

# 離散最適化基礎論

## 第13回

ラグランジュ緩和 (2) : 最適ラグランジュ緩和

岡本 吉央 (電気通信大学)

okamotoy@uec.ac.jp

2023年1月17日

最終更新 : 2023年1月23日 00:46

## <準備>

1. 整数計画法と線形計画法 (10/4)
2. 線形計画法の復習 (1) : 線形不等式系と凸多面集合 (10/11)
- \* 休み (体育祭) (10/18)
3. 線形計画法の復習 (2) : 単体法と双対定理 (10/25)
4. 線形計画緩和 (11/1)

## <モデリング>

5. 整数計画モデリング (1) : 組合せ最適化問題 (11/8)
6. 整数計画モデリング (2) : より複雑な問題 (11/15)
7. 整数計画モデリング (3) : 離接計画 (11/22)


## <アルゴリズム>

- |                               |         |
|-------------------------------|---------|
| 8. 分枝限定法                      | (11/29) |
| 9. 切除平面法                      | (12/6)  |
| 10. 妥当不等式の追加                  | (12/13) |
| 11. 列生成法                      | (12/20) |
| * 休み (国内出張)                   | (12/27) |
| * 休み (冬季休業)                   | (1/3)   |
| 12. ラグランジュ緩和 (1) : 原理         | (1/10)  |
| 13. ラグランジュ緩和 (2) : 最適ラグランジュ緩和 | (1/17)  |
| 14. 前求解                       | (1/24)  |


## <まとめ>

- |          |        |
|----------|--------|
| 15. 期末試験 | (1/31) |
|----------|--------|

- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法



- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法



## 整数計画問題 P

$$\min. \mathbf{c}^T \mathbf{x}$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$A_2 \mathbf{x} = \mathbf{b}_2,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

変数：  $\mathbf{x} \in \mathbb{R}^n$

定数：  $A_1 \in \mathbb{R}^{m_1 \times n}, A_2 \in \mathbb{R}^{m_2 \times n}, \mathbf{b}_1 \in \mathbb{R}^{m_1}, \mathbf{b}_2 \in \mathbb{R}^{m_2}, \mathbf{c} \in \mathbb{R}^n$

整数計画問題  $P$   $\longrightarrow$  ラグランジュ緩和  $L(\lambda)$

$$\min. \mathbf{c}^T \mathbf{x}$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$A_2 \mathbf{x} = \mathbf{b}_2,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

$$\min. \mathbf{c}^T \mathbf{x} + \boldsymbol{\lambda}^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

変数：  $\mathbf{x} \in \mathbb{R}^n$

(Lagrangian relaxation)

定数：  $A_1 \in \mathbb{R}^{m_1 \times n}$ ,  $A_2 \in \mathbb{R}^{m_2 \times n}$ ,  $\mathbf{b}_1 \in \mathbb{R}^{m_1}$ ,  $\mathbf{b}_2 \in \mathbb{R}^{m_2}$ ,  $\mathbf{c} \in \mathbb{R}^n$

