A \cup B) - f(B)$$

$B \subseteq N$ に対して $A \subseteq N$ を追加したときの増分

補題

$f: 2^N \rightarrow \mathbb{R}$ が劣モジュラるとき

任意の集合 $A, B \subseteq N$ について $f(A|B) \leq \sum_{v \in A} f(v|B)$

証明 $A \triangleq \{a_1, \dots, a_{|A|}\}$ 任意の順序

$$f(A|B) = \sum_{i=1}^{|A|} f(a_i | B \cup \{a_1, \dots, a_{i-1}\}) \leq \sum_{i=1}^{|A|} f(a_i | B)$$

$$f(\{\text{🍕}, \text{🍌}\} | \{\text{🎮}\}) \leq f(\text{🍕} | \{\text{🎮}\}) + f(\text{🍌} | \{\text{🎮}\})$$

定理 [Nemhauser-Wolsey-Fisher'78]

f が非負単調劣モジユラならば

$$f(X_k) \geq (1 - 1/e) \max_{X^* : |X^*| \leq k} f(X^*)$$

補題

f が劣モジユラならば $f(v_i | X_{i-1}) \geq \frac{1}{k} (f(X^*) - f(X_{i-1}))$

証明 $f(v_i | X_{i-1}) = \max_{v \in N} f(v | X_{i-1})$ (貪欲法の性質)

$\geq \frac{1}{k} \sum_{v \in X^*} f(v | X_{i-1}) \geq \frac{1}{k} f(X^* | X_{i-1})$ (劣モジユラ性)

$\geq \frac{1}{k} (f(X^*) - f(X_{i-1}))$ (単調性)

定理 [Nemhauser-Wolsey-Fisher'78]

f が非負単調劣モジュラならば

$$f(X_k) \geq (1 - 1/e) \max_{X^* : |X^*| \leq k} f(X^*)$$

証明 $f(X^*) - f(X_i) \leq (1 - \frac{1}{k})^i f(X^*)$ を数学的帰納法で示す

(i) $i = 0$ のとき非負性より $f(X^*) - f(\emptyset) \leq f(X^*)$

(ii) i で成り立つと仮定すると

$$\begin{aligned} f(X^*) - f(X_i) &= f(X^*) - f(X_{i-1}) - f(v_i | X_{i-1}) \\ &\leq \left(1 - \frac{1}{k}\right) (f(X^*) - f(X_{i-1})) \leq \left(1 - \frac{1}{k}\right)^i f(X^*) \end{aligned}$$

$i = k$ を代入すると $(1 - \frac{1}{k})^k \leq \frac{1}{e}$ より $f(X_k) \geq (1 - 1/e)f(X^*)$


単調

- 部分列挙によりナップサック制約に対して $(1 - 1/e)$ 近似 [Sviridenko'04]
- p システム制約に対して $1/(p + 1)$ 近似 [Jenkyns'76, CCPV'11]
- 連続貪欲法によりマトロイド制約に対して $(1 - 1/e)$ 近似 [Calinescu-Checkuri-Pál-Vondrák'11]
- ...

非単調

- 乱択貪欲法により要素数制約に対して $1/e$ 近似 [BFNS'14]
- マトロイド制約に対して 0.385 近似 [Buchbinder-Feldman'19]
- ...

組合せ最適化で広く用いられるアルゴリズム設計法



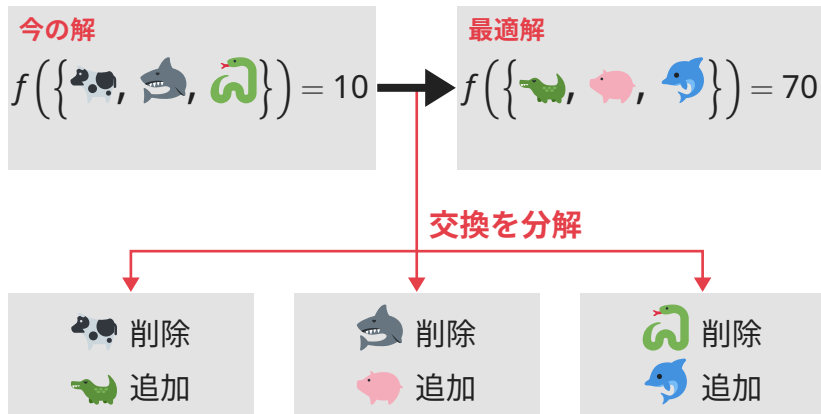
初期解から始めて、解を少しずつ変更しながら関数値を改善

各ステップで目的関数値が最も増える要素を追加していく

局所探索

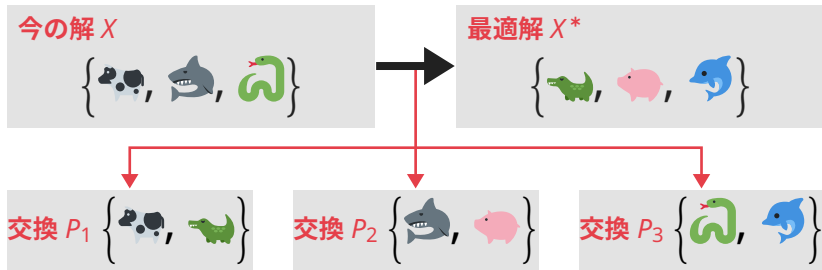
- 1: $X \leftarrow$ 任意の要素数 k の集合
- 2: **while** 関数値が改善する限り **do**
- 3: X から 1 要素だけ交換して関数値を改善
- 4: return X

