




Машина больших данных Скала^р МБД.КХ

Программно-аппаратный комплекс для быстрых аналитических витрин с реляционным доступом на базе технологии ClickHouse (Arenadata QuickMarts)

Технический обзор



ОГЛАВЛЕНИЕ

1. Введение	3
2. Основы аналитических СУБД с колоночным хранением	4
3. Отличительные черты	6
4. Особенности сценариев применения	7
5. Способы работы с данными	8
6. Технологические особенности решения	10
7. Состав решения	14
8. Специфичные черты Машины Скала^р МБД.КХ.....	29
9. Гарантированное качество.....	31
10. Реакция на возможные отказы	32
11. Вариативность решения	34
12. Требования к размещению решения.....	35
13. Техническая поддержка	36
14. Лицензирование ПО Машины больших данных	38
О компании	39

1. ВВЕДЕНИЕ

Машина больших данных Скала^р МБД.КХ — это программно-аппаратный комплекс быстрых аналитических витрин с реляционным доступом под управлением СУБД Arenadata QuickMarts (ADQM), созданной на основе ClickHouse.

Скала^р МБД.КХ — готовое решение, обеспечивающее высокую производительность и отказоустойчивость, позволяет снизить затраты за счёт проработанной интеграции аппаратного и программного обеспечения, оптимизации алгоритмов для используемых технологий, широкого применения методов обеспечения надёжности, комплексности решения, специальных моделей лицензирования.

Скала^р МБД.КХ более чем в 100 раз быстрее реляционных СУБД общего назначения и 2—20 раз быстрее классических аналитических реляционных СУБД с колоночным хранением на нагрузках витринного типа.

Скала^р МБД.КХ комплексное решение, включающее узлы сегментов баз данных, систему резервного копирования, высокоскоростную сетевую среду, систему интеллектуального управления.

Высокая производительность решения достигается, в том числе, применением оптимальных по производительности комплектующих и современных стандартов, накопителей SSD/NVMe, сетевых протоколов 100 Gigabit Ethernet.

Отказоустойчивость обеспечивается применением надёжных комплектующих, специализированной версии СУБД (ADQM) с резервированием критических компонентов, использованием устойчивых сетевых протоколов.

Скала^р МБД.КХ содержит все необходимые элементы для функционирования высоконагруженной СУБД ADQM. Подключение к внешним сетям осуществляется с помощью стандартного интерфейса Ethernet.

Машина допускает размещение сразу нескольких баз данных, предоставляя возможности для их консолидации и снижения стоимости эксплуатации.

Реализованы функции мониторинга состояния как аппаратных, так и программных компонентов решения, а также необходимые функции управления.

Машина больших данных Скала^р МБД.КХ впервые была представлена в 2021 году как продукт в линейке Скала^р МБД8.АДКМ.

Решение внедрено в крупных корпоративных и государственных организациях, инсталляционная база составляет более 40 узлов.

Программно-аппаратные комплексы **Скала^р** включены в Единый реестр российской радиоэлектронной продукции и работают на ПО, включённом в реестр Минцифры РФ.

2. ОСНОВЫ АНАЛИТИЧЕСКИХ СУБД С КОЛОНОЧНЫМ ХРАНЕНИЕМ

Реляционные СУБД общего назначения очень хорошо справляются с задачами обработки и изменения единичных записей в транзакционных системах, однако, при выполнении аналитических запросов такая СУБД требует значительных аппаратных ресурсов и их производительность, как правило, недостаточна. Строчное хранение, используемое в реляционных системах общего назначения, обеспечивает эффективную обработку транзакций ценой крайне медленной работы сложных аналитических запросов, в тех случаях, когда необходимо агрегировать информацию из миллиардов строк и всего лишь нескольких.

При создании отчётов в строковых СУБД приходится анализировать множество связанной информации, это приводит к необходимости считывания всех строк, необходимых для выполнения запроса, при этом в записях используется лишь некоторые из полей, а остальные данные просто являются сопутствующей нагрузкой, что загружает ресурсы системы. На скорость построения выборок из такого количества записей не влияет даже оптимизация, настроенные индексы и ключевые поля. Агрегация данных происходит уже на последующем этапе.

Поэтому для эффективной обработки аналитических запросов применяется колоночное хранение: данные физически хранятся не по строкам, а по столбцам, что позволяет эффективно сжимать данные (поскольку данные в столбцах одного типа) и производить доступ только к запрошенным столбцам, в результате объёмы данных, пропускаемые через подсистему ввода-вывода, сокращаются на порядки. При этом вставка единичных записей при такой организации хранения намного более ресурсозатратна.

Для аналитических задач характерны следующие свойства:

- большинство запросов поступает на чтение данных;
- данные добавляются и обновляются достаточно большими пачками более 1000 строк, а не по одной, или не добавляются и не обновляются;
- при чтении используется значительное количество строк данных, и небольшое количество столбцов.

Таким образом, неэффективность коротких вставок в базу данных со колоночной организации хранения в аналитических системах не является критическим недостатком, а эффект, получаемый при доступе к данным — существенный.

На Рис. 1 представлено сравнение колоночного хранения данных (по столбцам) и строкового хранения данных. Во втором случае объем считываемых данных существенно больше.




Рис. 1. Схема сравнения

Операции выборки при колоночном и строчном хранении СУБД ADQM созданы таким образом, чтобы можно было быстро строить аналитические отчёты по данным, не прошедшим предварительную агрегацию. Такой подход позволяет намного эффективнее, в сравнении с другими системами, решать задачи подготовки аналитической информации, поэтому его активно используют в мониторинге и бизнес-аналитике, а также для анализа данных телеметрии.