$\boldsymbol{\lambda} \in \mathbb{R}^{m_2}$

直感

$P$  における制約の非充足  $\rightarrow L(\lambda)$  における罰則

整数計画問題  $P$   $\longrightarrow$  ラグランジュ緩和  $L(\lambda)$

$$\min. c^T x$$

$$\text{s.t. } A_1 x = b_1,$$

$$A_2 x = b_2,$$

$$x \geq 0,$$

$$x \in \mathbb{Z}^n$$

$$\min. c^T x + \lambda^T (b_2 - A_2 x)$$

$$\text{s.t. } A_1 x = b_1,$$

$$x \geq 0,$$

$$x \in \mathbb{Z}^n$$

## 性質

$P$  と  $L(\lambda)$  が最適解を持つ  $\Rightarrow P$  の最適値  $\geq L(\lambda)$  の最適値



整数計画問題  $P$   $\longrightarrow$  ラグランジュ緩和  $L(\lambda)$

$$\min. c^T x$$

$$\text{s.t. } A_1 x = b_1,$$

$$A_2 x = b_2,$$

$$x \geq 0,$$

$$x \in \mathbb{Z}^n$$

$$\min. c^T x + \lambda^T (b_2 - A_2 x)$$

$$\text{s.t. } A_1 x = b_1,$$

$$x \geq 0,$$

$$x \in \mathbb{Z}^n$$

## 緩和問題に求められる性質

- 解きたい問題  $P$  の許容領域  $\subseteq$  緩和問題の許容領域
- 解きたい問題  $P$  の最適値  $\geq$  緩和問題の最適値
- 解きたい問題  $P$  よりも 緩和問題の方が解きやすい

整数計画問題  $P$   $\longrightarrow$  ラグランジュ緩和  $L(\lambda)$

$$\min. \mathbf{c}^T \mathbf{x}$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$A_2 \mathbf{x} = \mathbf{b}_2,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

$$\min. \mathbf{c}^T \mathbf{x} + \boldsymbol{\lambda}^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

$L(\lambda)$  の最適値として得られる

$P$  の最適値の下界として  
最大のものを求める問題

ラグランジュ双対  $LD$

$$\max_{\boldsymbol{\lambda}} \min_{\mathbf{x}} \mathbf{c}^T \mathbf{x} + \boldsymbol{\lambda}^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} \geq \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

(Lagrangian dual)

整数計画問題  $P$   $\longrightarrow$  最強ラグランジュ緩和  $L(\lambda^*)$

$$\min. \mathbf{c}^T \mathbf{x}$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$A_2 \mathbf{x} = \mathbf{b}_2,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

$$\min. \mathbf{c}^T \mathbf{x} + \lambda^{*T} (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

$L(\lambda)$  の最適値として得られる  
 $P$  の最適値の下界として  
最大のものを求める問題

$\lambda^* = \text{LD}$  の最適解

ラグランジュ双対 LD

$$\max_{\lambda} \min_{\mathbf{x}} \mathbf{c}^T \mathbf{x} + \lambda^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} \geq \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

(Lagrangian dual)

## 前回の内容

巡回セールスマン問題のラグランジュ緩和としてよいものを作る

これは Held, Karp ('70, '71) によるアイデア

## よさの基準

- 得られる下界が大きい
- 効率よく解ける
- 運がよいと,  
巡回路が得られる

## 解きたい問題 P


$$\begin{aligned} \min. \quad & \sum_{e \in E} d(e)x_e \\ \text{s.t.} \quad & \sum_{e \in \delta(i)} x_e = 2 && \forall i \\ & \sum_{e \subseteq S} x_e \leq |S| - 1 && \forall S \\ & x_e \in \{0, 1\} && \forall e \end{aligned}$$

## 最小重み 1-木問題のアルゴリズム

1.  $\{2, 3, \dots, n\}$  上の最小重み全域木を求める ←
2. 頂点 1 に接続する辺の中で重みの小さい方から 2 辺を求める
3. それらの合併を出力する

これは多項式時間アルゴリズム

Kruskal 法などで  
効率よく実行できる



したがって、  
いま作ったラグランジュ緩和は  
効率よく解ける

ラグランジュ緩和  $L(\lambda)$   $\longrightarrow$  最適解 (最小重み 1-木)  
効率よく  
計算できる


欲しいもの

最強ラグランジュ緩和  $L(\lambda^*)$


$\downarrow$   $\lambda^* =$  ラグランジュ緩和  $L(\lambda)$  の最適値を最大にする  $\lambda$

どのように  $\lambda^*$  を求めるのか  $\rightarrow$  今回 (劣勾配法)

- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法



- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法





ラグランジュ緩和  $L(\lambda)$

$$\min. \mathbf{c}^T \mathbf{x} + \lambda^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\text{s.t. } A_1 \mathbf{x} = \mathbf{b}_1,$$

$$\mathbf{x} \geq \mathbf{0},$$

$$\mathbf{x} \in \mathbb{Z}^n$$

最適値は  $\lambda$  に依存する

$$= g(\lambda) \text{ とする}$$

整数計画問題  $P$

$$\min. 2x_1 - 3x_2$$

$$\text{s.t. } -x_1 + x_2 \leq 1,$$

$$x_1 \leq 2,$$

$$4x_1 + 5x_2 \leq 20,$$

$$x_1, x_2 \geq 0,$$

$$x_1, x_2 \in \mathbb{Z}$$

ラグランジュ緩和  $L(\lambda)$



$$\min. 2x_1 - 3x_2 + \lambda(x_1 - 2)$$


$$\text{s.t. } -x_1 + x_2 \leq 1,$$

$$4x_1 + 5x_2 \leq 20,$$

$$x_1, x_2 \geq 0,$$

$$x_1, x_2 \in \mathbb{Z}$$







ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$

$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$







ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$

$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$







ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$

$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$






ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$



$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$



ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$



$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$



ラグランジュ緩和  $L(\lambda)$

$$\begin{aligned} \min. \quad & 2x_1 - 3x_2 + \lambda(x_1 - 2) \\ & = (2 + \lambda)x_1 - 3x_2 - 2\lambda \end{aligned}$$

$$\begin{aligned} \text{s.t.} \quad & -x_1 + x_2 \leq 1, \\ & 4x_1 + 5x_2 \leq 20, \\ & x_1, x_2 \geq 0, \\ & x_1, x_2 \in \mathbb{Z} \end{aligned}$$





ラグランジュ緩和  $L(\lambda)$

$$\min. \mathbf{c}^T \mathbf{x} + \lambda^T (\mathbf{b}_2 - A_2 \mathbf{x})$$

$$\begin{aligned} \text{s.t. } \quad & A_1 \mathbf{x} = \mathbf{b}_1, \\ & \mathbf{x} \geq \mathbf{0}, \\ & \mathbf{x} \in \mathbb{Z}^n \end{aligned}$$


最適値は  $\lambda$  に依存する  
 $= g(\lambda)$  とする

$$g: \mathbb{R}^{m_2} \rightarrow \mathbb{R}$$

性質：最適値関数は凹関数


最適値関数  $g$  は凹関数

凹関数の定義は次のページで



## 定義：凹関数 (concave function)

関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  が **凹関数** であるとは、次を満たすこと  
任意の  $x, y \in \mathbb{R}^n$  と  $\alpha \in [0, 1]$  に対して  
$$f(\alpha x + (1 - \alpha)y) \geq \alpha f(x) + (1 - \alpha)f(y)$$



$f$  の始域は凸集合でもよい

# 最適値関数は凹関数：証明 (1)

19/35

証明： 任意の  $\lambda, \mu \in \mathbb{R}^{m_2}$ ,  $\alpha \in [0, 1]$  を考える

**目標**：  $g(\alpha\lambda + (1 - \alpha)\mu) \geq \alpha g(\lambda) + (1 - \alpha)g(\mu)$

最適値関数  $g$  の定義より,

$$g(\lambda) = \min\{c^T x + \lambda^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\lambda$  とする

$$g(\mu) = \min\{c^T x + \mu^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\mu$  とする

# 最適値関数は凹関数：証明 (1)

証明： 任意の  $\lambda, \mu \in \mathbb{R}^{m_2}$ ,  $\alpha \in [0, 1]$  を考える

**目標**：  $g(\alpha\lambda + (1 - \alpha)\mu) \geq \alpha g(\lambda) + (1 - \alpha)g(\mu)$

最適値関数  $g$  の定義より,

$$g(\lambda) = \min\{c^T x + \lambda^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\lambda$  とする

$$g(\mu) = \min\{c^T x + \mu^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\mu$  とする