- ※ このアルゴリズムは多項式時間で終わるとは限らない
→ 改善の幅を ϵ 以上に制限すれば多項式時間
- ※ 元の論文 [NWF'78] では複数要素の交換も扱われている



f が非負単調劣モジュラならば、

それぞれの交換による増分の和 \geq 最適値 $- 2 \times$ 今の値



補題

f が非負単調劣モジュラならば、

$$\sum_{P \in \mathcal{P}} \{f(X \Delta P) - f(X)\} \geq f(X^*) - 2f(X)$$

※ $X \Delta P \triangleq (X \setminus P) \cup (P \setminus X)$ 対称差

定理 [Nemhauser-Wolsey-Fisher'78]

局所探索の出力を X とすると

$$f(X) \geq 0.5 \max_{X^* : |X^*| \leq k} f(X^*)$$

証明 前頁の補題より $\sum_{P \in \mathcal{P}} \{f(X \Delta P) - f(X)\} \geq f(X^*) - 2f(X)$

X は局所探索の出力だから $f(X \Delta P) - f(X) \leq 0$ ($\forall P \in \mathcal{P}$)

よって $f(X^*) - 2f(X) \leq 0$ $\therefore f(X) \geq 0.5 f(X^*)$

※ 貪欲法の近似比 $1 - 1/e \approx 0.632$ より悪い

単調

- マトロイド制約に対する $(1 - 1/e)$ 近似 [Filmus-Ward'14]
- p マトロイド交叉制約に対する $1/(p + \epsilon)$ 近似
[Lee-Sviridenko-Vondrák'10]
- p 交換システム制約に対する $1/(p + \epsilon)$ 近似
[Feldman-Naor-Schwartz-Ward'11]

非単調

- 制約なしに対する決定的 $1/3$ 近似と乱択 $2/5$ 近似
[Feige-Mirrokní-Vondrák'11]
- p マトロイド交叉制約に対する $\frac{1}{p+2+1/p+\epsilon}$ 近似
[Lee-Mirrokní-Nagarajan-Sviridenko'10]


1 劣モジュラ最大化

2 近似的劣モジュラ性による貪欲法の近似保証

3 近似的劣モジュラ性による局所探索の近似保証

線形回帰のスパースな解を求める問題

$$\begin{aligned} & \text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} && R^2 := 1 - \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2 \\ & \text{subject to} && \|\mathbf{w}\|_0 \leq s \quad \text{非凸な制約} \end{aligned}$$



\mathbf{w} の非ゼロ要素を選択する問題を集合関数最大化とみなす

$$\begin{aligned} & \text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} && R^2 := 1 - \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2 \\ & \text{subject to} && \|\mathbf{w}\|_0 \leq s \end{aligned}$$


↓ $f_{R^2}(X) \triangleq 1 - \min_{\mathbf{w}: \text{supp}(\mathbf{w}) \subseteq X} \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2$ を導入

$$\text{Maximize}_{X \subseteq N \triangleq \{1, \dots, n\}} f_{R^2}(X) \quad \text{subject to } |X| \leq s$$

$$\mathbf{y} = \mathbf{A} \mathbf{w} + \epsilon$$

$$f_{R^2}(X) \triangleq 1 - \min_{\mathbf{w}: \text{supp}(\mathbf{w}) \subseteq X} \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2$$

$$\mathbf{y} := \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad \mathbf{A} := \begin{bmatrix} 1 & -1 \\ 0.1 & 0.1 \end{bmatrix}$$



$$f(\emptyset) = 0$$

$$f(\{1\}) = f(\{2\}) \approx 0.0099$$

$$f(\{1, 2\}) = 1$$

$$f(1|\emptyset) \approx 0.0099$$

$$\neq f(1|\{2\}) \approx 0.99$$

劣モジュラ関数でない

目的関数が劣モジュラ性をもたなくても、
劣モジュラ性に近い性質（**近似的劣モジュラ性**）があれば
劣モジュラ最大化の技術を適用できるのではないか？



近似的劣モジュラ性を定義することで、
劣モジュラ性のない問題に対して近似アルゴリズムを設計

単調な集合関数の劣モジュラ関数への近さを表す

$\gamma = 0$ ←————→ $\gamma = 1$

劣モジュラ関数
から遠い

劣モジュラ関数
に近い

$\gamma_{U,k} \in [0, 1]$ が単調な集合関数 f の

(集合 U と自然数 k に関する) **劣モジュラ比**

$$\Leftrightarrow \gamma_{U,k} \overset{\Delta}{f(S|T)} \leq \sum_{v \in S} f(v|T) \quad (\forall T \subseteq U, S \subseteq N \text{ s.t. } |S| \leq k)$$