Ниже приведены архитектурные особенности ADQM:

- хранение данных в столбцах позволяет считывать информацию только из нужных колонок, а также обеспечивать сжатие однотипной информации;
- поддерживаются приближённые вычисления для частичных выборок данных, что позволяет снизить число обращений к подсистеме хранения и повышает скорость обработки запросов;
- физическая сортировка данных по первичному ключу позволяет быстро получать конкретные значения или диапазоны;
- векторные вычисления по фрагментам данных столбцов позволяют снизить издержки на диспетчеризацию и повысить эффективность использования процессоров;
- применение параллельных операций как в пределах одного сервера на несколько процессорных ядер, так и в рамках распределённых вычислений на кластере за счёт механизма сегментирования позволяет существенно повысить производительность системы;
- линейная масштабируемость позволяет построить кластер со многими десятками узлов;
- отказоустойчивость реализована за счёт репликации сегментов.

ADQM поддерживает множество клиентских программ для подключения: консольный клиент, HTTP API, компоненты Python, PHP, Node.js, Perl, Ruby, R и многие другие. Также для ADQM применяются ODBC, JDBC и Golang драйверы.

3. ОТЛИЧИТЕЛЬНЫЕ ЧЕРТЫ

Важное преимущество **Машины больших данных Скала^р МБД.КХ** по сравнению с аналогичными решениями — это **линейная масштабируемость**. Поставляемая Машина способна линейно масштабироваться на петабайты данных. Применение решения cross-datacenter позволяет даже «растянуть» решение на несколько удалённых друг от друга центров обработки данных.

Система построена так, что сервис **будет всегда доступен** за счет применения кластеризации. С помощью штатной настройки можно получить требуемый коэффициент репликации и распределения.

Машина больших данных Скала^р МБД.КХ обеспечивает сжатие данных в десятки, сотни и даже тысячи раз за счет колоночного хранения и большого количества оптимизаций.

Поддерживаемый **диалект SQL** имеет разнообразные дополнительные функции для приблизительных вычислений, для обработки URL и для работы с дополнительными типами данных.

Машина больших данных Скала^р МБД.КХ имеет следующие особенности ввода-вывода:

- **Сокращенное считывание.** Для выполнения аналитического запроса требуется прочитать небольшое количество столбцов таблицы, в этом случае система сканирует только необходимые столбцы.
- **Блочное сжатие.** Так как данные читаются блоками, то их проще сжимать. Данные, лежащие по столбцам, также лучше сжимаются. За счёт этого дополнительно уменьшается объём ввода-вывода.

В **Машине больших данных Скала^р МБД.КХ** используется **векторный движок**. Операции осуществляются не над отдельными значениями, а над наборами значений с использованием векторных процессорных инструкций (AVX). За счёт этого издержки на диспетчеризацию становятся пренебрежимо малыми.

Так же одной из особенностей вычислений **Машины больших данных Скала^р МБД.КХ** является **кодогенерация** — осуществляется динамическая компиляция запросов в нативный код, что обеспечивает лучшую производительность в сравнении с интерпретируемым выполнением.

4. ОСОБЕННОСТИ СЦЕНАРИЕВ ПРИМЕНЕНИЯ

Машина больших данных Скала^р МБД.КХ эффективно применяется в сценариях, где подавляющее большинство запросов выполняются на чтение. Максимальная эффективность достигается при соблюдении следующих условий:

Оптимальные сценарии чтения данных

- при чтении извлекается достаточно большое количество строк из БД и небольшое подмножество столбцов;
- запросы осуществляются к таблицам с большим количеством столбцов и огромным числом строк, и при этом используются соединения только с небольшими таблицами (словарями, «справочниками»);
- запросы поступают относительно редко (не более сотни в секунду на сервер);
- при выполнении простых запросов допустимы задержки порядка 50 мс;
- результат выполнения запроса существенно меньше исходных данных;
- результат выполнения запроса помещается в оперативную память одного узла;
- требуется высокая пропускная способность при обработке одного запроса (до миллиардов строк в секунду на один сервер).

Особенности хранения и обработки данных

В ADQM не поддерживаются механизмы изоляции транзакций. В качестве значений в столбцах должны быть записаны числа или относительно небольшие строки (пример — 60 байтов для URL).

Сферы применения

Благодаря своим возможностям, **Машина больших данных Скала^р МБД.КХ** на основе СУБД ADQM может использоваться в самых разных сферах, для которых характерны задачи аналитики над накапливаемыми данными журнального характера — платёжных систем, систем диспетчеризации, для веб-проектов, мобильных приложений.

Сверхвысокая скорость на аналитических запросах к огромным ненормализованным таблицам — это одно из главных преимуществ решения, которое в режиме реального времени генерирует данные для аналитических отчётов, что позволяет с успехом использовать её для нужд государственных органов, телекоммуникаций, ритейла, в области электронной коммерции, торгов в реальном времени, интернета вещей.

Отслеживание бизнес-показателей предоставляет широкие возможности для бизнес-аналитики, анализа поведения пользователей в различных системах, таких как интернет-магазины или онлайн-игры. Возможность создания витрин данных без предварительной разработки моделей хранилищ данных и сложных ETL-процессов позволяет безопасно предоставлять пользователям только нужный контент.

5. СПОСОБЫ РАБОТЫ С ДАННЫМИ

В **Машине больших данных Скала^Ар МБД.КХ** используется набор движков для работы с данными. Движок — это код, встроенный в таблицу, который определяет или обеспечивает:

- как и где хранятся данные, куда их записывать и откуда считать;
- какие запросы поддерживаются и каким образом;
- конкурентный доступ к данным;
- использование индексов, если они есть;
- возможность многопоточного выполнения запроса;
- параметры репликации данных.

