Проблемы масштабируемости Openstack Keystone

и методы их решения

Борисенко О.Д.,

В рамках проекта РФФИ 15-29-07111 офи_м

ИСП РАН

Облачные среды

Облачная среда — инфраструктура, предназначенная для предоставления вычислительных мощностей по запросу в виде услуги.

Основные модели предоставления услуг:

- Инфраструктура как услуга (IaaS)
- Платформа как услуга (PaaS)
- Программное обеспечение как услуга (SaaS)
- Бессерверные вычисления (serverless computing)

Некоторые возможности облачных сред

- Выделение виртуальных машин с заданными характеристиками по запросу
- Построение виртуальных сетевых инфраструктур
- Виртуализация блочного хранения
- Предоставление объектного хранения с поддержкой метаданных
- Встроенные системы оркестрации ресурсов
- Предоставление заранее настроенного ПО в качестве услуги по запросу пользователя

Разумеется, возможностей гораздо больше.

Все операции с облаком предоставляются, как правило, при помощи API, основанных на HTTP-протоколе (обычно REST API)

Amazon

Компания Amazon предоставляет самый полный набор решений на основе облачных технологий.

Остальные облачные среды пытаются догнать лидера.

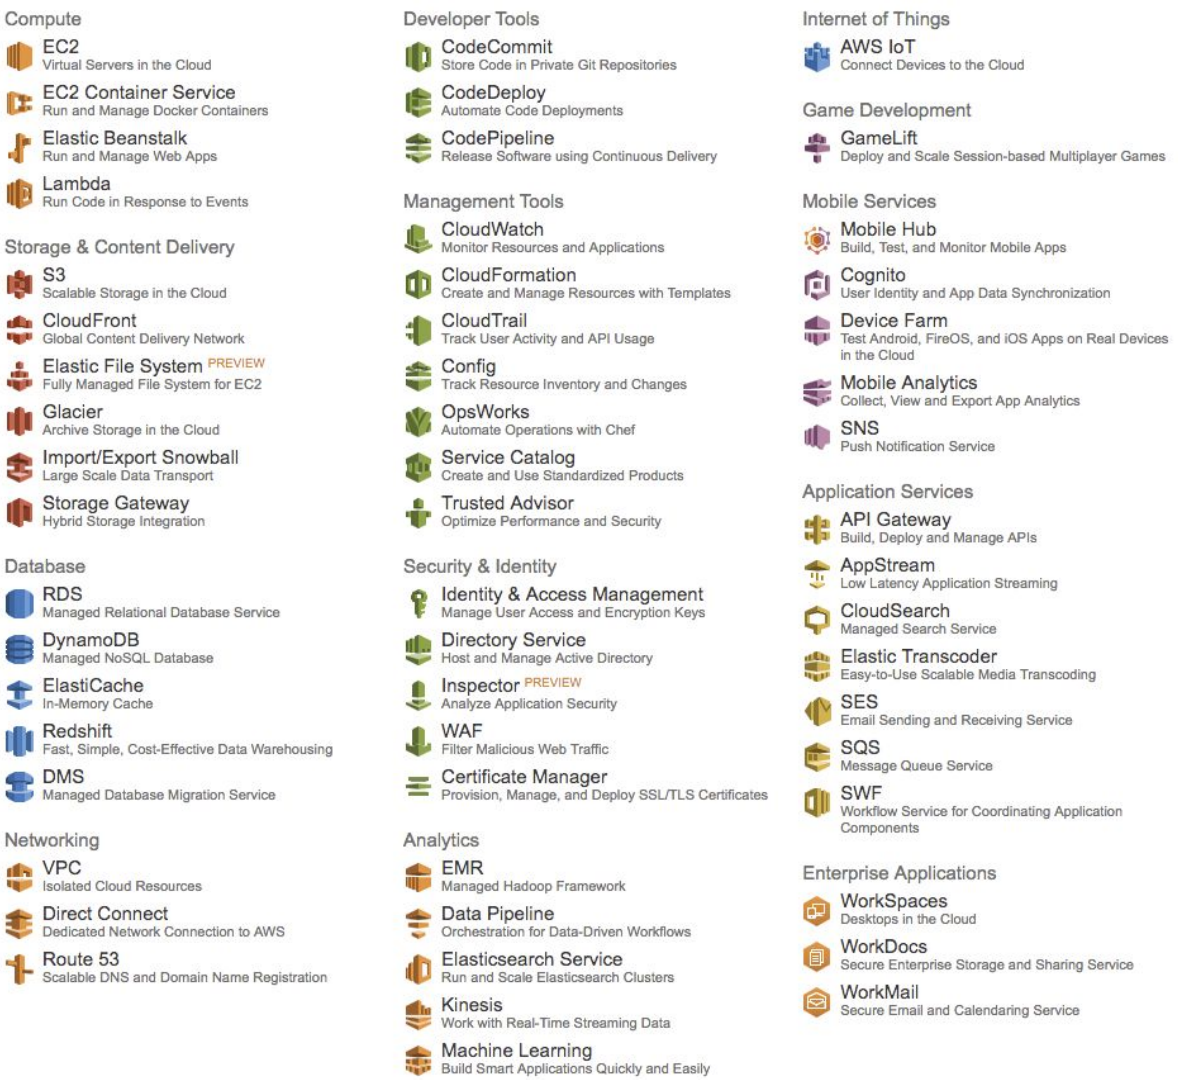

Базовые компоненты Openstack

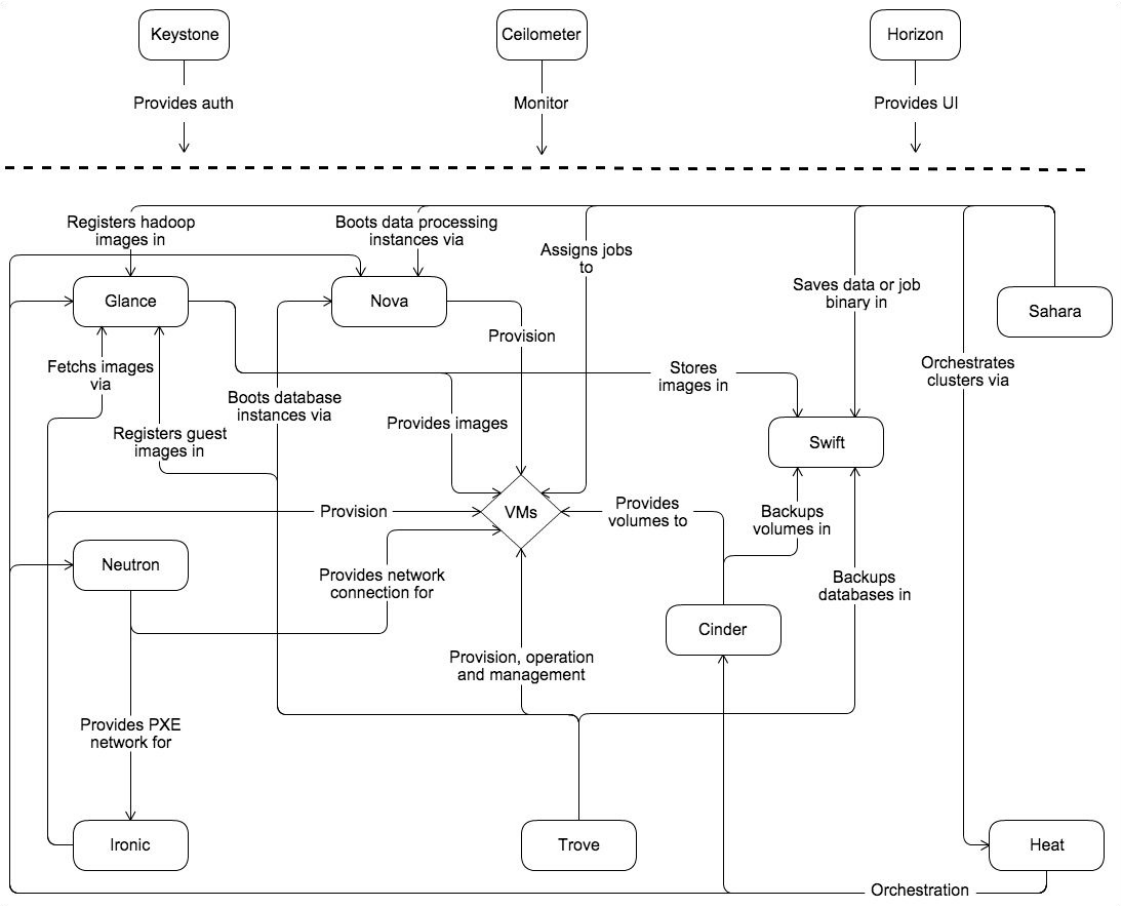

Openstack состоит из т.н. “проектов”. Основные из них:

- Keystone
- Nova
- Horizon
- Neutron
- Cinder
- Glance
- Swift
- Heat
- Sahara
- Ceilometer

Минимальный необходимый набор — Keystone, Glance и Nova.