$$f(A|B) \triangleq f(A \cup B) - f(B)$$

$B \subseteq N$ に対して $A \subseteq N$ を追加したときの増分

補題

$f: 2^N \rightarrow \mathbb{R}$ が劣モジュラるとき

任意の集合 $A, B \subseteq N$ について $f(A|B) \leq \sum_{v \in A} f(v|B)$

証明 $A \triangleq \{a_1, \dots, a_{|A|}\}$ 任意の順序

$$f(A|B) = \sum_{i=1}^{|A|} f(a_i | B \cup \{a_1, \dots, a_{i-1}\}) \leq \sum_{i=1}^{|A|} f(a_i | B)$$

$$f(\{\text{🍕}, \text{🍌}\} | \{\text{🎮}\}) \leq f(\text{🍕} | \{\text{🎮}\}) + f(\text{🍌} | \{\text{🎮}\})$$

貪欲法の近似保証に用いた劣モジュラ関数の性質を
どれくらい緩めれば成り立つかを表す

補題

$f: 2^N \rightarrow \mathbb{R}$ が劣モジュラるとき

任意の集合 $A, B \subseteq N$ について $f(A|B) \leq \sum_{v \in A} f(v|B)$

↓ 不等式を緩める


$\gamma_{U,k} \in [0, 1]$ が単調な集合関数 f の

(集合 U と自然数 k に関する) **劣モジュラ比**

$$\triangleq \Leftrightarrow \gamma_{U,k} f(S|T) \leq \sum_{v \in S} f(v|T) \quad (\forall T \subseteq U, S \subseteq N \text{ s.t. } |S| \leq k)$$

定理 [Das-Kempe'11]

単調な集合関数の劣モジュラ比が $\gamma_{U,k}$ のとき、
貪欲法の解 X は最適解の $(1 - \exp(-\gamma_{X,k}))$ 近似



$$f_{R^2}(X) \triangleq 1 - \min_{\mathbf{w}: \text{supp}(\mathbf{w}) \subseteq X} \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2$$

定理 [Das-Kempe'11]

\mathbf{A} の各列が正規化されていると仮定すると

f_{R^2} の (U と k に関する) 劣モジュラ比 $\gamma_{U,k}$ は次を満たす

$$\gamma_{U,k} \geq \min_{Z \subseteq [n]: |Z| \leq k} \lambda_{\min}(\mathbf{A}_Z^T \mathbf{A}_Z)$$

→ 貪欲法は $1 - \exp(-\min_{Z \subseteq [n]: |Z| \leq k} \lambda_{\min}(\mathbf{A}_Z^T \mathbf{A}_Z))$ 近似

R^2 を任意の制限強凹 / 平滑関数に一般化

$$\begin{aligned} & \text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} && u(\mathbf{w}) && u(\mathbf{0}) \geq 0 \\ & \text{subject to} && \|\mathbf{w}\|_0 \leq s \end{aligned}$$

R^2 の場合

$$u(\mathbf{w}) = 1 - \|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2 / \|\mathbf{y}\|_2^2$$

制限強凹 / 平滑定数が $\mathbf{A}^T \mathbf{A}$ の部分行列の最小固有値に対応

ほかの例


- ロジスティック回帰
- 一般化線形モデル

u は Ω において制限強凹 w.r.t. パラメータ m_Ω

$$\Leftrightarrow \forall \mathbf{x}, \mathbf{y} \in \Omega, u(\mathbf{y}) - u(\mathbf{x}) - \langle \nabla u(\mathbf{x}), \mathbf{y} - \mathbf{x} \rangle \leq -\frac{m_\Omega}{2} \|\mathbf{y} - \mathbf{x}\|_2^2$$

u は Ω において制限平滑 w.r.t. パラメータ M_Ω

$$\Leftrightarrow \forall \mathbf{x}, \mathbf{y} \in \Omega, u(\mathbf{y}) - u(\mathbf{x}) - \langle \nabla u(\mathbf{x}), \mathbf{y} - \mathbf{x} \rangle \geq -\frac{M_\Omega}{2} \|\mathbf{y} - \mathbf{x}\|_2^2$$



$\Omega_s = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq s\}$ における制限強凹定数を m_s

$\Omega_{s,t} = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq t\}$ における制限平滑定数を $M_{s,t}$ とする

解 \mathbf{w} のサポート（非ゼロ要素の集合）を選ぶ問題とみなす

$$\text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} u(\mathbf{w}) \quad \text{subject to } \|\mathbf{w}\|_0 \leq s$$

