


# Regret Ratio Minimization in Multi-objective Submodular Function Maximization

(AAAI 2017)





相馬 輔 (東京大学)

with 吉田 悠一 (NII & PFI)



# 劣モジュラ最適化

劣モジュラ関数: “効率的” に解ける離散構造に現れる関数



# 劣モジュラ最適化

劣モジュラ関数: “効率的” に解ける離散構造に現れる関数



$f : 2^S \rightarrow \mathbb{R}$  が **劣モジュラ関数**:

$$f(X \cup s) - f(X) \geq f(Y \cup s) - f(Y) \quad (X \subseteq Y, s \notin Y)$$

**“限界効用逓減 (diminishing return)”**

# 劣モジュラ関数最大化

$$\max f(X) \quad \text{sub. to} \quad X \in C$$

解の品質

制約(コスト)

# 劣モジュラ関数最大化

$$\max f(X) \quad \text{sub. to} \quad X \in C$$

解の品質

制約(コスト)

## 既存研究

- 一般には NP 困難
- 多くの制約に対して効率的な  
**定数近似**アルゴリズム

# 劣モジュラ関数最大化

$$\max f(X) \quad \text{sub. to} \quad X \in C$$

解の品質

制約(コスト)

## 既存研究

- 一般には NP 困難
- 多くの制約に対して効率的な  
**定数近似**アルゴリズム

## 応用

- 影響力最大化
- データ要約, etc

# Multiple Criteria




# Multiple Criteria



# Multiple Criteria



# Multiple Criteria



# 多目的最適化の出番?

× パレート最適解は指数個ありうる!

# 多目的最適化の出番?

× パレート最適解は指数個ありうる!

パレート解の“良い”代表集合を選ぶ既存手法

- $k$ -representative skyline queries [Lin et al. 07, Tao et al. 09]
- top- $k$  dominating queries [Yiu and Mamoulis 09]
- regret minimizing database [Nanongkai et al. 10]

# 多目的最適化の出番?

× パレート最適解は指数個ありうる!

パレート解の“良い”代表集合を選ぶ既存手法

- $k$ -representative skyline queries [Lin et al. 07, Tao et al. 09]
- top- $k$  dominating queries [Yiu and Mamoulis 09]
- regret minimizing database [Nanongkai et al. 10]

既存手法の問題点

すべての実行可能解が陽に与えられている必要...

# 概要

Regret minimizing database を劣モジュラ最大化に拡張

# 概要

Regret minimizing database を劣モジュラ最大化に拡張

## アルゴリズム

単目的最大化に対して  $\alpha$  近似アルゴリズムがあるとき

- リグレット比  $1 - \alpha/d$  ( $d$ :任意)
- リグレット比  $1 - \alpha + O(1/k)$  ( $k$ :任意,  $d = 2$ )

$d$  = 目的関数の数,  $k$  = 実行可能解の個数

# 概要

Regret minimizing database を劣モジユラ最大化に拡張

## アルゴリズム

単目的最大化に対して  $\alpha$  近似アルゴリズムがあるとき

- リグレット比  $1 - \alpha/d$  ( $d$ :任意)
- リグレット比  $1 - \alpha + O(1/k)$  ( $k$ :任意,  $d = 2$ )

$d =$  目的関数の数,  $k =$  実行可能解の個数

## 情報理論的下界

- $\alpha = 1$  (厳密アルゴリズム),  $d = 2$  であっても, リグレット比  $o(1/k^2)$  は達成不可能.