В **Машине больших данных Скала^Ар МБД.КХ** используются движки, показанные в таблице ниже.

Движки Скала^Ар МБД.КХ

Семейство	Описание	Движок
MERGETREE	Основное семейство для колоночного хранения, обеспечивают относительно быструю вставку данных без синхронизации с последующим слиянием в фоновом режиме.	MergeTree
		ReplacingMergeTree
		SummingMergeTree
		AggregatingMergeTree
		CollapsingMergeTree
		VersionedCollapsingMergeTree
LOG	Движки разработаны для сценариев, когда необходимо быстро записывать много таблиц с небольшим объемом данных (менее 1 миллиона строк), а затем читать их целиком.	GraphiteMergeTree
		TinyLog
		StripeLog
Движки для интеграции	Конфигурирование интеграционных движков для интеграции с внешними системами осуществляется с помощью запросов. С точки зрения пользователя, настроенная интеграция выглядит как обычная таблица, но запросы к	Log
		Kafka
		MySQL
		ODBC
		JDBC

Семейство	Описание	Движок
	ней передаются через прокси во внешнюю систему. Этот прозрачный запрос является одним из ключевых преимуществ этого подхода по сравнению с альтернативными методами интеграции, такими как внешние словари или табличные функции, которые требуют использования пользовательских методов запроса при каждом использовании.	S3
		EmbeddedRocksDB
		RabbitMQ
		PostgreSQL
Специальные движки	Несгруппированные в другие семейства движки таблиц, уникальные по назначению.	Distributed
		MaterializedView
		Dictionary
		Merge
		File
		Null
		Set
		Join
		URL
		View
		Memory
		Buffer

6. ТЕХНОЛОГИЧЕСКИЕ ОСОБЕННОСТИ РЕШЕНИЯ

Для обеспечения отказоустойчивости и высокой производительности при проектировании программно-аппаратного комплекса были заложены технологические принципы и применён ряд технических решений, описанных ниже.

Технологические принципы

- Дублирование критичных компонентов.
- Применение высокопроизводительных компонентов.
- Горизонтальное масштабирование вычислительных ресурсов.
- Сохранение работоспособности при отказе отдельных элементов системы (в отдельных случаях — со снижением производительности).

Технические решения

- Блочная-модульная архитектура.
- Специальное ПО управления и мониторинга.
- Глубокая адаптация компонентов для совместной работы в составе продукта.
- Многоуровневое тестирование комплекса и его узлов и компонентов при производстве для исключения отказов.

Архитектура **Машины больших данных Скала^р МБД.КХ** базируется на следующих принципах:

Программный RAID

- Производительнее аппаратного RAID-контроллера.
- Не подвержен аппаратным сбоям.
- Минимальное использование RAM (требуется менее 4 GB RAM).
- Минимальная снижение производительности в режиме восстановления RAID.

Спрогнозированная нагрузка

- Распараллеливание нагрузки достигается с помощью сегментирования.
- Производительность можно выбирать встраиванием согласованного с задачей движка.

Выделенный интерконнект

- Высокоскоростная сеть интерконнекта по схеме «Spine-Leaf» ускоряет взаимодействие между узлами, что отражено на (Рис. 2).
- Параллельная обработка запросов на узлах приводит к суммированию мощностей всех узлов.
- Создание параллельной синхронной копии не влияет на выполнение задания.
- Все узлы взаимодействуют между собой с одинаковой скоростью.




Рис. 2. Схема внутренних соединений Leaf Spine с увеличением скорости при горизонтальном масштабировании

Отказоустойчивость

В **Машине больших данных Скала^р МБД.КХ** осуществляется синхронное копирование сегментов, что позволяет обеспечивать стабильную доступность данных (Рис. 3).




Рис. 3. Схема синхронного копирования БД

Синхронная репликация доступна для следующих таблиц семейства MergeTree:

- ReplicatedMergeTree;
- ReplicatedSummingMergeTree;

- ReplicatedReplacingMergeTree;
- ReplicatedAggregatingMergeTree;
- ReplicatedCollapsingMergeTree;
- ReplicatedVersionedCollapsingMergeTree;
- ReplicatedGraphiteMergeTree.

Метаинформация о репликах хранится в трехточечном кластере Модуля Управления Машины.

Репликация работает на уровне отдельных таблиц, а не всей базы данных. На каждом узле могут быть расположены одновременно реплицируемые и нереплицируемые таблицы. Репликация не зависит от сегментирования, не привязана к именам таблиц и основана на запросах INSERT и ALTER.

Повышенная надежность

Асинхронная репликация позволяет повысить надежность системы и осуществлять распараллеливание запросов (Рис. 4).




Рис. 4. Схема асинхронного копирования БД

Машина больших данных Скала^р МБД.КХ использует распределенный кластер, что позволяет увеличить надежность за счет децентрализации и отсутствия единой точки отказа.

Асинхронная многосторонняя репликация обеспечивает реплицирование данных в фоновом режиме. СУБД поддерживает полную идентичность данных на разных репликах, автоматически восстанавливая их после сбоев.

В Машине используется кворумный режим записи данных. Запись считается успешной только после того, как информация записана на несколько узлов — обеспечен кворум.

Отставание асинхронной реплики определяется шириной канала связи и задержками.

Асинхронная реплика может быть использована для создания резервных копий, чтобы не останавливать основной синхронный контур.

