

# 組合せ最適化特論

## 第10回 (劣モジュラ最大化)

担当: 相馬 輔

2026/2/26

# 目次

## 1. 劣モジュラ最大化

- 定式化
- モデリング例

## 2. 貪欲法

- 古典貪欲法
- 連続貪欲法

# 目次

## 1. 劣モジュラ最大化

- 定式化
- モデリング例

## 2. 貪欲法

- 古典貪欲法
- 連続貪欲法

# 劣モジュラ関数

$f : 2^V \rightarrow \mathbb{R}$  が劣モジュラ関数


$\iff \forall X \subseteq \forall Y \subseteq V, \forall a \in V \setminus Y,$

$$f(X \cup a) - f(X) \geq f(Y \cup a) - f(Y)$$

小さい集合の増分

大きい集合の増分

$$\iff f(X) + f(Y) \geq f(X \cup Y) + f(X \cap Y) \quad (\forall X, Y \subseteq V)$$



# 単調劣モジュラ関数最大化

[Nemhauser, Wolsey, and Fisher 1978]

$f : 2^V \rightarrow \mathbb{R}_+$  ... 非負**単調**劣モジュラ,  $f(\emptyset) = 0$

[単調  $\iff f(X) \leq f(Y)$  ( $X \subseteq Y$ )]

$$\max f(X) \quad \text{s.t.} \quad X \in \mathcal{C}$$

# 単調劣モジュラ関数最大化

[Nemhauser, Wolsey, and Fisher 1978]

$f : 2^V \rightarrow \mathbb{R}_+$  ... 非負**単調**劣モジュラ,  $f(\emptyset) = 0$

[単調  $\iff f(X) \leq f(Y)$  ( $X \subseteq Y$ )]

$$\max f(X) \quad \text{s.t.} \quad X \in \mathcal{C}$$

$|X| \leq k, \sum_{i \in X} w(i) \leq 1$  など

# 単調劣モジュラ関数最大化

[Nemhauser, Wolsey, and Fisher 1978]

$f : 2^V \rightarrow \mathbb{R}_+$  ... 非負**単調**劣モジュラ,  $f(\emptyset) = 0$

[単調  $\iff f(X) \leq f(Y)$  ( $X \subseteq Y$ )]

$$\max f(X) \quad \text{s.t.} \quad X \in \mathcal{C}$$

$$|X| \leq k, \sum_{i \in X} w(i) \leq 1 \text{ など}$$

## 応用:

- 文書要約 [Lin and Bilmes 2011]
- モデル解釈 [Ribeiro, Singh, and Guestrin 2016]
- 変数選択 [Das and Kempe 2011; Elenberg et al. 2018]

# 単調劣モジュラ最大化

名前	制約	近似比
サイズ制約	$ X  \leq k$	$1 - 1/e$ [NWF '78]
ナップサック制約	$\sum_{i \in X} w_i \leq 1$	$1 - 1/e$ [Sviridenko 2004]
マトロイド制約	$X \in \mathcal{I}$	$1 - 1/e$ [Calinescu et al. 2011]


- $(1 - 1/e)$  近似  $\iff f(X) \geq (1 - 1/e) \max_{X^* \in \mathcal{C}} f(X^*)$  となる  $X$  を出力
- 近似比  $1 - 1/e$  はオラクルモデルの多項式時間アルゴリズムの中で最良 [Nemhauser and Wolsey 1978]

# 例: 最大被覆問題

## 最大被覆問題

**入力**  $V$ : 基地局候補地の集合,  $k \in \mathbb{Z}_+$


**出力**  $S \subseteq V$  で  $|S| \leq k$  かつ  $S$  に設置したときの被覆範囲が最大となるもの



# 例: 不可分財の分配

$U = \{v_1, \dots, v_n\}$  ... 財の集合  
 $f_i$  ...  $i$ さんの効用関数, 単調劣モ  
( $i = 1, \dots, m$ )


**社会効用**  $\sum_{i=1}^m f_i(X_i)$  が最大の分配  
( $X_1, \dots, X_m$ ) を求めたい.



# 例: 不可分財の分配

- $V := U$  の  $m$  個のコピー
- $f(X) := \sum_{i=1}^m f_i(X \cap U_i)$
- $\mathcal{C}$ :  $V$  上の分割マトロイド (各財は1人まで割当可能)

