



Гармония по-жёсткому

Параллелизм и упорядоченность в Transactional Outbox

Виталий Сушков

.NET developer | T-Bank

- Разрабатываю ПО с 2010 года
- С 2018 года использую .NET
- С 2022 года работаю в Т-Банке
- Автор библиотеки фоновых задач Jobby



Рассмотрим сценарий




Выполнить транзакцию в БД




Вызвать другую систему



Гарантированно
должны быть выполнены либо
обе операции, либо ни одной




Transactional Outbox




Ожидаемые гарантии

- ✓ **At least once**
- ✓ Обработка по порядку для связанных сообщений
- ✓ Параллельная обработка для не связанных сообщений



Ожидаемые гарантии

- ✓ At least once
- ✓ **Обработка по порядку для связанных сообщений**
- ✓ **Параллельная обработка для не связанных сообщений**



В докладе



**Два принципиально разных подхода
к реализации Transactional Outbox**

В докладе

- Два принципиально разных подхода к реализации Transactional Outbox
- **Эффективная реализация параллелизма и упорядоченности в обоих подходах**

В докладе

- Два принципиально разных подхода к реализации Transactional Outbox
- Эффективная реализация параллелизма и упорядоченности в обоих подходах
- **Погружение в неочевидные особенности PostgreSQL**

В докладе

- ➔ Два принципиально разных подхода к реализации Transactional Outbox
- ➔ Эффективная реализация параллелизма и упорядоченности в обоих подходах
- ➔ Погружение в неочевидные особенности PostgreSQL
- ➔ **Асинхронная архитектура фоновых сервисов на .NET**

A decorative yellow curved line that starts from the left edge, curves upwards and then downwards, framing the central text.

Подходы к реализации Outbox

Создание записей для Outbox через ORM



```
// Бизнес-логика
var order = await _dbContext.Orders
    .FirstOrDefaultAsync(x => x.Id == orderId);
order.Cancel(reason);

// Сообщение для outbox
var orderCancelledEvent = new OrderCancelledEvent(orderId, reason);
var outboxMessage = _outboxMessageFactory.Create(orderCancelledEvent);
_dbContext.Add(outboxMessage);

// Сохранить в одной транзакции
await _dbContext.SaveChangesAsync();
```

CDC / Debezium




Готовое решение



Читает записи из WAL



Отправляет в Kafka




Возможные сложности с Debezium

- ➔ **Инфраструктурные и операционные сложности и накладные расходы**
(Debezium, Kafka Connect, Avro, ...)
- ➔ **Низкий уровень гибкости при обработке**
(фиксированный формат сообщений, сложнее сделать приоритезацию, агрегацию батчей, сложную retry-логику)
- ➔ **Требует доступа к слоту репликации**
- ➔ **Риск роста WAL при нештатных ситуациях**

Чтение через SQL-запросы

- ✓ Своя реализация на привычном стеке
- ✓ Получение записей SQL-запросами по PULL-модели
- ✓ Обработка записей целевым образом



Подход на основе статусов

Поле **status** (New / Processing / ...)

VS

Подход на основе смещений (Kafka-Inspired)

Поле **num** (монотонно возрастающее)

Подход на основе статусов

Поле status (New / Processing / ...)

-- Чтение записей для обработки

```
SELECT * FROM outbox  
WHERE status = New  
ORDER BY created_at FOR UPDATE;
```

```
UPDATE outbox SET status = Processing;  
WHERE id = :selected
```

-- После обработки

```
DELETE FROM outbox WHERE id = ...
```

VS

Подход на основе смещений

Поле num (монотонно возрастающее)

Подход на основе статусов

Поле status (New / Processing / ...)

-- Чтение записей для обработки

```
SELECT * FROM outbox  
  WHERE status = New  
  ORDER BY created_at FOR UPDATE;
```

```
UPDATE outbox SET status = Processing;  
WHERE id = :selected
```

-- После обработки

```
DELETE FROM outbox WHERE id = ...
```

VS

Подход на основе смещений

Поле num (монотонно возрастающее)

Подход на основе статусов

Поле status (New / Processing / ...)

