Интеграция параллелизма в свободную СУБД PostgreSQL[1]

Пан К.С., Цымблер М.Л.

Введение

В настоящее время свободно распространяемая на уровне исходных кодов СУБД PostgreSQL [1] представляет собой надежную альтернативу коммерческим СУБД [2]. Научным сообществом в области технологий баз данных ведутся интенсивные исследования, целью которых является расширение и улучшение СУБД PostgreSQL [3–6]. Нами предлагается модификация PostgreSQL для обеспечения параллельной обработки запросов. Предлагаемая параллельная СУБД названа PargreSQL. В данной работе рассматриваются архитектура PargreSQL, реализация ее основных подсистем и вычислительные эксперименты.

1. Архитектура СУБД PargreSQL

PargreSQL использует идею фрагментного параллелизма [7]. Каждое отношение (таблица) базы данных делится на горизонтальные *фрагменты*, распределяемые по процессорным узлам вычислительной системы. Способ фрагментации определяется *функцией фрагментации*, вычисляющей для каждого кортежа отношения номер процессорного узла, на котором должен быть размещен этот кортеж. Запрос выполняется в виде нескольких параллельных процессов, каждый из которых обрабатывает отдельный фрагмент отношения. Полученные фрагменты сливаются в результирующее отношение.

Архитектура клиент-серверного взаимодействия в PargreSQL предполагает, что клиент соединяется с двумя и более серверами одновременно (см. Рис. 1). Сценарий взаимодействия клиента и серверов кратко может быть описан следующим образом.

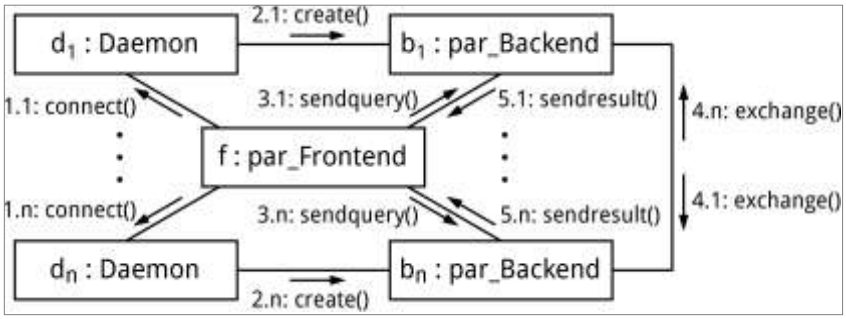

Рис. 1. Клиент-серверная модель PargreSQL

На шаге 1 клиентское приложение (par_Frontend) соединяется со всеми экземплярами СУБД, запущенными на узлах вычислительной системы. Затем, на шаге 2, демоны (Daemon) принимают соединения и создают для них обработчики (par_Backend), по одному на каждом вычислительном узле для каждого входящего соединения. На шаге 3 приложение отправляет запрос всем обработчикам. Шаг 4 заключается в обменах кортежами между экземплярами СУБД, которые необходимы для получения правильного результата. На шаге 5 приложение агрегирует результаты от всех экземпляров СУБД.

[1] Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проект 09-07-00241-а) и Минобрнауки РФ (государственный контракт № 07.514.11.4036).

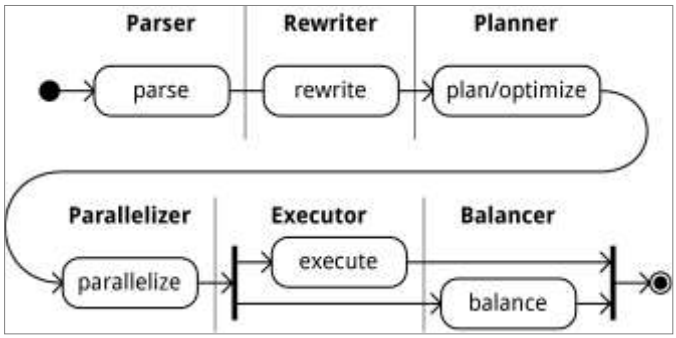

Рис. 2. Этапы обработки запроса

На Рис. 2 показаны этапы обработки запроса обработчиком par_Backend. На этапе **parallelize** предлагаемая нами подсистема *параллелизации запросов* превращает обычный план выполнения запроса в параллельный путем вставки специального оператора **exchange** в нужные места дерева плана запроса.

