

An exact pseudopolynomial algorithm for a bi-partitioning problem

Alexander Kel'manov, Vladimir Khandeev

*Sobolev Institute of Mathematics
Siberian Branch of the Russian Academy of Sciences, Novosibirsk*

10th International Conference
Intelligent Information Processing (IIP-10)
Crete, Greece
October 4-11, 2014

Введение

Предмет исследования —

квадратичная евклидова NP-трудная в сильном смысле задача разбиения конечного множества векторов.

Цель исследования —

обоснование точного псевдополиномиального алгоритма для специального случая этой задачи (когда размерность пространства фиксирована).

Области приложений:

анализ данных и распознавание образов, комбинаторная геометрия, математическая статистика, теория приближения.

Введение

Одной из самых известных задач анализа данных и распознавания образов является

Задача MSSC (Minimum Sum-of-Squares Clustering) [Fisher, 1958]

Дано: множество $\mathcal{Y} = \{y_1, \dots, y_N\}$ векторов из \mathbb{R}^q .

Найти: разбиение множества \mathcal{Y} на непустые подмножества (кластеры) $\mathcal{C}_1, \dots, \mathcal{C}_J$ такое, что

$$\sum_{j=1}^J \sum_{y \in \mathcal{C}_j} \|y - \bar{y}(\mathcal{C}_j)\|^2 \rightarrow \min,$$

где $\bar{y}(\mathcal{C}_j) = \frac{1}{|\mathcal{C}_j|} \sum_{y \in \mathcal{C}_j} y$, $j = 1, \dots, J$, — центр j -го кластера.

Эта задача также известна под названием k -Means [Edwards, Cavalli-Sforza, 1965].

К числу слабоизученных относится задача

Задача J -MSSC-F

(Minimum Sum-of-Squares Clustering for the case of Fixed cardinalities
and one cluster with known center)

Дано: множество $\mathcal{Y} = \{y_1, \dots, y_N\}$ векторов из \mathbb{R}^q , натуральные
числа M_1, \dots, M_J .

Найти: непересекающиеся подмножества $\mathcal{C}_1, \dots, \mathcal{C}_J \subseteq \mathcal{Y}$ такие, что

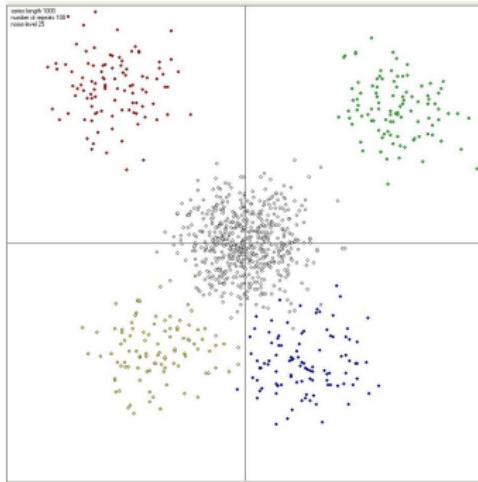
$$\sum_{j=1}^J \sum_{y \in \mathcal{C}_j} \|y - \bar{y}(\mathcal{C}_j)\|^2 + \sum_{y \in \mathcal{Y} \setminus (\mathcal{C}_1 \cup \dots \cup \mathcal{C}_J)} \|y\|^2 \rightarrow \min,$$

где $\bar{y}(\mathcal{C}_j) = \frac{1}{|\mathcal{C}_j|} \sum_{y \in \mathcal{C}_j} y$, $j = 1, \dots, J$, — центр j -го кластера, при
условии $|\mathcal{C}_j| = M_j$, $j = 1, \dots, J$.

Пример 1

1000 результатов измерений характеристик 4-х объектов, изображённые на плоскости.

Каждый объект может находиться в активном и пассивном состоянии.



Формулировка задачи

В настоящей работе рассматривается частный случай задачи J-MSSC-F при $J = 1$.

Задача 1-MSSC-F

Дано: множество $\mathcal{Y} = \{y_1, \dots, y_N\}$ векторов из \mathbb{R}^q и натуральное число M .