-- Чтение записей для обработки

```
SELECT * FROM outbox
  WHERE status = New
  ORDER BY created_at FOR UPDATE;
```

```
UPDATE outbox SET status = Processing;
WHERE id = :selected
```

-- После обработки

```
DELETE FROM outbox WHERE id = ...
```

VS

Подход на основе смещений

Поле num (монотонно возрастающее)

-- Чтение записей для обработки

```
SELECT * FROM outbox
  WHERE num > :lastProcessedNum
  ORDER BY num;
```

-- После обработки

```
UPDATE consumer_offset
  SET offset = :processedMessage.Num;
```

Подход на основе статусов

Поле status (New / Processing / ...)

-- Чтение записей для обработки

```
SELECT * FROM outbox
  WHERE status = New
  ORDER BY created_at FOR UPDATE;
```

```
UPDATE outbox SET status = Processing;
WHERE id = :selected
```

-- После обработки

```
DELETE FROM outbox WHERE id = ...
```

VS

Подход на основе смещений

Поле num (монотонно возрастающее)

-- Чтение записей для обработки

```
SELECT * FROM outbox
  WHERE num > :lastProcessedNum
  ORDER BY num;
```

-- После обработки

```
UPDATE consumer_offset
  SET offset = :processedMessage.Num;
```

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

VS

Подход на основе смещений

Эффективная работа с БД
(Таблица сообщений INSERT ONLY)

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

Сообщения не связаны
между собой

Просто распараллеливается
и масштабируется

VS

Подход на основе смещений

Эффективная работа с БД
(Таблица сообщений INSERT ONLY)

Сообщения жёстко связаны

Сложно распараллеливать
и масштабировать

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

Сообщения не связаны
между собой

Просто распараллеливается
и масштабируется

К параллелизму
сложно добавить упорядоченность

VS

Подход на основе смещений

Эффективная работа с БД
(Таблица сообщений INSERT ONLY)

Сообщения жёстко связаны

Сложно распараллеливать
и масштабировать

Упорядоченность из коробки

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

Сообщения не связаны
между собой

Просто распараллеливается
и масштабируется

К параллелизму
сложно добавить упорядоченность

VS


Подход на основе смещений

Эффективная работа с БД
(Таблица сообщений INSERT ONLY)

Сообщения жёстко связаны

Сложно распараллеливать
и масштабировать

Упорядоченность из коробки

A decorative yellow curved line that starts from the left edge, curves upwards and then downwards, framing the text on the right side.

Подход на основе статусов

Примеры применения

Доклад о Jobby с DotNext 2025
«Ускоряя невидимое: разработка эффективной библиотеки фоновых задач»



Hangfire

Очень ограниченные
возможности упорядоченной
обработки при сохранении
параллелизма

01

Quartz

Очень ограниченные
возможности упорядоченной
обработки при сохранении
параллелизма

02

CAP

Параллелизм и
упорядоченность
не поддерживаются
одновременно


03

Jobby

**Возможно совмещать
параллельную
и упорядоченную
обработку**

04


Запрос для получения готовых к запуску задач



TakeJobs... x

```
WITH ready_jobs AS (  
    SELECT id FROM jobby_jobs  
    WHERE  
        "status" = Scheduled  
        AND scheduled_start_at <= now()  
    ORDER BY scheduled_start_at  
    LIMIT :batchSize  
    FOR UPDATE SKIP LOCKED  
)  
UPDATE jobby_jobs  
SET  
    "status" = Processing,  
    started_count = started_count + 1  
WHERE id IN (SELECT id FROM ready_jobs)  
RETURNING *;  
  
-- Составной индекс (status, scheduled_start_at)
```


Запрос для получения готовых к запуску задач



TakeJobs... x

```
WITH ready_jobs AS (  
    SELECT id FROM jobby_jobs  
    WHERE  
        "status" = Scheduled  
        AND scheduled_start_at <= now()  
    ORDER BY scheduled_start_at  
    LIMIT :batchSize  
    FOR UPDATE SKIP LOCKED  
)  
UPDATE jobby_jobs  
SET  
    "status" = Processing,  
    started_count = started_count + 1  
WHERE id IN (SELECT id FROM ready_jobs)  
RETURNING *;  
  
-- Составной индекс (status, scheduled_start_at)
```