分割マトロイド制約の単調劣モ最大化



# 例: 文書要約 [Lin and Bilmes 2011]

$V$ : 元文書の文全ての集合,  $X \subseteq V \longleftrightarrow$  要約

$r_1, \dots, r_K$ : 参照文

$c_e(X)$  = n-gram  $e$  が要約  $X$  に現れる回数

$M_{e,i}$  = n-gram  $e$  が参照文  $r_i$  に現れる回数

## ROUGE-N

$$f(X) = \sum_{r \in R} \sum_{e: \text{文 } r \text{ に含まれる n-gram}} \min\{c_e(X), M_{e,i}\}$$

(※ 簡単のため正規化定数は省いた)

- ROUGE-N は単調劣モジュラ関数
- サイズ制約  $\longleftrightarrow$  要約に使える文の数に制約
- ナップサック制約  $\longleftrightarrow$  要約の文字数に制約

### 要約文

民間英語試験の延期  
を決定した。

### 参照文 A

英語教育が専門の〇〇  
氏は、民間英語試験は  
問題が多く、...

# 例: モデル解釈 (SP-LIME) [Ribeiro, Singh, and Guestrin 2016]

近年の機械学習モデルは複雑で解釈しづらい。 → **解釈性**

## Local Interpretable Model-agnostic Explanations (LIME)

各訓練データに対して，“特徴量ごとの予測への貢献度” を計算してくれる手法



引用: LIME のチュートリアル

データセット全体での挙動を知りたい場合は？

# 例: モデル解釈 (SP-LIME) [Ribeiro, Singh, and Guestrin 2016]


$V$  = 訓練データの集合

$U$  = 特徴量の集合

$a_{ij}$  = データ  $i$  に対する特徴量  $j$  の LIME スコア

$G = (V, U; E) \dots a_{ij} > 0$  の  $(i, j)$  に枝を引いた二部グラフ

$w_j := \sqrt{\sum_{i \in V} a_{ij}}$  ... 特徴量  $j$  の重み



$$f(X) = \sum_{j \in \Gamma_G(X)} w_j$$

- モデルの全体的挙動を理解する上で多様な訓練データを抽出できる
- サイズ制約  $\longleftrightarrow$  抽出するデータ数に制約

# 例: 変数選択 [Das and Kempe 2011; Elenberg et al. 2018]

$$V = \{1, \dots, n\}$$

$\mathbf{x}_i$ : 説明変数 ( $i = 1, \dots, n$ ),  $\mathbf{y}$ : 被説明変数

$$f(X) = \|\mathbf{y}\|_2^2 - \min_{\beta: \text{supp}(\beta) \subseteq X} \left\| \mathbf{y} - \sum_{i=1}^n \beta_i \mathbf{x}_i \right\|_2^2$$

...  $X$  に入っている変数だけ使ったときの最良残差

- 抑圧変数がない  $\implies f$ : 単調劣モジュラ
- $X = [\mathbf{x}_1 \dots \mathbf{x}_n]$  に対する RIP 仮定  $\implies f$ : 弱劣モジュラ (近似的に劣モジュラ)

# 目次

## 1. 劣モジュラ最大化

- 定式化
- モデリング例

## 2. 貪欲法

- 古典貪欲法
- 連続貪欲法

# 最大化アルゴリズム

## サイズ制約 $|X| \leq k$ (組合せ的アルゴリズム)

- 古典貪欲法 [Nemhauser, Wolsey, and Fisher 1978]
- 確率的貪欲法 [Mirzasoleiman et al. 2015]

## 一般の制約 $X \in \mathcal{C}$ (連続最適化的アルゴリズム)

- 連続貪欲法 [Calinescu et al. 2011; Chekuri, Vondrák, and Zenklusen 2010; Chekuri, Vondrák, and Zenklusen 2014]

# 最大化アルゴリズム

## サイズ制約 $|X| \leq k$ (組合せ的アルゴリズム)

- **古典貪欲法** [Nemhauser, Wolsey, and Fisher 1978]
- **確率的貪欲法** [Mirzasoleiman et al. 2015]