Найти: подмножество $\mathcal{C} \subseteq \mathcal{Y}$ мощности M такое, что

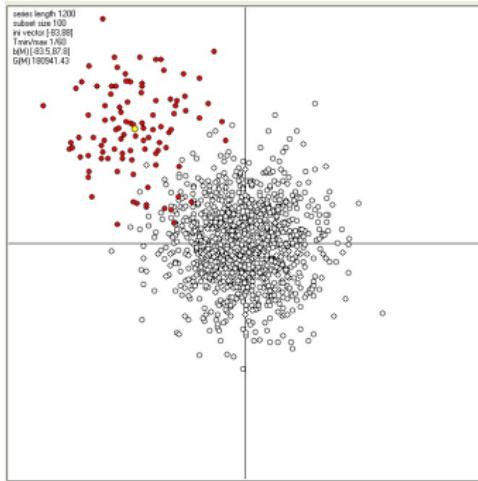
$$S(\mathcal{C}) = \sum_{y \in \mathcal{C}} \|y - \bar{y}(\mathcal{C})\|^2 + \sum_{y \in \mathcal{Y} \setminus \mathcal{C}} \|y\|^2 \rightarrow \min,$$

где $\bar{y}(\mathcal{C}) = \frac{1}{|\mathcal{C}|} \sum_{y \in \mathcal{C}} y$ — геометрический центр подмножества \mathcal{C} .

Пример 2

1000 результатов измерений характеристик объекта, изображённые на плоскости.

100 раз были измерены характеристики объекта в активном состоянии и 900 раз — в пассивном.



- Задача NP-трудна в сильном смысле (Кельманов А. В., Пяткин А. В. 2008).
- Предложены:
 - 2-приближённый алгоритм с временной сложностью $\mathcal{O}(qN^2)$ (Долгушев А. В., Кельманов А. В. 2011),
 - схема PTAS, временная сложность которой $\mathcal{O}(qN^{2/\varepsilon+1}(9/\varepsilon)^{3/\varepsilon})$, где ε — относительная погрешность (Долгушев А. В., Кельманов А. В., Шенмайер В. В. 2012),
 - рандомизированный алгоритм, позволяющий для установленного значения параметра при фиксированных ε и γ находить $(1 + \varepsilon)$ -приближённое решение с вероятностью $1 - \gamma$ за время $\mathcal{O}(qN)$ (Кельманов А. В., Хандеев В. И. 2013).

Полученные результаты

1. Установлено, что задача разрешима за время $\mathcal{O}(q^2 N^{2q})$, полиномиальное в случае, когда размерность q пространства фиксирована.
2. Построен точный псевдополиномиальный алгоритм для случая, когда компоненты векторов целочисленны, а размерность пространства фиксирована; временная сложность алгоритма есть величина $\mathcal{O}(N(MD)^q)$; здесь D — максимальное абсолютное значение координат векторов входного множества; алгоритм эффективнее известного полиномиального алгоритма при $MD < N^{2-\frac{1}{q}}$.

1. Полиномиальная разрешимость задачи при фиксированной размерности пространства

Утверждение

Задача 1-MSSC-F разрешима за время $\mathcal{O}(q^2 N^{2q})$, полиномиальное при фиксированной размерности q пространства.

Справедливость следует из равенства

$$S(\mathcal{C}) = \sum_{y \in \mathcal{Y}} \|y\|^2 - \frac{1}{|\mathcal{C}|} \left\| \sum_{y \in \mathcal{C}} y \right\|^2 \quad (1)$$

и результатов Гимади Э.Х., Пяткина А.В., Рыкова И.А. (2008), устанавливающих полиномиальную разрешимость при фиксированной размерности пространства задачи максимизации второго члена в правой части (1).

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Положим

$$G(\mathcal{B}, b) = \sum_{y \in \mathcal{B}} \|y - b\|^2 + \sum_{y \in \mathcal{Y} \setminus \mathcal{B}} \|y\|^2, \quad (2)$$

где $\mathcal{B} \subseteq \mathcal{Y}$, $|\mathcal{B}| = M$, $b \in \mathbb{R}^q$.

Лемма

- При любом фиксированном подмножестве $\mathcal{B} \subseteq \mathcal{Y}$ минимум функционала (2) доставляется вектором $\bar{y}(\mathcal{B}) = \frac{1}{M} \sum_{y \in \mathcal{B}} y$ и равен $S(\mathcal{B})$.
- При любом фиксированном векторе $b \in \mathbb{R}^q$ минимум функционала (2) достигается на множестве, состоящем из M векторов множества \mathcal{Y} , имеющих наибольшие проекции на вектор b .

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Пусть векторы из множества \mathcal{Y} имеют целочисленные компоненты.

Положим

$$D = \max_{y \in \mathcal{Y}} \max_{j \in \{1, \dots, q\}} |(y)^j|$$

и определим множество

$$\begin{aligned} \mathcal{D} = \{d \mid d \in \mathbb{R}^q, (d)^j = \frac{1}{M}(v)^j, \\ (v)^j \in \mathbb{Z}, |(v)^j| \leq MD, j = 1, \dots, q\}. \quad (3) \end{aligned}$$

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Замечание 1.