Запрос для получения готовых к запуску задач




TakeJobs... x

```
WITH ready_jobs AS (  
    SELECT id FROM jobby_jobs  
    WHERE  
        "status" = Scheduled  
        AND scheduled_start_at <= now()  
    ORDER BY scheduled_start_at  
    LIMIT :batchSize  
    FOR UPDATE SKIP LOCKED  
)  
UPDATE jobby_jobs  
SET  
    "status" = Processing,  
    started_count = started_count + 1  
WHERE id IN (SELECT id FROM ready_jobs)  
RETURNING *;
```

```
-- Составной индекс (status, scheduled_start_at)
```

Алгоритм получения и запуска задач




Параллелизм



Параллельное выполнение
внутри одного узла



Естественным образом
масштабируется на N узлов



Группы последовательного выполнения

≡ GroupId ×

```
// У задачи можно указать ID группы
await jobbyClient.EnqueueCommandAsync(command, new JobOpts
{
    SerializableGroupId = command.OrderId
});

// Задачи с одинаковой группы выполняются строго по одной

// Задачи с разными группами или без группы выполняются параллельно
```

Блокировка по факту статуса

Группа считается заблокированной
если:

- В группе существует задача
в статусе **Processing**
- В группе **упавшая задача**
которая должна блокировать группу

Вычисляемое поле is_group_locker

```
ALTER TABLE jobby_jobs
ADD COLUMN IF NOT EXISTS is_group_locker BOOLEAN GENERATED ALWAYS AS (
    -- Если есть группа
    group_id IS NOT NULL

    -- И задача в работе ИЛИ (упала И должна блокировать группу при падении)
    AND (
        "status" = PROCESSING
        OR (
            lock_group_if_failed = TRUE
            AND (
                "status" = FAILED
                OR "status" = SCHEDULED AND started_count > 0
            )
        )
    )
) STORED;
```

Вычисляемое поле is_group_locker

```
ALTER TABLE jobby_jobs
  ADD COLUMN IF NOT EXISTS is_group_locker BOOLEAN GENERATED ALWAYS AS (
    -- Если есть группа
    group_id IS NOT NULL

    -- И задача в работе ИЛИ (упала И должна блокировать группу при падении)
    AND (
      "status" = PROCESSING
      OR (
        lock_group_if_failed = TRUE
        AND (
          "status" = FAILED
          OR "status" = SCHEDULED AND started_count > 0
        )
      )
    )
  ) STORED;
```

Вычисляемое поле is_group_locker

```
ALTER TABLE jobby_jobs
  ADD COLUMN IF NOT EXISTS is_group_locker BOOLEAN GENERATED ALWAYS AS (
    -- Если есть группа
    group_id IS NOT NULL

    -- И задача в работе ИЛИ (упала И должна блокировать группу при падении)
    AND (
      "status" = PROCESSING
      OR (
        lock_group_if_failed = TRUE
        AND (
          "status" = FAILED
          OR "status" = SCHEDULED AND started_count > 0
        )
      )
    )
  ) STORED;
```

Ограничение уникальности блокировки группы

Partial-индекс на group_id
который не позволит иметь более
одного локера на одну группу

☰ Unique Lock ×

- Индекс, который не позволит иметь
- более одного локера в группе

```
CREATE UNIQUE INDEX  
ON jobby_jobs(group_id)  
WHERE is_group_locker = TRUE;
```

Получение задач с учётом блокировки

```
WITH candidates AS (  
    SELECT * FROM jobby_jobs c  
    WHERE  
        c.status = Scheduled AND c.scheduled_start_at <= now()  
        AND (  
            c.group_id IS NULL OR (  
                NOT EXISTS (  
                    SELECT 1 FROM jobby_jobs jl  
                    WHERE  
                        jl.group_id = c.group_id  
                        AND jl.is_group_locker = TRUE  
                        AND jl.id != c.id  
                )  
            AND pg_try_advisory_xact_lock(hashtext(c.group_id)) = TRUE  
        )  
    )  
    ORDER BY scheduled_start_at LIMIT batch_size FOR UPDATE SKIP LOCKED  
) , ...
```

Получение задач с учётом блокировки

```
WITH candidates AS (  
    SELECT * FROM jobby_jobs c  
    WHERE  
        c.status = Scheduled AND c.scheduled_start_at <= now()  
        AND (  
            c.group_id IS NULL OR (  
                NOT EXISTS (  
                    SELECT 1 FROM jobby_jobs jl  
                    WHERE  
                        jl.group_id = c.group_id  
                        AND jl.is_group_locker = TRUE  
                        AND jl.id != c.id  
                )  
            )  
        AND pg_try_advisory_xact_lock(hashtext(c.group_id)) = TRUE  
    )  
    )  
    ORDER BY scheduled_start_at LIMIT batch_size FOR UPDATE SKIP LOCKED  
) , ...
```

