

Распределенная кластеризация в мультиагентных системах на основе сжатых агрегированных данных с использованием глубокого обучения

В.Д. Панков

Санкт-Петербургский государственный университет
199034, г. Санкт-Петербург, Университетская наб., Д. 7/9
E-mail: st040308@student.spbu.ru

Ключевые слова: мультиагентные системы, compressive sensing, кластеризация в распределенных системах

Аннотация: В работе исследуется проблема распределенной кластеризации в мультиагентных системах. Одним из возможных применений метода является эффективное управление большим количеством агентов, где традиционные подходы сталкиваются с задержками передачи данных и сложностями управления. Предлагается использование кластерной синхронизации, присущей многим мультиагентным системам, для возможности синтеза управления на уровне кластеров, а не отдельных агентов. Разработанный метод позволяет агентам получать информацию о кластерах через локальные взаимодействия, используя теорию compressive sensing для обмена данными, и протокол локального голосования для сбора измерений. Это уменьшает объем передаваемых данных и позволяет адаптироваться к изменениям структуры кластеров в реальном времени. Исследование включает обучаемый метод на базе архитектуры нейронной сети PointNet, с функцией потерь венгерского алгоритма для предсказания центроидов кластеров. Предварительные результаты подтверждают эффективность метода для распределенной кластеризации в мультиагентных системах, несмотря на пока недостаточную точность восстановления параметров кластеров.

1. Введение

Мультиагентные системы моделируют множество реальных задач, таких как интернет вещей, системы распределенных сенсоров. Следовательно, возникает множество проблем управления такими системами, которые традиционно включают в себя мезоскопический (синтез управления индивидуально для каждого агента) и макроскопический уровень управления (синтез единого управления для всей системы). Макроскопическое управление не является достаточно точным во многих случаях, особенно когда имеются существенные задержки в передаче данных. Микроскопическое управление оказывается чрезмерно сложным с возрастанием количества агентов.

Альтернативным решением во многих случаях может быть использование того свойства, что многим системам присуща кластерная синхронизация [1] – состояния агентов кластеризуются в небольшое количество кластеров, в каждом

из которых они похожи друг на друга по поведению. В данном случае, возможно существенно упростить управление агентами, производя синтез управления для каждого кластера, а не каждого агента.

Для распределенного кластерного управления необходимо, чтобы каждый агент имел представление о параметрах кластера, к которому он принадлежит. Для этого, требуется разработать эффективный метод распределенной кластеризации: предоставить возможность каждому агенту, на основе локальных взаимодействий агентов, получать параметры всех кластеров системы. В докладе предложен метод распределенной кластеризации для мультиагентных систем, позволяющий снизить объемы передаваемых данных, и восстанавливать кластеры в режиме реального времени.

2. Постановка Задачи

Мультиагентная система представлена как набор агентов $\mathcal{N} = \{1, 2, \dots, N\}$, где каждый агент i из этого набора имеет свое состояние x_i , которое является вектором в пространстве \mathbb{R}^d . В системе насчитывается N агентов, а размерность пространства состояний равна d . Коммуникация между агентами моделируется с помощью направленного графа $G = (\mathcal{N}, E)$. Матрица смежности $B = [b_{ij}]$ описывает направленные пути коммуникации между агентами.

Параметры кластеров, обозначаемые как Θ , включают в себя центроиды k кластеров, которые определяются как $\bar{x}_k = \frac{1}{|C_k|} \sum_{i \in C_k} x_i$ для каждого кластера C_k . Предполагается, что состояния агентов кластеризованы в каждый момент времени, что обеспечивает разреженность системы, и позволяет использовать теорию опознания по сжатию (compressive sensing) для эффективной передачи данных. Отметим, что топология коммуникаций не обязательно связана с кластеризацией агентов – два агента в одном кластере могут быть не связаны, а агенты из разных кластеров могут обмениваться информацией.