## 一般の制約 $X \in \mathcal{C}$ (連続最適化的アルゴリズム)

- **連続貪欲法** [Calinescu et al. 2011; Chekuri, Vondrák, and Zenklusen 2010; Chekuri, Vondrák, and Zenklusen 2014]

# 古典貪欲法 [Nemhauser, Wolsey, and Fisher 1978]

- 1:  $X_0 \leftarrow \emptyset$
- 2: **for**  $i = 1, \dots, k$ :
- 3:      $a \in V \setminus X_{i-1}$  のうち  $f(X_{i-1} \cup a)$  が最大のものを求め,  $a_i$  とする.
- 4:      $X_i \leftarrow X_{i-1} \cup a_i$
- 5: **return**  $X = X_k$

# 古典貪欲法 [Nemhauser, Wolsey, and Fisher 1978]

- 1:  $X_0 \leftarrow \emptyset$
- 2: **for**  $i = 1, \dots, k$ :
- 3:    $a \in V \setminus X_{i-1}$  のうち  $f(X_{i-1} \cup a)$  が最大のものを求め,  $a_i$  とする.
- 4:    $X_i \leftarrow X_{i-1} \cup a_i$
- 5: **return**  $X = X_k$

- 貪欲アルゴリズムの出力を  $X$  とすると,

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

最適値

# 古典貪欲法の解析

## 補題

$f$ : 劣モジュラ

$$f(X \cup Y) \leq f(X) + \sum_{a \in Y \setminus X} [f(X \cup a) - f(X)]$$

$X^*$ : 最適解

# 古典貪欲法の解析

## 補題

$f$ : 劣モジュラ

$$f(X \cup Y) \leq f(X) + \sum_{a \in Y \setminus X} [f(X \cup a) - f(X)]$$

## 補題

各  $i = 1, 2, \dots, k$  に対して

$$f(X_i) - f(X_{i-1}) \geq \frac{1}{k} [f(X^*) - f(X_{i-1})]$$

$X^*$ : 最適解

$$\begin{aligned} X_0 &= \emptyset \\ X_i &= X_{i-1} \cup a_i \\ a_i &\in \operatorname{argmax}_{a \in V \setminus X_{i-1}} f(X_{i-1} \cup a) \end{aligned}$$

# 古典貪欲法の解析

## 補題

$f$ : 劣モジュラ

$$f(X \cup Y) \leq f(X) + \sum_{a \in Y \setminus X} [f(X \cup a) - f(X)]$$

## 補題

各  $i = 1, 2, \dots, k$  に対して

$$f(X_i) - f(X_{i-1}) \geq \frac{1}{k} [f(X^*) - f(X_{i-1})]$$

$X^*$ : 最適解

## 補題

各  $i = 0, 1, 2, \dots, k$  に対して

$$f(X^*) - f(X_i) \leq \left(1 - \frac{1}{k}\right)^i f(X^*)$$

# 古典貪欲法の解析

## 補題

$f$ : 劣モジュラ

$$f(X \cup Y) \leq f(X) + \sum_{a \in Y \setminus X} [f(X \cup a) - f(X)]$$

## 補題

各  $i = 1, 2, \dots, k$  に対して

$$f(X_i) - f(X_{i-1}) \geq \frac{1}{k} [f(X^*) - f(X_{i-1})]$$

$X^*$ : 最適解

## 補題

各  $i = 0, 1, 2, \dots, k$  に対して

$$f(X^*) - f(X_i) \leq \left(1 - \frac{1}{k}\right)^i f(X^*)$$

## 定理

$$f(X_k) \geq (1 - 1/e)f(X^*)$$

# 古典貪欲法 [Nemhauser, Wolsey, and Fisher 1978]

```
1:  $X_0 \leftarrow \emptyset$ 
2: for  $i = 1, \dots, k$ :
3:    $a \in V \setminus X_{i-1}$  のうち  $f(X_{i-1} \cup a)$  が最大のを求め,  $a_i$  とする.
4:    $X_i \leftarrow X_{i-1} \cup a_i$ 
5: return  $X = X_k$ 
```

- 貪欲アルゴリズムの出力を  $X$  とすると,

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

最適値

- $O(nk)$  回の  $f$  の関数値評価が必要 ( $n = |V|$ ,  $k$ : サイズ制約)  
→ 応用によっては重すぎる

# 確率的貪欲法 [Mirzasoleiman et al. 2015]

$\epsilon > 0$  を固定.

