Akka в Яндекс

JPoint 2014

Вадим Цесько
http://incubos.org
@incubos

Яндекс

18 апреля 2014 г.

jpoint

Предыстория

2 года назад

См. доклад «Потоковая обработка данных с помощью модели акторов (Actor Model)» на ADD-3[a]

[a] http://addconf.ru/talk.sdf/add/add_3/talks/12823

Содержание

- Actor Model на примере Akka
  - Происхождение
  - Концепции и API
  - Примеры кода
- Примеры систем в Яндекс
  - Конвейерная обработка данных
  - Реактивные иерархические системы
- Опыт разработки и эксплуатации
  - Подводные камни
  - Проблемы и некоторые решения
  - Дополнительные тулы

Происхождение

- Carl Hewitt[1], Peter Bishop and Richard Steiger. A Universal Modular Actor Formalism for Artificial Intelligence. 1973.
- Gul Agha. Actors: A Model of Concurrent Computation in Distributed Systems. 1986.
- Изначально для описания параллельных вычислений
- Позднее в качестве основы для многочисленных реализаций

[1] http://letitcrash.com/post/20964174345/carl-hewitt-explains-the-essence-of-the-actor

Actor

- Всё это актор
- Функционируют параллельно
- Асинхронно обмениваются сообщениями
- При обработке сообщения актор может
  - отправить конечное число сообщений другим акторам
  - создать конечное число новых акторов
  - назначить поведение для обработки следующего сообщения
- Порядок доставки сообщений не специфицирован
- Акторы имеют «адреса»

Concurrency vs Parallelism

- Actor Model не про Parallelism, а про Concurrency[2]

Concurrency

Способность выполняться параллельно.

Parallelism

Действительно параллельное выполнение.

[2] Rob Pike. Concurrency is not Parallelism: https://player.vimeo.com/video/49718712

Реализации

- Языки[3] с «родной» поддержкой: Erlang, Scala, ...
- Библиотеки для языков: Scala, Java, F#, ...

Будем рассматривать

Akka (Scala API).

[3] http://en.wikipedia.org/wiki/Actor_model

О проекте

Jonas Bonér:

- Java Champion
- Terracotta JVM clustering, JRockit JVM, AspectWerkz AOP, Eclipse AspectJ

Ресурсы:

- `http://akka.io/docs/`
- `http://letitcrash.com/`

Код:

- `https://github.com/akka/akka`
- Apache V2 license

Производительность

Внимание

Синтетические тесты ☺

Erlang R14B04 vs **Akka** 2.0-SNAPSHOT[4]:

- 1M mps vs **2.1M mps**

Akka 2.0[5]:

- **50M mps**
- 48-core, 128 GB, `ForkJoinPool`

[4] http://letitcrash.com/post/14783691760/akka-vs-erlang

[5] http://letitcrash.com/post/20397701710/50-million-messages-per-second-on-a-single-machine

Особенности реализации

- **300 байт** на актор
- Актор: состояние, поведение, почтовый ящик, список детей, стратегия супервизора
- Множество акторов на множестве нитей
- Нет гарантированной доставки, семантика **at-most-once**, порядок сохраняется
- Сообщения обрабатываются **строго по порядку**
- Иерархия: создаваемые акторы — дети, родитель — супервизор
- Актор скрыт за **переносимой** `ActorRef`
- Подход «Let it crash»

Пути

Примеры

- `akka://system/user/a/b`
- `akka.tcp://system@server.yandex.ru:2552/user/a/b`

Конструирование ссылок

- Создание акторов: `ActorRefProvider.actorOf`
- Поиск акторов: `ActorRefProvider.actorSelection`
- Каждый актор знает себя, родителя и детей

Можно делать так:

```
1 context.actorSelection("../brother") ! msg
2 context.actorSelection("/user/service") ! msg
3 context.actorSelection("../*") ! msg
```

Определение актора

```
1  class Partitioner(partitionStorage: ActorRef) extends Actor {
2
3    def receive = {
4      case PartitionFeed(partner, offers) =>
5          partition(partner, offers)
6      case msg =>
7          log.error("Unsupported message received: {}", msg)
8    }
9
10   def partition(partner: Partner, offers: Traversable[Offer]) {
11     ...
12
13     partitionStorage ! UpdatePartitions(partner, partitioning)
14   }
15 }
```

Создание актора

```
1  val system = ActorSystem("sharder")
2
3  val partitionStorage = ...
4
5  val partitioner =
6    system.actorOf(
7      FromConfig.props(
8        Props[Partitioner](new Partitioner(partitionStorage))
9          .withDispatcher("dispatcher.cpu")),
10     "partitioner")
```

Конфигурация диспетчера

Конфигурация в HOCON[6]:

```
1 dispatchers.cpu {
2   type = Dispatcher
3   executor = "fork-join-executor"
4
5   fork-join-executor {
6     parallelism-min = 4
7     parallelism-factor = 1.0
8   }
9 }
```

[6]Human-Optimized Config Object Notation: https://github.com/typesafehub/config

HOCON

Независимая самоценная библиотека:

- Чистая Java без зависимостей
- Поддерживает Java properties и JSON superset
- Merge и `include` из файлов, URL, classpath
- Мощная поддержка вложенности
- Поддержка duration (`10 seconds`) и size (`512K`)
- Конвертация типов

Диспетчеры

- Dispatcher
- PinnedDispatcher
- BalancingDispatcher
- CallingThreadDispatcher

на

- fork-join-executor
- thread-pool-executor

Почтовые ящики

- UnboundedMailbox
- BoundedMailbox
- UnboundedPriorityMailbox
- BoundedPriorityMailbox

```
1 trait MessageQueue {
2   def enqueue(receiver: ActorRef, handle: Envelope): Unit
3   def dequeue(): Envelope
4   def numberOfMessages: Int
5   def hasMessages: Boolean
6   def cleanUp(owner: ActorRef, deadLetters: MessageQueue): Unit
7 }
```