Openstack, полная архитектура

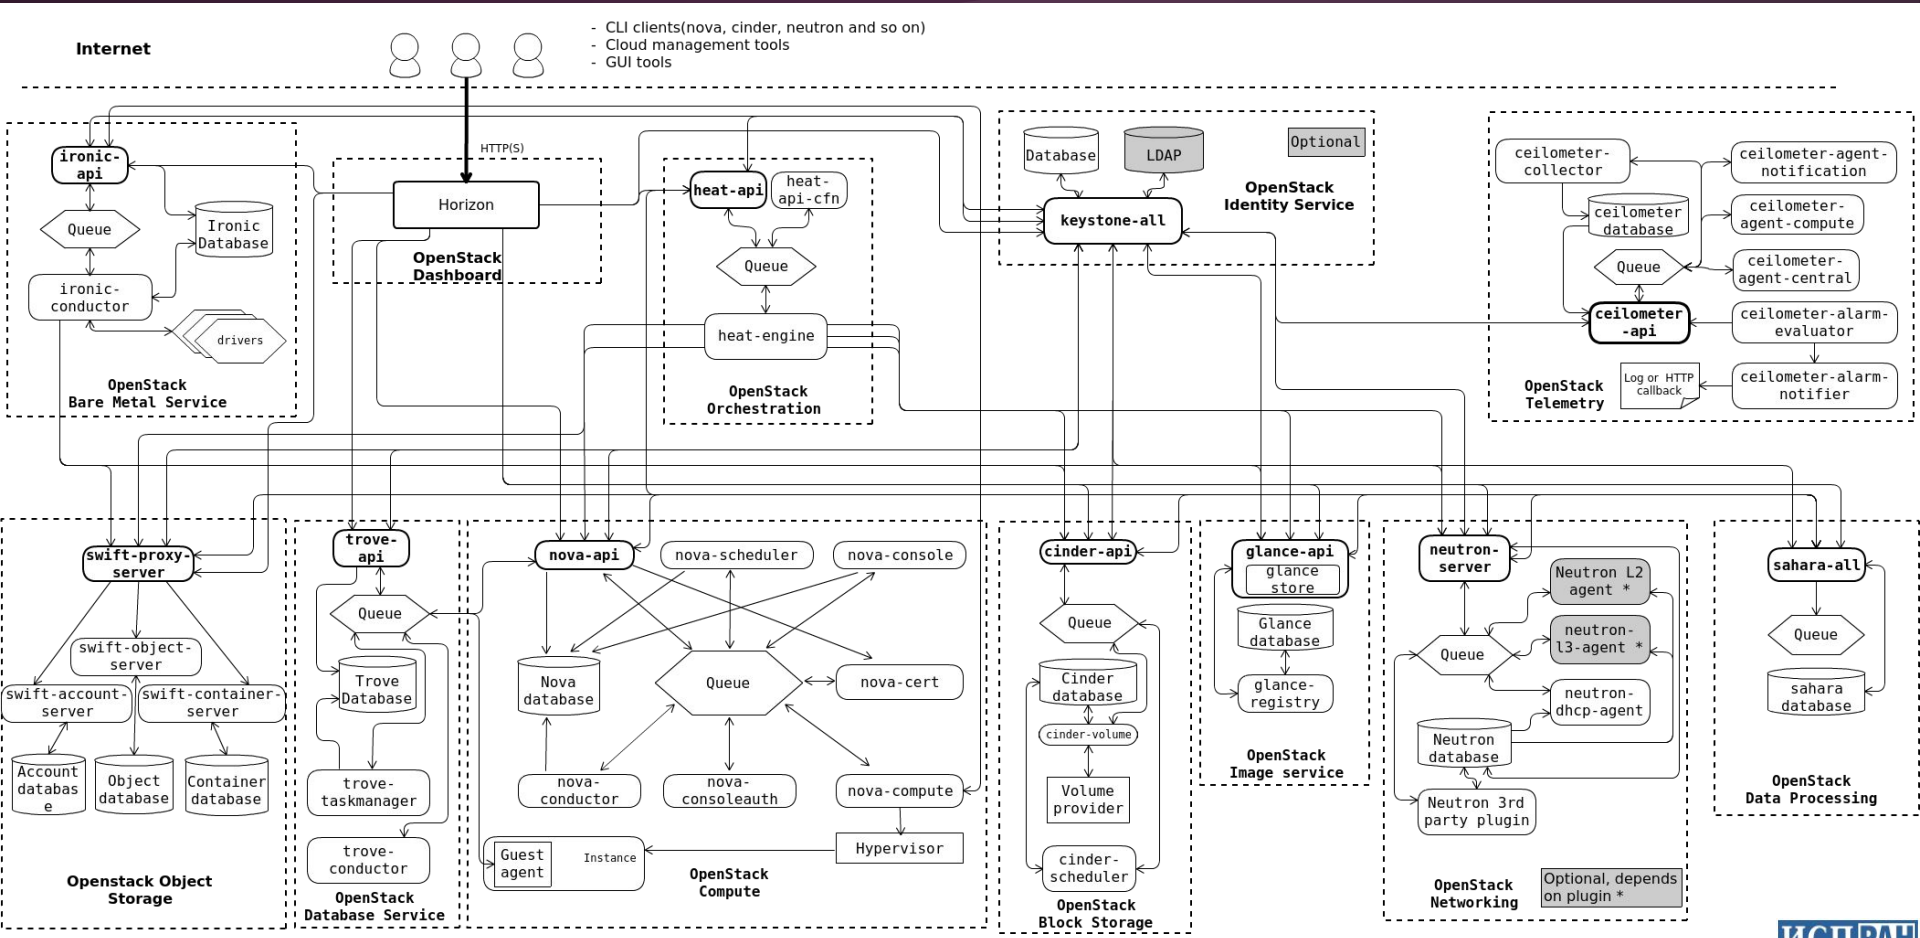

ИСП РАН

Облако ИСП РАН

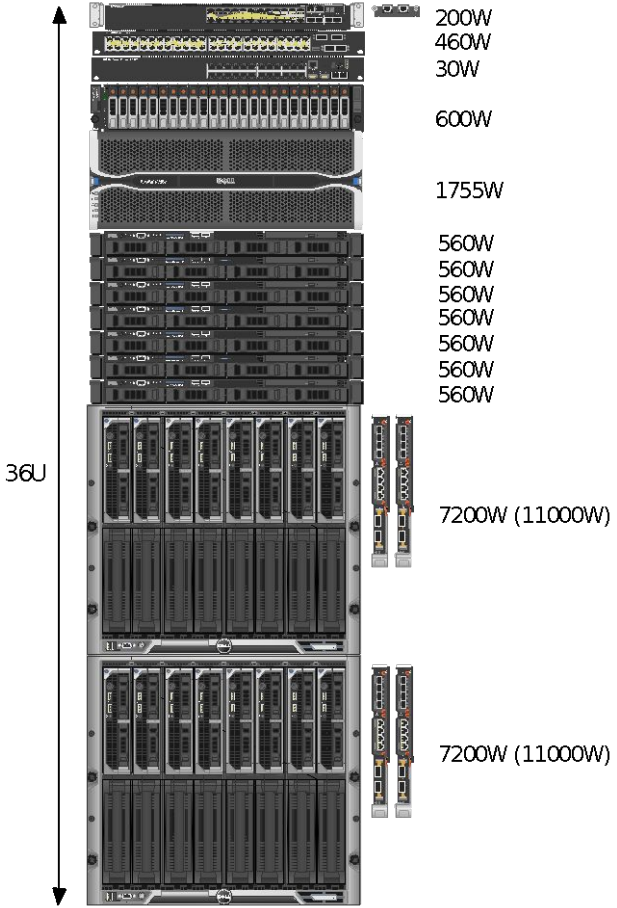

Характеристики (без контроллеров):

- Openstack Liberty из исходных кодов
- 3968GB RAM без учета overcommit
- 256 ядер (512 с учетом HT)
- 28.5TB локальных для виртуальных машин дисков
- >130TB нелокального хранения с пропускной способностью 10Гбит/с
- Полная связность 20Гбит/с
- Канал на вход/выход 1Гбит/с, но будет 10Гбит/с к декабрю
- 240 IPv4 внешних адресов
- 1000 внутренних адресов в сети ИСП

Масштабируемость - обман!

Openstack страдает от проблем масштабируемости, как по количеству физических узлов системы, так и по количеству активных пользователей.

Это касается именно открытой части кодовой базы: коммерческие компании, утверждающие, что предоставляют доступ к облачным услугам на основе Openstack, в реальности используют собственные закрытые решения с тем же набором API

Уязвимые сервисы в Openstack

Мы достоверно знаем о трех:

- Keystone — сервис центральной идентификации и аутентификации пользователей и сервисов
- Nova-conductor — внутренний сервис обмена данными в сервисе виртуализации (Nova)
- Oslo.messaging — набор библиотек, обеспечивающих гарантированную доставку сообщений в системе

Проблема сервисов аутентификации и авторизации

На момент начала 2016 года не существовало ни одного известного облака более чем на **200** физических узлов* на открытой кодовой базе Openstack

*по информации разработчиков основной ветки Openstack

Сервисы центральной идентификации и авторизации, слои

Все подобные сервисы построены по общему принципу:

- Слой внутренней маршрутизации запросов
  - Отвечает за работу сервиса через протокол HTTP.
- Слой промежуточного ПО (middleware)
  - На этом слое происходит вся логическая обработка запросов.
- Слой персистентного хранения
  - Отвечает за связь с СУБД и передачу запросов к базе данных.

Функциональность Openstack Keystone

- Проверка учетных данных пользователей системы