- 1:  $X_0 \leftarrow \emptyset$
- 2: **for**  $i = 1, \dots, k$  :
- 3:      $R_i := V \setminus X_{i-1}$  から  $\frac{n}{k} \log \frac{1}{\epsilon}$  個ランダムサンプル
- 4:      $a_i \in \operatorname{argmax}_{a \in R_i} f(X_{i-1} \cup a)$
- 5:      $X_i \leftarrow X_{i-1} \cup a_i$
- 6: **return**  $X = X_k$

# 確率的貪欲法 [Mirzasoleiman et al. 2015]

$\epsilon > 0$  を固定.

- 1:  $X_0 \leftarrow \emptyset$
- 2: **for**  $i = 1, \dots, k$  :
- 3:      $R_i := V \setminus X_{i-1}$  から  $\frac{n}{k} \log \frac{1}{\epsilon}$  個ランダムサンプル
- 4:      $a_i \in \operatorname{argmax}_{a \in R_i} f(X_{i-1} \cup a)$
- 5:      $X_i \leftarrow X_{i-1} \cup a_i$
- 6: **return**  $X = X_k$

- $\mathbb{E}[f(X)] \geq (1 - 1/e - \epsilon)f(X^*)$
- $O(n \log(1/\epsilon))$  回の関数値評価  
古典貪欲法の  $O(nk)$  に比べて改善！

# 最大化アルゴリズム

## サイズ制約 $|X| \leq k$ (組合せ的アルゴリズム)

- 古典貪欲法 [Nemhauser, Wolsey, and Fisher 1978]
- 確率的貪欲法 [Mirzasoleiman et al. 2015]

## 一般の制約 $X \in \mathcal{C}$ (連続最適化的アルゴリズム)

- **連続貪欲法** [Calinescu et al. 2011; Chekuri, Vondrák, and Zenklusen 2010; Chekuri, Vondrák, and Zenklusen 2014]

# 連続貪欲法 [Calinescu et al. 2011]

元問題

$$\max \{f(X) : X \in \mathcal{C}\}$$

# 連続貪欲法 [Calinescu et al. 2011]

**元問題**


$$\max \{f(X) : X \in \mathcal{C}\}$$

①連続緩和


**緩和問題**

$$\max \{F(\boldsymbol{x}) : \boldsymbol{x} \in P\}$$


# 連続貪欲法 [Calinescu et al. 2011]



# 連続貪欲法 [Calinescu et al. 2011]



# 連続貪欲法 [Calinescu et al. 2011]



# 多重線形拡張 (multilinear extension)

$f$  の多重線形拡張  $F : [0, 1]^n \rightarrow \mathbb{R}$

$$\begin{aligned} F(\mathbf{x}) &:= \sum_{S \subseteq V} f(S) \prod_{i \in S} x_i \prod_{i \notin S} (1 - x_i) \\ &= \mathbb{E}[f(R(\mathbf{x}))] \end{aligned}$$

$R(\mathbf{x})$ : 要素  $i$  を確率  $x_i$  で独立に含むランダム集合


**注**  $F, \nabla F$  は任意の精度で近似的に求められる (サンプリング).  
以下, 簡単のため  $F, \nabla F$  を与えるオラクルがあるものとする.

# 多重線形拡張 (multilinear extension)

## 性質

- $F(\mathbf{1}_X) = f(X)$
- $f$ : 単調  $\implies \nabla F \geq \mathbf{0}$
- $f$ : 劣モ  $\implies \frac{\partial^2 F}{\partial x_i \partial x_j} \leq 0$  ( $i \neq j$ )