Расширение объёма данных — сегментирование

Основные преимущества сегментирования:

- Снимает ограничение ресурсов одного узла, увеличивая объем базы на десятки и сотни узлов.
- Позволяет распараллеливать выполнение запросов, увеличивая скорость в десятки и сотни раз.
- Позволяет с помощью реплик строить защиту на любом уровне — таблицы, узла, кластера, стойки, ряда стоек, зала, центра обработки данных.

На схеме (Рис. 5) приведен вариант сегментирования и кольцевой репликации, при котором можно допустить выход из строя целой серверной стойки без потери данных.




Рис. 5. Вариант сегментирования и кольцевой репликации

Сокращенное считывание

Для выполнения аналитического запроса, требуется прочитать небольшое количество столбцов таблицы, что обеспечивается колоночным хранением, используемым в ADQM.

Блочное сжатие

Так как данные читаются блоками, то их проще сжимать. Данные, лежащие по столбцам, также лучше сжимаются, за счет этого дополнительно уменьшается объем ввода-вывода.

7. СОСТАВ РЕШЕНИЯ

Ниже приведены термины, используемые для комплектации **Машины больших данных Скала^р МБД.КХ**.

Машина — это набор аппаратного и программного обеспечения в виде модулей Скала^р, соединенных вместе для обеспечения определенного метода обработки данных или предоставления ИТ сервиса с заданными характеристиками.

Блок — группа модулей, выполняющих единую функцию в одной или нескольких стойках.

Модуль — это единица поставки Машин Скала^р, выполняющих определенные функции в соответствии с их назначением. Он является единым и неделимым элементом спецификации, содержит набор аппаратных узлов и программного обеспечения (ПО).

Узел — это элемент модуля, выполняющий определенную задачу в составе модуля.

Секция (Стойка) — набор функциональных блоков модульной архитектуры Машин Скала^р, объединенных в один серверный шкаф.

Формирование решения основано на принципе разделения на блоки и модули. Каждый из блоков komponуется из набора стандартных модулей. Этим обеспечивается универсальный подход, более высокий уровень технологичности и надежности эксплуатации. Модули, в свою очередь, формируются из одного или нескольких узлов.

Решение **Скала^р МБД.КХ** состоит из следующих блоков:

Блок вычисления и хранения

Блок коммутации и агрегации

Блок управления и распределения

Блок мониторинга и регистрации

Блок резервного копирования



Блок вычисления и хранения

Блок вычисления и хранения состоит из типовых Модулей вычисления и хранения на базе аппаратных узлов и программной платформы ADQM.

Образуемый узлами модулей кластер ADQM не имеет мастер-узла и единой точки входа. Запросы могут отправляться к любому из узлов в кластере. Архитектура кластера представлена на Рис. 6.




Рис. 6. Архитектура кластера

Локальные таблицы (Local table) отвечают за хранение и репликацию данных.

Распределенные таблицы (Distributed table) не хранят данные, они позволяют сделать запрос на несколько локальных таблиц, распределенных на хостах, объединённых в виртуальный кластер (remote_servers).

Сегменты (shards) — части данных, распределенные по серверам для распараллеливания запросов. Реплики (replicas) позволяют обеспечить отказоустойчивость на уровне узлов (hosts).

Модуль вычисления и хранения состоит из двух или трёх узлов и соединен с Модулем сетевого взаимодействия и сетевым узлом управления (Рис. 7).




Рис. 7. Модуль вычисления и хранения

Каждый отдельный узел вычисления и хранения:

- содержит выделенные накопители SAS SSD для загрузки ОС;
- использует локальные SAS SSD для размещения образов данных и журналов (RAID 10), что обеспечивает повышение производительности (нет необходимости дополнительного внешнего обмена с системой хранения);
- имеет дублированные интерфейсы данных (стандарт IEEE 802.3ad LACP) — повышение производительности, отказоустойчивость (в случае отказа одного из интерфейсов возможно снижение производительности);
- оснащен двухпортовыми сетевыми картами 100 Gigabit Ethernet для интерконнекта в рамках Машины;
- содержит два блока питания в режиме резервирования по схеме 1+1;
- имеет два процессора Xeon не ниже 2-го поколения;
- использует 512 GB RAM в узле 1-го типа и 384 GB RAM в узле 2-го типа.

Применяемое программное обеспечение:

- ОС: Linux CentOS;
- специальная версия платформы ADQM;
- управление резервным копированием: специализированные программные модули платформы ADQM;
- управление кластером средствами ADQM.

Блок коммутации и агрегации

Обеспечивает передачу данных между элементами **Машиной больших данных Скала^р МБД.КХ** (интерконнект) и информационный обмен с внешними сетями, а также низкоуровневое управление узлами Машины. Соответственно эффективное сетевое взаимодействие является важным фактором для быстрого и надежного функционирования кластера.

Схема сетевого взаимодействия представлена на Рис. 8.

Реализованные подсети:

- Internal VLAN — сеть интерконнекта, для внутреннего взаимодействия между узлами БД, сеть резервного копирования, сеть кластерного взаимодействия на схеме ниже обозначена стрелками (оранжевого цвета);
- External VLAN — сеть для подключения к сервисам БД внешних пользователей и прикладных систем, подключение к серверу управления на схеме ниже обозначена стрелками (черного цвета);
- Сети мониторинга и управления - обмен служебными данными, данными для мониторинга и сеть управления узлами Машины на схеме ниже обозначена стрелками (синего цвета).
- Стрелками зеленого цвета обозначены соединения коммутаторов между стойками с агрегированным трафиком.




