



Модуль балансировки нагрузки
Скала^р МС.БН

scalaport

Скала[^]р – модульная платформа

для построения инфраструктуры высоконагруженных
корпоративных и государственных информационных систем



10 лет
серийного
выпуска

680

комплексов
в промышленной
эксплуатации

10 тыс. +
вычислительных
узлов

Продуктовые направления Скала[^]р

решения для высоконагруженных корпоративных и государственных систем



Динамическая инфраструктура

Машины динамической инфраструктуры Скала[^]р МДИ
на основе решений BASIS для создания динамической конвергентной и гиперконвергентной инфраструктуры ЦОД и виртуальных рабочих мест пользователей



Инфраструктура ИИ

Машина искусственного интеллекта Скала[^]р
на основе оптимизированного программно-аппаратного стека для максимальной производительности при работе с моделями ИИ



Управление данными

Машины баз данных Скала[^]р МБД

на основе решений Postgres Pro для замены Oracle Exadata в высоконагруженных системах с обеспечением высокой доступности и сохранности критически важных данных

Машины больших данных Скала[^]р МБД

на основе решений ARENADATA и PICODATA для создания инфраструктуры хранения, преобразования, аналитической, статистической обработки данных, а также распределенных вычислений

Машины хранения данных Скала[^]р МХД

- на основе технологии объектного хранения S3 для геораспределенных катастрофоустойчивых систем с сотнями миллионов объектов различного типа и обеспечения быстрого доступа к ним
- решения на основе платформы S3 и российского ПО для комплексных задач резервного копирования и восстановления крупных массивов данных со встроенной иерархией хранения и обеспечением высокой доступности копий



Специализированные решения

Машина управления технологическими процессами Скала[^]р МСП.ТП (АСУ ТП)

Высоконадежная инфраструктура для различных АСУ ТП промышленных предприятий с высокими требованиями к отказоустойчивости и информационной безопасности. Соответствует требованиям ЗОКИИ, в том числе критериям к Доверенным ПАК

Машина автоматизированных банковских систем Скала[^]р МСП.БС


на платформе Машин Скала[^]р для задач класса АБС и процессинговых решений с поддержкой высокой транзакционной и аналитической нагрузки, сегментирования баз данных и обеспечения ИБ

О технологии балансировки нагрузки



Балансировка нагрузки или выравнивание нагрузки (англ. load balancing) – метод распределения заданий между несколькими сетевыми устройствами (например, серверами) с целью оптимизации использования ресурсов, сокращения времени обслуживания запросов, горизонтального масштабирования кластера (динамическое добавление/удаление устройств), а также обеспечения отказоустойчивости (резервирования). Процедура балансировки осуществляется при помощи целого комплекса алгоритмов и методов.

- **DNS балансировка** (Сетевой уровень) – Обеспечивает балансировку нагрузки и отказоустойчивость в нескольких центрах обработки данных.
- **L4 балансировка** (Транспортный уровень) – Распределение трафика идет на основе информации из протоколов TCP или UDP. Данный метод популярен в сетевых сервисах, где важно учитывать порты и протоколы, но не требуется анализировать содержимое трафика.
- **L7 балансировка** (Прикладной уровень) – Распределение идет на базе содержимого приложения (HTTP/HTTPS). Идеален для сложных веб-приложений, микросервисных архитектур, API-шлюзов, где нужно учитывать контекст запроса и принимать решения на основе содержимого HTTP-запросов.



Какие бывают балансирующие нагрузки?



▪ Аппаратные балансирующие нагрузки

Это специализированные устройства, которые используются в центрах обработки данных для управления сетевым трафиком. Они предоставляют высокую производительность, безопасность и масштабируемость.

Примеры: F5 Networks, Citrix ADC (ранее NetScaler), A10 Networks.

▪ Программные балансирующие нагрузки

Это программные решения, которые работают на стандартных серверах заказчика.


Они гибкие и часто более доступные по сравнению с аппаратными балансирующими нагрузками.