↓ 集合関数 $f_u(X) \triangleq \max_{\mathbf{w}: \text{supp}(\mathbf{w}) \subseteq X} u(\mathbf{w})$ を導入

$$\text{Maximize}_{X \subseteq N \triangleq [n]} f_u(X) \quad \text{subject to } |X| \leq s$$

定理 [Das-Kempe'11]

f_u の（集合 U と自然数 k に関する）劣モジュラ比 $\gamma_{U,k}$ は

$$\gamma_{U,k} \geq m_{|U|+s} / M_{|U|+1,1} \text{ を満たす}$$

→ 貪欲法は $1 - \exp(-m_{2s} / M_{s+1,1})$ 近似

劣モジュラ最大化のアイデアを特徴選択に利用

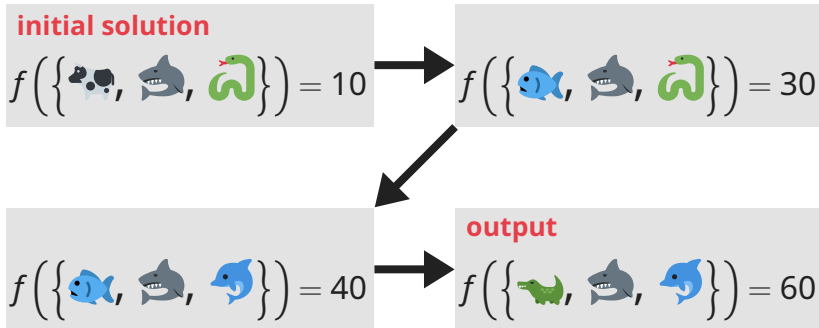
- 分散アルゴリズム [KannaEDNG'17]
- 高速な乱択アルゴリズム [KannaEDNG'17]
- ストリーミングアルゴリズム
[Elenberg-Dimakis-Feldman-Karbasi'17]
- 二段階最適化（辞書選択） [Cevher-Krause'11, Fujii-Soma'18]
- 適応的最適化 [Fujii-Sakaue'19]

1 劣モジュラ最大化

2 近似的劣モジュラ性による貪欲法の近似保証

3 近似的劣モジュラ性による局所探索の近似保証

組合せ最適化で広く用いられるアルゴリズム設計法



初期解から始めて、解を少しずつ変更しながら関数値を改善

貪欲法に用いられる性質を緩めることで
劣モジュラ比が定義された



局所探索に用いられる性質を緩めれば
劣モジュラ性のない問題に対して
局所探索の近似保証ができるのでは？

localizability という集合関数の性質を提案

- 1 集合関数が localizability を満たすなら
局所探索がよい近似解を出力する
- 2 スパース最適化の目的関数は localizability を満たす
- 3 スパース最適化に対する局所探索は高速化できる

要素数 s 以下の最適な部分集合を探す問題

Maximize $f(X)$

subject to $|X| \leq s$

要素数 s 以下の最適な部分集合を探す問題

Maximize $f(X)$

subject to $|X| \leq s$

$$f: 2^N \rightarrow \mathbb{R}_{\geq 0}$$

f の単調性を仮定

(劣モジュラとは限らない)

X を任意の極大な実行可能解とする

For $i = 1, \dots, T$:

各 $a \in N \setminus X, b \in X$ について $f(X \setminus \{b\} \cup \{a\})$ を計算

この値を最大化する a と b で X を更新

現在の解

$$f(\{\text{🐼}, \text{🦈}, \text{🐍}\}) = 30$$

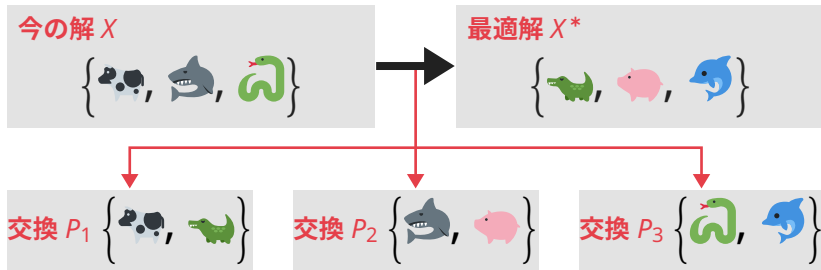
各ステップで
最良の交換を
見つける

$$f(\{\text{🐟}, \text{🦈}, \text{🐍}\}) = 35$$

...