- Осуществление мультиарендности для разных групп пользователей системы
- Проверка прав пользователей
- Проверка принадлежности других сервисов облачной среды к данному облаку (защита от подмены)
- Выдача токенов авторизации
- Каталог сервисов системы

Keystone

Openstack Keystone реализован на языке Python в соответствии со стандартом WSGI и с использованием ORM SQLAlchemy для коммуникаций с СУБД.

Несмотря на универсальность стандарта WSGI и поддержку множества СУБД данной ORM, количество поддерживаемых вариантов развертывания системы ограничено.

Варианты развертывания Keystone

- Маршрутизация запросов:
  - Apache2 + mod_wsgi
  - uWSGI + Nginx
- Промежуточное ПО:
  - CPython
- СУБД
  - MariaDB/MySQL
  - PostgreSQL
- Слой кэширования
  - Dogpile
  - memcached

Выявление деградации

Нами был реализован набор утилит:

- автоматизирующих развертывание Keystone во всех возможных конфигурациях,
- автоматизирующих процесс тестирования (при помощи Openstack Rally)
- собирающих информацию о проведенных тестах и выявляющих замедление системы при возрастании нагрузки

Также тестировался бэкенд системы хранения:
данные, хранящиеся в СУБД, попадали на обычный SATA HDD, на RAID-0 из 3 SSD или в tmpfs в зависимости от сценария

Метод тестирования

Цели тестирования:

1. Нахождение такого числа запросов в секунду (RPS) к Keystone, при котором время задержки (latency) ответа на запрос начинает линейно или быстрее возрастать в течение фиксированного временного окна.
2. Поиск причин роста времени задержки ответов.

Тестирование проводилось как в режиме единственного узла Keystone, так и в High Availibility варианте развертывания, рекомендованном разработчиками.

В качестве сценария тестирования выбраны наиболее естественные операции: выдача токена и валидация токена.

Разница между вариантами развертывания

Были протестированы все комбинации вариантов развертывания каждого из слоев системы, включая бэкенд хранения (HDD/SSD/tmpfs).