Из определения (3) следует, что центр $\bar{y}(\mathcal{C}) = \frac{1}{M} \sum_{y \in \mathcal{C}} y$ любого

подмножества $\mathcal{C} \subseteq \mathcal{Y}$ мощности M лежит во множестве \mathcal{D} .

Следовательно, и центр оптимального подмножества лежит в этом же множестве.

Замечание 2.

$$|\mathcal{D}| = (2MD + 1)^q.$$

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Алгоритм \mathcal{A}

Вход алгоритма: множество \mathcal{Y} , натуральное число M .

Шаг 1. Для каждого вектора $b \in \mathcal{D}$ построим множество $\mathcal{B}(b)$, состоящее из M векторов множества \mathcal{Y} , имеющих наибольшие проекции на вектор b . Вычислим значение $G(\mathcal{B}(b), b)$.

Шаг 2. Найдём вектор $b_A = \arg \min_{b \in \mathcal{D}} G(\mathcal{B}(b), b)$ и соответствующее ему подмножество $\mathcal{B}(b_A)$. В качестве решения задачи возьмём подмножество $\mathcal{C}_A = \mathcal{B}(b_A)$. Если решений несколько, то выберем любое из них.

Выход алгоритма: множество \mathcal{C}_A .

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Теорема

Пусть в условиях задачи 1-MSSC- F векторы из множества \mathcal{Y} имеют целочисленные компоненты из интервала $[-D, D]$. Тогда алгоритм \mathcal{A} находит оптимальное решение задачи 1-MSSC- F за время $\mathcal{O}(qN(2MD + 1)^q)$.

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Доказательство Теоремы

По определению шага 2 алгоритма имеем

$$G(\mathcal{C}_A, b_A) \leq G(\mathcal{B}(y^*), y^*), \quad (4)$$

где $y^* = \frac{1}{M} \sum_{y \in \mathcal{C}^*} y$ — центр оптимального подмножества \mathcal{C}^* .

Из первого утверждения леммы следует оценка

$$S(\mathcal{C}_A) \leq G(\mathcal{C}_A, b_A), \quad (5)$$

а из второго — равенство

$$G(\mathcal{B}(y^*), y^*) = S(\mathcal{C}^*). \quad (6)$$

Объединяя (4) — (6), получаем оценку

$$S(\mathcal{C}_A) \leq S(\mathcal{C}^*).$$

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Доказательство Теоремы

С другой стороны, так как множество \mathcal{C}_A является допустимым решением задачи 1-MSSC-F, то справедливо неравенство

$$S(\mathcal{C}^*) \leq S(\mathcal{C}_A),$$

что устанавливает равенство значений $S(\mathcal{C}^*)$ и $S(\mathcal{C}_A)$.

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Доказательство Теоремы

Оценим временную сложность алгоритма.

- Шаг 1. Для каждого из $(2MD + 1)^q$ векторов множества \mathcal{D} :
 - вычисление проекций на этот вектор — $\mathcal{O}(qN)$ операций;
 - выбор M векторов, имеющих наибольшие проекции — $\mathcal{O}(N)$ операций;
 - вычисление значения функции $G(\mathcal{B}(b), b)$ — $\mathcal{O}(qN)$ операций.
- Шаг 2. Поиск наименьшего элемента — $\mathcal{O}((2MD + 1)^q)$ операций.

Итоговая временная сложность — $\mathcal{O}(qN(2MD + 1)^q)$.

2. Точный псевдополиномиальный алгоритм для специального случая задачи

Замечание

Если размерность q пространства фиксирована, то трудоёмкость $\mathcal{O}(qN(2MD + 1)^q)$ алгоритма оценивается величиной $\mathcal{O}(N(MD)^q)$. Время работы точного полиномиального алгоритма есть величина $\mathcal{O}(N^{2q})$. Поэтому предложенный псевдополиномиальный алгоритм более эффективен при $MD < N^{2 - \frac{1}{q}}$.

Основные результаты

1. Установлена полиномиальная разрешимость задачи 1-MSSC-F в случае, когда размерность пространства фиксирована.
2. Обоснован псевдополиномиальный алгоритм, гарантирующий отыскание оптимального решения задачи в случае, когда компоненты векторов целочисленны и размерность пространства фиксирована. Установлены условия, при которых этот алгоритм быстрее полиномиального алгоритма.

Актуальные вопросы

1. Построение FPTAS для случая фиксированной размерности пространства.
2. Рассмотрение обобщения задачи на случай нескольких кластеров — задачи J -MSSC-F.

Спасибо за внимание!