新しい解

$$f(\{\text{🐼}, \text{🦈}, \text{🐰}\}) = 40$$



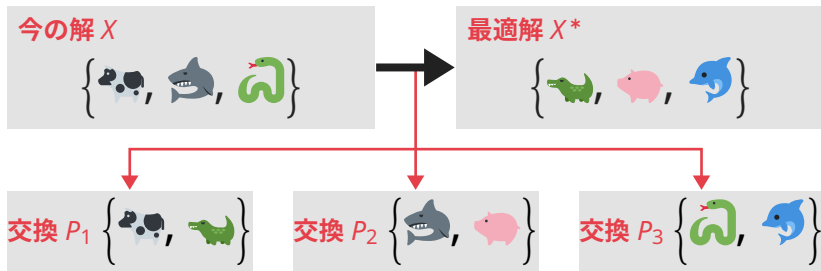
補題

f が非負単調劣モジュラならば、

$$\sum_{P \in \mathcal{P}} \{f(X \Delta P) - f(X)\} \geq f(X^*) - 2f(X)$$

※ $X \Delta P \triangleq (X \setminus P) \cup (P \setminus X)$ 対称差

局所探索の近似保証に用いられる性質を緩めたもの



f is (α, β) -localizable

$$\Leftrightarrow \sum_{P \in \mathcal{P}} \{f(X \Delta P) - f(X)\} \geq \alpha f(X^*) - \beta f(X)$$

($\forall X, X^* \subseteq N$ of size at most s , $\forall P$ partition of $X \Delta X^*$)

定理

目的関数が (α, β) -localizable なら

局所探索法は $\frac{\alpha}{\beta} \left(1 - \exp\left(-\frac{\beta T}{s}\right) \right)$ 近似

T 反復回数、 s 実行可能解の要素数の最大値

定理

目的関数が (α, β) -localizable なら

局所探索法は $\frac{\alpha}{\beta} \left(1 - \exp\left(-\frac{\beta T}{s}\right) \right)$ 近似

T 反復回数、 s 実行可能解の要素数の最大値

よく現れる関数に対する近似保証

| | (α, β) | 近似比 |
|---------|-------------------|-------------------------------|
| 線形関数 | $(1, 1)$ | $(1 - \exp(-T/s))$ |
| 劣モジュラ関数 | $(1, 2)$ | $\frac{1}{2}(1 - \exp(-T/s))$ |

Maximize $f(X)$

subject to $X \in \mathcal{I}$

$\mathcal{I} \subseteq 2^N$ は

実行可能な部分集合の族

さまざまな制約のクラス

p 交換システム

$\not\subseteq$

p マトロイド交差

$\not\supseteq$

\cup

マトロイド

\cup

\cup

要素数制約

$$\mathcal{I} = \{X \subseteq N \mid |X| \leq s\}$$

N 有限集合、 $\mathcal{I} \subseteq 2^N$ s.t. $\emptyset \in \mathcal{I}$ かつ " $A \subseteq B \in \mathcal{I} \Rightarrow A \in \mathcal{I}$ "

$\mathcal{M} = (N, \mathcal{I})$ は **マトロイド**




$\forall A, B \in \mathcal{I}, |A| < |B| \Rightarrow \exists i \in B \setminus A, A \cup \{i\} \in \mathcal{I}$

例：分割マトロイド



独立



非独立

N 有限集合、 $\mathcal{I} \subseteq 2^N$ s.t. $\emptyset \in \mathcal{I}$ かつ " $A \subseteq B \in \mathcal{I} \Rightarrow A \in \mathcal{I}$ "

$\mathcal{M} = (N, \mathcal{I})$ は **マトロイド**



$\forall A, B \in \mathcal{I}, |A| < |B| \Rightarrow \exists i \in B \setminus A, A \cup \{i\} \in \mathcal{I}$

(N, \mathcal{I}) は p **マトロイド交叉**



$\exists (N, \mathcal{I}_1), \dots, (N, \mathcal{I}_p)$ マトロイド s.t. $\mathcal{I} = \bigcap_{i=1}^p \mathcal{I}_i$

N 有限集合、 $\mathcal{I} \subseteq 2^N$ s.t. $\emptyset \in \mathcal{I}$ かつ " $A \subseteq B \in \mathcal{I} \Rightarrow A \in \mathcal{I}$ "


(N, \mathcal{I}) は p 交換システム



$\forall A, B \in \mathcal{I}$

$\exists \phi: B \setminus A \rightarrow 2^{A \setminus B}$ s.t.


- 任意の $B' \subseteq B \setminus A$ に対して $(A \setminus (\bigcup_{b \in B'} \phi(b))) \cup B' \in \mathcal{I}$
- $|\phi(b)| \leq p$ ($\forall b \in B \setminus A$)
- 各 $a \in A \setminus B$ は $(\phi(b))_{b \in B \setminus A}$ に高々 p 回出現




N 有限集合、 $\mathcal{I} \subseteq 2^N$ s.t. $\emptyset \in \mathcal{I}$ かつ " $A \subseteq B \in \mathcal{I} \Rightarrow A \in \mathcal{I}$ "

(N, \mathcal{I}) は p 交換システム

例： b マッチング



2 マッチング



2 マッチングでない

$\mathcal{I} = \{X \subseteq E \mid \forall v \in V, \deg_v(X) \leq b\}$ は 2 交換システム

