

Тензорные методы и их приложения

Е.Е.Тыртышников

Институт вычислительной математики им. Г.И.Марчука
Российской академии наук

Московский университет им. М.В.Ломоносова

Московский физико-технический институт

tee@inm.ras.ru

Иннополис, 6 июня 2024



Проклятие размерности

Массив $A = [a(i_1, \dots, i_d)]$ размера $n \times \dots \times n$ невозможно задавать списком всех элементов даже при небольших d .

Если $d = 83$ и $n = 10$, то число элементов 10^{83} равно числу атомов во Вселенной!



Нужны *модели данных* с приемлемо малым числом параметров и *алгоритмы, работающие только с параметрами*.

Представление матриц малого ранга

Если r - ранг матрицы A порядка n , то

$$A = \sum_{\alpha=1}^r u_{\alpha} v_{\alpha}^{\top} = UV^{\top}$$

$$U = [u_1, \dots, u_r], \quad V = [v_1, \dots, v_r]$$

(матрицы размера $n \times r$)

$$2rn \ll n^2$$

Малый ранг повсюду

- ▶ Многие матрицы специального вида получают малый ранг после линейного преобразования. Для теплицевой матрицы $A = [a_{i-j}]$ после сдвигов $\text{rank}(PA - AP) = 2$.
- ▶ В приложениях, например при решении интегральных уравнений математической физики, многие невырожденные матрицы состоят из блоков малого ранга (мозаично-скелетонный метод, мультипольный метод).
- ▶ Невырожденные матрицы могут быть близки к матрицам малого ранга поэлементно (в чебышевской норме):

$$\|I_n - R_n\|_C \leq \varepsilon, \quad \text{rank}(R_n) \leq c \frac{\log n}{\varepsilon^2}.$$

Польза приближений малого ранга

- ▶ Сжатие данных
 - ▶ в случае матриц размера $n \times n$:
$$r \ll n \Rightarrow 2nr \ll n^2$$
 - ▶ в случае d -тензоров размера $n \times \dots \times n$:
$$r \ll n^{d-1} \Rightarrow dnr \ll n^d$$
- ▶ Выделение наиболее значимой информации и устранение шума
- ▶ Быстрые вычисления в малоранговых форматах

Эффективная парадигма вычислений

- ▶ Для “больших” объектов выбирается модель их представления на основе “малых” векторов $A = A(p)$, $B = B(q)$, $C = C(s)$.
- ▶ Чтобы найти “большой” объект $C = A * B$, мы строим *быстрый алгоритм* приближенного вычисления s по p и q . При этом “большие” объекты A и B не должны возникать явным образом.
- ▶ Для широкого класса приложений для параметризации и аппроксимации “больших” объектов можно использовать разложения малого ранга.

Сингулярное разложение матрицы

Можно построить разложение, в котором векторы u_1, \dots, u_r и v_1, \dots, v_r ортогональны.

После нормировки

$$u_\alpha v_\alpha^\top = \sigma_\alpha u_\alpha v_\alpha^\top, \quad u_\alpha := u_\alpha / \|u_\alpha\|, \quad v_\alpha := v_\alpha / \|v_\alpha\|,$$

получаем *сингулярное разложение*:

$$A = \sum_{\alpha=1}^r \sigma_\alpha u_\alpha v_\alpha^\top = U \Sigma V^\top, \quad \Sigma = \begin{bmatrix} \sigma_1 & & \\ & \ddots & \\ & & \sigma_r \end{bmatrix},$$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0.$$

Приближения малого ранга

Для любой матрицы B ранга $\leq k$ имеет место неравенство

$$\|A - B\| \geq \sqrt{\sum_{\alpha=k+1}^n \sigma_{\alpha}^2}$$

$$\min_B \|A - B\| = \|A - A_k\|$$

$$A_k = \sum_{\alpha=1}^k \sigma_{\alpha} u_{\alpha} v_{\alpha}^{\top}$$

Здесь $\|A\| = \sqrt{\sum_{i,j} |a_{ij}|^2}$ (норма Фробениуса).