Структура СУБД PargreSQL изображена на Рис. 3.

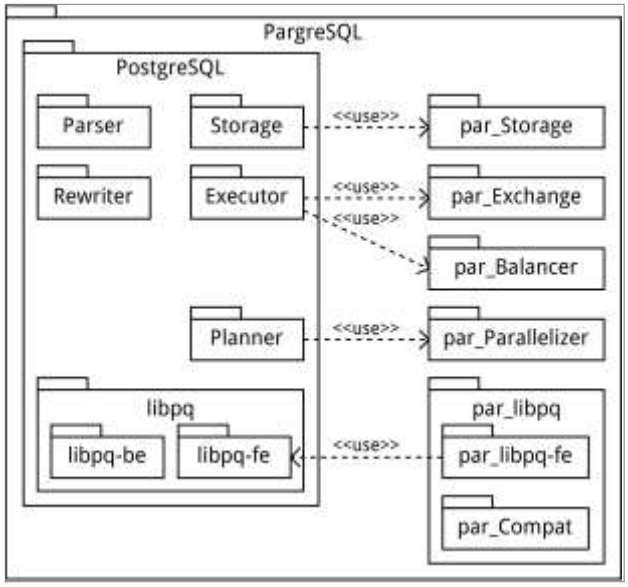

Рис. 3. Структура PargreSQL

Подсистема исполнения запросов Executor дополняется новым модулем, который реализует оператор обмена **exchange**. Подсистема хранения метаданных Storage расширяется для хранения данных о фрагментации отношений. Планировщик Planner дополняется параллелизатором Parallelizer. Пользовательская библиотека libpq дополняется оберткой par_libpq, тиражирующей запросы.

Подсистема *тиражирования запросов* служит для реализации шагов 1, 3 и 5 (см. Рис. 1). Другая подсистема — *оператор exchange* — реализует шаг 4. *Параллелизатор плана запроса* осуществляет модификацию плана, генерируемого планировщиком. Далее рассмотрены особенности реализации новых подсистем.

2. Тиражирование запросов

Приложения PostgreSQL используют библиотеку libpq-fe для доступа к СУБД. Данная библиотека реализует следующие основные функции: установление соединения с демоном, отправка запросов, получение результатов, проверка статуса выполнения запроса и др. Приложение PargreSQL подключает библиотеку-обертку par_libpq-fe, ко-

торая обладает аналогичным интерфейсом (см. Табл. 1), но реализует его путем многократного вызова соответствующих функций оригинальной библиотеки libpq-fe.

Табл. 1. Изменения в интерфейсе прикладной библиотеки libpq

Библиотека libpq-fe	**Библиотека par_libpq-fe**

`struct PGconn {`
`  ...`
`}`
 	
Хранит данные о соединении с сервером.
	`struct par_PGconn {`
	`  int len;`
	`  struct PGconn *conns;`
	`}`
	Хранит данные о соединениях с узлами PargreSQL. Является контейнером, содержащим массив структур PGconn.

`PGconn *PQconnectdb(`
`  const char *conninfo`
`)`
 	
Устанавливает соединение с сервером, указанным в conninfo.
	`par_PGconn *par_PQconnectdb() {`
	`  for (...) {`
	`  PQconnectdb(...);`
	`  }`
	`}`
	Устанавливает соединение с узлами, указанными в конфигурационном файле PargreSQL.

...	...

Таким образом, приложение устанавливает соединение сразу с несколькими узлами и отправляет каждому один и тот же запрос, после чего агрегирует результаты. Переход к новой библиотеке осуществляется прозрачно для приложения с помощью набора макросов, заменяющих вызовы функций оригинального интерфейса на вызовы соответствующих функций нового интерфейса.

3. Оператор exchange

Оператор **exchange** [8] служит для обмена кортежами между экземплярами параллельной СУБД PargreSQL. Он вставляется в план запроса подсистемой Parallelizer. Для каждого оператора **exchange** задан его уникальный номер в плане запроса, а также *функция обмена* ψ, вычисляющая для каждого кортежа номер процессорного узла, на который нужно передать данный кортеж. Таким образом, оператор **exchange** связан со всеми операторами **exchange**, находящимися в том же самом месте плана запроса на других процессорных узлах.