したがって,

$$g(\lambda) = c^T x_\lambda + \lambda^T (b_2 - A_2 x_\lambda)$$

$$g(\mu) = c^T x_\mu + \mu^T (b_2 - A_2 x_\mu)$$

# 最適値関数は凹関数：証明 (2)

20/35

証明： 任意の  $\lambda, \mu \in \mathbb{R}^m$ ,  $\alpha \in [0, 1]$  を考える

**目標**：  $g(\alpha\lambda + (1 - \alpha)\mu) \geq \alpha g(\lambda) + (1 - \alpha)g(\mu)$

最適値関数  $g$  の定義より,  $\alpha\lambda + (1 - \alpha)\mu = \nu$  とする

$$g(\nu) = \min\{c^T x + \nu^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\nu$  とする

$$\begin{aligned} g(\nu) &= c^T x_\nu + \nu^T (b_2 - A_2 x_\nu) \\ &= (\alpha + (1 - \alpha))c^T x_\nu + (\alpha\lambda + (1 - \alpha)\mu)^T (b_2 - A_2 x_\nu) \\ &= \alpha(c^T x_\nu + \lambda^T (b_2 - A_2 x_\nu)) \\ &\quad + (1 - \alpha)(c^T x_\nu + \mu^T (b_2 - A_2 x_\nu)) \end{aligned}$$

# 最適値関数は凹関数：証明 (2)

20/35

証明： 任意の  $\lambda, \mu \in \mathbb{R}^m$ ,  $\alpha \in [0, 1]$  を考える

**目標** :  $g(\alpha\lambda + (1 - \alpha)\mu) \geq \alpha g(\lambda) + (1 - \alpha)g(\mu)$

最適値関数  $g$  の定義より,  $\alpha\lambda + (1 - \alpha)\mu = \nu$  とする

$$g(\nu) = \min\{c^T x + \nu^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\nu$  とする

$$\begin{aligned} g(\nu) &= c^T x_\nu + \nu^T (b_2 - A_2 x_\nu) \\ &= (\alpha + (1 - \alpha))c^T x_\nu + (\alpha\lambda + (1 - \alpha)\mu)^T (b_2 - A_2 x_\nu) \\ &= \alpha(c^T x_\nu + \lambda^T (b_2 - A_2 x_\nu)) \\ &\quad \geq c^T x_\lambda + \lambda^T (b_2 - A_2 x_\lambda) = g(\lambda) \\ &\quad + (1 - \alpha)(c^T x_\nu + \mu^T (b_2 - A_2 x_\nu)) \\ &\quad \geq c^T x_\mu + \mu^T (b_2 - A_2 x_\mu) = g(\mu) \end{aligned}$$

# 最適値関数は凹関数：証明 (2)

20/35

証明： 任意の  $\lambda, \mu \in \mathbb{R}^m$ ,  $\alpha \in [0, 1]$  を考える

**目標** :  $g(\alpha\lambda + (1 - \alpha)\mu) \geq \alpha g(\lambda) + (1 - \alpha)g(\mu)$

最適値関数  $g$  の定義より,  $\alpha\lambda + (1 - \alpha)\mu = \nu$  とする

$$g(\nu) = \min\{c^T x + \nu^T (b_2 - A_2 x) \mid A_1 x = b_1, x \geq 0, x \in \mathbb{Z}^n\}$$

↳ 最適解を  $x_\nu$  とする

$$\begin{aligned} g(\nu) &= c^T x_\nu + \nu^T (b_2 - A_2 x_\nu) \\ &= (\alpha + (1 - \alpha))c^T x_\nu + (\alpha\lambda + (1 - \alpha)\mu)^T (b_2 - A_2 x_\nu) \\ &= \alpha(c^T x_\nu + \lambda^T (b_2 - A_2 x_\nu)) \\ &\quad \geq c^T x_\lambda + \lambda^T (b_2 - A_2 x_\lambda) = g(\lambda) \\ &\quad + (1 - \alpha)(c^T x_\nu + \mu^T (b_2 - A_2 x_\nu)) \\ &\quad \geq c^T x_\mu + \mu^T (b_2 - A_2 x_\mu) = g(\mu) \\ &\geq \alpha g(\lambda) + (1 - \alpha)g(\mu) \end{aligned}$$

