

## ИСПОЛЬЗОВАНИЕ MAPREDUCE И ПАРАЛЛЕЛЬНЫХ СУБД ДЛЯ ЗАДАЧ АНАЛИЗА ДАННЫХ

*Спихальский Дмитрий Станиславович*

*E-mail: dmitry@spikhalskiy.com*

*Кафедра системного программирования*

*Научный руководитель: д.т.н., профессор, г.л.н.с. ИСП РАН Кузнецов Сергей Дмитриевич*

Передовые методы управления бизнесом все чаще основываются на принятии решений на основе исторических данных, таким образом, у компаний возрастает интерес к системам, которые способны управлять данными, обрабатывать и анализировать их на разных уровнях детализации. В то же время, лавинообразно возрастает объем данных, который требуется сохранять и обрабатывать в системах аналитических баз данных. Причинами этому являются возрастание уровня автоматизации производства данных, увеличение числа датчиков и других устройств, генерирующих данные, переход на использование Web-технологий при взаимодействиях с заказчиками [1].

Для решения данных проблем, многие компании предлагают свои параллельные СУБД на архитектуре без совместно используемых ресурсов – наборе независимых машин с собственными локальными дисками и основной памятью, соединенных высокоскоростной сетью. Существует гипотеза, что такая архитектура масштабируется наилучшим образом, особенно если принимать во внимание стоимость аппаратных средств. Рабочие нагрузки анализа данных обычно содержат много крупных операций сканирования, многомерной агрегации и соединений со звездообразной схемой, которые сравнительно просто распараллеливаются по узлам сети без совместно используемых ресурсов [2].

С другой стороны, некоторые специалисты утверждают, что для выполнения анализа на сотнях и более узлов лучше всего подходят системы, основанные на парадигме MapReduce, поскольку они разрабатывались изначально в расчете на масштабирование до тысяч узлов в архитектуре без совместно используемых ресурсов [3]. Таким образом, сравнение и анализ применимости существующих подходов к хранению и обработке больших массивов данных является актуальной задачей, стоящей как перед разработчиками хранилищ данных, так и перед компаниями, специализирующимися на анализе данных.

В данной работе рассмотрены архитектуры различных аналитических хранилищ данных семейств параллельных СУБД и MapReduce. Для обеих парадигм оценивается сложность разработки и поддержки реализованных аналитических систем. В работе проведено экспериментальное исследование влияния характеристик и архитектурных особенностей хранилищ на производительность аналитических запросов в ситуациях вертикального и горизонтального масштабирования. Для решения данной задачи были разработаны наборы аналитических функций и тестовых данных, расши-

ряющие исследование работы «A Comparison of Approaches to Large-Scale Data Analysis» [4], проведены запуски на кластерах систем Hadoop&HDFS, Vertica, Greenplum, а также классической строковой базы данных. В качестве тестовой площадки использовался кластер из 100 рабочих станций, а также полносвязная сеть из 3 высокопроизводительных серверов. Практической значимостью обладают полученное в результате работы обоснованное объяснение различий в быстродействии систем хранения на разных объемах данных, задачах и размерах кластеров, а также описанные различия в областях применимости изученных систем.

### Литература

1. Abouzeid A., Bajda-Pawlikowski K., Abadi D., Silberschatz A., Rasin A. *HadoopDB: An Architectural Hybrid of MapReduce and DBMS Technologies for Analytical Workloads*. Proceedings of the 35th VLDB Conference, August 24-28, 2009, Lyon, France.
2. Lammel R. *Google's MapReduce programming model — Revisited*. Science of Computer Programming, 2007, Volume 68, Issue 3, pp. 108-137.
3. Dean J., Ghemawat S. *MapReduce: Simplified Data Processing on Large Clusters*. Communications of the ACM – 50th anniversary issue: 1958 – 2008, 2008, Volume 51, Issue 1, pp. 107-113.
4. Pavlo A., Paulson E., Rasin A., Daniel J., Abadi D., D.J. DeWitt, Madden S., Stonebraker M. *A Comparison of Approaches to Large-Scale Data Analysis*. Proceedings of the 35th SIGMOD International Conference on Management of Data, 2009, pp. 165-178.