

УДК 51-7

КРОСС-ЭНТРОПИЙНАЯ ОПТИМАЛЬНАЯ РЕДУКЦИЯ РАЗМЕРНОСТИ МАТРИЦЫ ДАННЫХ С ОГРАНИЧЕНИЕМ ИНФОРМАЦИОННОЙ ЁМКОСТИ

Академик РАН Ю. С. Попков^{1,2,*}, А. Ю. Попков¹

Поступило 29.04.2019 г.

Развивается метод редукции матрицы с неотрицательными элементами, основанный на кросс-энтропийной оптимизации матриц-проекторов при условии сохранения информационной ёмкости исходной матрицы.

Ключевые слова: снижение размерности, прямые и обратные проекции, информационная ёмкость, кросс-энтропия.

DOI: <https://doi.org/10.31857/S0869-5652488121-23>

1. ВВЕДЕНИЕ

Одна из проблем использования данных связана с их достаточным количеством для решения той или иной задачи. Один из путей определения достаточного количества данных может быть реализован с помощью перебора задач, контроля точности их решения, выбора приемлимой точности и соответствующего ей объёма данных. Базовым инструментом в этой группе является процедура случайных проекций (RP) [1], когда для фиксированной размерности редуцированной матрицы генерируются случайные матрицы проекций на основе нормального распределения, а в некоторых случаях — равномерного распределения [2]. В работе [3] был предложен метод “прямого и обратного проектирования” (DIP-метод — direct-inverse-projection), в котором для каждого фиксированного количества данных определялись энтропийно-оптимальные матрицы-проекторы.

Другой путь — в формировании процедуры редукции с количественно измеряемым функционалом её качества. Наиболее распространённой является процедура PCA (principal component analysis), основанная на методе опорных векторов [4, 5]. Функционал качества в этой процедуре — остаточная дисперсия, которая монотонно зависит от количества опорных векторов и, косвенно, от объёма данных [6]. На основе процедуры PCA развито

много модификаций, ориентированных на особенности прикладных задач. Среди них линейный дискриминантный анализ (LDA) [7], в котором используется матрица данных и метки классов объектов, процедуры ICE [8] для анализа цифровых сигналов и NMF [9] для обработки аудиосигналов. Упомянутые методы используют в той или иной степени метод опорных векторов, который весьма чувствителен к ошибкам в данных. Некоторое уменьшение этой зависимости даёт его робастная модификация [10].

Данное сообщение посвящено модификации DIP-метода, построенной на понятии информационной ёмкости матрицы. DIP-метод дополняется условием сохранения информационной ёмкости исходной матрицы данных в заданных пределах. Модифицированный метод редукции матрицы данных (mDIP) моделируется задачей максимизации кросс-энтропийной функции на множестве, описываемом линейным неравенством. Для поиска минимума предлагается использовать мультипликативный алгоритм первого порядка [11, 12]. Получены условия его локальной сходимости.

2. КРОСС-ЭНТРОПИЙНАЯ РЕДУКЦИЯ С ОГРАНИЧЕНИЕМ ИНФОРМАЦИОННОЙ ЁМКОСТИ (mDIP-МЕТОД)

Рассмотрим невырожденную матрицу $U_{(m \times s)} \geq 0$ данных: m — количество объектов, s — количество признаков. Для сокращения размерности признакового пространства с s до r применим метод “прямого” с матрицей-проектором $Q_{(s \times r)} \geq 0$ и “обратного” с матрицей-проектором $T_{(r \times s)} \geq 0$ проектирования [3]. Будем иметь

¹ Федеральный исследовательский центр “Информатика и управление” Российской Академии наук, Москва

² Department of Software Engineering, ORT Braude College, Karmiel, Israel

* E-mail: popkov@isa.ru

$$Y_{(m \times r)} = U_{(m \times s)} Q_{(s \times r)}, \quad X_{(m \times s)} = U_{(m \times s)} Q_{(s \times r)} T_{(r \times s)} \leq 0. \quad (1)$$