Разница между результатами в разных вариантах не существенна в пределах одного бэкенда хранения.

Тем не менее, приведем некоторые из них.

Примеры нормальной работы системы

Total durations

Action	Min (sec)	Median (sec)	90%ile (sec)	95%ile (sec)	Max (sec)	Avg (sec)	Success	Count
total	0.031	0.059	0.079	0.086	0.16	0.061	100.0%	53640

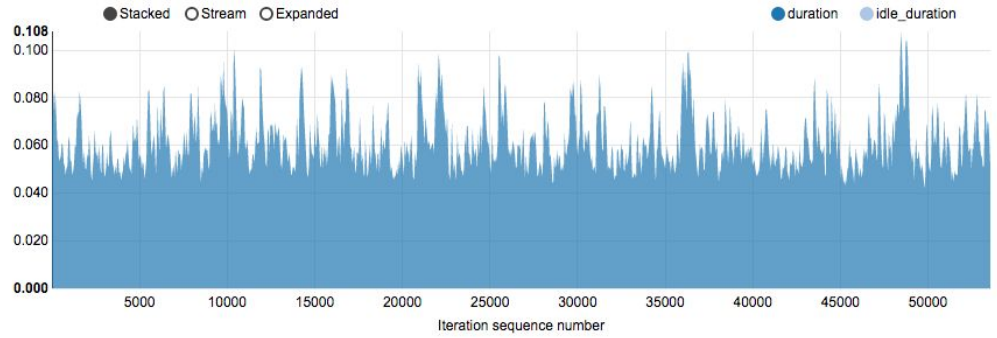

Total durations

Action	Min (sec)	Median (sec)	90%ile (sec)	95%ile (sec)	Max (sec)	Avg (sec)	Success	Count
total	0.031	0.042	0.045	0.046	0.181	0.043	100.0%	54000

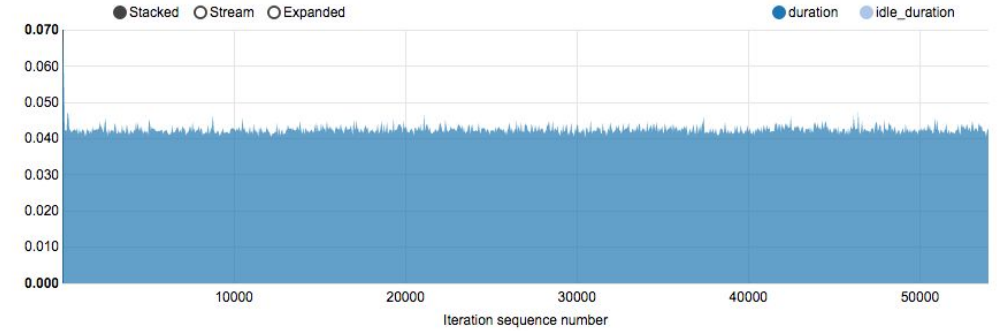

ИСП РАН

Примеры деградации производительности

Total durations

Action	Min (sec)	Median (sec)	90%ile (sec)	95%ile (sec)	Max (sec)	Avg (sec)	Success	Count
total	0.036	0.503	1.01	1.032	1.23	0.546	100.0%	63000

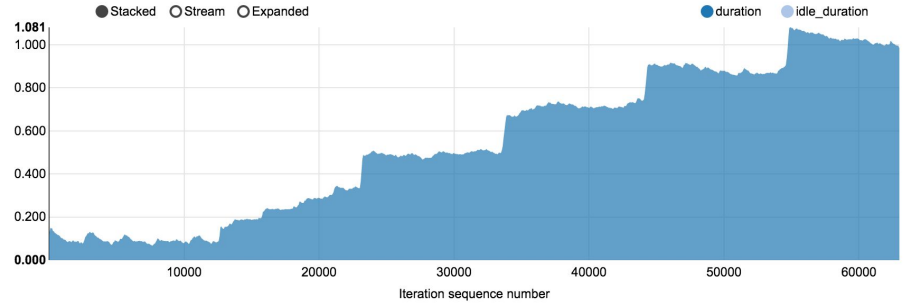

Total durations

Action	Min (sec)	Median (sec)	90%ile (sec)	95%ile (sec)	Max (sec)	Avg (sec)	Success	Count
total	0.033	0.138	1.092	1.115	1.262	0.39	100.0%	54720

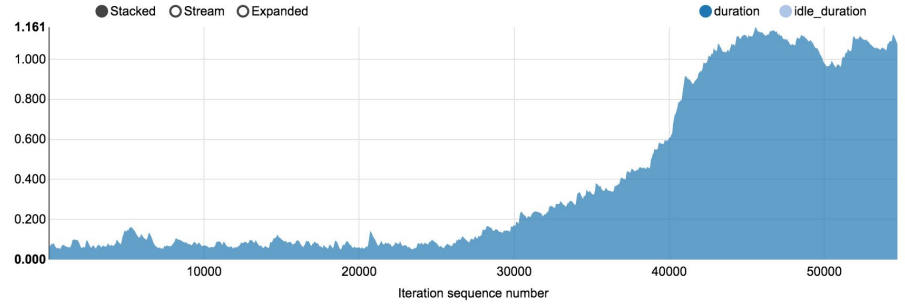

Total durations

Action	Min (sec)	Median (sec)	90%ile (sec)	95%ile (sec)	Max (sec)	Avg (sec)	Success	Count
total	0.046	2.116	4.076	4.262	4.456	2.194	100.0%	64800