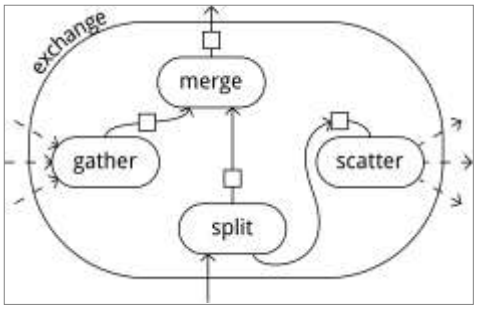

Рис. 4. Архитектура оператора **exchange**

Архитектура оператора **exchange** представлена на Рис. 4. Он состоит из четырех узлов: Merge, Split, Scatter и Gather. Данные узлы реализованы в соответствии с итераторной моделью, используемой в PostgreSQL.

Узел Split вычисляет функцию обмена для каждого поступающего кортежа и передает «свои» кортежи выше по плану (узлу Merge), а «чужие» — узлу Scatter, для дальнейшей отправки на нужный процессорный узел. Узел Scatter вычисляет функцию

обмена для каждого поступающего кортежа и отправляет их на процессорные узлы с соответствующим номером. Узел Gather выполняет получение кортежей от всех остальных процессорных узлов. Узел Merge осуществляет слияние кортежей, поступающих от узлов Gather и Split. Кортежи, возвращаемые узлом Merge являются результатом оператора **exchange**. Таким образом, оператор **exchange**, вставленный в план, перераспределяет кортежи в соответствии с функцией обмена ψ.

4. Распараллеливание плана запроса

Параллелизатор плана запроса выполняет вставку операторов обмена в последовательный план запроса, тем самым превращая план в параллельный. Операторы обмена вставляются между узлом Join (операция соединения отношений по общему атрибуту) и его поддеревьями и обеспечивают фрагментацию отношений, участвующих в соединении, по атрибуту соединения.

Оптимизатор запросов PostgreSQL поддерживает три способа реализации операции соединения: HashJoin (соединение хешированием), MergeJoin (соединение слиянием) и NestedLoop (соединение вложенными циклами). Вставка оператора **exchange** для каждого способа выполняется различным образом (см. Рис. 7).

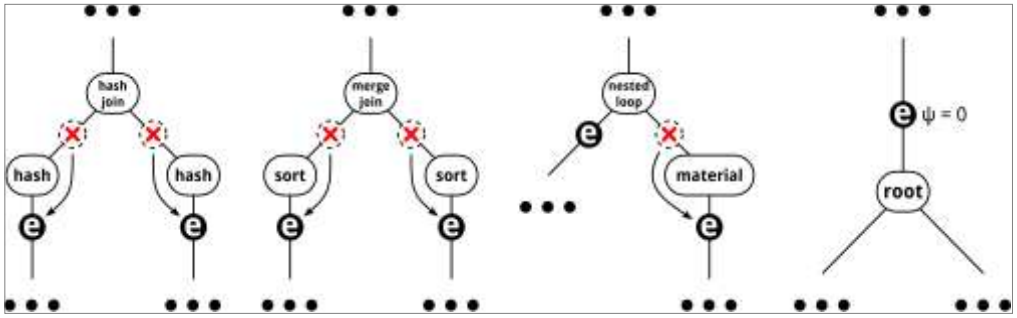

Рис. 7. Особые случаи при вставке оператора **exchange**

Если перед вставкой оператора обмена параллелизатор обнаруживает, что сыном **exchange** может оказаться узел Hash, Sort или Materialize, то оператор **exchange** вставляется на уровень глубже. В противном случае обмены кортежами приведут к несогласованности данных фрагмента и неверному результату запроса.

Особым случаем является вставка оператора **exchange** корень плана. В корень вставляется оператор **exchange** с функцией обмена, тождественно равной нулю. Такая функция позволяет собрать результирующее отношение на одном вычислительном узле (с номером 0).