特に  $F$  は非負方向に凹,  
 $\mathbf{e}_i - \mathbf{e}_j$  方向に凸



※一般には凸でも凹でもない

# 多重線型拡張の性質

## 補題

$f$ : 単調  $\implies \nabla F \geq 0$

$i \in V$  を任意に取る.  $\nabla F(\mathbf{x})_i$  を計算してみると

$$\nabla F(\mathbf{x})_i = \sum_{X \subseteq V \setminus i} f(X \cup i) \Pr(X) - \sum_{X \subseteq V \setminus i} f(X) \Pr(X).$$

ここで,  $\Pr(X) = \prod_{k \in X} x_k \prod_{k \notin X: k \neq i} (1 - x_k)$  である.  $f$  の単調性より  $f(X \cup i) - f(X) \geq 0$  なので,  $\nabla F(\mathbf{x})_i \geq 0$ .

# 多重線型拡張の性質

## 補題

$$f: \text{劣モ} \implies \frac{\partial^2 F}{\partial x_i \partial x_j} \leq 0 \quad (i \neq j)$$

特に  $\varphi(t) = F(\mathbf{x} + t\mathbf{d})$  ( $\mathbf{d} \geq \mathbf{0}$ ) は凹関数,  $\psi(t) = F(\mathbf{x} + t(\mathbf{e}_i - \mathbf{e}_j))$  は凸関数

$i = j$  の場合は自明に  $\frac{\partial^2 F}{\partial x_i \partial x_j} = 0$ .  $i \neq j$  のとき,

$$\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x}) = \sum_{X \subseteq V \setminus \{i, j\}} [f(X \cup i \cup j) + f(X) - f(X \cup i) - f(X \cup j)] \Pr(X).$$

ここで,  $\Pr(X) = \prod_{k \in X} x_k \prod_{k \notin X: k \neq i, j} (1 - x_k)$  である. 劣モジュラ性より  $f(X \cup i \cup j) + f(X) - f(X \cup i) - f(X \cup j) \leq 0$  なので  $\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x}) \leq 0$ .

# 多重線型拡張の性質

## 補題

$f$ : 劣モ  $\implies \frac{\partial^2 F}{\partial x_i \partial x_j} \leq 0$  ( $i \neq j$ )

特に  $\varphi(t) = F(\mathbf{x} + t\mathbf{v})$  ( $\mathbf{v} \geq \mathbf{0}$ ) は凹関数,  $\psi(t) = F(\mathbf{x} + t(\mathbf{e}_i - \mathbf{e}_j))$  は凸関数

連鎖律より

$$\varphi''(t) = \sum_{i,j \in V} \frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x} + t\mathbf{v}) v_i v_j$$

であるが,  $\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x} + t\mathbf{v}) \leq 0$  で, 仮定より  $v_i, v_j \geq 0$  であるから,  $\varphi''(t) \leq 0$ . よって  $\varphi$  は凹関数.

# 多重線型拡張の性質

## 補題

$$f: \text{劣モ} \implies \frac{\partial^2 F}{\partial x_i \partial x_j} \leq 0 \quad (i \neq j)$$

特に  $\varphi(t) = F(\mathbf{x} + t\mathbf{v})$  ( $\mathbf{v} \geq \mathbf{0}$ ) は凹関数,  $\psi(t) = F(\mathbf{x} + t(\mathbf{e}_i - \mathbf{e}_j))$  は凸関数