Примеры Open Source решений: HA Proxy, Nginx, Traefik, Apache HTTP Server

Балансирующие нагрузки – ключевой компонент современных распределённых систем, который помогает им работать эффективно даже во время пиковых нагрузок.

Балансирующие нагрузки применяются для:

- Повышения надежности системы
- Уменьшения времени ответа на запрос
- Оптимизации использования ресурсов
- Предотвращения перегрузки какого-либо одного ресурса
- Максимизации пропускной способности



Модуль балансировки нагрузки Скала^р

Описание продукта



Модуль балансировки нагрузки Скала^р МС.БН

представляет собой аппаратный отказоустойчивый кластер балансировки нагрузки с использованием OEM компонентов ПО Angie ADC

Возможности:

- Балансировка нагрузки на уровнях L3/L4/L7 модели OSI
- Глобальная балансировка на основе DNS (GSLB)
- Система управления и мониторинга
- Управление через API, CLI, GUI



Производительность кластера в режиме Active–Active – 2x 20 Гбит/с, сетевые интерфейсы 25 Гбит/с

Модуль балансировки нагрузки Скала[®]

Функциональность



- **DNS-балансировка** – распределяются запросы, возвращая разные IP-адреса одного доменного имени для разных клиентов. Решения принимаются на основе географического расположения пользователей, загруженности серверов, политик маршрутизации
- **Балансировка нагрузки на уровне L4** – принимаются решения на основе алгоритма балансировки и информации о TCP/UDP-сессиях, включая IP-адреса, порты источника и назначения
- **Балансировка нагрузки на уровне L7** – анализ содержимое HTTP/HTTPS запросов (например, URL, заголовки, куки, методы запроса) и принятие решения о маршрутизации на основе этих данных
- **Удержание клиентских сессий** – возможность определения всех запросов от одного клиента, и направление их на один бэкенд
- **Обработка и ускорение TLS** – Балансировщик может терминировать на себе шифрованные соединения, снимая таким образом нагрузку с серверов
- **Проверка доступности серверов** – используются гибкие механизмы проверки доступности серверов
- **Ролевая модель доступа** – набор полномочий, привязанных к должностям или рабочим задачам
- **Управление и мониторинг** – через API/GUI/CLI

Модуль балансировки нагрузки Скала^р

Поддерживаемые режимы балансировки



- **Round Robin** – запросы распределяются по серверам последовательно (используется по умолчанию)
- **Балансировка на основе веса** (weight) – запросы распределяются по серверам с учетом веса каждого сервера
- **Балансировка ip-hash** – сервер выбирается с помощью хэш-функции на основе IP-адреса клиента, что обеспечивает «sticky session». Гарантирует, что запросы от одного клиента будут попадать на один сервер, если этот сервер доступен
- **least_conn** – новый запрос направляется на сервер с минимальным количеством активных соединений (наименее загруженный)
- **least_bandwidth** – балансировка на основе наименьшего потребления полосы пропускания. Периодически вычисляется среднее использование полосы пропускания для каждого апстрим-сервера, используя формулу скользящего среднего для сглаживания колебаний со временем
- **least_packets** – балансировка на основе наименьшего числа пакетов в единицу времени
- **least_time** – балансировка на основе наименьшего времени ответа. Вероятность передачи соединения активному серверу обратно пропорциональна среднему времени его ответа
- **feedback** – механизм балансировки нагрузки по обратной связи (по произвольному параметру из ответа на основной или проверочный запрос)

Модуль балансировки нагрузки Скала[®]

Поддерживаемые проверки доступности серверов



Балансировщик Скала[®] МС.БН использует пассивные и активные проверки состояния бэкендов. Если бэкенд начинает отвечать с ошибками, то он временно исключается из пула доступных бэкендов.