Рис. 8. Общая схема сети интерконнекта

Сети мониторинга и управления Машины:

- PXE (OS) VLAN — сеть для развёртывания операционной системы по PXE, платформы МБД, мониторинга (оранжевого цвета);
- Агрегация (Ring VLAN) — резервная сеть кластерного взаимодействия, доступ к IPMI (зеленого цвета);
- IPMI VLAN — сеть управления оборудованием через интерфейсы удалённого управления (синего цвета).

На рисунке Рис. 9 представлена архитектура сети управления.




Рис. 9. Общая схема сетей мониторинга и управления

Сетевой узел управления

Сетевой узел управления состоит из одного коммутатора для организации сетей мониторинга, управления и служебного обмена (Рис. 10).




Рис. 10. Сетевой узел управления

Модуль агрегации

Модуль агрегации — пара коммутаторов, собранных по технологии MLAG для агрегации коммутаторов интерконнекта.

Модуль агрегации устанавливается в Базовый Модуль в тех случаях, когда уже нет доступных портов в базовом комплекте узлов сетевого взаимодействия.

Модуль состоит из узлов сетевого взаимодействия (Рис. 11).



Рис. 11. Модуль агрегации

Блок управления и распределения

Основное предназначение блока — управление синхронизацией реплик БД и поддержание отказоустойчивого кластера средствами Zookeeper. Он состоит из трехузлового кластера показанного на Рис. 12.



Рис. 12. Модуль управления и распределения

Каждый узел управления и распределения:

- использует SSD для обеспечения высокой производительности при хранении служебных данных;
- содержит выделенные SSD для загрузки ОС;
- оснащен двухпортовыми сетевыми картами 100 Gigabit Ethernet для интерконнекта в рамках Машины;
- имеет 2 порта 10 Gigabit Ethernet для сетей управления и IPMI;
- содержит два блока питания в режиме резервирования по схеме 1+1;
- имеет два процессора Xeon не ниже 2-го поколения;
- использует 128 GB RAM.

Блок мониторинга и регистрации

Блок мониторинга и регистрации состоит из двух или трех узлов вычисления и хранения — высокопроизводительных серверов одного из двух типов на выбор. Он обеспечивает управление Машиной на всех этапах жизненного цикла программных и аппаратных компонентов.

Основные функции блока:

- мониторинг и визуализация работы сети и оборудования, входящего в состав Машины;
- мониторинг и визуализация функционирования платформы ADQM, связи реплик платформы и компонентов физической инфраструктуры (Рис. 13);
- накопление данных о функционировании Машины для автоматизированной и/или ручной оптимизации настроек аппаратной и программной платформы;
- автоматизированное реагирование на неблагоприятные события и отклонения параметров функционирования Машины;
- репозиторий пакетов для ОС и платформы ADQM для автоматизированной установки.




Рис. 13. Пример экрана подсистемы мониторинга МБД.КХ

Модуль мониторинга и регистрации состоит из двух высокопроизводительных узлов, объединенных в зеркальный кластер (Рис. 14).



Рис. 14. Модуль мониторинга и регистрации

Каждый узел мониторинга и регистрации представлен специализированным серверным узлом:

- использует SSD для обеспечения высокой производительности при хранении служебных данных;
- содержит выделенные SSD для загрузки ОС;
- оснащен двухпортовыми сетевыми картами 100 Gigabit Ethernet для интерконнекта в рамках Машины;
- имеет 2 порта 1 Gigabit Ethernet для сетей управления и IPMI;
- одержит два блока питания в режиме резервирования по схеме 1+1;
- имеет два процессора Xeon не ниже 2-го поколения;
- использует 256 GB RAM.

Применяемое программное обеспечение:

- ОС: Альт Линукс, сервер с виртуализацией Базис vCore;
- мониторинг и управление: разработка «Скала^р»;
- управление жизненным циклом: ПО «Геном» (разработка «Скала^р»).

Блок резервного копирования

Основное предназначение блока — запись хранение резервных копий базы данных, а также их восстановление. Блок собирается из Модулей резервного копирования. Каждый такой модуль состоит из одного узла резервного копирования (Рис. 15).



Рис. 15. Модуль резервного копирования

Каждый отдельный узел резервного копирования:

- содержит выделенные накопители SAS SSD для загрузки ОС — обеспечение отказоустойчивости;
- применяется аппаратный RAID;
- оснащен 14 HDD для хранения данных;
- имеет интерфейсы данных дублированы (стандарт IEEE 802.3ad LACP) — повышение производительности, отказоустойчивость (в случае отказа одного из интерфейсов возможно снижение производительности);
- оснащен двухпортовыми сетевыми картами 100 Gigabit Ethernet для интерконнекта в рамках Машины;
- содержит два блока питания в режиме резервирования по схеме 1+1;
- имеет два процессора Xeon не ниже 2-го поколения;
- использует 384 GB RAM.

Применяемое программное обеспечение

Для создания резервных копии используются встроенные средства резервного копирования.

Резервное копирование рассчитывается для объема от 4-х копий максимальной базы.

Базовый Модуль

Базовый Модуль — основа любого решения. Может содержать все виды модулей и узлов Машины (Рис. 16) и способен доукомплектовываться отдельностоящими секциями (стойками) расширения. Состоит из узлов сетевого взаимодействия, мониторинга и регистрации и узла сетевого управления.




Рис. 16. Базовый Модуль

Модуль коммутации, вычисления и хранения

Модуль комплектуется в отдельную стойку и применяется для горизонтального масштабирования Машины. Содержит узлы сетевого взаимодействия и управления, наполняется следующими видами модулей (Рис. 17):

- Модули вычисления и хранения;
- Модули резервного копирования.