Предлагается разработать децентрализованный алгоритм для оценки параметров Θ на основе Протокола Локального Голосования (LVP) и метода глубокого обучения для быстрого восстановления центроидов кластеров. Алгоритм должен быть масштабируемым в зависимости от количества агентов N и адаптируемым к изменениям в структуре кластеров. Чтобы избежать прямой передачи больших объемов данных о состояниях мультиагентов, используются только сжатые измерения в коммуникации, представленные как $\bar{y} = Ax$. Здесь $\mathbf{x} = [x_1^T, \dots, x_N^T]^T$ – вектор, состоящий из состояний всех агентов в пространстве \mathbb{R}^{Nd} , а матрица $A \in \mathbb{R}^{md \times Nd}$, где $m \sim k \ll N$.

3. Метод

Мы предполагаем, что каждый агент $i \in \mathcal{N}$ независимо собирает частные измерения следующим образом:

$$(1) \quad y_i = A_i x_i,$$

где $y_i \in \mathbb{R}^{md}$ – сжатое наблюдение агента i , $A_i = A_{(\cdot, i)} \in \mathbb{R}^{md \times d}$ – оператор измерения агента i , $A_{(\cdot, i)}$ представляет столбцы матрицы A , соответствующие i -му агенту. Таким

образом, мы можем получить общий вектор измерений следующим образом:

$$(2) \quad \bar{y} = \frac{1}{N} \sum_{i \in \mathcal{N}} y_i = \frac{1}{N} \sum_{i \in \mathcal{N}} A_i x_i,$$

где \bar{y} – набор сжатых измерений, вычисляемых как взвешенные суммы состояний агентов со случайными весами. Данный метод сбора измерений \bar{y} позволяет использовать Протокол Локального Голосования для синхронизации сжатых измерений между всеми агентами. Для восстановления параметров кластеров предлагается обучаемый метод – на основе нейронной сети, по архитектуре схожей с PointNet [2], за исключением первого и последнего слоев:

1. **Первый слой:** Обучаемая проекция из N (количество агентов) в m (128 – размерность сжатых измерений) с использованием линейного слоя, независимо применяемого к каждому из двух измерений (коэффициент сжатия – N/m).
2. **Сверточные слои:** Пять последующих сверточных слоев с активацией Rectified Linear Unit (ReLU) и Batch нормализацией. Размеры каналов: $2 \rightarrow 64 \rightarrow 64 \rightarrow 128 \rightarrow 1024$, что отображает двумерный вход в вектор признаков размером 1024.
3. **Average Pooling:** Применяется вдоль одной из размерностей, уменьшая размер с m до 1. Результат затем объединяется с выходом третьего слоя (для учета локальных и глобальных признаков сжатого облака точек).
4. **Сверточные слои:** Применяется пять сверточных слоев, уменьшающих размерность с $1024 + 64$ до числа выходных каналов, соответствующих количеству кластеров K .
5. **Финальная проекция:** Вторая размерность проецируется в 2 на последнем этапе, для получения размерности на выходе: $[B, 2, K]$.

В качестве функции потерь используется функция на основе венгерского метода для решения линейной задачи назначения, в соответствии с методом из [3]. Данный выбор позволяет учесть произвольный порядок в предсказываемом наборе кластеров, и упростить процесс обучения (важно предсказать только множество центроидов, а не их порядок).

Для обучения и тестирования использован синтетический набор данных – на основе случайно сгенерированных состояний 3000 агентов, разбитых на 3 или 10 случайных кластеров.

$$(3) \quad L_{\text{hun}}(\hat{Y}, Y) = \min_{\pi \in \Pi} \|\hat{y}_i - y_{\pi(i)}\|_2^2$$

где \hat{Y} – предсказанные центроиды, Y – истинные центроиды, Π – пространство перестановок. Задача о назначениях решается венгерским алгоритмом за время $O(n^3)$.

Эксперименты проводились с batch size = 128. Использовался оптимизатор Adam с начальной скоростью обучения 0.003, линейно уменьшающейся до 0.0003.

4. Результаты

Для оценки эффективности предложенного метода были проведены эксперименты с использованием 10 и 3 кластеров. Для сравнения приведены результаты кластеризации с помощью k-means, а также для случайного распределения центров кластеров. В качестве метрики используется минимальное абсолютное отклонение.