5. Хранение метаданных о фрагментации

Для корректной работы параллелизатора требуются метаданные о фрагментации. Хранение и управление ими реализовано с помощью существующего в PostgreSQL механизма Relation Options. Словарь данных PostgreSQL содержит атрибут pg_class, где содержатся метаданные о хранении отношений в виде строки пар «ключ=значение», перечисленных через запятую.

6. Эксперименты

Над разработанной параллельной СУБД были поставлены эксперименты с использованием следующего запроса.

```
select * from t1 join t2 on t1.b = t2.a
where t1.a % 10007 = 0;
```

Таблица **t1** состоит из 10^8 кортежей, таблица **t2** — из 10^7 кортежей. Общий объем данных в таком случае приблизительно равен 2 ГБ. Обе таблицы фрагментированы по атрибуту **a**. Таким образом, возникают обмены кортежами таблицы **t1**, поскольку в условии соединения фигурирует атрибут **t1.b**, а таблица фрагментирована по атрибуту **t1.a**.

Эксперименты проводились на узлах суперкомпьютера «СКИФ Урал» [9] в Юж-

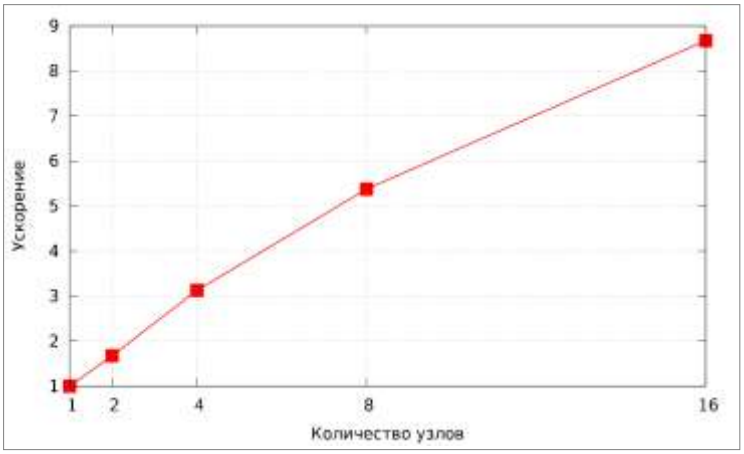

но-Уральском государственном университете.

Рис. 8. Результаты экспериментов

Результаты изображены на Рис. 8 в виде графика ускорения относительно оригинальной версии СУБД PostgreSQL.

Заключение

В данной работе представлена архитектура параллельной СУБД PargreSQL, реализация ее основных подсистем и результаты экспериментов. Разработанная система демонстрирует ускорение, близкое к линейному.

Дальнейшие исследования могут быть направлены на решение задачи балансировки загрузки, реализацию транзакций, вставки и обновления данных, а также обеспечение надежности системы на больших масштабах.

Литература

1. M. Stonebraker, G. Kemnitz. The Postgres Next Generation Database Management System // Commun. ACM. 1991. Vol. 34, no. 10. Pp. 78–92.
2. L.D. Paulson. Open Source Databases Move into the Marketplace // IEEE Computer. Vol. 37. Issue. 7. Pp. 13–15. 2004.
3. N. Samokhvalov. XML Support in PostgreSQL // SYRCoDIS, volume 256 of CEUR Workshop Proceedings. 2007.
4. Y. Havinga, W. Dijkstra, A. de Keijzer. Adding HL7 version 3 data types to PostgreSQL // CoRR, abs/1003.3370, 2010.
5. D. Guliato, E.V. de Melo, R.M. Rangayyan, R.C. Soares. POSTGRESQL-IE: An Image-handling Extension for PostgreSQL // Journal of Digital Imaging, 22(2):149–165. 2009.
6. D.V. Levshin, A.S. Markov. Algorithms for integrating PostgreSQL with the semantic web // Programming and Computer Software, 35(3):136–144. 2009.
7. D.J. DeWitt, J. Gray. Parallel Database Systems: The Future of High Performance Database Systems // Commun. ACM. 1992. Vol. 35, no. 6. Pp. 85–98.

8. Л.Б. Соколинский. Организация параллельного выполнения запросов в многопроцессорной машине баз данных с иерархической архитектурой // Программирование. 2001. No. 6. С. 13–29.
9. Вычислительный кластер «СКИФ Урал». URL: http://supercomputer.susu.ru/computers/skif_ural/