# リグレット比

## 単目的最適化

$S \subseteq C$ ,  $f$  に対する **リグレット比**

$$rr(S) = \frac{\max_{X \in C} f(X) - \max_{X \in S} f(X)}{\max_{X \in C} f(X)}.$$

# リグレット比

## 単目的最適化

$S \subseteq C$ ,  $f$  に対する **リグレット比**

$$\text{rr}(S) = \frac{\max_{X \in C} f(X) - \max_{X \in S} f(X)}{\max_{X \in C} f(X)}.$$


## 多目的最適化

$S \subseteq C$  and  $f_1, \dots, f_d$  に対する **リグレット比**


$$\text{rr}_{f_1, \dots, f_d, C}(S) = \max_{\mathbf{a} \in \mathbb{R}_+^d} \text{rr}_{f_{\mathbf{a}}, C}(S),$$

ただし  $f_{\mathbf{a}} := a_1 f_1 + \dots + a_d f_d$ . (**非負結合**)


# リグレット比の幾何的解釈



# リグレット比の幾何的解釈



# リグレット比の幾何的解釈




$$\text{rr}(S) \leq 1 - \varepsilon \iff \mathbf{f}(X) \in \varepsilon^{-1}P(S) \quad (X \in C).$$

# リグレット比最小化

**Given:**  $f_1, \dots, f_d$ : 劣モジユラ,  $C \subseteq 2^E, k > 0$


$$\begin{array}{ll} \text{minimize} & \text{rr}(\mathcal{S}) \\ \text{subject to} & \mathcal{S} \subseteq C, |\mathcal{S}| \leq k. \end{array}$$

# アルゴリズム 1: Coordinate




$\mathcal{S}_{\text{coord}}$ :  $\max_{X \in C} f_i(X)$  の  $\alpha$  近似解の集合 ( $i = 1, \dots, d$ )  
 $\implies \text{rr}(\mathcal{S}_{\text{coord}}) \leq 1 - \alpha/d.$


# アルゴリズム 2: Polytope




# アルゴリズム 2: Polytope




# アルゴリズム 2: Polytope



# アルゴリズム 2: Polytope




# アルゴリズム 2: Polytope



$\mathcal{S}$ : Polytope の出力,  $d = 2$   
 $\implies \text{rr}(\mathcal{S}) \leq 1 - \alpha + O(1/k).$

# リグレット比の下界

$$f_1(X) = \cos \frac{\pi|X|}{2n}, \quad f_2(X) = \sin \frac{\pi|X|}{2n}$$



# 数値実験

## アルゴリズム

- Coordinate
- Polytope
- Random:  $k$  個のランダムベクトル  $\mathbf{a}_1, \dots, \mathbf{a}_k$  を生成,  $\{X_1, \dots, X_k\}$  ( $X_i : \max_{X \in C} f_{\mathbf{a}_i}(X)$  の近似解) を出力

## 計算機環境

- Intel Xeon E5-2690 (2.90 GHz) CPU, 256 GB RAM
- C#で実装

# データ要約

データセット: MovieLens

$E$ : 映画の集合,  $s_{i,j}$ : 映画  $i$  と  $j$  の類似度

$$f_1(X) = \sum_{i \in E} \sum_{j \in X} s_{i,j}, \quad \text{coverage}$$


$$f_2(X) = \lambda \sum_{i \in E} \sum_{j \in E} s_{i,j} - \lambda \sum_{i \in X} \sum_{j \in X} s_{i,j} \quad \text{diversity}$$

$C = 2^E$  (無制約),  $1 \leq k \leq 20$ ,  $\lambda > 0$ ,


単目的アルゴリズム: double greedy (1/2 近似)

[Buchbinder et al. 12]

# 実験結果



# 実験結果



リグレット比が劇的に低下

# 概要

Regret minimizing database を劣モジュラ最大化に拡張

## アルゴリズム

単目的最大化に対して  $\alpha$  近似アルゴリズムがあるとき

- リグレット比  $1 - \alpha/d$  ( $d$ :任意)
- リグレット比  $1 - \alpha + O(1/k)$  ( $k$ :任意,  $d = 2$ )

$d =$  目的関数の数,  $k =$  実行可能解の個数

## 情報理論的下界

- $\alpha = 1$  (厳密アルゴリズム),  $d = 2$  であっても, リグレット比  $o(1/k^2)$  は達成不可能.