Let $X \leftarrow \emptyset$

For $i = 1, \dots, T$:

各 $X' \in \mathcal{F}_q(X)$ について $f(X')$ を計算

そのなかで関数値を最大にする交換で X を更新

以下の操作で得られる実行可能解全体：

q 個以下の要素の追加と

(p マトロイド交叉) $2pq$ 要素以下の削除

(p 交換システム) $pq - q + 1$ 要素以下の削除

今の解

$$f(\{\text{🐼}, \text{🦈}, \text{🐰}\}) = 30$$

各ステップで
 $\mathcal{F}_q(X)$ のなかで最良の
交換を見つける

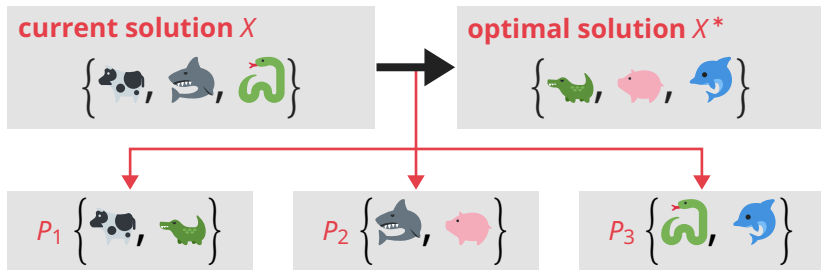
...

$$f(\{\text{🐬}, \text{🦈}, \text{🐰}\}) = 35$$

...

次の解

$$f(\{\text{🐼}, \text{🦈}, \text{🐰}\}) = 40$$



$\mathcal{P} \subseteq 2^N$ は多重集合 s.t. $\begin{cases} \text{各 } X^* \setminus X \text{ は } k \text{ 回出現} \\ \text{各 } X \setminus X^* \text{ は } l \text{ 回出現} \end{cases}$

f is $(\alpha, \beta_1, \beta_2)$ -localizable

$$\Leftrightarrow \sum_{P \in \mathcal{P}} \{f(X \Delta P) - f(X)\} \geq \alpha k f(X^*) - (\beta_1 l + \beta_2 k) f(X)$$

($\forall X, X^* \subseteq N$ of size at most s , 上記の条件を満たす任意の \mathcal{P})

定理

目的関数が $(\alpha, \beta_1, \beta_2)$ -localizable なら

マトロイド 局所探索法は

$$\frac{\alpha}{\beta_1 + \beta_2} \left(1 - \exp \left(-\frac{(\beta_1 + \beta_2)T}{s} \right) \right) \text{ 近似}$$

p-MI/p-ES パラメタ $q \in \mathbb{Z}_{>0}$ の局所探索法は

$$\frac{\alpha \left(1 - \exp \left(\frac{(\beta_1(p-1+1/q) + \beta_2)T}{s} \right) \right)}{\beta_1(p-1+1/q) + \beta_2} \text{ 近似}$$

q は選べるパラメタ

(各ステップで $n^{O(q)}$ 個の集合を確認しなければならない)

解のサポートに構造的な制約がある連続最適化問題

$$\begin{aligned} & \text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} && u(\mathbf{w}) \\ & \text{subject to} && \text{supp}(\mathbf{w}) \in \mathcal{I} \end{aligned}$$

仮定

- $u(\mathbf{0}) \geq 0$
- $\Omega_s = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq s\}$ において制限強凹 w.r.t. m_s
- $\Omega_{s,t} = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq t\}$ において制限平滑 w.r.t. $M_{s,t}$

解のサポートに構造的な制約がある連続最適化問題

Maximize $\mathbf{w} \in \mathbb{R}^n$ $u(\mathbf{w})$

subject to


$\text{supp}(\mathbf{w}) \in \mathcal{I}$

構造的な制約

仮定

- $u(\mathbf{0}) \geq 0$
- $\Omega_s = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq s\}$ において制限強凹 w.r.t. m_s
- $\Omega_{s,t} = \{\mathbf{x}, \mathbf{y} \mid \|\mathbf{x}\|_0 \leq s, \|\mathbf{y}\|_0 \leq s, \|\mathbf{x} - \mathbf{y}\|_0 \leq t\}$ において制限平滑 w.r.t. $M_{s,t}$

各分割から一つずつ特徴を選ぶ問題などを含む




$$\begin{aligned} &\text{Maximize} && U_{R^2}(\mathbf{w}) \triangleq 1 - \frac{\|\mathbf{y} - \mathbf{A}\mathbf{w}\|_2^2}{\|\mathbf{y}\|_2^2} \\ &\text{subject to} && \text{supp}(\mathbf{w}) \in \mathcal{I} \end{aligned}$$

