

УДК 004.65

## СПОСОБЫ КЛАСТЕРИЗАЦИИ ДАННЫХ СРЕДСТАМИ СУБД

Наумов Р.К. (федеральное государственное автономное образовательное учреждение высшего образования Университет ИТМО)

**Научный руководитель – д.т.н., доцент Басов О.О.**

(федеральное государственное автономное образовательное учреждение высшего образования Университет ИТМО)

Одним из перспективных направлений развития реляционных СУБД является внедрение в них средств интеллектуального анализа данных. Одной из задач интеллектуального анализа является задача кластеризация. В работе описаны алгоритмы кластеризации данных, а также способы ее реализации внутри СУБД: кластеризация с помощью системы ATLAS, с помощью библиотеки MADlib и с помощью расширения языка SQL – добавления оператора CLUSTER BY.

**Введение.** На сегодняшний день, несмотря на растущую популярность NoSQL СУБД, реляционные СУБД занимают лидирующую позицию среди инструментов управления базами данных. Основным из направлений развития РСУБД является внедрение в них средств интеллектуального анализа данных. Интеллектуальный анализ данных ориентирован на извлечение знаний, необходимых для принятия решений в различных сферах человеческой деятельности. Интеграция позволяет как избежать накладных расходов по экспорту анализируемых данных из хранилища и импорту результатов анализа обратно в хранилище, так и использовать при анализе данных системные сервисы, заложенные в архитектуре СУБД. Одной из задач анализа данных является задача кластеризации. Задача кластеризации заключается в разбиении множества объектов сходной структуры на заранее неизвестные группы (кластеры) в зависимости от схожести свойств объектов. Кластеризация применяется в широком спектре приложений: сегментирование медицинских и спутниковых изображений, анализ ДНК-микрочипов и текстов и др.

**Основная часть.** Основным способом интеллектуального анализа данных в СУБД, в том числе решения задачи кластеризации, является разработка библиотеки хранимых процедур. Подключая библиотеку к своему приложению базы данных, прикладной программист получает возможность выполнять интеллектуальный анализ данных, не выходя за рамки СУБД.

Кластеризация данных в СУБД Oracle может производиться с помощью системы интеллектуального анализа данных ATLAS, которая поддерживает одноименный язык запросов, являющийся надстройкой над SQL. Язык ATLAS добавляет в SQL поддержку пользовательских функций и функций, возвращающих в качестве значения реляционную таблицу. На языке ATLAS реализованы алгоритм кластеризации DBSCAN, а также алгоритмы поиска шаблонов и классификации.

Одним из методов анализа данных в реляционных СУБД PostgreSQL и Greenplum является библиотека MADlib, с помощью которой можно произвести операцию кластеризации, классификации, регрессия и др. Работа с библиотекой не требует экспорта и импорта данных внешних аналитических приложений. В реализации MADlib используются пользовательские функции, написанные разработчиками на язык программирования Python, которые обеспечивают обращения к словарю базы данных и формирование корректной структуры таблиц с выходными данными для заданных таблиц с входными данными.

Также начинает набирать популярность способ кластеризации непосредственно самим языком работы с данными внутри СУБД – SQL. Так, например, для кластеризации данных предлагается расширить язык SQL оператором CLUSTER BY. Данная конструкция подразумевает выполнение группировки строк результата запроса в соответствии со специфицированным алгоритмом кластеризации, в отличие от стандартного оператора

GROUP BY, который осуществляет группировку по точному совпадению значений в полях записей. Такой подход задействует PostGIS - расширение СУБД PostgreSQL, обеспечивающее поддержку географических объектов.

**Выводы.** В работе предлагается производить несложные задачи анализа данных, такие как кластеризация данных, непосредственно в месте хранения данных, в СУБД. Таким образом, разработчик сможет не только избежать расходов по экспорту анализируемых данных из хранилища и импорту результатов анализа обратно в хранилище, но и воспользоваться вшитыми в архитектуру СУБД средствами. Были представлены различные способы кластеризации данных: с помощью хранимых процедур, библиотек, а также с помощью расширения (надстройки) языка SQL.