Уменьшение фрагментации ресурсов при честном планировании на распределенных вычислительных кластерах

Тонких Андрей Александрович

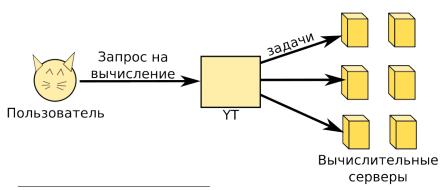
Руководитель: Игнатий Игоревич Колесниченко

ниу вшэ спб

7 июня 2019 г.

MapReduce

Работа выполнялась в рамках MapReduce-системы YT^1 .



¹YT: зачем Яндексу своя MapReduce-система и как она устроена — https://habr.com/ru/company/yandex/blog/311104

Планировщик

Планировщик выбирает, какие задачи на каких вычислительных серверах запускать.

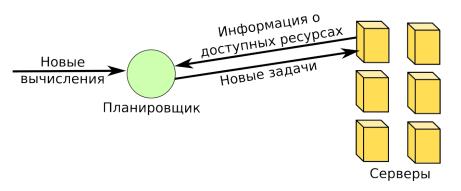


Рис.: Устройство планировщика ҮТ

Честное планирование

- В основе алгоритма планирования YT лежит понятие Dominant Resource Fairness² (DRF), а точнее его обобщение для иерархий пользователей – HDRF³.
- Честный алгоритм обладает рядом важных свойств. Например, устойчивость к обману и стимул делиться.

²Ali Ghodsi, Matei Zaharia, Benjamin Hindman, Andy Konwinski, Scott Shenker, and Ion Stoica. Dominant Resource Fairness: Fair Allocation of Multiple Resource Types. In Nsdi, 2011.

³Arka A. Bhattacharya, David Culler, Eric Friedman, Ali Ghodsi, Scott Shenker, and Ion Stoica. Hierarchical Scheduling for Diverse Datacenter Workloads. In SoCC'13, 2013.

Фрагментация

Фрагментация может приводить к низкой утилизации ресурсов кластера.

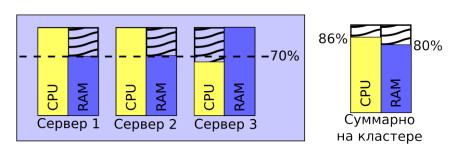


Рис.: Пример фрагментированного кластера из 3 серверов

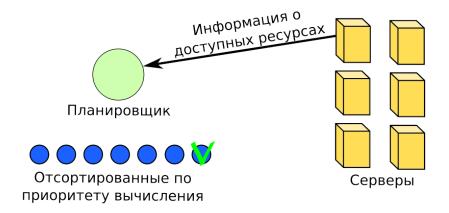
Tetris

Tetris 5 – планировщик, разработанный в Microsoft, одной из задач которого являлась эффективная упаковка задач.

⁵Grandl, R., Ananthanarayanan, G., Kandula, S., Rao, S., & Akella, A. (2015). Multi-resource packing for cluster schedulers. ACM SIGCOMM Computer Communication Review, 44(4), 455-466.

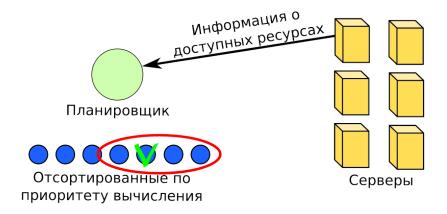
Архитектура Tetris

Честный планировщик:



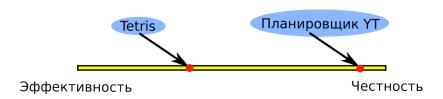
Архитектура Tetris

Tetris:



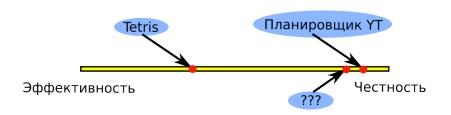
Честность Tetris

- Авторы Tetris сознательно жертвуют большинством гарантий честного алгоритма.
- Существует trade-off между честностью и эффективностью планирования. Задачей Tetris было предоставить более эффективное и менее честное решение.



Цель

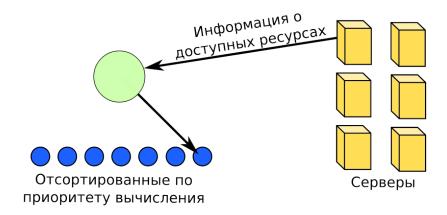
Разработать новый более гибкий подход к борьбе с фрагментацией ресурсов.

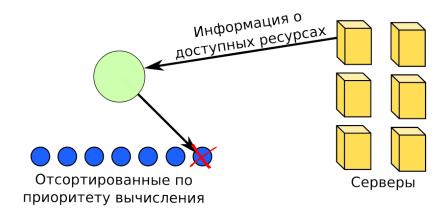


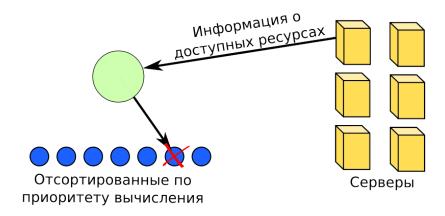
Задачи

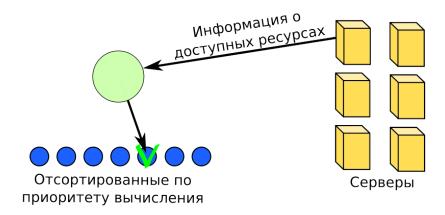
Задачи:

- Разработать архитектуру.
- Разработать алгоритм в рамках выбранной архитектуры.
- Реализовать прототип.
- Провести эксперименты.









Контроллер вычисления

Алгоритм принятия решений контроллером вычисления:

- Посмотрим на вектор предлагаемых ресурсов как на случайную величину.
- Предполагается, что распределение предлагаемых ресурсов имеет длинные промежутки стабильности.
- Контроллер смотрит на последние n=15 предложений как на выборку из случайной величины и отказывается от аллокации, если задачи данного вычисления относительно плохо упаковываются на данный сервер.
- Качество упаковки оценивается при помощи эвристической функции $H:(server_resources, task_resources) o double.$

Анализ

- Каждый контроллер вычислений может иметь свою собственную стратегию принятия решений, что делает данный подход крайне гибким и хорошо настраиваемым.
- Аллокация сходится к честной при некоторых предположениях, которые выполняется на больших кластерах, разделяемых между многими пользователями.

Результаты экспериментов

Прототип алгоритма упаковки был реализован в планировщике YT и протестирован на кластере из 73 серверов.

	Без упаковки	С упаковкой
Утилизация CPU	92.2%	96.7% (+3.5%)
Утилизация RAM	91.5%	96.4% (+4.9%)

Результаты экспериментов.

Выводы

- Был предложен новый гибкий подход для борьбы с фрагментацией при честном планировании задач.
- Анализ решения показал, что аллокация сходится к честной.
- Реализован прототип в рамках MapReduce-системы YT.
- Эксперименты показали, что предложенный подход может значительно увеличивать утилизацию.

Направления для развития

- Разработать и протестировать алгоритм для контроллера с лучшей или регулируемой сходимостью.
- Использовать машинное обучение для принятия решений на контроллере.