Рис. 17. Модуль коммутации, вычисления и хранения

Секция расширения (отдельностоящая стойка)

Секция расширения (Рис. 18) предназначена для размещения дополнительных модулей в дополнение к Базовому Модулю и/или Модулю коммутации, вычисления и хранения и содержит следующие виды модулей:

- Модули вычисления и хранения;
- Модули резервного копирования.




Рис. 18. Секция расширения

Применение дополнительных стоек обуславливается требованиями и ограничениями инженерной инфраструктуры заказчика, в том числе — по допустимой потребляемой мощности и допустимому тепловыделению на отдельный серверный монтажный шкаф (стойку).

К любому основному модулю можно добавить одну или две дополнительных секции (стойки).

Схема размещения блоков и их модулей в стойках по этапам роста масштаба Машины

На диаграмме ниже (Рис. 19) представлен пример размещения базовых блоков и вариантов расширения при двух этапах горизонтального масштабирования.




Рис. 19. Пример размещения базовых блоков и вариантов расширения

Этапы масштабирования приведены ниже:

- Первый этап — это установка модулей в Базовый Модуль. Как правило, это возможно, пока позволяет предельная мощность энергопотребления первой стойки Базового Модуля.
- Далее устанавливается дополнительная отдельно стоящая стойка, в которой размещаются Модули вычисления и хранения, а также резервного копирования (при необходимости). Такое расширение возможно в одной или двух таких дополнительных стойках, и до достижения ограничения по питанию стоек или до заполнения количества портов в узлах внутреннего взаимодействия первой стойки — Базового Модуля. Важно, что в этих дополнительных стойках нет сетевого оборудования.
- Установка Модуля коммутации, вычисления и хранения выполняется при заполнении портов внутреннего взаимодействия в Базовом Модуле. Стойка этого модуля включает в себя набор узлов сетевого взаимодействия и требует установки дополнительного модуля агрегации в Базовый Модуль (первая стойка на схеме).

Пример такого размещения в стойках представлен на диаграмме ниже (Рис. 20).




Рис. 20. Пример размещения базовых блоков, модулей и узлов в серверных стойках

Система управления жизненным циклом Скала^р Геном

В **Машине больших данных Скала^р МБД.КХ** применяется специализированное программное обеспечение Скала^р.Геном (Рис. 21).




Рис. 21. Пример интерфейса Скала^р Геном

Данный программный продукт обеспечивает:

- контроль развертывания компонентов Машины;
- ведение электронного паспорта Машины;
- отслеживание состояния узлов;
- отслеживание конфигурации программно-аппаратного состава Машины;
- снижение влияния человеческого фактора — сокращение рисков, связанных с ошибками эксплуатирующего персонала.

8. СПЕЦИФИЧНЫЕ ЧЕРТЫ МАШИНЫ СКАЛА^Р МБД.КХ

Проектирование и реализация Машины больших данных Скала^р МБД.КХ осуществлялись с учётом ряда выбранных приоритетов, оказывающих непосредственное влияние на функциональные и эксплуатационные показатели. Наиболее значимые из них следующие.

Приоритет обеспечения сохранности данных перед повышенной доступностью

Такой подход обеспечивает гарантию сохранности данных при любых единичных отказах оборудования и быстрое восстановление из резервных копий в случае фатальных сбоев. В ряде сценариев возможны одновременные отказы разных компонентов без потери данных.

Реализация вычислительного блока на аппаратном решении вместо использования виртуальной среды

Это позволяет достичь максимума производительности на данном оборудовании (нет потерь на работу среды виртуализации, прочие сведены к минимуму) и повысить надёжность (нет дополнительного программного слоя).

Использование локальных дисков вместо сетевой системы хранения для снижения затрат на передачу данных

Так как СУБД ADQM изначально создана для работы с накопителями прямого подключения, ей не требуются сети для доступа к данным на внешних массивах, что обеспечивает линейную масштабируемость системы и отсутствие порога по суммарной пропускной способности подсистемы ввода-вывода. Отсутствие дополнительного сложного элемента в виде сетей хранения данных также способствует повышению надёжности решения, а снижение стоимости решения обеспечивается благодаря отсутствию расходов на внешнюю систему хранения в целом, затраты идут только на SSD.

Применение стандартного высоконадёжного и производительного оборудования в качестве платформы для размещения компонентов решения взамен уникальных аппаратных разработок

Обеспечение стабильного уровня производительности достигается за счет использования компонентов, проверенных временем и лабораторией Скала^р. Отсутствие уникальных элементов также повышает надёжность решения.

Использование программных RAID отечественных производителей вместо отдельных аппаратных RAID

Это позволяет достичь более высокой производительности, высокой гибкости в настройках (в зависимости от требований), снижение зависимости от производителей оборудования и гарантирует оптимальность алгоритмов RAID.

Возможность применения типовых и сторонних решений для мониторинга и управления в дополнение к предустановленным

Это позволяет сохранить ранее сделанные инвестиции в системы управления ИТ-инфраструктурой и дает возможность построения сквозных систем управления, в которые интегрируются Машины линейки Скала^р МБД.

9. ГАРАНТИРОВАННОЕ КАЧЕСТВО

Качественные показатели **Машины больших данных Скала^р МБД.КХ** обеспечиваются её соответствием проверенному стандартному варианту, формированием из блоков и модулей, производством работ высококвалифицированными специалистами и процедурами приемки качества.