データ $\{\mathbf{x}^1, \dots, \mathbf{x}^m\} \sim p(\mathbf{x}|\mathbf{w})$ から

$$p(\mathbf{x}|\mathbf{w}) \propto \exp\left(\sum_{(u,v) \in E} w_{uv} X_u X_v + \sum_{u \in V} w_u X_u\right)$$

スパースなイジングモデルの $\text{supp}(\mathbf{w})$ を推定



各点の次数の制約は 2 交換システム制約

$\text{supp}(\mathbf{w})$ を選択する問題を集合関数最大化とみなす

$$\text{Maximize}_{\mathbf{w} \in \mathbb{R}^n} u(\mathbf{w}) \quad \text{subject to} \quad \text{supp}(\mathbf{w}) \in \mathcal{I}$$

↓ $f_u(X) \triangleq \max_{\mathbf{w}: \text{supp}(\mathbf{w}) \subseteq X} u(\mathbf{w})$ を導入

$$\text{Maximize}_{X \subseteq N} f_u(X) \quad \text{subject to} \quad X \in \mathcal{I}$$

定理

各交換 $P \in \mathcal{P}$ が
 $|P| \leq t$ を満たす \mathcal{P}

f_u is $\left(\frac{m_{2s}}{M_{s,t}}, \frac{M_{s,t}}{m_{2s}}, 0 \right)$ -localizable with size s and exchange size t

| 制約 | 局所探索法 | 貪欲法 |
|------------------|--|---|
| 要素数制約 | $\frac{m_{2s}^2}{M_{s,2}^2} (1 - \epsilon_1(T))$ | $1 - \exp\left(-\frac{m_{2s}}{M_{s+1,1}}\right) \dagger$ |
| マトロイド | $\frac{m_{2s}^2}{M_{s,2}^2} (1 - \epsilon_1(T))$ | $\frac{1}{\left(1 + \frac{M_{s+1,1}}{m_s}\right)^2} \ddagger$ |
| p -MI/ p -ES | $\frac{1}{p-1+1/q} \frac{m_{2s}^2}{M_{s,t}^2} (1 - \epsilon_2(T))$ | N/A |

$\epsilon_1(T)$ と $\epsilon_2(T)$ は $T \rightarrow \infty$ のとき 0 に収束

† [Elenberg–Khanna–Dimakis–Negahban’18]

‡ [Chen–Feldman–Karbasi’18]

$\operatorname{argmax}_{a \in N \setminus X, b \in X} f_u(X \setminus \{a\} \cup \{b\})$ の計算には時間がかかる

→ f_u の値を近似的に計算することで高速化

$\operatorname{argmax}_{a \in N \setminus X, b \in X} f_u(X \setminus \{a\} \cup \{b\})$ の計算には時間がかかる

→ f_u の値を近似的に計算することで高速化

semi-oblivious

$\operatorname{argmax}_{a \in N \setminus X} f_u(X \setminus \{b\} \cup \{a\})$, where $b \in \operatorname{argmin}_{b \in X} (\mathbf{w}^{(X)})_b^2$

$$\mathbf{w}^{(X)} \in \operatorname{argmax}_{\mathbf{w}: \operatorname{supp}(\mathbf{w}) \subseteq X} u(\mathbf{w})$$

削除する要素を高速に決定

$\operatorname{argmax}_{a \in N \setminus X, b \in X} f_u(X \setminus \{a\} \cup \{b\})$ の計算には時間がかかる

→ f_u の値を近似的に計算することで高速化

semi-oblivious

$$\mathbf{w}^{(X)} \in \operatorname{argmax}_{\mathbf{w}: \operatorname{supp}(\mathbf{w}) \subseteq X} u(\mathbf{w})$$

$\operatorname{argmax}_{a \in N \setminus X} f_u(X \setminus \{b\} \cup \{a\})$, where $b \in \operatorname{argmin}_{b \in X} (\mathbf{w}^{(X)})_b^2$

削除する要素を高速に決定

non-oblivious


$$\operatorname{argmax}_{a \in N \setminus X, b \in X} \left\{ \frac{1}{2M_{s,2}} (\nabla u(\mathbf{w}^{(X)}))_a^2 - \frac{M_{s,2}}{2} (\mathbf{w}^{(X)})_b^2 \right\}$$

データセット


- $\mathbf{A}_{ij} \sim \text{Unif}([0, 1])$ の各列を正規化
- 特徴全体をランダムに s グループに分割し
各グループから 1 つずつランダムに選んで S^* とする
- $\mathbf{y} = \mathbf{A}_{S^*} \mathbf{w} + \epsilon$ (ただし $\mathbf{w}_i \sim \mathcal{N}(0, 1)$, $\epsilon_i \sim \mathcal{N}(0, 0.2)$)

比較手法

- **Residual random greedy** [Chen-Feldman-Karbasi'18]
- **Modular approximation**



R^2 (近似比)



