



Яндекс



Использование распределенной
очереди задач для обработки данных
в бэкенде Яндекс Спортa

Александр Южаков
20 сентября 2014

Агрегация данных



Задачи решаемые на бэкенде

- Импорт и обработка данных
- Валидация импорта
- Интернационализация
- Хранение данных, модерация

Задачи решаемые на бэкенде

- Подготовка данных (экспорт) для API и фронта
- Полное логирование процессов импорта/экспорта
- Независимость модулей различных видов спорта

Задачи решаемые на бэкенде

- Высокая скорость работы
- Балансировка нагрузки
- Отказоустойчивость

Особенности спортивных проектов

- Данных не очень много
- Строгие требования к свежести данных
- Множество источников, различные форматы
- Схожие сущности в различных видах спорта будут иметь разные схемы данных

Особенности спортивных проектов

- Большие пиковые нагрузки, при относительно низких средних нагрузках
- Всегда есть задержки в данных относительно реальности
- Дедлайн не перенести

спортсмены

...

расписание

...

результаты

составы
команд


...

расписание ТВ

...

онлайн
трансляции

видео лучших
моментов и голов



Яндекс **Бразилия-2014** Расписание Плей-офф Команды

Что ищут болельщики

О каких матчах и участниках Чемпионата мира по футболу в Бразилии чаще всего спрашивали у Яндекса.

Бразилия — Германия

1:7

Яндекс **русская премьер лига 2014-2015** — 427 тыс. ответов

Футбол. Чемпионат России

Турнирная таблица По дням

	И	В	Н	П	Р	О
1. Зенит	4	4	0	0	15:2	12
2. Спартак	4	3	0	1	7:6	9
3. Динамо	4	3	0	1	12:6	9
4. ЦСКА	4	3	0	1	6:2	9
5. Краснодар	4	2	2	0	7:1	8
6. Локомотив	4	2	2	0	5:2	8

Все команды

Лига Европы

Матч завершен 22 августа

Реал Сосьедад — Краснодар

1:0

71' Хаби Прието 1:0 ▶

Информация о матче:
Championat.com, Livesport.ru,
Sportbox.ru, [еще 4](#)

Инструментарий



Celery 3.1.x

- Python 2.x
- Django
- MySQL
- MongoDB

Celery

```
# предварительно необходимо сконфигурировать Celery  
# и запустить воркеры
```

```
from celery import task
```

```
@task
```

```
def my_super_task(*args, **kwargs):  
    do_some_magic_here()
```

```
from celery import Task
```

```
class MyMegaTask(Task):
```

```
    def __init__(*args, **kwargs):  
        initialization(*args, **kwargs)
```

```
    def run(*task_args, **task_kwargs):  
        task_job_here(*task_args, **task_kwargs)
```

Задачи импорта в виде функций

@task

def

import_

competition

event

person

team

result

...

for each sports

(...):

Задачи импорта в виде функций

```
@task
def import_smth(source):
    raw_data = get_data_from_source(source)
    data = parse_and_validate_data(raw_data)
    import_results = import_data(data)
    do_smth_after_import(import_results)
```

Плюс

+ просто и очевидно

Задачи импорта в виде функций

Минусы:

- многократное повторение одного и того же кода
- нет возможности использовать уже готовые функции импорта/экспорта с небольшими изменениями
- трудно отслеживать движение задачи
- сложно обрабатывать исключения

К чему мы пришли...