Получение задач с учётом блокировки

```
WITH candidates AS (  
    SELECT * FROM jobby_jobs c  
    WHERE  
        c.status = Scheduled AND c.scheduled_start_at <= now()  
        AND (  
            c.group_id IS NULL OR (  
                NOT EXISTS (  
                    SELECT 1 FROM jobby_jobs jl  
                    WHERE  
                        jl.group_id = c.group_id  
                        AND jl.is_group_locker = TRUE  
                        AND jl.id != c.id  
                )  
            )  
        AND pg_try_advisory_xact_lock(hashtext(c.group_id)) = TRUE  
    )  
    )  
    ORDER BY scheduled_start_at LIMIT batch_size FOR UPDATE SKIP LOCKED  
) , ...
```

Получение задач с учётом блокировки

WITH

candidates AS (...),

-- Из каждой группы берём по одной задаче

candidates_with_group_unique (

SELECT DISTINCT ON (group_id), ...

FROM candidates

ORDER BY group_id, scheduled_start_at

WHERE group_id IS NOT NULL


)

UPDATE jobby_jobs

SET "status" = Processing, started_count = started_count + 1

WHERE id IN (...)

RETURNING *;



Получение задач с учётом блокировки

WITH

```
candidates AS (...),  
candidates_with_group_unique AS (...)
```

```
-- Отобранным задачам обновляем статус и берём в работу
```

UPDATE jobby_jobs

```
SET "status" = Processing, started_count = started_count + 1
```

WHERE id IN (

```
SELECT id FROM candidates WHERE group_id IS NULL
```

UNION

```
SELECT id FROM candidates_with_group_unique
```

)

```
RETURNING *;
```

Рекомендательные блокировки



<https://postgrespro.ru/docs/postgresql/12/explicit-locking#ADVISORY-LOCKS>



<https://habr.com/ru/companies/tensor/articles/488024/>

`pg_try_advisory_xact_lock`

- ➔ Блокировкой владеет транзакция
- ➔ При завершении транзакции снимается автоматически
- ➔ Безопасно использовать совместно с pgbouncer

`pg_try_advisory_lock`

- ➔ Блокировкой владеет сеанс
- ⚠ Нужно делать unlock явно, иначе будет висеть до закрытия соединения
- ⚠ Опасно использовать с pgbouncer в transactional mode

Аналоги в других СУБД


FOR UPDATE SKIP LOCKED

- Есть в **Oracle**, **MySQL 8+**
- Для **MSSQL**: см. READPAST / UPDLOCK


Рекомендательные блокировки

- **MySQL**: GET_LOCK / IS_FREE_LOCK / RELEASE_LOCK
- **Oracle**: DBMS_LOCK.REQUEST()
- **MSSQL**: sp_getapplock / sp_releaseapplock


Одновременное выполнение




Одновременное выполнение




Одновременное выполнение



Одновременное выполнение - **ERROR**



Видимость новых версий строк



Отдельный запрос для UPDATE с проверкой существования локера

```
BEGIN;
```

```
-- Первым запросом в транзакции только получаем кандидатов для запуска  
WITH
```

```
    candidates AS (...),  
    candidates_with_group_unique AS (...)  
SELECT id FROM candidates WHERE group_id IS NULL  
UNION  
SELECT id FROM candidates_with_group_unique;
```


```
...
```

Отдельный запрос для UPDATE с проверкой существования локера

...

```
...  
UPDATE jobby_jobs  
SET "status" = Processing, started_count = started_count + 1  
WHERE  
    id IN (:listOfIdsFromSelect)  
    AND (group_id IS NULL OR NOT EXISTS (  
        SELECT 1 FROM jobby_jobs jl  
        WHERE  
            jl.group_id = group_id  
            AND jl.is_group_locker = TRUE  
            AND jl.id != id  
    ))  
RETURNING *;  
  
COMMIT;
```