Пулы акторов

```
akka.actor.deployment {
  /partitioner {
    router = smallest-mailbox-pool
    nr-of-instances = 4
  }
}
```

```
akka.actor.deployment {
  /unifier {
    router = round-robin-pool
    resizer {
      lower-bound = 2
      upper-bound = 16
    }
  }
}
```

Типы роутеров

Реализации `Pool` и `Group`:

- `RoundRobin`
- `Random`
- `SmallestMailbox`
- `Broadcast`
- `ScatterGatherFirstCompleted`
- Самописные

Конфигурирование из кода

```
1 val shardActorPaths: immutable.Seq[String] = ...
2
3 val shard = system.actorOf(
4   RoundRobinGroup(shardActorPaths).props(),
5   "shard")
```

Удалённые акторы

```
1  akka {
2    actor {
3      provider = "akka.remote.RemoteActorRefProvider"
4    }
5
6    remote {
7      enabled-transports = ["akka.remote.netty.tcp"]
8
9      netty.tcp {
10       hostname = "server.yandex.ru"
11       port = 2553
12     }
13   }
14 }
```

Тестирование акторов

- Модульное тестирование с `TestActorRef`
- Интеграционное тестирование с `Probe`
- Проверки с сопоставлением по шаблону

Пример теста

```
1  val probe = TestProbe()
2  val burstScaler = TestActorRef(new BurstScaler(probe.ref))
3
4  before {
5    burstScaler.underlyingActor.sent =
6        burstScaler.underlyingActor.sent.empty
7  }
8
9  "A BurstScaler" should {
10   "always forward the first message" in {
11     probe.within(1 second) {
12       burstScaler ! 1
13       probe.expectMsg(1)
14     }
15   }
16 }
```

Супервизор

Решение при сбое:

1. `Resume`
2. `Restart`
3. `Stop`
4. `Escalate`

- Принятое решение (1-3) действует рекурсивно
- Функция `Exception` $\Rightarrow$ `Directive`
- `Terminated`, `preStart`, `preRestart`, `postStop`, `postRestart`
- `OneForOneStrategy` и `AllForOneStrategy`
- Ограничение количества перезапусков

Супервизор по умолчанию

```
1 final val defaultDecider: Decider = {
2   case _: ActorInitializationException => Stop
3   case _: ActorKilledException         => Stop
4   case _: DeathPactException           => Stop
5   case _: Exception                    => Restart
6 }
7
8 final val defaultStrategy: SupervisorStrategy =
9   OneForOneStrategy()(defaultDecider)
```

Классификация

- Конвейерная индексация
  - Яндекс.{Авто, Недвижимость, Работа}
  - etc.
- Иерархическая обработка пользовательских запросов
  - Spray[7]
  - Маршрутизация и обработка кликов и показов
  - Матчинг объявлений на подписки
  - etc.

[7] http://spray.io

Конвейер

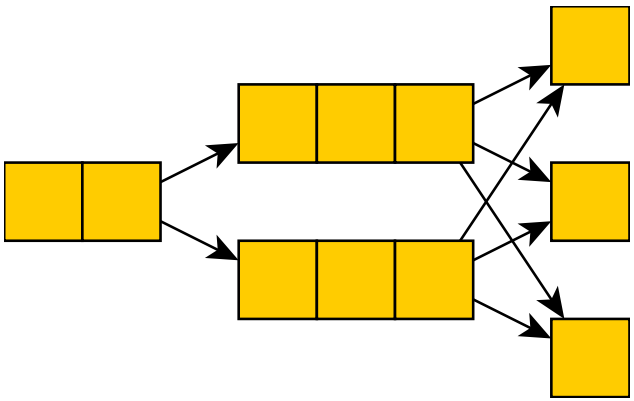

- Масштабируемость
- Устойчивость к сбоям
- Ограниченные очереди
- Back pressure
- Выделенные диспетчеры
- Детерминированное потребление памяти
- Графики размеров очередей
- Декомпозиция стадий
- Масштабирование пулами
- Загрузка CPU 100%