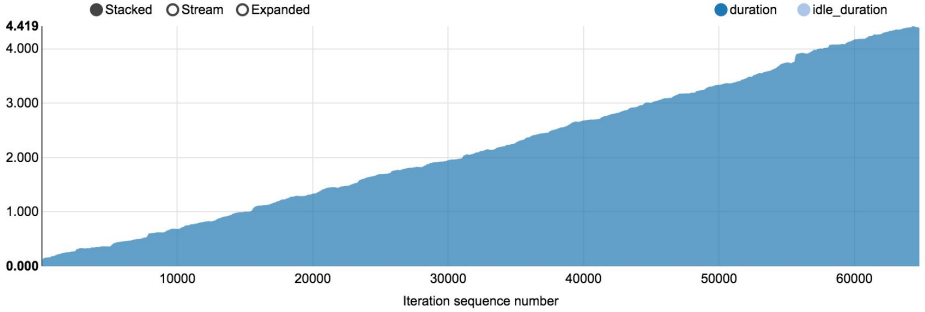

ИСП РАН

Результаты для одного узла Keystone

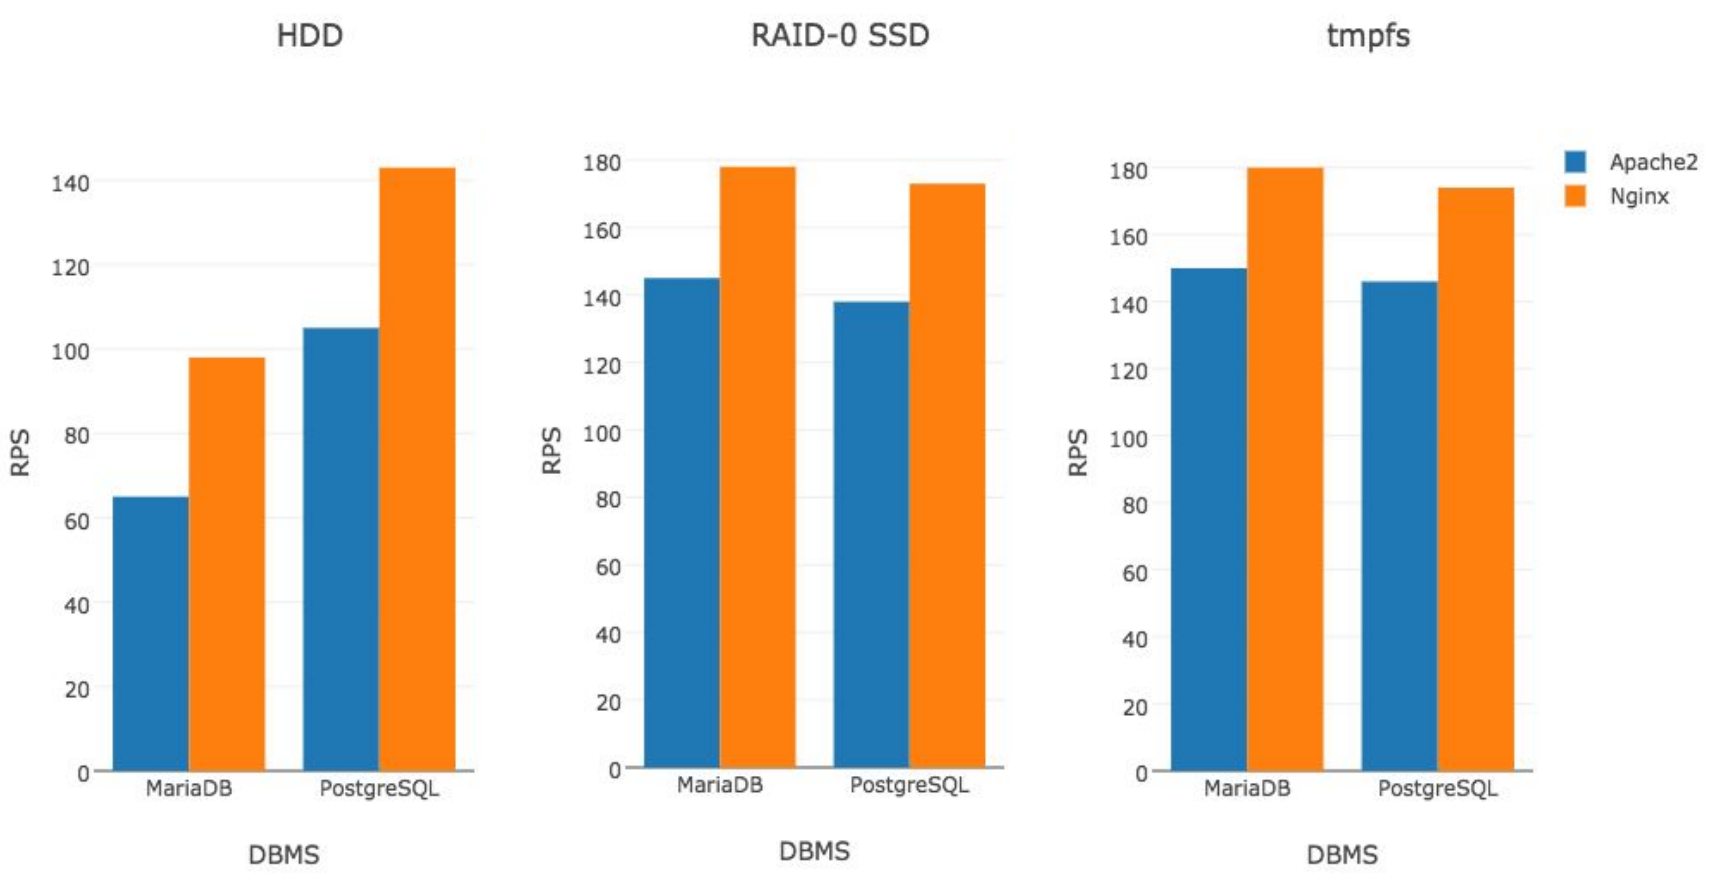

Граф вызовов и профилирование

Перед тестированием HA-варианта, мы решили проанализировать поведение программного кода.

Мы реализовали утилиту, которая накладывает результаты профилирования системы при разных RPS на граф вызовов и при помощи специальной эвристики фильтрует узлы этого графа по набору параметров.

Изначальное число узлов в графе вызовов для основного сценария тестирования — 1172