Производство (сборка Машины и предустановка ПО)

При производстве используются только высококачественные комплектующие, а сборка продукции осуществляется строго в соответствии с технологическими картами. Первичное развертывание ПО осуществляется в автоматическом режиме, дополнительные настройки ПО осуществляются в соответствии с утверждённой пошаговой инструкцией. Сформированная Машина тщательно тестируется, таким образом отклонения от типового решения **Скала^р МБД.КХ** исключены.

Передача в эксплуатацию

Машина больших данных Скала^р МБД.КХ полностью сформирована, протестирована, готова к размещению в сети заказчика и установке прикладного ПО заказчика. В комплекте с Машиной передаётся Паспорт изделия, эксплуатационная документация, Сертификат на техническую поддержку.

10. РЕАКЦИЯ НА ВОЗМОЖНЫЕ ОТКАЗЫ

Отказы, связанные со стандартными элементами Скала^р МБД.КХ

В рамках **Машины больших данных Скала^р МБД.КХ** обеспечена отказоустойчивость её основных элементов, в том числе:

- узлов (дублирование процессоров, источников питания и др.);
- подсистемы ввода-вывода (программный RAID);
- сети интерконнекта (дублирование сетевых интерфейсов и самих коммутаторов);
- системы резервного копирования.

Отказы перечисленных элементов отрабатываются стандартными алгоритмами в соответствии с произведёнными настройками. Любой единичный отказ не повлияет на доступность системы в целом, хотя по конкретному сервису возможно небольшое снижение производительности. После устранения неисправности исходная производительность **Скала^р МБД.КХ** также восстанавливается.

Отказы, связанные с узлами кластера баз данных

Аппаратные сбои

Архитектура программного обеспечения, лежащего в основе **Скала^р МБД.КХ**, позволяет построить отказоустойчивый многоузловой кластер, в том числе катастрофоустойчивый кластер.

Отказоустойчивость обеспечивается за счет настройки репликации таблиц между узлами, а также избыточности экземпляров сервиса ZooKeeper, который отвечает за хранение метаданных, необходимых для репликации. При этом отказоустойчивым считается кластер, состоящий как минимум из трех узлов ZooKeeper и двух узлов сегментов ADQM.

Отказ любых двух узлов с разными ролями, либо отказ всех узлов с ролью ADQM, кроме одного, не влияет на работоспособность кластера и позволяет ему обрабатывать запросы как на чтение, так и на запись. При этом общая производительность системы снижается.

В случае, если ZooKeeper недоступен, реплицируемые таблицы остаются доступными только для чтения, а запросы на запись приведут к выдаче исключения. При восстановлении доступности сервиса данные будут автоматически синхронизированы, если это возможно, а в противном случае неизвестные участки данных будут перемещены в подкаталог detached. Если блоки данных внутри файлов оказались повреждены, запрос SELECT приведет к исключению, после чего будет предпринята попытка их проверки и восстановления.

Если после сбоя локальный набор данных критически отличается от ожидаемого, сработает защитный механизм, и потребуются ручное (полуавтоматическое) восстановление.

Если данные на одной из реплик полностью утеряны, доступен вариант ручного восстановления.

Программные сбои и человеческий фактор

Кроме обеспечения отказоустойчивости, необходимо организовать систему резервного копирования, исходя из ресурсов и потребностей.

Одним из вариантов решения данной задачи является дублирование данных в Hadoop или S3, например, путем подписки дополнительных подписчиков на темы Kafka.

Детальный порядок обеспечения отказоустойчивости кластера и рекомендации по действиям при его администрировании в той или иной конкретной ситуации с конкретным экземпляром **Машины больших данных Скала^р МБД.КХ** могут быть предоставлены по запросу.

11. ВАРИАТИВНОСТЬ РЕШЕНИЯ

Приоритет производительности

Область применения:

- дополнение к аналитической части систем класса Data Warehouse;
- хранение информации оперативного доступа;
- системы с множественными аналитическими запросами.

Варианты решения:

- увеличенный объём оперативной памяти;
- повышение базовой частоты работы процессоров;
- высокопроизводительные SSD;
- RAID 10.

Приоритет объёма хранения

Область применения:

- база аналитической информации предприятия;
- данные с датчиков, устройств интернета вещей;
- журналы действий пользователей;
- данные исторического анализа.

Вариант решения:

- стандартные параметры вычислительного модуля;
- SSD повышенного объёма.

Специальный тюнинг

Вариант решения:

- может использоваться в комплексе с любым из вариантов;
- требуется участие разработчиков прикладных систем;
- достигается адаптацией настроек и конфигурации оборудования под структуру данных заказчика, типы и периодичность запросов и т.п.

12. ТРЕБОВАНИЯ К РАЗМЕЩЕНИЮ РЕШЕНИЯ

Решение Машины представляет собой серверный монтажный шкаф 19", высота 42U, с дальнейшей возможностью модульной расширяемости до 14 стоек.

Наполнение шкафа оборудованием и совокупный вес зависят от выбранного варианта решения и могут составлять от 400 до 800 кг.

Для подключения шкафа к системе электроснабжения должны быть предусмотрены два независимых входа электропитания.

Расчётная потребляемая мощность шкафа составляет от 6 до 11 кВт.

В месте установки должны быть предусмотрены соответствующие мощности по отводу тепла.

Для подключения к локальной сети заказчика необходим резервированный канал до 4x100 Gigabit Ethernet или до 8x10/25 Gigabit Ethernet. Требуемые трансиверы определяются на этапе формирования спецификации Машины.

При развёртывании решения на нём будут выполнены настройки сетевых адресов в соответствии со структурой сети заказчика. Заказчик должен предоставить необходимые данные в соответствии с номенклатурой компонентов решения.

В сети заказчика должны быть настроены соответствующие маршруты и права доступа.