Таблица 1. Сравнение методов кластеризации. Метрика посчитана по 128000 случайно сгенерированным наборам состояний агентов

Метод	10 кластеров	3 кластера
k-means	0.012 ± 0.01	0.00 ± 0.00
proposed	0.11 ± 0.01	0.12 ± 0.01
random	0.17 ± 0.03	0.30 ± 0.10

Визуализация истинных и предсказанных центроидов, а также расположения агентов для экспериментов с 3 и 10 кластерами, представлена на рисунках ниже.




Рис. 1. Пример для 3 кластеров

5. Заключение

В настоящий момент предложенный метод существенно менее точен, чем классические нераспределенные методы кластеризации, такие как k-means. Тем не менее, предложенный метод обеспечивает возможность распределенной кластеризации, и позволяет предсказывать параметры кластеров

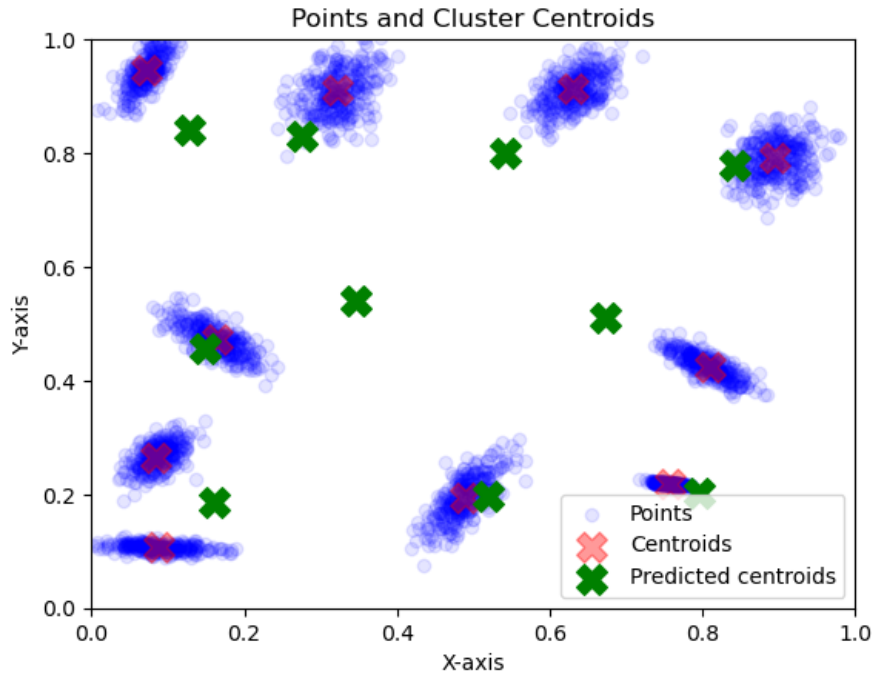


Рис. 2. Пример для 10 кластеров

в реальном времени, для быстрой адаптации к изменяющейся структуре кластеров. В дальнейших экспериментах планируется рассмотреть возможность предварительного преобразования набора точек – состояний агентов, в пространство большей размерности, где они бы обладали полезными свойствами для эффективного обучения и применения метода. Также, по аналогии со свойством ограниченной изометрии в *compressive sensing*, планируется сформулировать и доказать теорему, позволяющую определить минимальное количество измерений, необходимое для точного восстановления параметров кластеров.

Список литературы

1. Ерофеева В., Ершов В., Граничин О., Панков В., Ужва Д., Граничина О. Адаптивное распределенное управление потоком кластеров для группы автономных роботов // *IFAC-PapersOnLine*. 2023. Том 56. № 2. С. 8690-8695.
2. Qi C. R., Su H., Mo K. и другие. PointNet: Deep learning on point sets for 3D classification and segmentation // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. – 2017. – С. 652-660.
3. RezaTofighi S. H., Tsoi N., Gwak J. и другие. DeepSetNet: Predicting sets with deep neural networks // *2017 IEEE International Conference on Computer Vision (ICCV)*. – IEEE, 2017. – С. 5257-5266.