Уменьшенный и отфильтрованный граф вызовов

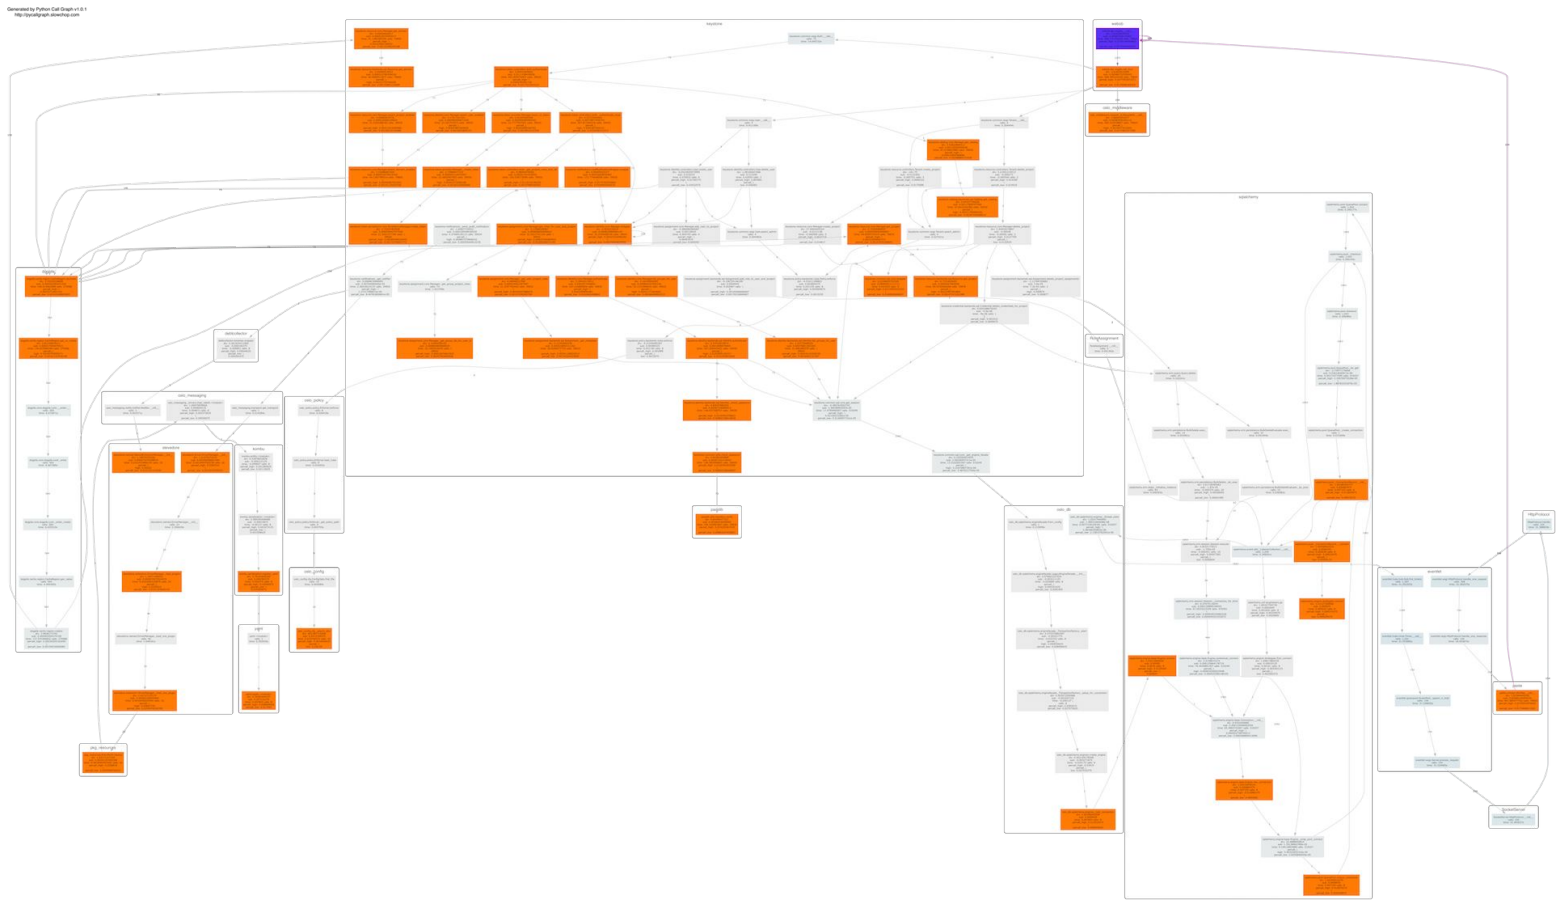

Шифрование!

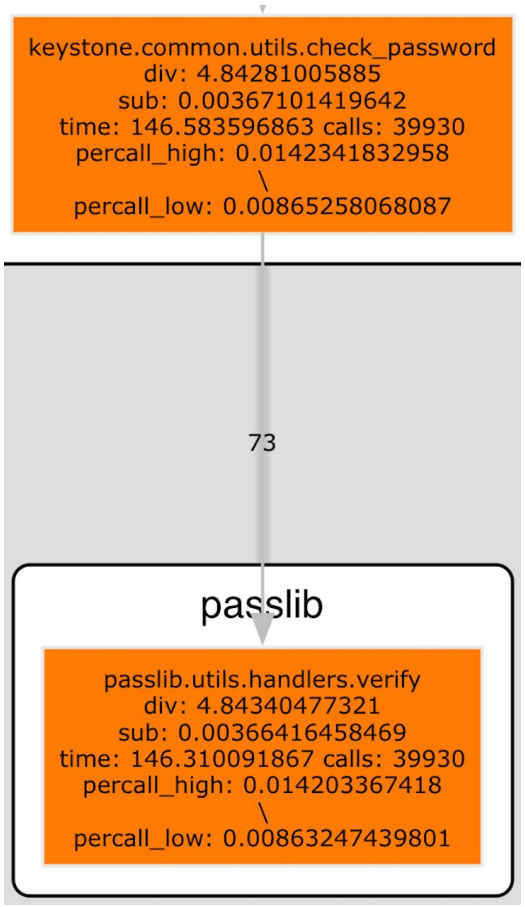

После изучениях всех “интересных” узлов графа, стало ясно, что в варианте развертывания Keystone на одном узле главная проблема — проверка пароля.

Пароль хэшируется при помощи SHA-512 с использованием 10000 раундов.

Центральная SQL база

В то же самое время, при проведении любой операции в Keystone, проверяется принадлежность пользователя к мультиарендной группе и сверяется его SHA-512 хэш пароля с тем, который приходит в систему для получения токена.

Фактически любая операция затрагивает реляционную СУБД

Технологии масштабирования сервиса идентификации

Единственный метод, предлагаемый сообществом Openstack для обеспечения HA:

- Использовать строго MySQL/MariaDB
- Сохранность данных обеспечивается за счет нескольких реплик базы данных
- Координация MariaDB при помощи Galera
- Балансировка запросов к Keystone-узлам при помощи HAProxy