□

## はじめの目標

$\lambda^*$  = ラグランジュ緩和  $L(\lambda)$  の最適値を最大にする  $\lambda$  を求めること



## はじめの目標

$\lambda^*$  = ラグランジュ緩和  $L(\lambda)$  の最適値 を最大にする  $\lambda$  を求めること

$g(\lambda)$

証明した性質： $g$  は凹関数

できれば十分であること

凹関数の最大化

使用できるアルゴリズム, 有効なアルゴリズムは  
最大化したい凹関数の性質に依存する

できれば十分であること

凹関数の最大化

使用できるアルゴリズム, 有効なアルゴリズムは  
最大化したい凹関数の性質に依存する

ラグランジュ緩和の最適値関数  $g$  の性質

- 凹関数
- 微分可能であるとは限らない (non-smooth)

今から紹介する **劣勾配法** (subgradient method) は  
微分不可能な凹関数の最大化を行う伝統的なアルゴリズム

劣勾配法は，普通「凸関数の最小化」に対して記述される


## 定義：凸関数 (convex function)

関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  が **凸関数** であるとは，次を満たすこと  
任意の  $x, y \in \mathbb{R}^n$  と  $\alpha \in [0, 1]$  に対して  
$$f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y)$$

凹関数では「 $\geq$ 」だった

性質  $f$  が凹関数  $\Leftrightarrow -f$  が凸関数

つまり，凹関数の最大化は  
凸関数の最小化と変わらない



$f$  の始域は凸集合でもよい

性質：凸関数にて極小解は最小解


$x^* \in \mathbb{R}^n$  が次を満たすとする

$x^*$  に近い任意の  $\tilde{x}$  に対して,  $f(x^*) \leq f(\tilde{x})$

このとき, 次が成り立つ

任意の  $x \in \mathbb{R}^n$  に対して,  $f(x^*) \leq f(x)$

証明：ある  $x \in \mathbb{R}^n$  に対して,  $f(x) < f(x^*)$  であると仮定する



性質：凸関数にて極小解は最小解

$x^* \in \mathbb{R}^n$  が次を満たすとする

$x^*$  に近い任意の  $\tilde{x}$  に対して,  $f(x^*) \leq f(\tilde{x})$


このとき, 次が成り立つ

任意の  $x \in \mathbb{R}^n$  に対して,  $f(x^*) \leq f(x)$

証明：ある  $x \in \mathbb{R}^n$  に対して,  $f(x) < f(x^*)$  であると仮定する

$x$  と  $x^*$  の内分点として,  $x^*$  に近い  $\tilde{x}$  を取れる

ある  $\alpha \in (0, 1)$  を用いて,  $\tilde{x} = \alpha x + (1 - \alpha)x^*$  とする



性質：凸関数にて極小解は最小解

$x^* \in \mathbb{R}^n$  が次を満たすとする

$x^*$  に近い任意の  $\tilde{x}$  に対して,  $f(x^*) \leq f(\tilde{x})$

このとき, 次が成り立つ


任意の  $x \in \mathbb{R}^n$  に対して,  $f(x^*) \leq f(x)$

証明：ある  $x \in \mathbb{R}^n$  に対して,  $f(x) < f(x^*)$  であると仮定する

$x$  と  $x^*$  の内分点として,  $x^*$  に近い  $\tilde{x}$  を取れる

ある  $\alpha \in (0, 1)$  を用いて,  $\tilde{x} = \alpha x + (1 - \alpha)x^*$  とする

$$\begin{aligned} f(x^*) &\leq f(\tilde{x}) = f(\alpha x + (1 - \alpha)x^*) \leq \alpha f(x) + (1 - \alpha)f(x^*) \\ &< \alpha f(x^*) + (1 - \alpha)f(x^*) = f(x^*) \end{aligned}$$



凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  が微分可能であるならば ...