“Расстояние” между указанными матрицами будем оценивать функционалом кросс-энтропии [12, 13]:

$$\begin{aligned} H(X_{(m \times s)} | U_{(m \times s)}) &= H(Q_{(s \times r)}, T_{(r \times s)} | U) = \\ &= - \sum_{i=1}^m \sum_{j=1}^s h_{ij}(Q_{(s \times r)}, T_{(r \times s)} | U_{(m \times s)}), \end{aligned} \quad (2)$$

где

$$\begin{aligned} h_{ij}(Q_{(s \times r)}, T_{(r \times s)} | U_{(m \times s)}) &= \\ &= x_{ij}(Q_{(s \times r)}, T_{(r \times s)} | U_{(m \times s)}) \ln \frac{x_{ij}(Q_{(s \times r)}, T_{(r \times s)} | U_{(m \times s)})}{u_{ij}}, \end{aligned} \quad (3)$$

$$x_{ij}(Q_{(s \times r)}, T_{(r \times s)} | U_{(m \times s)}) = \sum_{\mu=1}^r \sum_{\nu=1}^s t_{\mu,j} q_{\nu,\mu} u_{i,\nu}, \quad (4)$$

$$i = 1, 2, \dots, m; \quad j = 1, 2, \dots, s.$$

Теорема 1. Существует множество $\mathcal{G}_{(Q,T)}$ неотрицательных матриц Q, T :

$$\begin{aligned} (Q, T) &\in \mathcal{G}_{(Q,T)} = \\ &= \left\{ \sum_{i=1}^m \sum_{j=1}^s x_{ij}(Q, T) \ln \frac{x_{ij}(Q, T)}{u_{ij}} + ms \geq 0, \quad Q \geq 0, \quad T \geq 0 \right\}, \end{aligned} \quad (5)$$

на котором матричный гессиан функции $H(Q, T | U) \leq 0$.

Под матричным гессианом понимается матрица вторых производных скалярной функции $H(Q, T)$ по элементам матриц Q, T [14]. Доказательство следует из вида элементов матричного гессиана.

Введём понятие информационной ёмкости прямоугольной неотрицательной матрицы $U_{(m \times s)}$. Рассмотрим функционал

$$\mathcal{I}(U) = \sum_{(i,j)=1}^{m,s} u_{ij} \ln u_{ij}. \quad (6)$$

Для $0 \leq u_{ij} \leq 1$, $\mathcal{I} \leq 0$ и для $u_{ij} > 1$, $\mathcal{I} > 0$. Минимальное значение $\mathcal{I}_{\min} = -mse^{-1}$. Определим информационную ёмкость матрицы $U_{(m \times s)}$ в виде

$$E_U = \mathcal{I}(U) + e^{-1}ms \geq 0. \quad (7)$$

Оптимальные элементы неотрицательных матриц Q, T (1) будем определять, максимизируя кросс-энтропию (2) на множестве $\mathcal{G}_{Q,T}$ (5) (где существует единственный локальный максимум $H(Q, T)$) при условии, что снижение информационной ёмкости редуцированной матрицы Y (1) не более допустимого:

$$H(Q_{(s \times r)}, T_{(r \times s)} | U) \Rightarrow \max,$$

$$(Q, T) \in \mathcal{D}(Q) = \{(Q) : E_U - E_Y(Q)\} \leq \delta, \quad (8)$$

где

$$E_Y(Q) = \sum_{(i,j)=1}^{m,r} y_{ij}(Q) \ln y_{ij}(Q) + e^{-1}mr,$$

$$y_{ij}(Q) = \sum_{k=1}^s u_{i,k} q_{k,j}, \quad i = 1, 2, \dots, m, \quad j = 1, 2, \dots, r. \quad (9)$$

Преобразуем задачу (8), (9) к стандартному виду, используя процедуру векторизации матриц:

$$(Q, T) \rightarrow \mathbf{q} \in R^{mr}, \quad \mathbf{t} \in R^{mr}. \quad (10)$$