Схема масштабирования от разработчиков Openstack

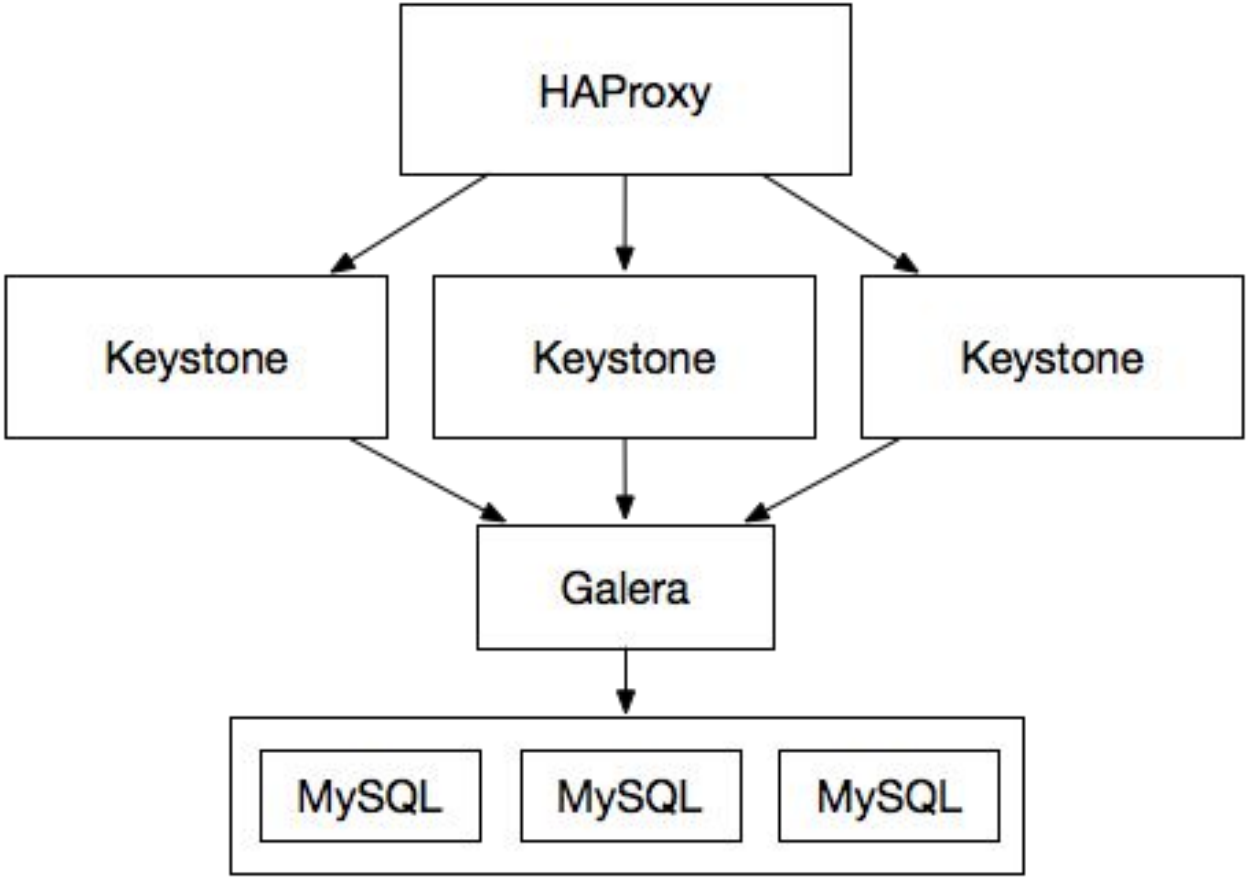

Слабости подхода

- Galera является внешним способом синхронизации СУБД и обеспечивает работу системы с производительностью самого медленного узла + накладные расходы
- Увеличение числа узлов с Keystone увеличивает количество соединений с БД
- Увеличение числа рабочих процессов Keystone увеличивает число соединений с БД

Тестирование на множестве узлов

Мы проводили тестирование HA-развертывания в двух вариантах с числом узлов Keystone от 1 до 32:

- Пропускная способность сети 4Гбит/с (из-за инкапсуляции в VXLAN)
- Rally (тестирующий фреймворк):
  - 8 VCPU, 32GB RAM
- HAProxy:
  - 8 VCPU, 32GB RAM
- Keystone узлы:
  - 2 VCPU, 8GB RAM каждый
- СУБД-узел:
  - 8 VCPU, 32GB RAM