Яндекс.Авто: Архитектура

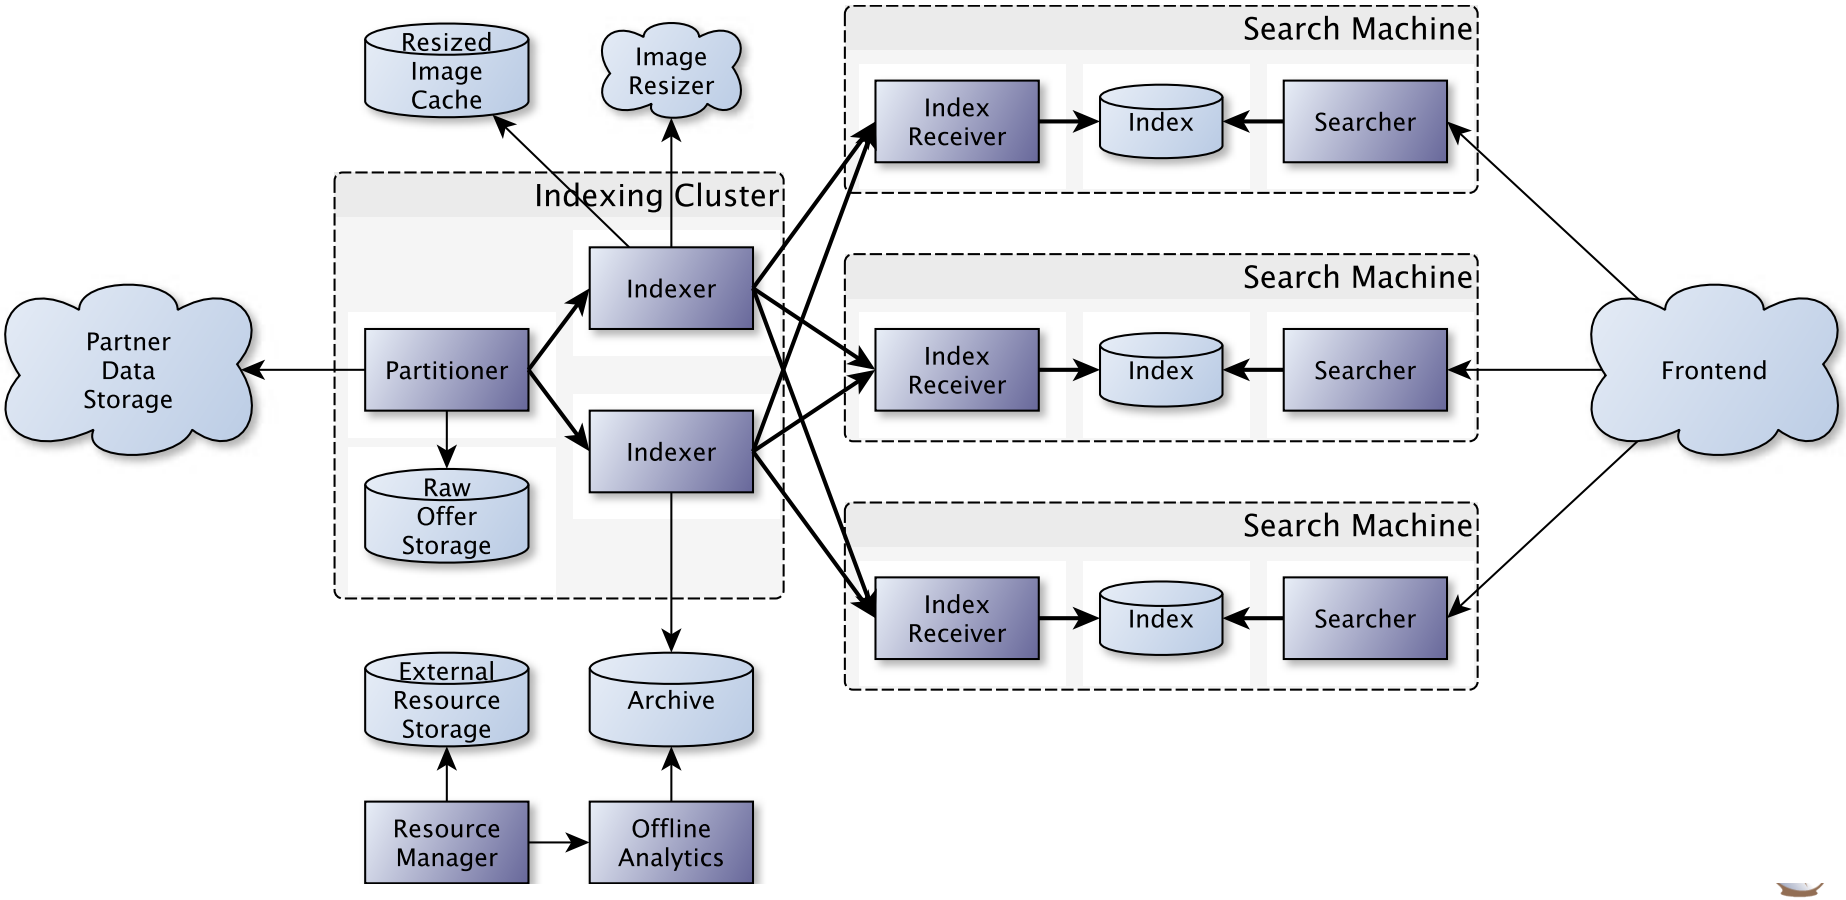

Яндекс.Авто: Гиперконвейер

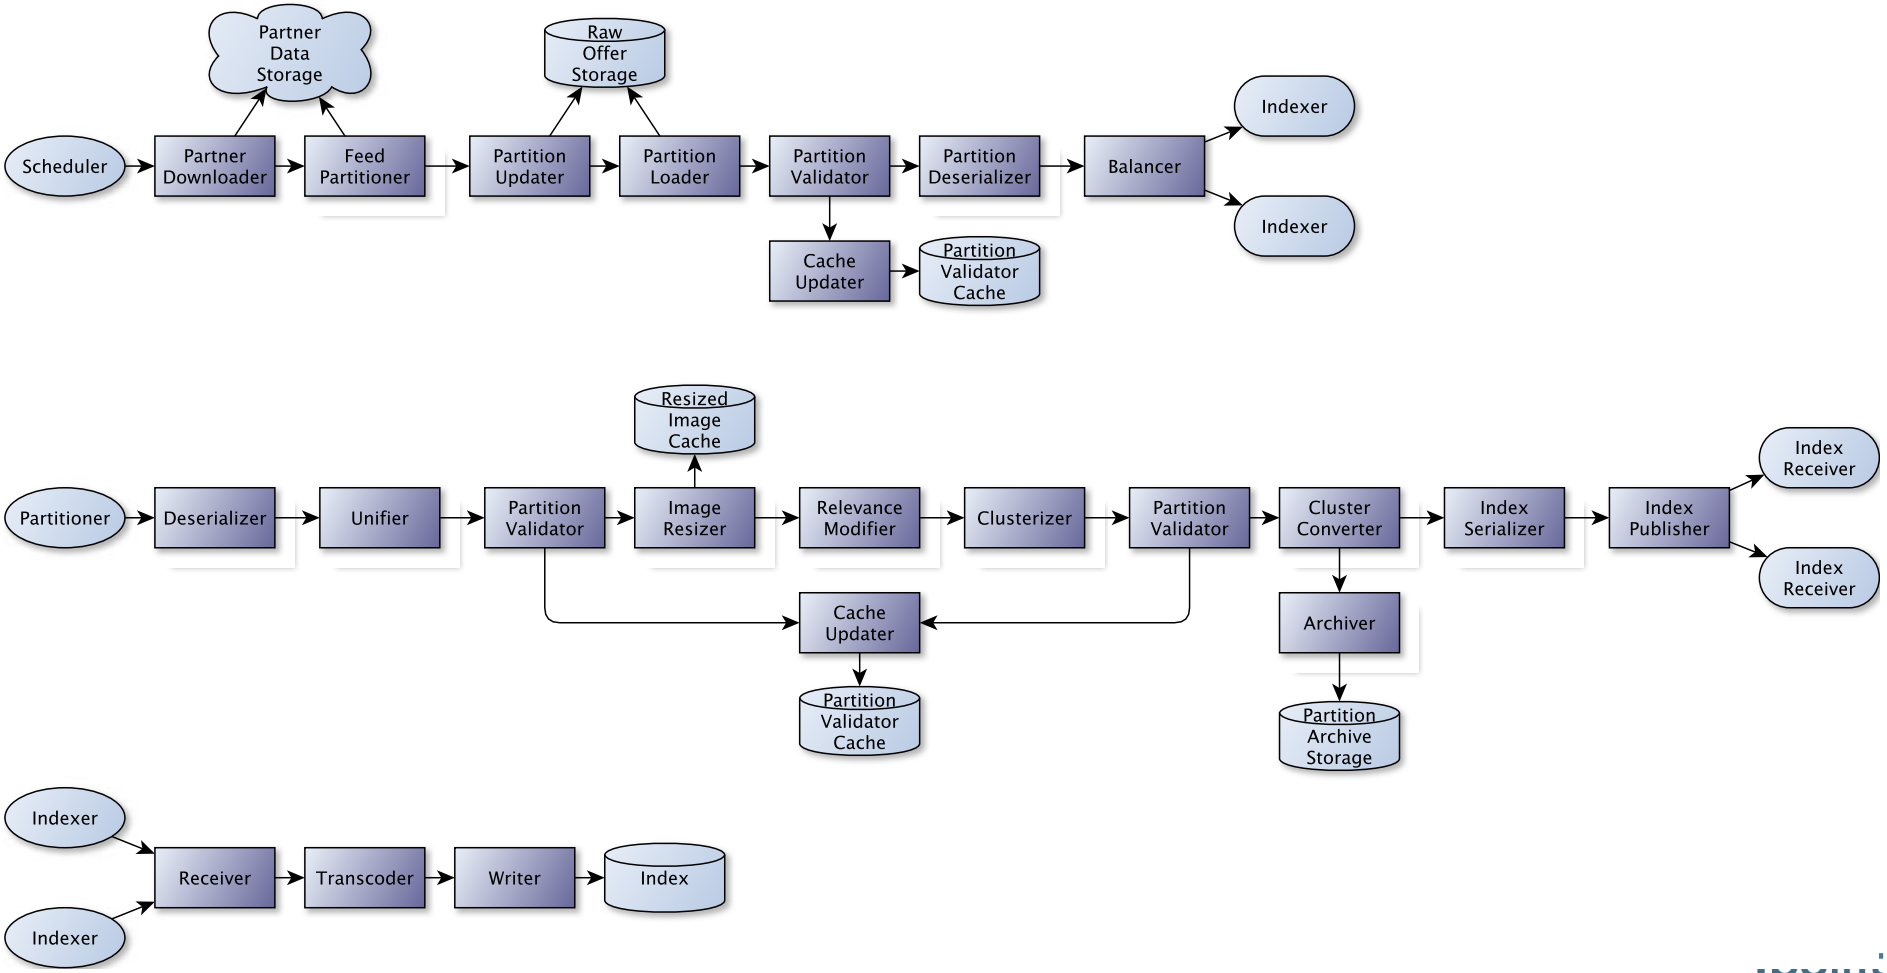

Яндекс.Авто: Цифры

- **4 ДЦ**, **4 машины** для индексации, **60 машин** для поиска (общие для разных сервисов)
- Больше **2M объявлений**
- Время в конвейере — до **5 мин**
- Принудительная переиндексация — каждые **15 мин**
- Объём поискового индекса — больше **2 ГБ**
- Scala — **8 KLOC**, Java — **210 KLOC**

Инструментированные очереди

Metrics[8] + Graphite:

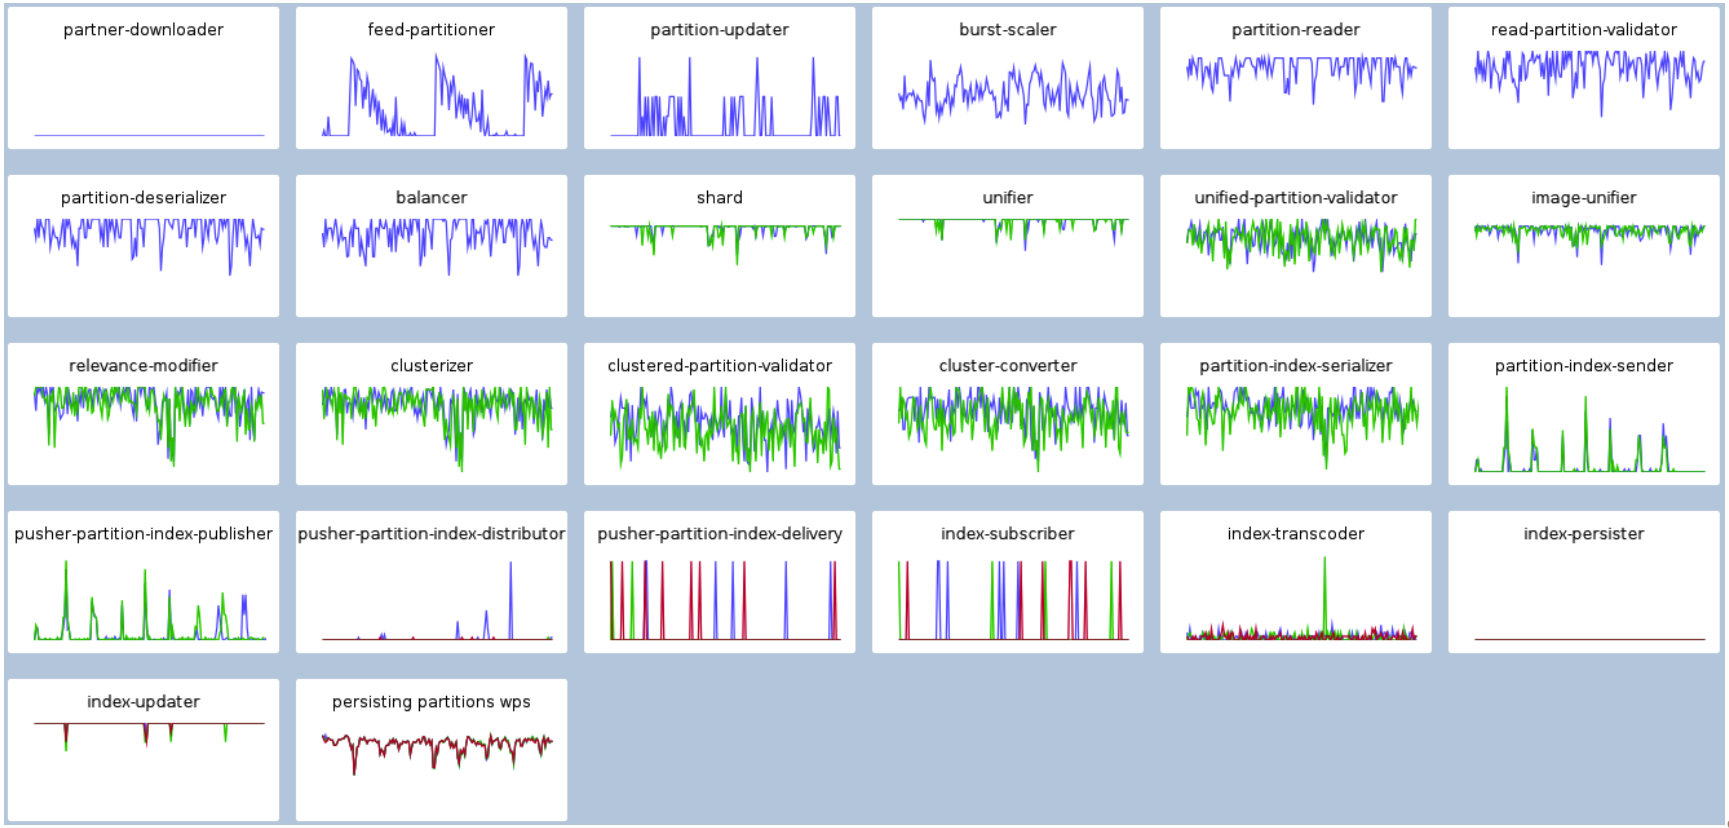

[8] http://metrics.codahale.com/

Диагностика

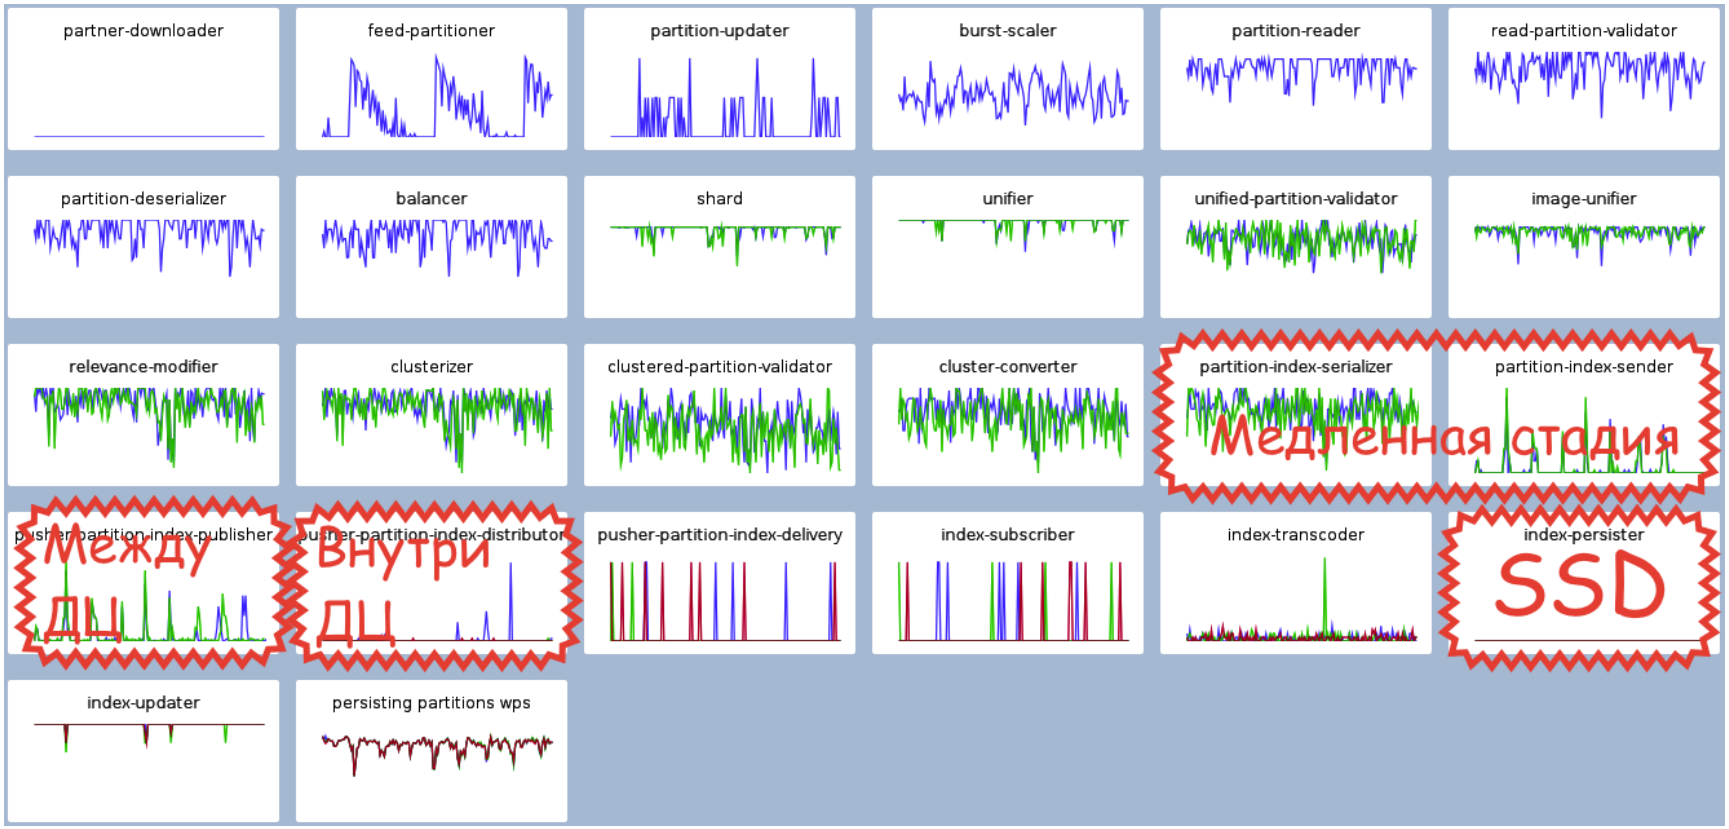

Интересное

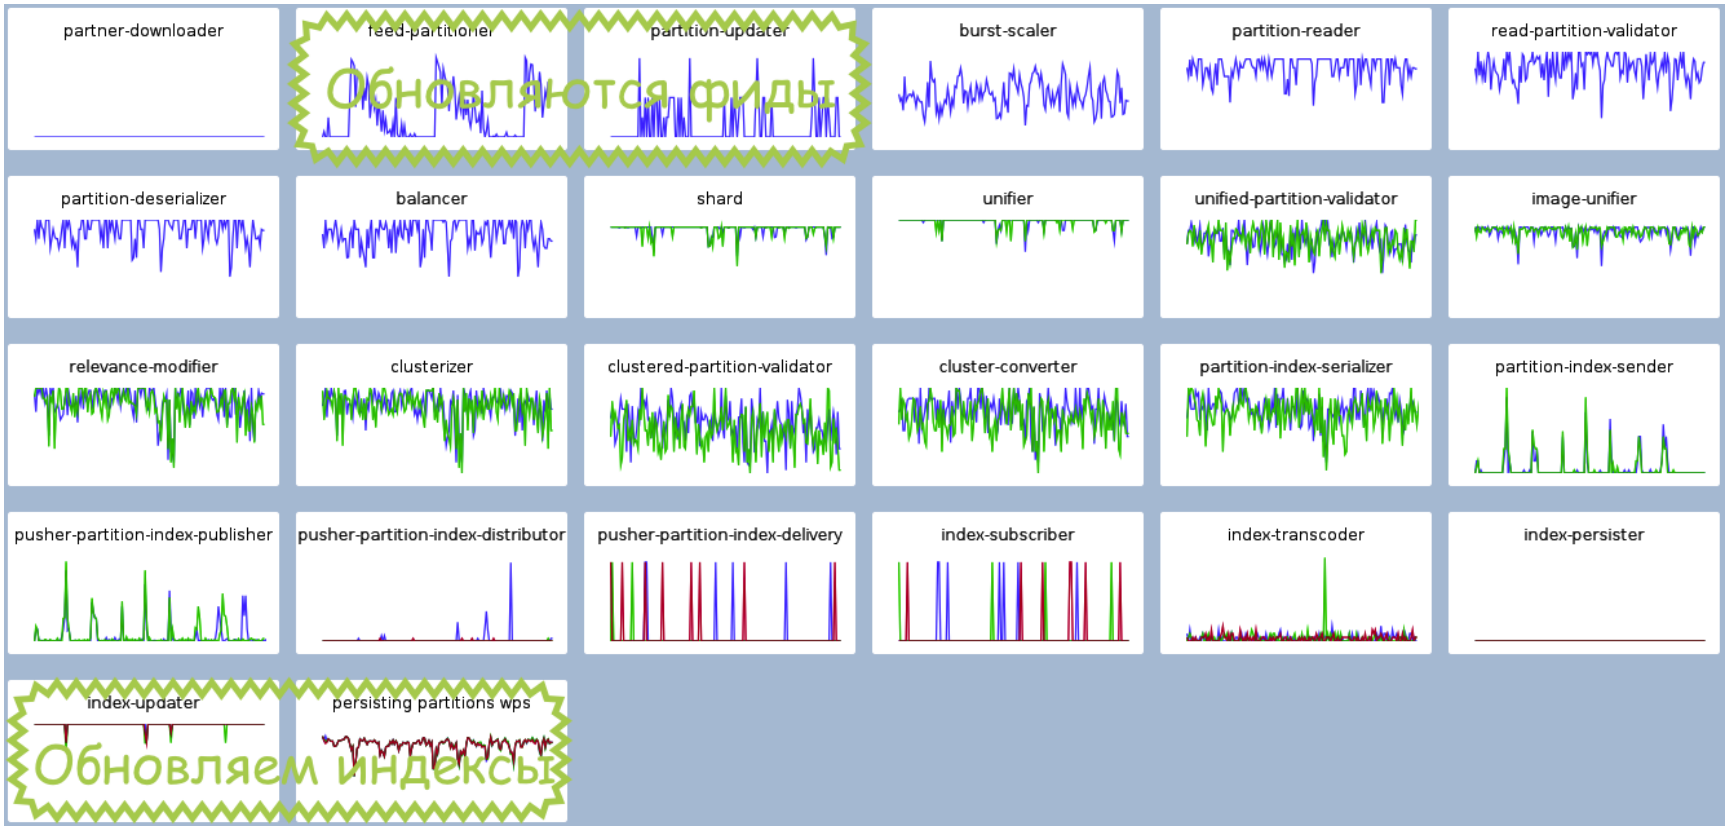
partner-downloader
feed-partitioner
partition-updater
Обновляются фиды
burst-scaler
partition-reader
read-partition-validator
partition-deserializer
balancer
shard
unifier
unified-partition-validator
image-unifier
relevance-modifier
clusterizer
clustered-partition-validator
cluster-converter
partition-index-serializer
partition-index-sender
pusher-partition-index-publisher
pusher-partition-index-distributor
pusher-partition-index-delivery
index-subscriber
index-transcoder
index-persister
index-updater
persisting partitions wps
Обновляем индексы