## アルゴリズム：勾配法 (gradient method)


1. 初期点  $\mathbf{x}^{(0)}$  を適当に選ぶ
2.  $i = 0, 1, \dots$  で収束するまで以下を繰り返す

$$\mathbf{x}^{(i+1)} := \mathbf{x}^{(i)} - \alpha_i \nabla f(\mathbf{x}^{(i)})$$

( $\alpha_i > 0$  はうまく選んだ実数)


劣勾配法は勾配法の考え方を  
微分不可能凸関数に適用したもの

$\mathbf{x}^{(i)}$  における  $f$  の勾配




$$\begin{bmatrix} \frac{\partial f}{\partial x_1}(\mathbf{x}^{(i)}) \\ \frac{\partial f}{\partial x_2}(\mathbf{x}^{(i)}) \\ \vdots \\ \frac{\partial f}{\partial x_n}(\mathbf{x}^{(i)}) \end{bmatrix}$$

- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法





- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法




凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 点  $\boldsymbol{x}^{(0)} \in \mathbb{R}^n$

定義：劣勾配 (subgradient)

ベクトル  $\boldsymbol{s} \in \mathbb{R}^n$  が点  $\boldsymbol{x}^{(0)}$  における  $f$  の **劣勾配** であるとは、次を満たすこと

任意の  $\boldsymbol{x} \in \mathbb{R}^n$  に対して、 $\boldsymbol{s}^T (\boldsymbol{x} - \boldsymbol{x}^{(0)}) \leq f(\boldsymbol{x}) - f(\boldsymbol{x}^{(0)})$

$$\boldsymbol{s}^T \boldsymbol{x} - \boldsymbol{s}^T \boldsymbol{x}^{(0)} + f(\boldsymbol{x}^{(0)}) \leq f(\boldsymbol{x})$$



補足：  $f$  が  $\boldsymbol{x}^{(0)}$  で微分可能  $\Rightarrow$

$\boldsymbol{x}^{(0)}$  における  $f$  の勾配が

$\boldsymbol{x}^{(0)}$  における  $f$  の (唯一の) 劣勾配


凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 点  $\boldsymbol{x}^{(0)} \in \mathbb{R}^n$

定義：劣勾配 (subgradient)

ベクトル  $\boldsymbol{s} \in \mathbb{R}^n$  が点  $\boldsymbol{x}^{(0)}$  における  $f$  の **劣勾配** であるとは、次を満たすこと

任意の  $\boldsymbol{x} \in \mathbb{R}^n$  に対して、 $\boldsymbol{s}^T(\boldsymbol{x} - \boldsymbol{x}^{(0)}) \leq f(\boldsymbol{x}) - f(\boldsymbol{x}^{(0)})$

$$\boldsymbol{s}^T \boldsymbol{x} - \boldsymbol{s}^T \boldsymbol{x}^{(0)} + f(\boldsymbol{x}^{(0)}) \leq f(\boldsymbol{x})$$



$$y = \boldsymbol{s}^T \boldsymbol{x} - \boldsymbol{s}^T \boldsymbol{x}^{(0)} + f(\boldsymbol{x}^{(0)})$$

補足：  $f$  が  $\boldsymbol{x}^{(0)}$  で微分可能  $\Rightarrow$

$\boldsymbol{x}^{(0)}$  における  $f$  の勾配が

$\boldsymbol{x}^{(0)}$  における  $f$  の (唯一の) 劣勾配

凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 点  $x^{(0)} \in \mathbb{R}^n$


定義：劣微分 (subdifferential)

点  $x^{(0)}$  における  $f$  の **劣微分** とは,  
 $x^{(0)}$  における  $f$  の劣勾配をすべて集めた集合のこと

$$\underline{\partial f(x^{(0)})} = \{s \in \mathbb{R}^n \mid s \text{ は } x^{(0)} \text{ における } f \text{ の劣勾配}\}$$