連鎖律より

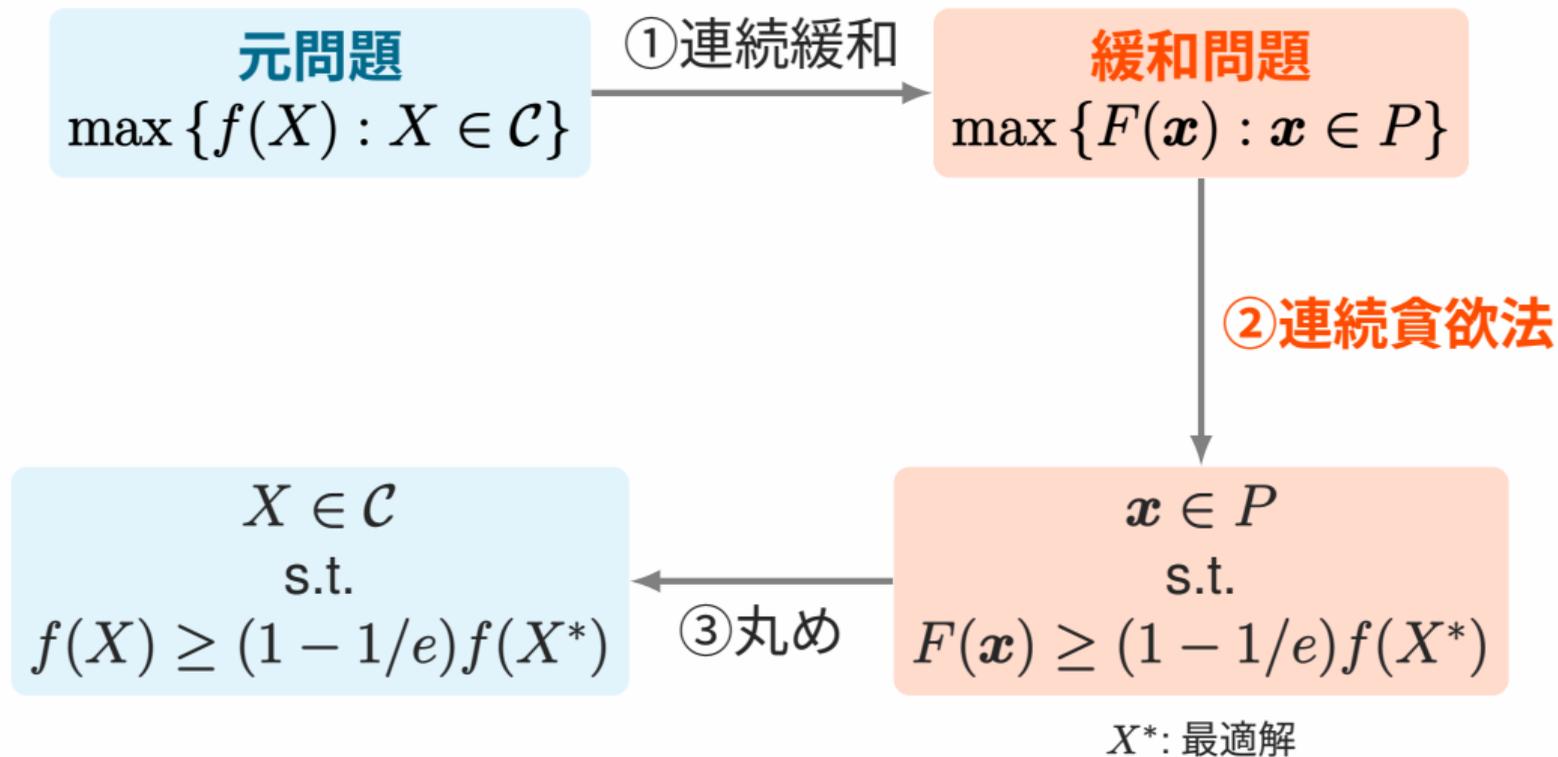
$$\varphi''(t) = \sum_{i,j \in V} \frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x} + t\mathbf{v}) v_i v_j$$

であるが,  $\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x} + t\mathbf{v}) \leq 0$  で, 仮定より  $v_i, v_j \geq 0$  であるから,  $\varphi''(t) \leq 0$ . よって  $\varphi$  は凹関数.

再び連鎖律より

$$\psi''(t) = -2 \frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x} + t(\mathbf{e}_i - \mathbf{e}_j)) \geq 0$$

# 連続貪欲法 [Calinescu et al. 2011]



# 連続貪欲法 (連続時間版)

## 連続緩和問題

$$\max F(\boldsymbol{x}) \quad \text{s.t.} \quad \boldsymbol{x} \in P$$


# 連続貪欲法 (連続時間版)

## 連続緩和問題

$$\max F(\mathbf{x}) \quad \text{s.t.} \quad \mathbf{x} \in P$$

以下の微分方程式に従って  $\mathbf{x}(t)$  を動かす

$$\begin{aligned} \mathbf{x}(0) &= \mathbf{0} \\ \frac{d\mathbf{x}(t)}{dt} &= \operatorname{argmax}_{\mathbf{v} \in P} \nabla F(\mathbf{x}(t))^\top \mathbf{v} \end{aligned}$$



