

Невыпуклые гладкие релаксации задач квадратичной комбинаторной оптимизации

Роман Погодин, Михаил Кречетов

МФТИ, Skoltech

Постановка задачи

Задачи вида

$$\begin{aligned} \max x^T Ax, \\ \text{s.t. } x \in \{-1, 1\}^n. \end{aligned}$$

SDP релаксация: $xx^T = X$, но убираем $\text{rank } X = 1$:

$$\begin{aligned} \max \text{Tr}(AX), \\ \text{s.t. } \text{diag } X = \mathbf{1}_n, \\ X^T = X, X \succeq 0. \end{aligned}$$

Ответ x ищется рандомизированно. Для $A \succeq 0$ в среднем дает разрез не хуже $2/\pi$ от максимального

Постановка задачи

Один из примеров – поиск максимального разреза

$$\begin{aligned} \max \quad & \frac{1}{2} \sum_{i < j} w_{ij} (1 - x_i x_j), \\ \text{s.t.} \quad & x_i \in \{-1, 1\}, \quad i = 1, \dots, n. \end{aligned}$$

Эквивалентно в терминах Лапласиана:

$$\begin{aligned} \max \quad & \frac{1}{4} x^\top L x, \\ \text{s.t.} \quad & x \in \{-1, 1\}^n. \end{aligned}$$

Здесь гарантии лучше – средний разрез не хуже ≈ 0.878 от максимального

Ранг решений

Мы хотим решения маленького ранга. Почему?

- ▶ Меньше вариантов при рандомизации
- ▶ При $\text{rank } X = 1$ точное решение

Что мы знаем про ранг:

Theorem (Pataki, 1998)

Разрешимая SDP-задача имеет решение X , такое что $\text{rank } X = r$, $r(r + 1) \leq 2m$, где m – число ограничений.

В нашем случае $m = n$

Поиск малоранговых решений

Что можно делать:

- ▶ Представить $X = VV^T$, где V размера $n \times r$, решать такую задачу [Burer, Monteiro, 2003]
- ▶ Разрешить выполнение ограничений только приближенно [Ye, Zhang, 2007]
- ▶ Минимизировать ранг полученного решения

Последняя постановка для Max Cut:

$$\begin{aligned} \min \operatorname{rank} X \\ \text{s.t. } \operatorname{diag} X &= \mathbf{1}_n, \\ X^T &= X, X \succeq 0, \\ \operatorname{Tr}(LX) &= 4 \cdot \text{SDP}. \end{aligned}$$

Идея – релаксировать разрывную функцию ранга и ограничение на функционал

Релаксации ранга. Сингулярные значения

Приближим отношением сингулярных значений:

$$\text{rank } X \approx \sum \frac{\sigma_i^2(X)}{\sigma_i^2(X) + \varepsilon} = \text{Tr } X^\top (XX^\top + \varepsilon I)^{-1} X.$$

Улучшение

$$\text{rank } X \approx \Phi(X, \varepsilon) = (1 + \varepsilon^q) \text{Tr} \left(X^\top (XX^\top + \varepsilon I)^{-1} X \right)$$

гарантирует

$$|\text{rank } X - \Phi(X, \varepsilon)| \leq \varepsilon^q \max \left\{ \text{rank } X, \sum_{i=1}^{\text{rank } X} \left| \frac{\varepsilon^{1-q}}{\sigma_i^2(X)} - 1 \right| \right\}.$$

Релаксации ранга. Шаттеновские нормы

При $p < 1$ такая квази-норма:

$$\|X\|_{S_p}^p = \sum_{i \geq 1} \sigma_i^p = \text{Tr} \left(X^\top X \right)^{\frac{p}{2}}.$$

Предел по p даст функцию ранга. Сгладим:

$$\|X\|_{S_{p,\varepsilon}}^p = \sum_{i \geq 1} (\sigma_i^2 + \varepsilon)^{\frac{p}{2}} = \text{Tr} \left(X^\top X + \varepsilon I \right)^{\frac{p}{2}} \approx \|X\|_{S_p}^p.$$