- Пассивные проверки доступности определяют состояние бэкенд узлов на основе пользовательских ответов. Позволяет мгновенно принимать решение.
- Активные периодические проверки устанавливают доступность бэкенд узлов, в том числе со сложной логикой. Узел проходит проверку, если запрос к нему успешно выполняется с учетом всех заданных параметров.
- Механизмы определения доступности сервера: tcp-check, http-check, icmp-check.
- Slow start позволяет постепенно вводить в строй восстановленный бэкенд узел. Тем самым «непрогретый» бэкенд узел не будет немедленно испытывать критическую нагрузку.

Модуль балансировки нагрузки Скала^р

Распределение нагрузки




Основные методы балансировки можно использовать как по отдельности, так и в различных сочетаниях:

- **Round Robin** – запросы распределяются последовательно по каждому бэкенду
- **Weighted Round Robin** – аналогично, с учётом весов бэкендов
- **Least Connections** – новый запрос отправляется на бэкенд с наименьшим количеством активных соединений
- **Weighted Least Connections** – аналогично, но учитывается вес бэкендов

Весовые коэффициенты позволяют задать долю (вес) запросов, обрабатываемых каждым сервером приложений.

Вес может задаваться/определяться как статически, так и динамически по заданным критериям, с учётом, например:

- Производительности
- Текущей утилизации
- Времени отклика
- По настраиваемой пользователем логике



```
upstream myapp1 {
    server 192.168.56.61 weight=20;
    server 192.168.56.62 weight=30;
    server 192.168.56.63 weight=50;
}

server {
    listen 80;
    server_name localhost;

    location / {
        proxy_pass http://myapp1;
    }
}
```

Модуль балансировки нагрузки Скала^р


Отказоустойчивость и проверки



Доступность бэкендов может контролироваться в Балансировщике динамически разными методами, отдельно или в разных сочетаниях, например:

- На уровне сети: **ICMP Ping** – проверка доступности через стандартный ICMP Echo Request
- На уровне транспорта: **TCP Health Check** (TCP Ping) – проверка доступности порта приложения
- На уровне сессии и/или приложения: **HTTP(S) Health Check** – проверка через запрос специального URL, и ожидание корректного кода ответа
- Кастомизированная** проверка по пользовательской логике – с помощью встроенных или внешних скриптов
- Пассивный мониторинг** – без активного опроса, Балансировщик определяет доступность бэкенда по наблюдениям на успешными/неуспешными реальными соединениями

Конечное решение может быть принято как по отдельным критериям оценки работоспособности, так и по совокупности



```
upstream myapp1 {
    server 192.168.56.61 max_fails=2
    fail_timeout=10s;
    server 192.168.56.62 max_fails=2
    fail_timeout=10s;
    server 192.168.56.63 max_fails=2
    fail_timeout=10s;
}

server {
    listen 80;
    server_name localhost;

    location / {
        proxy_pass http://myapp1;
    }
}
```

Модуль балансировки нагрузки Скала^р

Конвертация протоколов





Балансировщик может в ряде сценариев преобразовывать протоколы с фронта на бэкенд.

Например, Балансировщик нагрузки может терминировать на себе **HTTP/HTTPS** (SSL) трафик в различных вариациях и использовать **HTTP без шифрования** при коммуникациях с бэкендами.

Также возможна балансировка трафика с statefull- и stateless-сессиями, по протоколам **TCP/UDP** на уровне L4 без раскрытия, с применением тех же правил и методик, как и для балансировка HTTP.

Например, можно применять Балансировщик для распределения нагрузки на **RDP/VDI** фермы, **SSL VPN** шлюзы.



Модуль балансировки нагрузки Скала^р


Персистентность сессий и распределение



Балансировщик может распределять нагрузку с учётом персистентности клиентских сессий — чтобы трафик от одного пользователя терминировался на одном бэкенде до тех пор, пока он доступен.

Это достигается за счёт применения **хэширования** пользовательских идентификаторов (в простейшем случае — по IP) в динамическом режиме.