# 連続貪欲法 (連続時間版)

## 連続緩和問題

$$\max F(\mathbf{x}) \quad \text{s.t.} \quad \mathbf{x} \in P$$

以下の微分方程式に従って  $\mathbf{x}(t)$  を動かす


$$\begin{aligned} \mathbf{x}(0) &= \mathbf{0} \\ \frac{d\mathbf{x}(t)}{dt} &= \operatorname{argmax}_{\mathbf{v} \in P} \nabla F(\mathbf{x}(t))^\top \mathbf{v} \end{aligned}$$

## 定理 ([Calinescu et al. 2011])

$f$ : 単調劣モ,  $P$ : down closed

$\implies \mathbf{x}(1) \in P$  かつ

$$F(\mathbf{x}(1)) \geq (1 - 1/e) \max_{\mathbf{x}^* \in P} F(\mathbf{x}^*)$$



# 解析


$\Psi(t) := e^{t-1}F(\mathbf{x}(t))$  とする.  $\frac{d\Psi}{dt} = e^{t-1}[F(\mathbf{x}(t)) + \nabla F(\mathbf{x}(t))^\top \frac{d\mathbf{x}(t)}{dt}]$ .

$\mathbf{x}^* \in P$  を最適解,  $\mathbf{x}^* \vee \mathbf{x}(t)$  を  $\mathbf{x}^*$  と  $\mathbf{x}(t)$  の成分ごとに max をとったベクトルとする.

$$\begin{aligned} F(\mathbf{x}^*) &\leq F(\mathbf{x}^* \vee \mathbf{x}(t)) \\ &\leq F(\mathbf{x}(t)) + \nabla F(\mathbf{x}(t))^\top (\mathbf{x}^* \vee \mathbf{x}(t) - \mathbf{x}(t)) \\ &\leq F(\mathbf{x}(t)) + \nabla F(\mathbf{x}(t))^\top \mathbf{v}(t) \\ &= F(\mathbf{x}(t)) + \nabla F(\mathbf{x}(t))^\top \frac{d\mathbf{x}(t)}{dt} \end{aligned}$$

$$\therefore \frac{d\Psi}{dt} \geq e^{t-1}F(\mathbf{x}^*).$$

$[0, 1]$  で積分:  $\Psi(1) - \Psi(0) = F(\mathbf{x}(1)) \geq (1 - e^{-1})F(\mathbf{x}^*)$ .




# 連続貪欲法 (離散時間版)

実際には微分方程式を厳密に解くことはできないので、時間を離散化して近似する

- 1:  $\mathbf{x}(0) = \mathbf{0}$
- 2: **for**  $t = 0, \delta, 2\delta, \dots, 1 - \delta$  :
- 3:      $\mathbf{v}(t) \in \operatorname{argmax}_{\mathbf{v} \in P} \nabla F(\mathbf{x}(t))^\top \mathbf{v}$  を求める
- 4:      $\mathbf{x}(t + \delta) \leftarrow \mathbf{x}(t) + \delta \mathbf{v}(t)$
- 5: **return**  $\mathbf{x}(1)$

- Frank-Wolfe 法の亜種
- 精度  $\epsilon > 0$  に応じて 時間幅  $\delta$  を十分小さく取れば、同様の仮定のもと  $F(\mathbf{x}) \geq (1 - 1/e - \epsilon) \max_{\mathbf{x}^* \in P} F(\mathbf{x}^*)$

# 連続貪欲法 [Calinescu et al. 2011]



# 丸めアルゴリズム

連続貪欲法で得られる緩和解  $x$  は  $\{0, 1\}$  ベクトルとは限らないので、 $\{0, 1\}$  ベクトルに丸める必要がある。

→ **制約ごとに丸めアルゴリズムを設計**

## マトロイド制約


- Pipage Rounding [Calinescu et al. 2011]
- Swap Rounding [Chekuri, Vondrák, and Zenklusen 2010]