Тогда задача (8), (9) примет следующий вид:

$$H(\mathbf{q}, \mathbf{t}) \Rightarrow \max,$$

$$(\mathbf{q}, \mathbf{t}) \in \mathcal{D}(q) = \{\mathbf{q} : E_Y(\mathbf{q}) - E_U \geq \delta\}, \quad (11)$$

$$\mathbf{q} \geq 0, \quad \mathbf{t} \geq 0.$$

3. УСЛОВИЯ ОПТИМАЛЬНОСТИ И МУЛЬТИПЛИКАТИВНЫЙ АЛГОРИТМ

Определим функционал Лагранжа в виде

$$\mathcal{L}(\mathbf{q}, \mathbf{t}, \lambda) = P(\mathbf{q}, \mathbf{t}, \lambda) - \langle \mu, \mathbf{q} \rangle - \langle \nu, \mathbf{t} \rangle, \quad (12)$$

$$P(\mathbf{q}, \mathbf{t}, \lambda) = H(\mathbf{q}, \mathbf{t}) + \lambda(\delta - E_U + E_Y(\mathbf{q})),$$

$$\mathbf{q} \in R_+^{mr}, \quad \mathbf{t} \in R_+^{mr}, \quad \mu \in R^{mr}, \quad \nu \in R^{mr}.$$

Необходимые условия оптимальности Куна—Такера в терминах функции $P(\mathbf{q}, \mathbf{t}, \lambda)$ имеют вид [12]

$$P_{\mathbf{q}}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) \geq 0, \quad \mathbf{q}^* \otimes P_{\mathbf{q}}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) = 0, \quad \mathbf{q}^* \geq 0, \quad \mathbf{t} \geq 0,$$

$$P_{\mathbf{t}}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) \geq 0, \quad \mathbf{q}^* \otimes P_{\mathbf{t}}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) = 0, \quad \mathbf{q}^* \geq 0, \quad \mathbf{t}^* \geq 0,$$

$$P_{\lambda}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) \leq 0, \quad \lambda^* \otimes P_{\lambda}(\mathbf{q}^*, \mathbf{t}^*, \lambda^*) = 0, \quad (13)$$

$$\mathbf{q}^* \geq 0, \quad \mathbf{t}^* \geq 0, \quad \lambda^* \geq 0.$$

Алгоритм решения этой системы имеет вид:

а) начальный шаг

$$(\mathbf{q}^0, \mathbf{t}^0) > 0, \quad (\mathbf{q}^0, \mathbf{t}^0) \in \mathcal{G}_{Q,T};$$

б) итерационный шаг

$$\mathbf{q}^{s+1} = \mathbf{q}^s \otimes (1 - \gamma P_{\mathbf{q}}(\mathbf{q}^s, \mathbf{t}^s, \lambda^s)),$$

$$\mathbf{t}^{s+1} = \mathbf{t}^s \otimes (1 - \alpha P_{\mathbf{t}}(\mathbf{q}^s, \mathbf{t}^s, \lambda^s)),$$

$$\lambda^{s+1} = \lambda^s (1 + \beta P_{\lambda}(\mathbf{q}^s, \mathbf{t}^s, \lambda^s)).$$

Доказательство сходимости основано на исследовании поведения функции Ляпунова

$$\begin{aligned}
 V(\mathbf{q}, \mathbf{t}, \lambda) = & \sum_{i=1}^{mr} (q_i - q_i^*) - q_i^* (\ln q_i - \ln q_i^*) + \\
 & + \sum_{i=1}^{mr} (t_i - t_i^*) - t_i^* (\ln t_i - \ln t_i^*) + \\
 & + (\lambda - \lambda^*) - \lambda^* (\ln \lambda - \ln \lambda^*)
 \end{aligned} \quad (14)$$

на решениях системы:

$$\begin{aligned}
 \frac{d\mathbf{q}}{dt} &= -\mathbf{q} \otimes P_q(\mathbf{q}, \mathbf{t}, \lambda), \\
 \frac{d\mathbf{t}}{dt} &= -\mathbf{t} \otimes P_t(\mathbf{q}, \mathbf{t}, \lambda), \\
 \frac{d\lambda}{dt} &= \lambda P_\lambda(\mathbf{q}, \mathbf{t}, \lambda).
 \end{aligned} \quad (15)$$

Источники финансирования. Работа поддержана Российским фондом фундаментальных исследований (проекты 17–29–03119, 17–29–02115).