劣微分の記法

例：  $n = 1$ ,  $f(x) = |x|$  のとき



$$\partial f(x) = \begin{cases} \{-1\} & (x < 0 \text{ のとき}) \\ [-1, 1] & (x = 0 \text{ のとき}) \\ \{1\} & (x > 0 \text{ のとき}) \end{cases}$$


凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , 点  $x^{(0)} \in \mathbb{R}^n$

性質：劣微分と最小解

$$x^{(0)} \text{ が } f \text{ の最小解} \iff \mathbf{0} \in \partial f(x^{(0)})$$


微分可能である場合と同様に証明できる (微分積分学の内容を参照)

例：  $n = 1$ ,  $f(x) = |x|$  のとき




$$\partial f(x) = \begin{cases} \{-1\} & (x < 0 \text{ のとき}) \\ [-1, 1] & (x = 0 \text{ のとき}) \\ \{1\} & (x > 0 \text{ のとき}) \end{cases}$$

- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法



- ラグランジュ緩和：復習
- ラグランジュ緩和の性質
- 劣微分と劣勾配
- 劣勾配法



凸関数  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  (微分可能であるとは限らない)


## アルゴリズム：劣勾配法 (subgradient method)

1. 初期点  $\boldsymbol{x}^{(0)}$  を適当に選ぶ
2.  $i = 0, 1, \dots$  で収束するまで以下を繰り返す  
 $\boldsymbol{s}^{(i)} \in \partial f(\boldsymbol{x}^{(i)})$ ,  
 $\boldsymbol{x}^{(i+1)} := \boldsymbol{x}^{(i)} - \alpha_i \boldsymbol{s}^{(i)}$   
( $\alpha_i > 0$  はうまく選んだ実数)

### 課題

1. 劣勾配  $\boldsymbol{s}^{(i)}$  の見つけ方
2. 係数  $\alpha_i$  の定め方

ステップサイズ とよく呼ばれる





いろいろな決め方があるが、理論的には次が古くから知られている

## 性質：ステップサイズの選び方

(Polyak '67)

$\alpha_i$  は次を満たす数列であるとする

- $\lim_{i \rightarrow \infty} \alpha_i = 0, \sum_{i=0}^{\infty} \alpha_i = \infty$

$s^{(i)}$  は次を満たすとする

- 数列  $\{\|s^{(i)}\|^2\}$  が有界

このとき、 $x^{(0)}, x^{(1)}, \dots$  は  $f$  の最小解に収束する

ただ、このステップサイズでは収束が遅いことが知られている

実用上は、経験的に収束が速いステップサイズを用いることも多い

(例：指数的に減少するステップサイズ  $\alpha_{i+1} = r\alpha_i$ )

ラグランジュ緩和の最適値関数  $g$  の場合

$$-g(\boldsymbol{\lambda}) = -\min\{\mathbf{c}^T \mathbf{x} + \boldsymbol{\lambda}^T (\mathbf{b}_2 - A_2 \mathbf{x}) \mid A_1 \mathbf{x} = \mathbf{b}_1, \mathbf{x} \geq \mathbf{0}, \mathbf{x} \in \mathbb{Z}^n\}$$

↳ 最適解を  $\mathbf{x}_\lambda$  とする

性質：最適値関数  $-g$  の劣勾配

$$A_2 \mathbf{x}_\lambda - \mathbf{b}_2 \in \partial(-g)(\boldsymbol{\lambda})$$

証明：次を証明する

$$\text{任意の } \boldsymbol{\mu} \in \mathbb{R}^m \text{ に対して, } (A_2 \mathbf{x}_\lambda - \mathbf{b}_2)^T (\boldsymbol{\mu} - \boldsymbol{\lambda}) \leq -g(\boldsymbol{\mu}) + g(\boldsymbol{\lambda})$$