Релаксации ранга. Log-Det

Используем

$$\text{rank } X \approx \log \det (X + \varepsilon I).$$

Из ряда Тейлора

$$\log \det (X + \varepsilon I) \approx \log \det (X_n + \varepsilon I) + \text{Tr} \left((X_n + \varepsilon I)^{-1} (X - X_n) \right).$$

Это приведет к следующей итеративной процедуре:

$$X_{n+1} = \underset{X \in K}{\text{argmin}} \text{Tr} \left((X_n + \varepsilon I)^{-1} X \right),$$

Методы решения. IRLS

Для Шаттеновских норм введем вес

$$A(X) = \left(X^T X + \varepsilon I \right)^{\frac{p-2}{2}}.$$

Тогда такие итерации сойдутся к ККТ-точке:

$$\begin{aligned} \min & \frac{p}{2} \text{Tr} \left(A X^T X \right) \\ \text{s.t.} & \text{diag } X = \mathbf{1}_n, \\ & X^T = X, X \succeq 0, \\ & 4 \cdot W^* \leq \text{Tr}(LX) \leq 4 \cdot SDP. \end{aligned}$$

Методы решения. Градиентный спуск

Для Шаттеновских норм и сингулярных значений репараметризуем задачу:


$$X = \begin{pmatrix} 1 & x_1 & \dots & x_{n-1} \\ x_1 & 1 & x_n & \dots \\ \dots & \dots & \dots & \dots \end{pmatrix}$$

- ▶ Нужны проекции только на PSD-конус и нижнюю грань функционала
- ▶ Для Шаттена при шаге $\alpha \leq \frac{1}{2p} \varepsilon^{(2-p)/p}$ не выходит из PSD-конуса
- ▶ Для сингулярных значений при шаге $\alpha < \frac{\varepsilon}{4(1+\varepsilon^q)}$ не выходит из PSD-конуса
- ▶ Быстрее IRLS, применимо для больших задач


Результаты. Улучшения ранга

Шаттеновские нормы и сингулярные значения улучшают ранг, но значительно реже. Log-det:

Log-Det rank improvement (n=100, p=0.5)

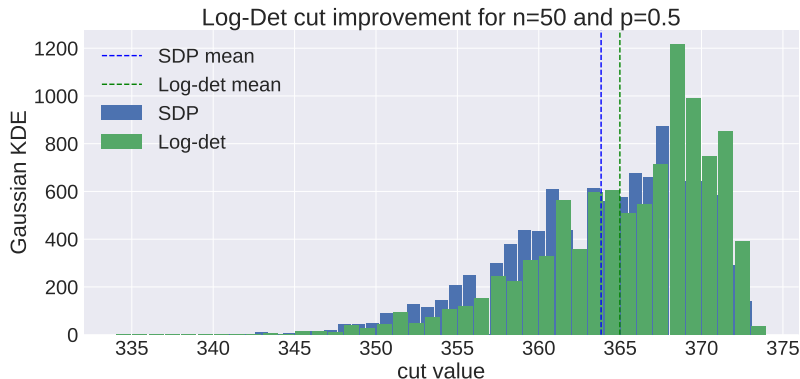


Log-Det rank improvement (n=200, p=0.5)



Результаты. Улучшения среднего разреза

Все методы сохраняют среднее значение разреза ± 1 ,
но уменьшают дисперсию (хотя $\text{Tr}(LX)$ не равен оптимальному)



Выводы

В работе проанализирована минимизация ранга для получения малоранговых решений SDP-релаксации.

Показано:

- ▶ сходимость IRLS
- ▶ гарантии на шаг градиентных спусков, что дает применимость для больших размерностей

Эксперименты показали:

- ▶ Снижение ранга улучшает распределение разрезов
- ▶ Log-Det лучше других понижает ранг задачи
- ▶ Релаксация значения функционала улучшает ранг решения, но не ухудшает средний разрез