СПИСОК ЛИТЕРАТУРЫ

1. *Bingham E., Manilla H.* Random projection in dimensionality reduction: Application to image and next data // Proc. of the Seventh ACM SICKDD Intern. Conf. on Knowledge Discovery and Data Mining. N.Y.: Association for Computing Machinery. P. 245–250.
2. *Achlioptas D.* Database-friendly random projection // Proceeding PODS'01, Proc. of the twentieth ACM SIGMOD-SIGACT-SIGART symposium on principles of data base systems. 2001. P. 274–281.
3. *Попков Ю.С., Дубнов Ю.А., Попков А.Ю.* Энтропийная редукция размерности в задачах рандомизированного машинного обучения // *АиТ.* 2018. № 11. С. 106–123.
4. *Кендал М.Дж., Стюарт А.* Статистические выводы и связи // Пер. с англ. М.: Наука, 1973.
5. *Jolliffe I.T.* Principle Component Analysis // N.Y.: Springer-Verlag, 2002.
6. *Айвазян С.А., Бухштабер И.М., Енюков И.С., Мешалкин Л.Д.* Прикладная статистика: Классификация и снижение размерности // М.: Финансы и статистика, 1989.
7. *Fisher R.A.* The Use of Multiple Measurements in Taxonomic Problems // *Annals of Eugenics.* 1936. V. 7. P. 179–188.
8. *Comon P., Jutten C.* Handbook of Blind Source Separation, Independent Component Analysis and Applications. Oxford: Acag. Press, 2010.
9. *Michael W., et all.* Algorithms and Application for Approximate Nonnegative Matrix Factorization // *Computational Statistics and Data Analysis.* 2007. V. 52. P. 150–173.
10. *Поляк Б.Т., Хлебников М.В.* Метод главных компонент: робастные версии // *АиТ.* 2017. № 3. С. 130–148.
11. *Попков Ю.С.* Мультипликативные схемы итерационных алгоритмов II: выпуклое программирование // *Техническая кибернетика.* 1993. № 2. С. 31–45.
12. *Попков Ю.С.* Теория макросистем: равновесные модели. М.: УРСС, 1999. 317 с.
13. *Kullback S., Leibler R.A.* On information and Sufficiency. *Ann. of Math. Statistics.* 1951. V. 22(1). P. 79–86.
14. *Magnus J., Neudecker H.* Matrix Differential Calculus with Applications in Statistics and Econometrics. John Willey and Sons. 1999.

CROSS-ENTROPY OPTIMAL DIMENSIONALITY REDUCTION WITH CONDITION ON INFORMATION CAPACITY

Academician of the RAS **Yu. S. Popkov^{1,2,*}, A. Yu. Popkov¹**

¹ *Federal Research Center “Computer Science and Control” of Russian Academy of Sciences, Moscow, Russian Federation*

² *Department of Software Engineering, ORT Braude College, Karmiel, Israel*

Received April 29, 2019

Using a data leads to a problem of its sufficiency to solve specific task. Proposed paper is devoted to a modification of direct-inverse projection method (DIP-method) based on an idea of information capacity. DIP-method is updated with a condition on maintaining the information capacity in given ranges. Modified dimensionality reduction method (mDIP) based on the problem of minimization cross-entropy function on a set defined by linear inequality. Minimization of the function is suggested to perform by the first-order multiplicative algorithm. There obtained conditions of local convergence.

Keywords: dimensionality reduction, direct and inverse projections, information capacity, cross-entropy.