Крестовая строчно-столбцовая аппроксимация

$$A = \begin{array}{|c|c|c|} \hline & & \\ \hline & & \\ \hline & & \\ \hline \end{array} \begin{array}{l} \hat{A} \\ R \\ C \end{array} = C \hat{A}^{-1} R \approx CGR$$

The diagram shows a 3x3 grid representing matrix A. A diagonal line from the top-right to the bottom-left is labeled \hat{A} . A horizontal line across the middle row is labeled R . A vertical line down the middle column is labeled C . An arrow points from the \hat{A} label to the diagonal line.

$$\hat{A}, G - n \times n$$

Как найти "хороший" крест



Принцип наибольшего объема

Теорема (Горейнов, Тыртышников).

Пусть блок $A_{11} \in \mathbb{C}^{r \times r}$ имеет наибольший объем среди всех $r \times r$ -блоков матрицы

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, \quad r = \text{rank}(A + F).$$

Тогда

$$\|A - CA_{11}^{-1}R\|_C \leq (r + 1)^2 \|F\|_C,$$

$$C = \begin{bmatrix} A_{11} \\ A_{21} \end{bmatrix}, \quad R = [A_{11} \quad A_{12}].$$

Как искать “хороший” блок


Возьмем обратимый блок $\hat{C} \in \mathbb{R}^{k \times k}$ в матрице $C \in \mathbb{R}^{n \times k}$ и перейдем к матрице

$$C\hat{C}^{-1} = \begin{bmatrix} 1 & & & \\ & \ddots & & \\ & & 1 & \\ q_{r+1,1} & \dots & q_{r+1,r} & \\ \dots & \dots & \dots & \\ q_{n1} & \dots & q_{nr} & \end{bmatrix}$$

Необходимое условие для того, чтобы блок \hat{C} имел наибольший объем в матрице C : $|q_{ij}| \leq 1$, $r+1 \leq i \leq n$, $1 \leq j \leq r$. Если не так, то делаем перестановку двух строк и увеличиваем объем!

D.Knuth, Semi-optimal bases for linear dependencies,
Linear and Multilinear Algebra, 1985

Поиск больших элементов в матрицах малого ранга



В столбцовой подматрице $C \in \mathbb{R}^{n \times k}$ найдем k “хороших” строк. Они выделяют строчную подматрицу $R \in \mathbb{R}^{k \times n}$, найдем в ней k “хороших” столбцов. Новые столбцы определяют новую столбцовую подматрицу $C \in \mathbb{R}^{k \times n}$, ищем в ней k “хороших” строк. И так далее.

Данный алгоритм с высокой вероятностью приводит к блоку почти максимального объема, в котором имеются почти максимальные элементы. На его основе получен новый эвристический алгоритм глобальной оптимизации. В ряде задач (например, докинга) он оказался на порядок эффективнее традиционных методов.

Представления многомерных массивов

- ▶ Каноническое разложение:

$$a_{i_1, \dots, i_d} = \sum_{\alpha_1=1}^r u_{i_1, \alpha}^{(1)} \cdots u_{i_d, \alpha}^{(d)}$$

Много теоретических и вычислительных проблем. Массив может быть пределом массивов строго меньшего ранга.

- ▶ Тензорный поезд:

$$a_{i_1, \dots, i_d} = \sum_{\alpha_1=1}^{r_1} \cdots \sum_{\alpha_{d-1}=1}^{r_{d-1}} g_{i_1 \alpha_1}^{(1)} g_{\alpha_1 i_2 \alpha_2}^{(2)} \cdots g_{\alpha_{d-2} i_{d-1} \alpha_{d-1}}^{(d-1)} g_{\alpha_{d-1} i_d}^{(d)}$$

Теоретических проблем нет. Все вычисления сводятся к работе с матрицами, ассоциированными с массивом.