ラグランジュ緩和の最適値関数  $g$  の場合

$$-g(\boldsymbol{\lambda}) = -\min\{\boldsymbol{c}^T \boldsymbol{x} + \boldsymbol{\lambda}^T (\boldsymbol{b}_2 - A_2 \boldsymbol{x}) \mid A_1 \boldsymbol{x} = \boldsymbol{b}_1, \boldsymbol{x} \geq \mathbf{0}, \boldsymbol{x} \in \mathbb{Z}^n\}$$

↳ 最適解を  $\boldsymbol{x}_\lambda$  とする

性質：最適値関数  $-g$  の劣勾配

$$A_2 \boldsymbol{x}_\lambda - \boldsymbol{b}_2 \in \partial(-g)(\boldsymbol{\lambda})$$

証明：次を証明する

任意の  $\boldsymbol{\mu} \in \mathbb{R}^m$  に対して,  $(A_2 \boldsymbol{x}_\lambda - \boldsymbol{b}_2)^T (\boldsymbol{\mu} - \boldsymbol{\lambda}) \leq -g(\boldsymbol{\mu}) + g(\boldsymbol{\lambda})$

$$-g(\boldsymbol{\lambda}) + (A_2 \boldsymbol{x}_\lambda - \boldsymbol{b}_2)^T (\boldsymbol{\mu} - \boldsymbol{\lambda})$$

$$= -\boldsymbol{c}^T \boldsymbol{x}_\lambda - \boldsymbol{\lambda}^T (\boldsymbol{b}_2 - A_2 \boldsymbol{x}_\lambda) + (A_2 \boldsymbol{x}_\lambda - \boldsymbol{b}_2)^T (\boldsymbol{\mu} - \boldsymbol{\lambda})$$

$$= -\boldsymbol{c}^T \boldsymbol{x}_\lambda - \boldsymbol{\mu}^T (\boldsymbol{b}_2 - A_2 \boldsymbol{x}_\lambda)$$

$$\leq -g(\boldsymbol{\mu})$$

□

## 劣勾配法以外のアルゴリズム

- 平滑化法
- FISTA
- ...

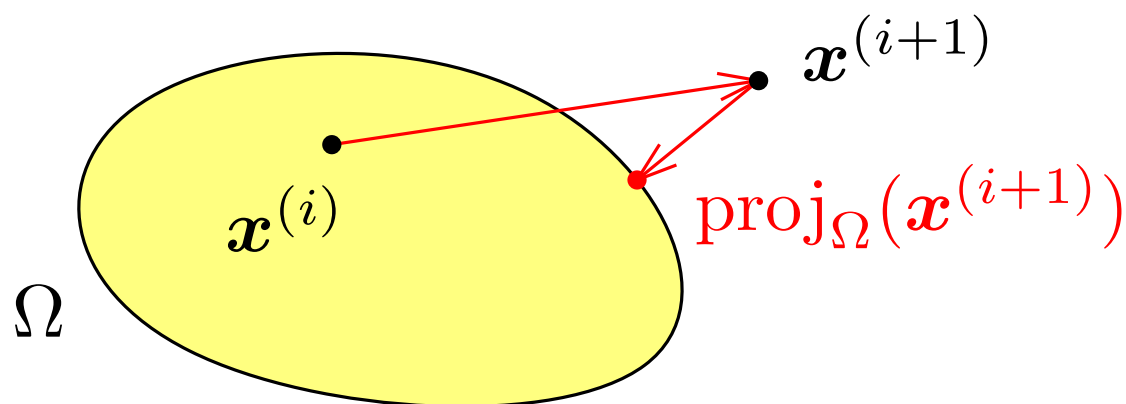
(Nesterov '05)

(Beck, Teboulle '09)

## 始域が $\mathbb{R}^n$ ではなく、凸集合 $\Omega$ の場合

計算した  $\mathbf{x}^{(i+1)}$  が  $\Omega$  をはみ出ることがある

- $\Omega$  に引き戻す必要がある (射影)



## 次回の内容

### 前求解

- 問題のサイズを小さくする / 問題を解きやすくする

授業評価アンケートに回答する時間も設ける