計算時間

- 提案手法は比較手法よりよい R^2 を達成
- 高速化により計算時間を 1/10 以下に短縮


データセット

- 頂点数 10、次数 5 のランダムレギュラーグラフを真のグラフ構造とする
- イジングモデルの各枝 uv のパラメタ w_{uv} は $\{\pm 0.5\}$ からランダムに選ぶ
- Gibbs サンプリングで生成した 100 点を入力


比較手法

Modular approximation

目的関数を線形近似して最大おもみマッチング



近似比



計算時間

- 提案手法は比較手法よりよい近似比を達成
- 高速化により計算時間を 1/10 以下に短縮

localizability という集合関数の性質を提案

- 1 集合関数が localizability を満たすなら
局所探索がよい近似解を出力する
- 2 スパース最適化の目的関数は localizability を満たす
- 3 スパース最適化に対する局所探索は高速化できる

- Niv Buchbinder, Moran Feldman: Constrained Submodular Maximization via a Nonsymmetric Technique. *Math. Oper. Res.* 44(3): 988-1005 (2019).
- Niv Buchbinder, Moran Feldman, Joseph Naor, Roy Schwartz: Submodular Maximization with Cardinality Constraints. SODA 2014: 1433-1452.
- Gruia Calinescu, Chandra Chekuri, Martin Pál, Jan Vondrák: Maximizing a Monotone Submodular Function Subject to a Matroid Constraint. *SIAM J. Comput.* 40(6): 1740-1766 (2011).
- Volkan Cevher, Andreas Krause: Greedy Dictionary Selection for Sparse Representation. *IEEE J. Sel. Top. Signal Process.* 5(5): 979-988 (2011).
- Lin Chen, Moran Feldman, Amin Karbasi: Weakly Submodular Maximization Beyond Cardinality Constraints: Does Randomization Help Greedy? ICML 2018: 803-812.

- Abhimanyu Das, David Kempe: Approximate Submodularity and its Applications: Subset Selection, Sparse Approximation and Dictionary Selection. *J. Mach. Learn. Res.* 19: 3:1-3:34 (2018).
- Ethan R. Elenberg, Alexandros G. Dimakis, Moran Feldman, Amin Karbasi: Streaming Weak Submodularity: Interpreting Neural Networks on the Fly. NIPS 2017: 4044-4054.
- Ethan R. Elenberg, Rajiv Khanna, Alexandros G. Dimakis, and Sahand Negahban: Restricted strong convexity implies weak submodularity. *Ann. Statist.* 46(6B): 3539-3568 (2018).
- Uriel Feige, Vahab S. Mirrokni, Jan Vondrák: Maximizing Non-monotone Submodular Functions. *SIAM J. Comput.* 40(4): 1133-1153 (2011).
- Moran Feldman, Joseph Naor, Roy Schwartz, Justin Ward: Improved Approximations for k-Exchange Systems - (Extended Abstract). ESA 2011: 784-798.

- Kaito Fujii, Shinsaku Sakaue: Beyond Adaptive Submodularity: Approximation Guarantees of Greedy Policy with Adaptive Submodularity Ratio. ICML 2019: 2042-2051
- Kaito Fujii, Tasuku Soma: Fast greedy algorithms for dictionary selection with generalized sparsity constraints. NeurIPS 2018: 4749-4758.
- T. A. Jenkyns, The efficacy of the “greedy” algorithm, in *Proceedings of the 7th Southeastern Conference on Combinatorics, Graph Theory and Computing*: 341 – 350 (1976).
- Rajiv Khanna, Ethan R. Elenberg, Alexandros G. Dimakis, Sahand N. Negahban, Joydeep Ghosh: Scalable Greedy Feature Selection via Weak Submodularity. AISTATS 2017: 1560-1568
- Jon Lee, Vahab S. Mirrokni, Viswanath Nagarajan, Maxim Sviridenko: Maximizing Nonmonotone Submodular Functions under Matroid or Knapsack Constraints. *SIAM J. Discret. Math.* 23(4): 2053-2078 (2010).

- Jon Lee, Maxim Sviridenko, Jan Vondrák: Submodular Maximization over Multiple Matroids via Generalized Exchange Properties. *Math. Oper. Res.* 35(4): 795-806 (2010).
- Sahand N. Negahban, Pradeep Ravikumar, Martin J. Wainwright, and Bin Yu: A Unified Framework for High-Dimensional Analysis of M -Estimators with Decomposable Regularizers. *Statist. Sci.* 27(4): 538-557 (2012).
- George L. Nemhauser, Laurence A. Wolsey, Marshall L. Fisher: An analysis of approximations for maximizing submodular set functions - I. *Math. Program.* 14(1): 265-294 (1978).
- Maxim Sviridenko: A note on maximizing a submodular set function subject to a knapsack constraint. *Oper. Res. Lett.* 32(1): 41-43 (2004).
- イラスト: "Twemoji" by Twitter, Inc and other contributors is licensed under CC BY 4.0