Модель тензорного поезда



$$a(i_1, i_2, i_3, i_4, i_5) =$$

$$\sum_{\alpha_1, \alpha_2, \alpha_3, \alpha_4} g_1(i_1, \alpha_1) g_2(\alpha_1, i_2, \alpha_2) g_3(\alpha_2, i_3, \alpha_3) g_4(\alpha_3, i_4, \alpha_4) g_5(\alpha_4, i_5)$$

$$= \underbrace{A_1^{(i_1)}}_{1 \times r_1} \underbrace{A_2^{(i_2)}}_{r_1 \times r_2} \underbrace{A_3^{(i_3)}}_{r_2 \times r_3} \underbrace{A_4^{(i_4)}}_{r_3 \times r_4} \underbrace{A_5^{(i_5)}}_{r_4 \times 1}$$

Восстановление тензора и оптимизация в формате тензорного поезда

Тензорный поезд:

$$\begin{aligned} a_{i_1, \dots, i_d} &= \sum_{\alpha_1=1}^{r_1} \cdots \sum_{\alpha_{d-1}=1}^{r_{d-1}} g_{i_1 \alpha_1}^{(1)} g_{\alpha_1 i_2 \alpha_2}^{(2)} \cdots g_{\alpha_{d-2} i_{d-1} \alpha_{d-1}}^{(d-1)} g_{\alpha_{d-1} i_d}^{(d)} \\ &= G_{i_1}^{(1)} G_{i_2}^{(2)} \cdots G_{i_{d-1}}^{(d-1)} G_{i_d}^{(d)} \end{aligned}$$

Алгоритмы строятся на основе структурированных малоранговых представлений для ассоциированных матриц развертки

$$A_k = [a_{i_1 \dots i_k; i_{k+1} \dots i_d}^k]_{(n_1 \dots n_k) \times (n_{k+1} \dots n_d)}$$

$$a_{i_1 \dots i_k; i_{k+1} \dots i_d}^k = a_{i_1, \dots, i_d}$$

Быстрое суммирование элементов астрономически большого вектора

$$i = \overline{i_1 i_2 \dots i_d} \quad d = 83$$

$$a(i) = a(i_1, \dots, i_d) = \sum_{\alpha_1, \dots, \alpha_{d-1}} g_1(i_1, \alpha_1) g_2(\alpha_1, i_2, \alpha_2) \dots g_d(\alpha_{d-1}, i_d)$$

$$\sum_{i_1, \dots, i_d} a(i_1, \dots, i_d) = \sum_{\alpha_1, \dots, \alpha_{d-1}} \hat{g}_1(\alpha_1) \hat{g}_2(\alpha_1, \alpha_2) \dots \hat{g}_d(\alpha_{d-1})$$

$$\hat{g}_k = \sum_{i_k} g_k$$

Тензорный поезд и квадратуры

$$I(d) = \int \sin(x_1 + x_2 + \dots + x_d) dx_1 dx_2 \dots dx_d =$$

$$\operatorname{Im} \int_{[0,1]^d} e^{i(x_1+x_2+\dots+x_d)} dx_1 dx_2 \dots dx_d = \operatorname{Im}\left(\left(\frac{e^i - 1}{i}\right)^d\right).$$

$n = 11$ узлов по одной оси \Rightarrow всего n^d значений! Но вычисляется лишь малая часть.

| d | $I(d)$ | Rel.error | Time |
|------|---------------|--------------|--------|
| 100 | -3.926795e-03 | 2.915654e-13 | 0.77 |
| 1000 | -2.637513e-19 | 3.482065e-11 | 11.60 |
| 2000 | 2.628834e-37 | 8.905594e-12 | 33.05 |
| 4000 | 9.400335e-74 | 2.284085e-10 | 105.49 |

Тензоризация векторов и матриц

Любой вектор размера $N = n_1 \dots n_d$ можно рассматривать как d -мерный массив, а любую $N \times N$ -матрицу

$$a(i, j) = a(i_1 \dots i_d, j_1 \dots j_d)$$

как $2d$ -мерный массив или же, склеив пары индексов, как d -мерный массив размера $n_1^2 \times \dots \times n_d^2$. вида

$$a(i_1 j_1, \dots, i_d j_d)$$

Тензоризация с последующим построением тензорного поезда может радикально сократить число параметров модели!

