

# ОЦЕНКА ВЫЧИСЛИТЕЛЬНОЙ СЛОЖНОСТИ ОБОБЩЕННОГО АЛГОРИТМА КЛАСТЕРИЗАЦИИ

Сасин Е. А., Сидорович А. С.

Кафедра электронных вычислительных машин, Белорусский государственный университет информатики  
и радиоэлектроники  
Минск, Республика Беларусь  
E-mail: a.s.sidorovich@gmail.com

*В работе рассмотрен обобщенный алгоритм кластеризации данных. Приведены алгоритмы последовательной и параллельной работы алгоритма. Оценена их временная сложность*

## ВВЕДЕНИЕ

Развитие методов работы с информацией привело к ее увеличению до колоссальных объемов. Для удобства работы с информацией проектируются и используются базы данных. Но в большинстве своем они таких размеров, что получение и анализ данных из них является проблемой. Часто для решения таких задач используется DataMining. Data Mining — собирательное название, используемое для обозначения совокупности методов обнаружения в данных ранее неизвестных, нетривиальных, практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

## I. КЛАСТЕРНЫЙ АНАЛИЗ

Одним из методов DataMining является кластеризация (кластерный анализ). Кластеризация занимается разбиением данных на группы (кластеры) на основе схожести определенных признаков. Методы кластерного анализа позволяют решать следующие задачи:

- проведение классификации объектов с учетом признаков, отражающих сущность объектов;
- проверка выдвигаемых предположений о наличии некоторой структуры в изучаемой совокупности объектов;
- построение новых классификаций для установления наличия связей внутри совокупности;
- сжатие данных – если исходная выборка избыточно большая, можно сократить ее, оставив по одному наиболее типичному представителю от каждого кластера.

Опишем обобщенный алгоритм всех используемых методов кластеризации:

1. Случайным образом выбираются центры кластеров;
2. Вычисляются расстояния от каждого объекта до центра каждого кластера;
3. Объекты причисляются к кластерам;
4. Производится пересчет центров каждого кластера;
5. Если центры не изменились, то работа алгоритма заканчивается, иначе продолжаем

работу алгоритма с вычисления расстояния.

Для вычисления расстояний между центрами кластеров используются различные метрики. Тремя наиболее распространенными метриками расстояний являются классическая Евклидова метрика и метрики Чебышева и Манхеттена.

## II. ОЦЕНКА СЛОЖНОСТИ

Особое место при построении систем и алгоритмов является оценка их сложности. Оценка сложности помогает реализовывать более эффективное решение в каждой конкретной ситуации. Сложность алгоритма бывает временная и пространственная. Пространственная – показывает затраты памяти на реализацию алгоритма, а временная описывает количество и время выполнения элементарных операций алгоритма. При работе с большими объемами данных подразумевается использование достаточных физических ресурсов данных, а вот временные затраты на реализацию алгоритмов можно эффективно сокращать (без потери точности). Точные затраты времени рассчитать практически невозможно, т.к. это зависит от физических характеристик вычислительной системы: архитектуры и количества процессоров, особенностей компилятора и многих других. Для оценки временной сложности можно использовать  $O$  - нотацию, которая использует математическую функцию  $f(n)$ , которая зависит от количества операций  $n$ . Использование данной нотации позволяет описать характер функции  $f(n)$  с изменением  $n$ : насколько быстро растет эта функция. Данная нотация использует принцип «худшего случая». Стандартные функции используемые в  $O$  - нотации в зависимости от степени их роста:

- остоянные функции, которые с ростом  $n$  не изменяются,  $O(1)$ ;
- функции с логарифмической скоростью роста  $O(\log_2 n)$ ;
- функции с линейным ростом  $O(n)$ ;
- функции с линейно-логарифмической скоростью роста  $O(n \log_2 n)$ ;
- функции с квадратичной скоростью роста  $O(n^2)$ ;

- функции экспоненциальной скоростью роста  $O(2^n)$ ;
- функции с факториальной степенью роста  $O(n!)$ .

Стоит заметить, что сложность алгоритма по данной нотации не обязательно должна принадлежать одной из этих групп.

### III. СРАВНЕНИЕ СЛОЖНОСТИ ВЫПОЛНЕНИЯ АЛГОРИТМА

При выполнении алгоритма кластеризации на многоядерных процессорах появляется возможность сокращения временных затрат. Алгоритмы кластеризации получают в качестве входных данных  $n$  векторов, каждый размерностью  $m$ . Количество разбиений на кластеры предопределено в начале и равно  $k$ . Пусть  $t$  – количество итераций, необходимых для завершения кластеризации.

Сравнение временной сложности последовательного и параллельного выполнения алгоритмов может проводиться без учета сложности вычислений метрик расстояний и нахождения центров кластеров. Т.к. эти алгоритмы усложняют и параллельную, и последовательную реализацию одинаково.

При обработке больших объемов данных последовательно большую часть времени вычисляются расстояния между кластерами и их центры. Таким образом, последовательно делается  $n$  одинаковых операций, которые не затрагивают другие вектора. Обобщенная схема последовательной реализации алгоритма представлена на рисунке 1.



Рис. 1 – Последовательная реализация алгоритма кластеризации

Вычислительная сложность последовательного алгоритма кластеризации  $O(nmkt)$

Для организации распараллеливания необходимо выполнить за один такт сразу  $n$  операций вычисления центров кластеров, а затем столько же для вычисления расстояний. Обобщенный алгоритм параллельной кластеризации можно представить следующим образом:

1. Генерируется  $k$  объектов-центров классов.
2. Производится разбивка на кластеры, путем выяснения какой либо меры близости вектора с центром кластера. Для каждого вектора мера близости вычисляется отдельным процессом, параллельно с остальными.
3. Для каждого кластера выполняется поиск нового центра. Т.к. в каждом кластере данные не связаны с векторами из других кластеров, то и эту операцию можно выполнять одновременно для  $k$  разных кластеров.
4. Выполняется проверка, изменился ли центр класса. Если да, то выполняется переход к шагу 2. Если нет, то кластеризация завершена.

Обобщенная схема параллельной реализации алгоритма представлена на рисунке 2.

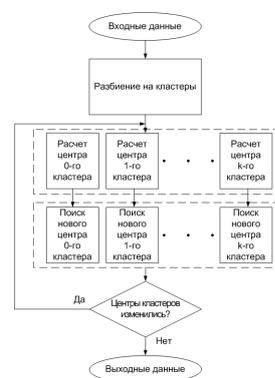


Рис. 2 – Параллельная реализация алгоритма кластеризации

Используя алгоритм нахождения частичной суммы элементов массива путем сдвигания временная сложность вышеприведенного алгоритма составит  $O(\log(nmkt))$ .

### ЗАКЛЮЧЕНИЕ

В ходе выполнения данной работы были получены следующие выводы:

- алгоритмы кластеризации могут быть распараллелены независимо от методов вычисления центров и расстояний.
- алгоритм можно выполнять параллельно, если есть минимум две операции с независимыми данными
- при увеличении количества векторов – производительность параллельных вычислений увеличится

1. Методы и модели анализа данных: OLAP и DataMining. / А. А. Барсегян [и др.]//Спб.: БХВ-Петербург/ –2004.
2. Крупский, В. Н Введение в сложность вычислений. / В. Н. Крупский//–М.: Факториал Пресс. –2006.
3. Arabie, P., Hubert, L. J. Clustering and Classification. / P. Arabie, L. J. Hubert, // Singapore: World Scientific/ –1996