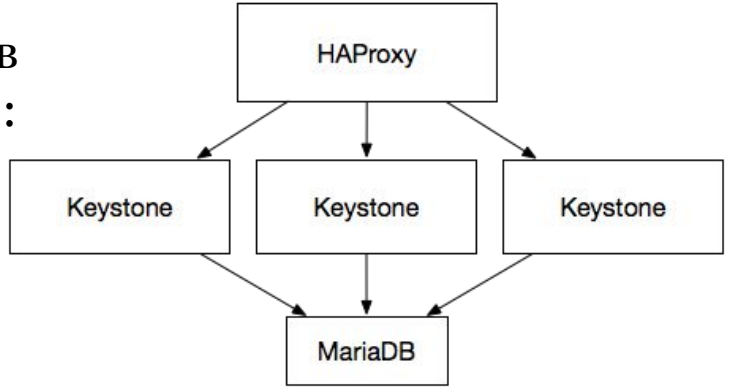

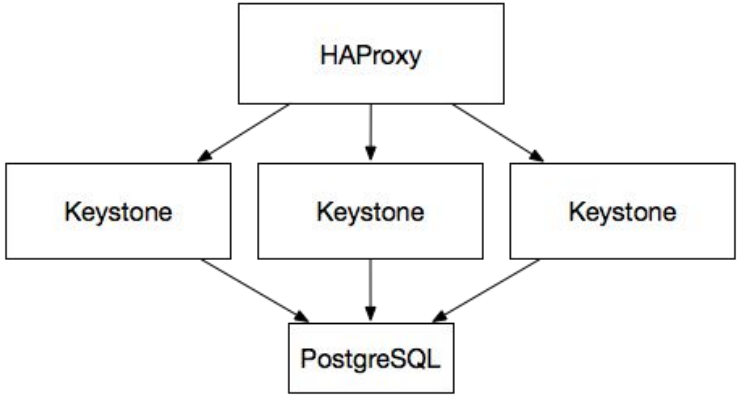

Эксперименты

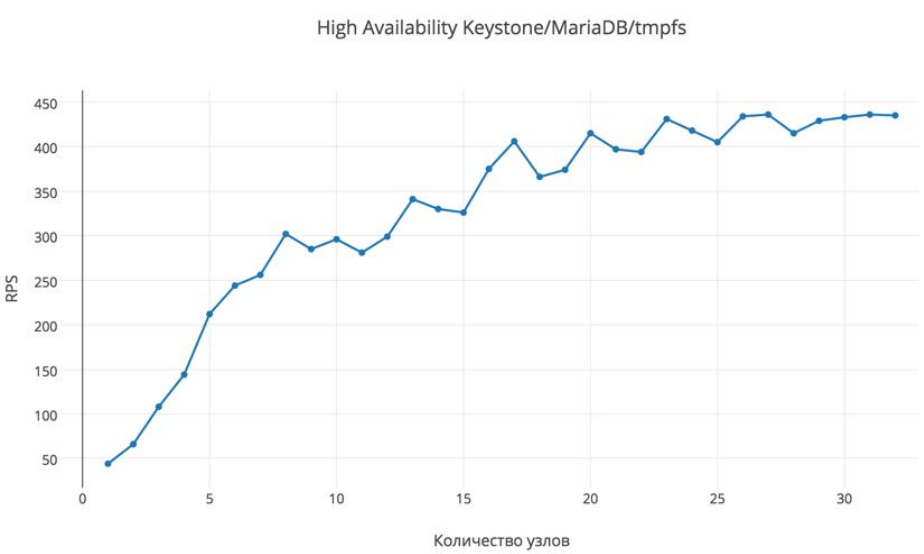

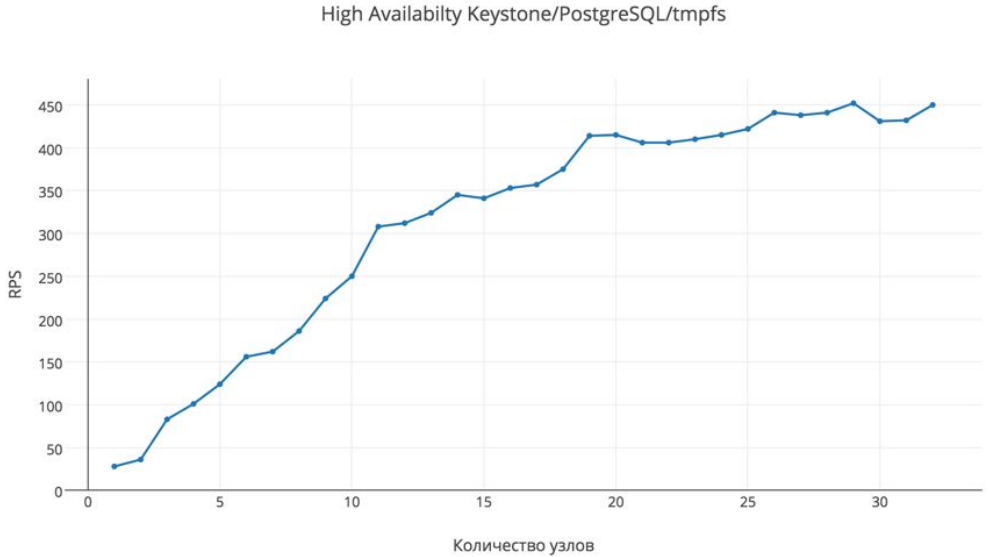

Ограничения по масштабируемости

Найденные значения RPS характеризуют максимальное количество одновременных пользователей системы.

Выявленные ограничения:

- 45RPS на одно вычислительное ядро с частотой 3ГГц
- С ростом числа узлов порождается все больше соединений с СУБД, и это проблема

Так почему это проблема?

1. Каждый запрос аутентификации съедает 1 RPS и при этом обращается к базе данных
2. Каждая операция с любым сервисом облака также порождает запрос к Keystone. В процессе создания виртуальной машины обычно порождается 12 внутренних запросов.
3. Каждый пользователь и каждый сервис Openstack обязан переполучить токен раз в час

И все еще, почему это проблема?

Представим себе эталонную конфигурацию, предлагаемую разработчиками:

3 узла с Keystone (остальное за скобками).

Самый мощный серверный процессор из доступных сейчас — Intel® Xeon® Processor E7-8890 v4 (24 ядра, 2.6ГГц, до 8 ядер на одной материнской плате). Т.е 3 сервера в пределе 576 ядер, которые выдержат ~ 23000 RPS в идеальном случае. Суммарная стоимость только процессоров ~172000$

И все это ради сервиса аутентификации и авторизации на 23000 RPS?

Безумие

Тем не менее, 23000 RPS ограничивают число пользователей 23000 одновременными пользователями единовременно, при условии, что они ничего особенно не делают и в системе есть только Keystone. При этом мощности делятся с узлами системы.

Новый подход: noSQL distributed/IMDG

- От сложности хэширования избавиться нельзя
- Тем не менее, можно избавиться от узкого места в виде соединений с СУБД
- Для этого необходимо отказаться от реляционных СУБД и перейти к решениям, которые масштабируются линейно от числа узлов и работают в оперативной памяти: In-Memory Data Grid

In-Memory Data Grid

Мы проводили исследования на эту тему, и выяснили, что существует как минимум два решения, который обеспечивают устойчивость при уровне изоляции Repeatable Read с линейным ростом производительности:

1. Tarantool: 55 тысяч транзакций в секунду на узел
2. Apache Ignite/Gridgain 23 тысячи транзакций в секунду на узел

Сохранность данных гарантируется синхронной репликацией с заданным числом копий объектов между узлами системы.

Более того, транзакционный режим нужен не для всего.

Предлагаемое построение системы

- Каждый узел сервиса центральной идентификации и авторизации обеспечивает работу всех слоев системы сразу
- Масштабируемость достигается за счет близости данных к узлу и репликации этих данных между узлами системы
- Быстродействие достигается работой с данными исключительно в памяти и без ограничений реляционных СУБД

Устройство прототипа

Он еще не готов, но мы надеемся на 30000+ RPS на узел с минимально возможной конфигурацией в три узла (т.е 90000+RPS). Это позволит строить облачные среды для датацентров.
(дальнейший план — kong + tarantool + lua)

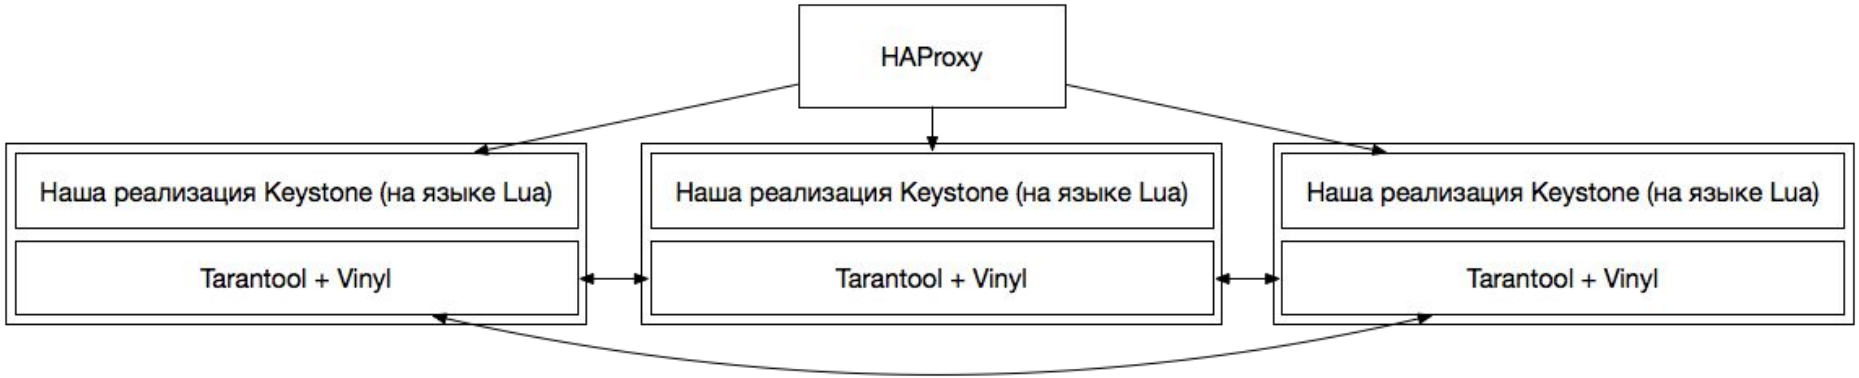

Итоги

- Системы аутентификации и авторизации в облачных системах опираются на методы шифрования/хэширования и реляционные СУБД
- Хэширование — узкое место при выдаче токенов с точки зрения одного узла
- Использование вариантов реляционных СУБД ограничено использованием ORM для всех систем
- Отсутствие полноценного master-master режима в распространенных РСУБД становится проблемой
- Выход: перенос решений на noSQL СУБД с полноценным режимом master-master.

Спасибо за внимание

ИСП РАН