Польза даже для одномерных интегралов!

При вычислении интеграла

$$\int_0^{\infty} \frac{\sin x}{x} dx = \frac{\pi}{2}$$

сначала переходим к ограниченной области, а затем применяем формулу прямоугольников.

Чтобы получить машинную точность, нужно взять порядка 2^{77} узлов. Вектор значений функции в этих узлах рассматривается как тензор размера $2 \times 2 \times \dots \times 2$.

ТТ-ранги: ≤ 12 . Время: меньше 1 секунды на ноутбуке.

Каноническое тензорное разложение

$$a_{i_1 \dots i_d} = \sum_{\alpha=1}^r u_{i_1, \alpha}^{(1)} \dots u_{i_d, \alpha}^{(d)} \Leftrightarrow a = \sum_{\alpha=1}^r u_{\alpha}^{(1)} \otimes \dots \otimes u_{\alpha}^{(d)}$$

Минимальное r называется *рангом* тензора $A = [a_{i_1 \dots i_d}]$.

Проблема незамкнутости:

$$\begin{aligned} T &= a \otimes a \otimes b + a \otimes b \otimes a + b \otimes a \otimes a \\ (a + \varepsilon b) \otimes (a + \varepsilon b) \otimes (a + \varepsilon b) &= a \otimes a \otimes a + \varepsilon T + O(\varepsilon^2) \\ \Rightarrow T &= \varepsilon^{-1} (a + \varepsilon b)^{\otimes 3} - \varepsilon^{-1} a^{\otimes 3} + O(\varepsilon) \end{aligned}$$

Если векторы a и b линейно независимы, то $\text{rank } T = 3$.

Теорема о ранге обобщенного лапласиана

$$T_d = T_1^{(d)} + \dots + T_d^{(d)}$$

$$T_i^{(d)} = a_1 \otimes \dots \otimes a_{i-1} \otimes b_i \otimes a_{i+1} \otimes \dots \otimes a_d$$

Если a_i, b_i линейно независимы, то $\text{rank}(T_d) = d$.

- ▶ Tyrtysnikov E., Tensor decompositions and rank increment conjecture, RJNAMM, 25 (4), 239–246 (2020).

По индукции доказывается более общее утверждение:

$$\text{rank}(T_d + \gamma a_1 \otimes \dots \otimes a_d) = d \quad \forall \gamma \in \mathbb{C}.$$

Вопросы о незамкнутости ранговых множеств

Замыкание \bar{X}_k рангового множества $X_k := \{T : \text{rank}(T) \leq k\}$ является алгебраическим многообразием.

- ▶ Множества X_1 и $X_{R_{\max}}$ замкнуты.
- ▶ Множества X_k при $R_{\text{gen}} \leq k < R_{\max}$ незамкнуты.
- ▶ Множество X_2 незамкнуто.
- ▶ Верно ли, что при $2 \leq k < R_{\max}$ множество X_k незамкнуто?
- ▶ Каков максимальный ранг R_k предела тензоров ранга k ?

R_{\max} и R_{gen} — максимальный и главный ранги в пространстве тензоров заданного размера. Любой тензор является пределом тензоров ранга R_{gen} .

Теорема об увеличении ранга

Для любого $1 < k < R_{\text{gen}}$ существует алгебраическое многообразие $W \subsetneq \bar{X}_k$ такое, что для любого тензора из множества $X_k \setminus W$ найдется тензор ранга 1, прибавление которого увеличивает ранг данного тензора.

- ▶ Tyrtysnikov E., Tensor decompositions and rank increment conjecture, RJNAMM, 25 (4), 239–246 (2020).

Гипотеза об увеличении ранга: утверждение верно для любого тензора, ранг которого меньше максимального ранга.

Существует последовательность $n \times n \times n$ -тензоров ранга n с предельным тензором ранга $2n - 1$.

Спасибо за внимание!