Дальнейшие мероприятия по вводу в эксплуатацию осуществляются заказчиком путём настройки прикладных программных систем.

13. ТЕХНИЧЕСКАЯ ПОДДЕРЖКА

Машина больших данных Скала^р МБД.КХ поставляется с обязательной годовой поддержкой (может быть предоставлена также на 2, 3 и 5 лет), которая включает в себя решение всех вопросов, связанных с нарушениями работоспособности как комплекса в целом, так и его отдельных аппаратных компонентов и программного обеспечения. Поддержка предоставляется непосредственно производителем или сертифицированным партнёром. У заказчика есть возможность выбора варианта поддержки из актуальных на момент поставки, а также дополнительных опций. В сложных случаях к решению проблем привлекаются архитекторы и инженеры, непосредственно участвовавшие в разработке **Машины больших данных Скала^р МБД.КХ**.

Поставка Скала^р МБД.КХ осуществляется с предварительными сборкой, тестированием и настройкой оборудования согласно требованиям заказчика. Качественная поддержка Машины обеспечивается едиными стандартами гарантийного и постгарантийного технического обслуживания:

- Пакет услуг по технической поддержке на первый год включен в поставку.
- Заказчик может выбирать пакет в базовом режиме 9×5, или в расширенном режиме 24×7 (опция для критической функциональности).
- Срок начально приобретаемой технической поддержки может быть увеличен до 3 и 5 лет, также доступна пролонгация поддержки.
- Возможно включение в состав стандартных пакетов дополнительных опций и услуг.

Состав типовых пакетов услуг по технической поддержке представлен в таблице ниже.

Пакеты услуг по технической поддержке Скала^р МБД.КХ

Услуга	Пакет «9×5»	Пакет «24×7»
Режим «Обслуживание комплекса Скала^р МБД.КХ в режиме 9х5» (в рабочее время по рабочим дням)	+	+
Режим «Обслуживание комплекса Скала^р МБД.КХ в режиме 24×7» (круглосуточно)	—	+
Предоставление доступа к системе регистрации запросов/инцидентов Service Desk	+	+
Предоставление доступа к базе знаний по продуктам Скала^р	+	+
Предоставление обновлений лицензионного ПО Скала^р	+	+
Диагностика, анализ и устранение проблем в работе комплекса Скала^р МБД.КХ, включая:	+	+

Услуга	Пакет «9×5»	Пакет «24×7»
■ устранение аппаратных неисправностей; ■ техническое сопровождение ПО.		
Консультации по работе комплекса Скала^р МБД.КХ	+	+
«Защита конфиденциальной информации» (неисправные носители информации не возвращаются Заказчиком)	Опция	Опция
Замена и ремонт оборудования по месту установки	+	+
Доставка оборудования на замену за счет производителя	+	+
Расширенные опции обслуживания	—	+
Времена реагирования и отклика, не более:		
Время регистрации обращений	30 минут, рабочие часы (9×5)	30 минут, круглосуточно (24×7)
Подключение специалиста к решению инцидентов критичного и высокого уровней	В течение 1 рабочего часа (9×5)	В течение 1 часа (24×7)

Примечание к срокам ремонта оборудования: комплекс **Скала^р МБД.КХ** архитектурно является устойчивым к выходу из строя отдельных компонентов и даже узлов, поэтому нет необходимости в обеспечении дорогостоящего сервиса срочного восстановления оборудования в течение суток и менее. В комплексе предусмотрено, как минимум, двойное резервирование основных компонентов, позволяющее сохранять данные и работоспособность даже при выходе из строя нескольких дисков и/или серверов.

14. ЛИЦЕНЗИРОВАНИЕ ПО МАШИНЫ БОЛЬШИХ ДАННЫХ

Все наименования ПО лицензируется по модулям Машины и их количеству в Машине.

Лицензирование ПО Машины больших данных Скала^р МБД.КХ

Программное обеспечение СУБД Arenadata QuickMarts (ADQM) лицензируется согласно объёму ресурсов в Модуле вычисления и хранения, при этом на каждый модуль выдается единая лицензия.

Программное обеспечение Скала^р Спектр, Скала^р Спектр.Мониторинг (Визион), Скала^р Геном поставляется исключительно в составе **Машин больших данных Скала^р МБД.КХ**, и лицензируется по количеству модулей в ней.

Варианты лицензирования

Лицензирование ПО комплекса Скала^р МБД.КХ имеет две редакции:

- фиксированная — приобретается бессрочная (постоянная) лицензия;
- временная — приобретается лицензия на период времени.

Политика обновления ПО

Обновления функционального и системного ПО предоставляются по минорным и мажорным версиям, выпускаемым партнером АренаДата и иными, в течение действия технической поддержки бесплатно.

Также команда Скала^р активно занимается развитием собственных программных продуктов и утилит для **Машины больших данных Скала^р МБД.КХ** и предоставляет обновления по мере их появления.

О КОМПАНИИ

Компания Скала^р — разработчик и производитель модульной платформы для высоконагруженных корпоративных и государственных информационных систем.

Машины Скала^р являются серийно выпускаемыми преднастроенными комплексами и позволяют осуществлять быстрое развёртывание и ввод в эксплуатацию.

Модульный принцип обеспечивает интеграцию разнородных компонентов ИТ-инфраструктуры в единую платформу предприятий, корпораций и ведомств.

Единые поддержка и сервисное обслуживание для всех продуктов линейки Скала^р от производителя обеспечивают оперативное разрешение инцидентов на стыке технологий.

Дополнительная информация — на сайте www.skala-r.ru.