Специфика

Для прореживания потока задач:

- `BurstScaler`
- `InstrumentedUnboundedSkipClonesMailbox`
- `InstrumentedSkippingBoundedMailbox`

Горизонтальное масштабирование (1)

Планировали масштабировать индексацию так:

- Добавляем машины-`indexer`'ы
- Используем `RoundRobin`- или `Random`-пул

Не работает

Одна из машин патологически тупит — сильно тормозит весь конвейер

`AdaptiveBalancer`

Измеряем время пропихивания данных и штрафуем на некоторое время втупливающие ноды

Горизонтальное масштабирование (2)

Обновление данных на поисковых машинах:

- Несколько ДЦ + *ненадёжная* сеть

Эволюция

- `BroadcastPool`
- ZeroMQ (EPGM, TCP)
- JGroups (Multicast + Relay)

Akka-based Spanning Tree

- Доставляем хотя бы одной ноде в каждом ДЦ
- Нода распространяет данные внутри ДЦ
- Всё на `akka-remote` + ZooKeeper
- Тюнинг и патчинг `akka-remote`

Иерархическая обработка

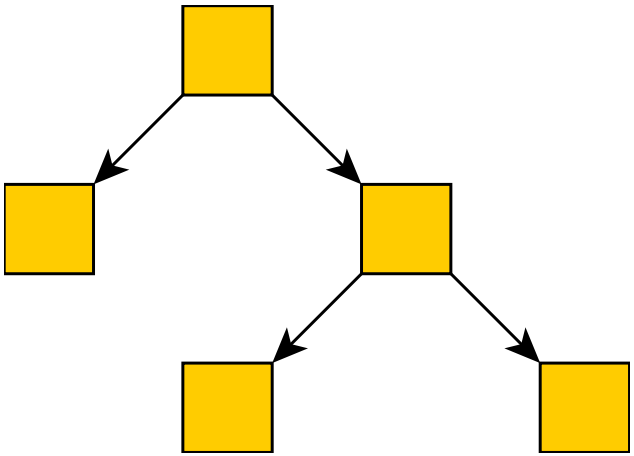

- Масштабируемость
- Высокая доступность
- Естественные подсистемы
- Часто динамическая топология
- Actor per request
- Request-reply

Иерархические системы

- Внутренние сервисы
- Иерархия акторов для каждого активного пользователя/подписки/визита/запроса
- Динамическая выгрузка/подгрузка сущностей
- Распределение пользователей на бакеты (и ноды) через ZooKeeper + Curator[9] (Consistent Hashing[10])