## その他の制約

- Contention Resolution Scheme [Chekuri, Vondrák, and Zenklusen 2014]

# Pipage Rounding [Calinescu et al. 2011]

- 1  $x_i, x_j$  が  $\{0,1\}$  でない  $i, j \in V$  を取る
- 2  $\alpha_+ = \max\{\alpha \geq 0 : \mathbf{x} + \alpha(\mathbf{e}_i - \mathbf{e}_j) \in P\}$   
 $\alpha_- = \max\{\alpha \geq 0 : \mathbf{x} - \alpha(\mathbf{e}_i - \mathbf{e}_j) \in P\}$
- 3  $\mathbf{x}_+ = \mathbf{x} + \alpha_+(\mathbf{e}_i - \mathbf{e}_j)$ ,  $\mathbf{x}_- = \mathbf{x} - \alpha_-(\mathbf{e}_i - \mathbf{e}_j)$  のうち  $F$  の値が大きいものに  $\mathbf{x}$  を更新
- 4  $P$  をぶつかった面に制限して 1 に戻る



## 定理

$P$ : マトロイド多面体のとき, Pipage Rounding の出力  $\bar{\mathbf{x}}$  は  $\{0,1\}$  ベクトルで,  $F(\bar{\mathbf{x}}) \geq F(\mathbf{x})$  を満たす ( $\mathbf{x}$ : Pipage Rounding の初期点)

# 劣モジュラ最大化: 発展的な話題

## 整数格子点上の劣モジュラ最大化



- 最適予算配分問題
- 最大化アルゴリズム

## 連続劣モジュラ関数

- 非凸連続最適化 (連続 DR 劣モジュラ関数)

## オンライン劣モジュラ最大化

- 近似 no-regret アルゴリズム
- 連続 DR 劣モジュラ関数の CVaR 最大化



## 参考文献

- Calinescu, G., C. Chekuri, M. Pál, and J. Vondrák (2011). "Maximizing a monotone submodular function subject to a matroid constraint". In: *SIAM Journal on Computing* 40.6, pp. 1740–1766.
- Chekuri, C., J. Vondrák, and R. Zenklusen (2010). "Dependent randomized rounding via exchange properties of combinatorial structures". In: *Proceedings of IEEE 51st Annual Symposium on Foundations of Computer Science (FOCS)*, pp. 575–584.
- (2014). "Submodular function maximization via the multilinear relaxation and contention resolution schemes". In: *SIAM Journal on Computing* 43.6, pp. 1831–1879.
- Das, A. and D. Kempe (2011). "Submodular meets spectral: greedy algorithms for subset selection, sparse approximation and dictionary selection". In: *Proceedings of the 28th International Conference on Machine Learning (ICML)*, pp. 1057–1064.
- Elenberg, E. R., R. Khanna, A. G. Dimakis, and S. Negahban (2018). "Restricted strong convexity implies weak submodularity". In: *Annals of Statistics* 46.6B, pp. 3539–3568.
- Lin, H. and J. Bilmes (2011). "A class of submodular functions for document summarization". In: *Proceedings of the Annual Conference of the North American Chapter of the Association for Computational Linguistics*, pp. 510–520.
- Mirzasoleiman, B., A. Badanidiyuru, A. Karbasi, J. Vondrak, and A. Krause (2015). "Lazier than lazy greedy". In: *Proceedings of AAAI Conference on Artificial Intelligence (AAAI)*.
- Nemhauser, G. L. and L. A. Wolsey (1978). "Best Algorithms for Approximating the Maximum of a Submodular Set Function". In: *Mathematics of Operations Research* 3.3, pp. 177–188.
- Nemhauser, G. L., L. A. Wolsey, and M. L. Fisher (1978). "An analysis of approximations for maximizing submodular set functions - II". In: *Mathematical Programming* 8, pp. 73–87.
- Ribeiro, M. T., S. Singh, and C. Guestrin (2016). ""Why should i trust you?" Explaining the predictions of any classifier". In: *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, pp. 1135–1144.

Sviridenko, M. (2004). "A note on maximizing a submodular set function subject to a knapsack constraint". In: *Operations Research Letters* 32.1, pp. 41–43.