Кроме этого, типовые сценарии балансировки предполагают **перенаправление определённой доли** клиентского трафика на выделенный отдельный бэкенд (или группу), например, для постепенного релиза новой версии приложения или сервиса на ограниченную аудиторию.




```
upstream myapp1 {
    ip_hash;
    server 192.168.56.61;
    server 192.168.56.62;
}

server {
    listen 80;
    server_name localhost;
    location / {
        proxy_pass http://myapp1;
    }
}
```

Модуль балансировки нагрузки Скала^р

Мониторинг и графические панели параметров работы



Модуль балансировки нагрузки Скала[®]

Сравнение с конкурентами



№	Параметр	HA Proxy	Nginx	Скала [®] МС.БН	F5
1	Периодическая проверка доступности обслуживающих (бэкенд) серверов	✓		✓	✓
2	Несколько алгоритмов определения доступности сервера: tcp-check, http-check, mysql-check	✓		✓	✓
3	Балансировка HTTP / HTTPS / TCP-запросов между «живыми» серверами	✓	✓	✓	✓
4	Поддержка TLS	✓	✓	✓	✓
5	Возможность закрепления определенных клиентов за конкретными обслуживающими серверами (stick-tables)	✓		✓	✓
6	Поддержка HTTP/2.	✓	✓	✓	✓
7	Балансировка на основе наименьшего потребления полосы пропускания (least bandwidth)			✓	✓
8	Балансировка на основе наименьшего числа пакетов в единицу времени (least packets)			✓	✓
9	Балансировка нагрузки на основе кратчайшего ответа (least time)			✓	✓
10	Постепенная подача трафика на проксируемый сервер (slow start)			✓	✓
11	Обновление списка upstream серверов по SRV-записям DNS	✓	✓	✓	✓
12	Конфигурация через API проксируемых серверов без перезапуска приложения			✓	✓
13	Балансировка по произвольному параметру из ответа на основной или проверочный запрос		✓	✓	✓
14	Поддержка балансировки GSLB с учетом активных проверок upstream серверов у каждого балансера			✓	✓

№	Параметр	HA Proxy	Nginx	Скала [®] МС.БН	F5
15	Поддержка протоколов динамической и статической маршрутизации			✓	✓
16	Встроенная поддержка ACME для перевыпуска сертификатов без использования сторонних утилит (таких как certbot)			✓	✓
17	Поддержка ГОСТ TLS на основе КриптоПро			✓	
18	API для интеграции с Prometheus для сбора метрик в реальном времени			✓	✓
19	Визуальный интерфейс управления конфигурацией и мониторинга с ролевой моделью доступа			✓	✓
20	Наличие технической поддержки производителем на территории России			✓	
21	Возможность приоритизации дорожной карты с вендором			✓	
22	Присутствие в реестре отечественного ПО			✓	
23	GSLB на основе хеша IP адреса назначения/источника, хеш порта/источника				✓
24	GSLB на основе наименьшего числа соединений				✓
25	GSLB на основе кратчайшего ответа				✓
26	GSLB на основе RTT (round-trip time)				✓
27	Возможность аутентификации администратора по Tacacs/Radius/Ldap				✓
28	Поддержка SNMPv3 и SNMP Trap				✓
29	Детальное логирование				✓
30	Возможность формирования отчетов				✓
31	Откат настроек на предыдущее состояние				✓
32	iRules				✓

Модуль балансировки нагрузки Скала^р

Аппаратная поставка в виде модуля МС.БН



- Функциональность локальной балансировки (LTM)
- Функциональность глобальной балансировки (GTM)
- Поддержка динамических протоколов маршрутизации BGP, OSPF, IS-IS
- Сетевые интерфейсы 4x25 Гбит/с на сервер
- Кластер Active-Active
- Производительность 2x20 Гбит/с на Модуль

Дополнительные преимущества:

- Присутствие в реестре ПО (Реестровая запись №24972)
- Локальная техническая поддержка от вендора Скала^р 8x5 или 24x7
- Возможность доработки функционала по требованиям заказчика





Модуль балансировки
нагрузки
Скала^р МС.БН