[9] http://curator.apache.org

[10] http://en.wikipedia.org/wiki/Consistent_hashing

Компонент сервиса уведомлений

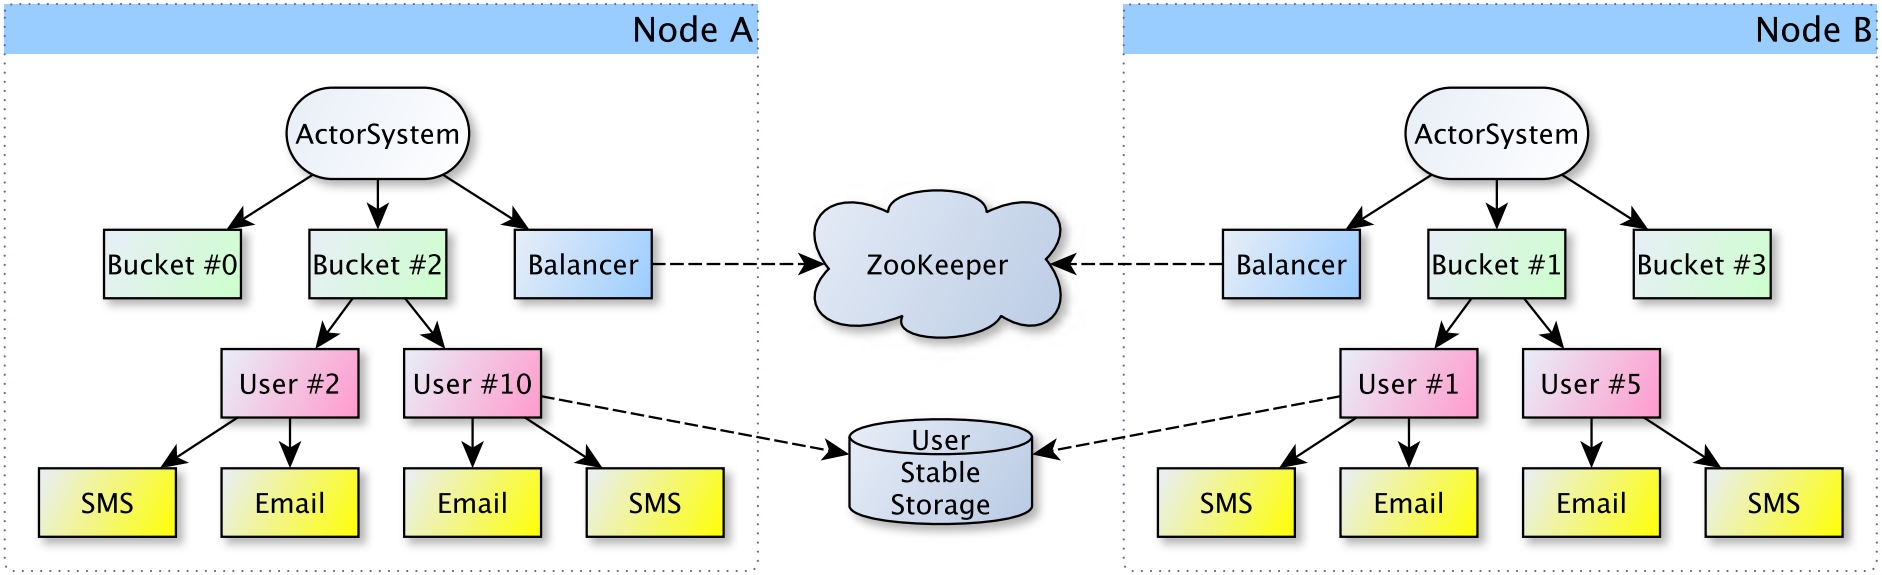

О чём нужно думать

- Наблюдаемость
  - Логгирование
  - Агрегатные графики
  - Мониторинги
- Поведение при перегрузке
  - Детектирование перегрузки
  - Ограничение ресурсов
  - Превентивный reject
  - Восстановление после перегрузки
  - Выравнивание нагрузки

Deadlocks

Ограниченные ресурсы:

- Очереди
- Диспетчеры
- Пулы нитей (в т. ч. в `akka-remote`)
- Косвенная синхронизация между акторами

Типы:

- Локальные
- **Распределённые**

OOMs

Возможные причины:

- Перегрузка + неограниченные очереди
- Логические утечки памяти (в т. ч. через замыкания, см. `ActorContext.sender`)

Logging

ActorLogging

- `Slf4jLogger` (Logback) vs `akka.loglevel`
- Перегрузка `EventBus`
- OOM

Решение

- Использовать `slf4j-api` напрямую
- Обёртки для наполнения MDC спецификой Akka

Dead Letters

Внимание

В любой непонятной ситуации сообщение пойдёт в `DeadLetter`

Рекомендация

Подписываться на `DeadLetter`, логгировать, вылавливать и мониторить «интересные» сообщения

Blocking

- Актор на время обработки сообщения берёт нитку из диспетчера
- Thread starvation при блокировании в акторе
- Особенно «интересные» результаты на `default-dispatcher`

Рекомендация

Запускайте блокирующихся акторов на собственном выделенном диспетчере

Akka и JMM

Happens before

- Message `send` happens before `receive`
- Actor `receive` happens before previous `receive`

Следствия:

- Не нужно защищать состояние актора
- Возможны гонки на изменяемых сообщениях
- Используйте неизменяемые структуры данных[11]

[11] Chris Okasaki. *Purely Functional Data Structures*. 1999. `http://www.cs.cmu.edu/~rwh/theses/okasaki.pdf`

Наблюдаемость

Статическая топология

Никаких проблем

Динамическая топология

Пока только с привлечением мозга

Akka

- Бинарная несовместимость на пустом месте
- API иногда колбасит (диспетчеры и очереди)
- До многих вещей не дотянуться — приходится копипастить и патчить

Scala

- `spray-routing` (`shapeless`) крепкий орешек для IDEA
- Closures (call-by-name, laziness) — утечки памяти, гонки и гейзенбаги
  - Незащищённое состояние актора
  - В т. ч. `sender()`

Рассмотрели

- Actor Model в реализации Akka
- Конвейерные и иерархические системы на Akka
- Некоторые проблемы и решения

В итоге

- Прошли путь от Akka 1.x до 2.3.x
- 1.5 года в production
- Множество граблей, но жить можно
- Исключительно простой и выразительный формализм
- Удобно проектировать, разрабатывать и тестировать

Ссылки

- «Потоковая обработка данных с помощью модели акторов (Actor Model)» на ADD-3[12]
- Typesafe Activator[13]
- Principles of Reactive Programming[14]
- Книги:
  - Jamie Allen. *Effective Akka*. 2013
  - Derek Wyatt. *Akka Concurrency*. 2013
  - Series: The Neophyte's Guide to Scala[15]
  - EAI Patterns Series[16]

[12] http://addconf.ru/talk.sdf/add/add_3/talks/12823

[13] http://typesafe.com/activator

[14] https://class.coursera.org/reactive-001/class

[15] http://letitcrash.com/post/64667109914/series-the-neophytes-guide-to-scala

[16] http://letitcrash.com/post/59190266995/

Вопросы?

- http://incubos.org/contacts/
- @incubos
- vadim.tsesko@gmail.com

Alan Kay on OOP, 1967

I thought of objects being like biological cells and/or individual computers on a network, only able to communicate with messages (so messaging came at the very beginning – it took a while to see how to do messaging in a programming language efficiently enough to be useful).
OOP to me means only messaging, local retention and protection and hiding of state-process, and extreme late-binding of all things. It can be done in Smalltalk and in LISP. There are possibly other systems in which this is possible, but I'm not aware of them.