Задачи как классы

```
class BaseTask(Task):
    abstract = True

    @classmethod
    def task(cls):
        return cls.app.tasks[cls.name]

    @property
    def type(self):
        ...

    def on_success(self, retval, task_id, args, kwargs):
        ...

    def on_retry(self, exc, task_id, args, kwargs, einfo):
        ...

    def on_failure(self, exc, task_id, args, kwargs, einfo):
        ...

    def delay(self, *args, **kwargs):
        ...
```


Базовый класс для импорта

```
class Importer(BaseTask):
    abstract = True
    ... # class fields

    @classmethod
    def import_data(cls, url, params=None, *args, **kwargs):
        ...

    @classmethod
    def prepare_cache(cls, data, params=None, **kwargs):
        ...

    @classmethod
    def import_chunk(cls, chunk, cache, params=None, **kwargs):
        raise NotImplementedError

    def run(self, url, params, *args, **kwargs):
        key = md5(url).hexdigest()
        with MongoLock('import_locks', key) as lock:
            self.import_data(url, params, *args, **kwargs)
```

```

@classmethod
def import_data(cls, url, params=None, *args, **kwargs):
    try:
        data = cls.prepare_and_validate(url, params=params, **kwargs)
        cache = cls.prepare_cache(data, params, **kwargs)
    except ValidationError, e:
        ... # отбрасываем данные как плохие, с обработкой ошибки

    cls.before_import(data, cache, **kwargs)
    changed_objects = []
    for chunk in data:
        try:
            inst, changed = cls.import_chunk(
                chunk, cache, params=params, **kwargs
            )
            if cls.multilang:
                cls.import_translations(chunk, cache, **kwargs)
            if changed:
                changed_objects.append(inst.pk)
        except SkipImport as e:
            ... # отбрасываем только часть данных

    cls.after_import(data, cache, **kwargs)
    if changed_objects:
        ... # автоэкспорт объектов которые изменились

```

Пример импорта команд в футболе

```
# def prepare_cache(...):|

@classmethod
def import_chunk(cls, data, cache, params=None, **kwargs):
    match, created = models.Match.objects.get_or_create(
        outer_id=data['n_MatchID'],
    )

    data.update({
        'team1': cache['teams'].get(data['n_HomeTeamID']),
        'team2': cache['teams'].get(data['n_AwayTeamID']),
        'n_Result1': data['n_HomeGoals'],
        'n_Result2': data['n_AwayGoals'],
        'score': data['c_Score'],
        'score_suffix': data['c_ScoreSuffix'],
        'team1_goals_shootout': data['n_HomeGoalsShootout'],
        'team2_goals_shootout': data['n_AwayGoalsShootout']
    })

    return match, update_instance(match, data, created, **kwargs)
```

Плюсы?

- + Минимум кода
- + Фокус на импорте данных без явного взаимодействия с подсистемами
- + Обработка ошибок через генерацию стандартных исключений (`SkipImport`, `ValidationError`)

Плюсы?

- + Декларативность
- + Стандартизация логирования
- + Предварительное кэширование для оптимизации работы с БД
- + Многоуровневая абстракция

Минусы?

- Стал выше порог вхождения для программиста

Еще много чего интересного...

- Классы экспортеры
- Классы импорта/экспорта переводов из Танкера
- Удобное централизованное логирование


Логи

eb41e6a8a16b	football.MatchInfoImporter	Finished
eb41e6a8a16b	football.MatchInfoImporter	New task (PlayoffExporter) enqueued: e945b8b66d43
eb41e6a8a16b	football.MatchInfoImporter	New task (MatchAPIExporter) enqueued: f7fad79d6683
eb41e6a8a16b	football.MatchInfoImporter	New task (EventsExporter) enqueued: 712de80d1e82
eb41e6a8a16b	football.MatchInfoImporter	Match with id = 423069 was changed Details here.
eb41e6a8a16b	football.MatchInfoImporter	In progress.
eb41e6a8a16b	football.MatchInfoImporter	Import url: http://yandex.api.infostradasports.com/svc/Football.svmatchid=1905292&languagecode=2
eb41e6a8a16b	football.MatchInfoImporter	Task enqueued.

Еще много чего интересного...

- Импорт переводов (если данные на разных языках)
`import_translations(data, cache, *args, **kwargs)`
- Интеграция в Django-админку
- Независимость модулей системы
- Класс `Resolver` для автоимпорта по URL

Админка



Спасибо за внимание!