Отдельный запрос для UPDATE с проверкой существования локера



Проблема очень больших заблокированных групп

```
WITH candidates AS (  
    SELECT * FROM jobby_jobs c  
    WHERE  
        -- Быстрый поиск в индексе  
        c.status = Scheduled AND c.scheduled_start_at <= now()  
  
        -- Всё что ниже вызовет дополнительный фильтр при index scan  
        -- Может быть неоптимальным если скопилось много задач в заблокированных группах  
    AND (  
        c.group_id IS NULL OR (  
            NOT EXISTS (  
                SELECT 1 FROM jobby_jobs j1  
                WHERE  
                    j1.group_id = c.group_id  
                    AND j1.is_group_locker = TRUE  
                    AND j1.id != c.id  
            )  
        AND pg_try_advisory_xact_lock(hashtext(c.group_id)) = TRUE  
    )  
)
```



Альтернативный способ

Альтернатива



Оставить исходный запрос



Исключить возможность существования более одной задачи в статусе Scheduled на группу

≡ TakeJobs... ×

```
WITH ready_jobs AS (  
    SELECT id FROM jobby_jobs  
    WHERE  
        "status" = Scheduled  
        AND scheduled_start_at <= now()  
    ORDER BY scheduled_start_at  
    LIMIT :batchSize  
    FOR UPDATE SKIP LOCKED  
)  
UPDATE jobby_jobs  
SET  
    "status" = <Processing>,  
    started_count = started_count + 1  
WHERE id IN (SELECT id FROM ready_jobs)  
RETURNING *;
```


Доработка ограничения уникальности

```
ALTER TABLE jobby_jobs
  ADD COLUMN IF NOT EXISTS is_group_locker BOOLEAN GENERATED ALWAYS AS (
    -- Если есть группа
    group_id IS NOT NULL
    -- И задача в работе ИЛИ запланирована к запуску
    -- ИЛИ упала
    AND (
      "status" = PROCESSING OR "status" = SCHEDULED
      OR (
        lock_group_if_failed = TRUE
        AND "status" = FAILED
      )
    )
  )
```

.....

```
-- Такой индекс не позволит иметь более одной Scheduled-записи на группу
CREATE UNIQUE INDEX ON jobby_jobs(group_id)
WHERE is_group_locker = TRUE;
```

Подмена статуса при вставке





**Как сделать
INSERT
ON CONFLICT
DO OTHER INSERT**

Создание записи с подменой статуса

WITH

try_insert_scheduled AS (

-- Пытаемся вставить запись в статусе SCHEDULED

INSERT INTO jobby_jobs (... , "status")

VALUES (... , SCHEDULED)

-- Если группа уже заблокирована - запись не добавится и ничего не вернётся

-- DO UPDATE вместо DO NOTHING – чтобы заблокировать конфликтующую строку

ON CONFLICT (group_id) WHERE is_group_locker = TRUE

DO UPDATE SET ... WHERE FALSE

RETURNING 1

)

...

INSERT FROM SELECT

Вариант INSERT, выполняющегося
по условию

≡ Insert

×

```
INSERT INTO some_table (c_1, c_2, ..., c_N)
-- Вместо VALUES – SELECT с условием
SELECT value_1, value_2, ... value_N
WHERE some_predicate;
```

```
-- Если указанный предикат false
-- то INSERT не выполнится
```


Создание записи с подменной статуса

```
WITH try_insert_scheduled AS (...)  
  
-- Вставляем запись в статусе WAITING_PREV  
INSERT INTO jobby_jobs(..., "status")  
  SELECT ..., WAITING_PREV  
-- Но только если не отработала вставка в статусе SCHEDULED  
WHERE NOT EXISTS (  
  SELECT 1 FROM try_insert_scheduled  
)  
  
-- Получили фактически INSERT ... ON CONFLICT DO OTHER INSERT
```

Завершение с запуском следующей

```
-- В транзакции
-- Удаляем обработанную запись
DELETE FROM jobby_jobs
WHERE id = :completedJobId;

-- И разблокируем следующую
UPDATE jobby_jobs
SET
    "status" = SCHEDULED
WHERE id IN (
    SELECT id FROM jobby_jobs
    WHERE
        group_id = :completedJobGroupId
        AND "status" = WAITING_PREV
    ORDER BY scheduled_start_at
    LIMIT 1
);
```



Завершение с запуском следующей задачи группы


Complete ×

```
DELETE FROM jobby_jobs  
WHERE id = :completedJobId;
```

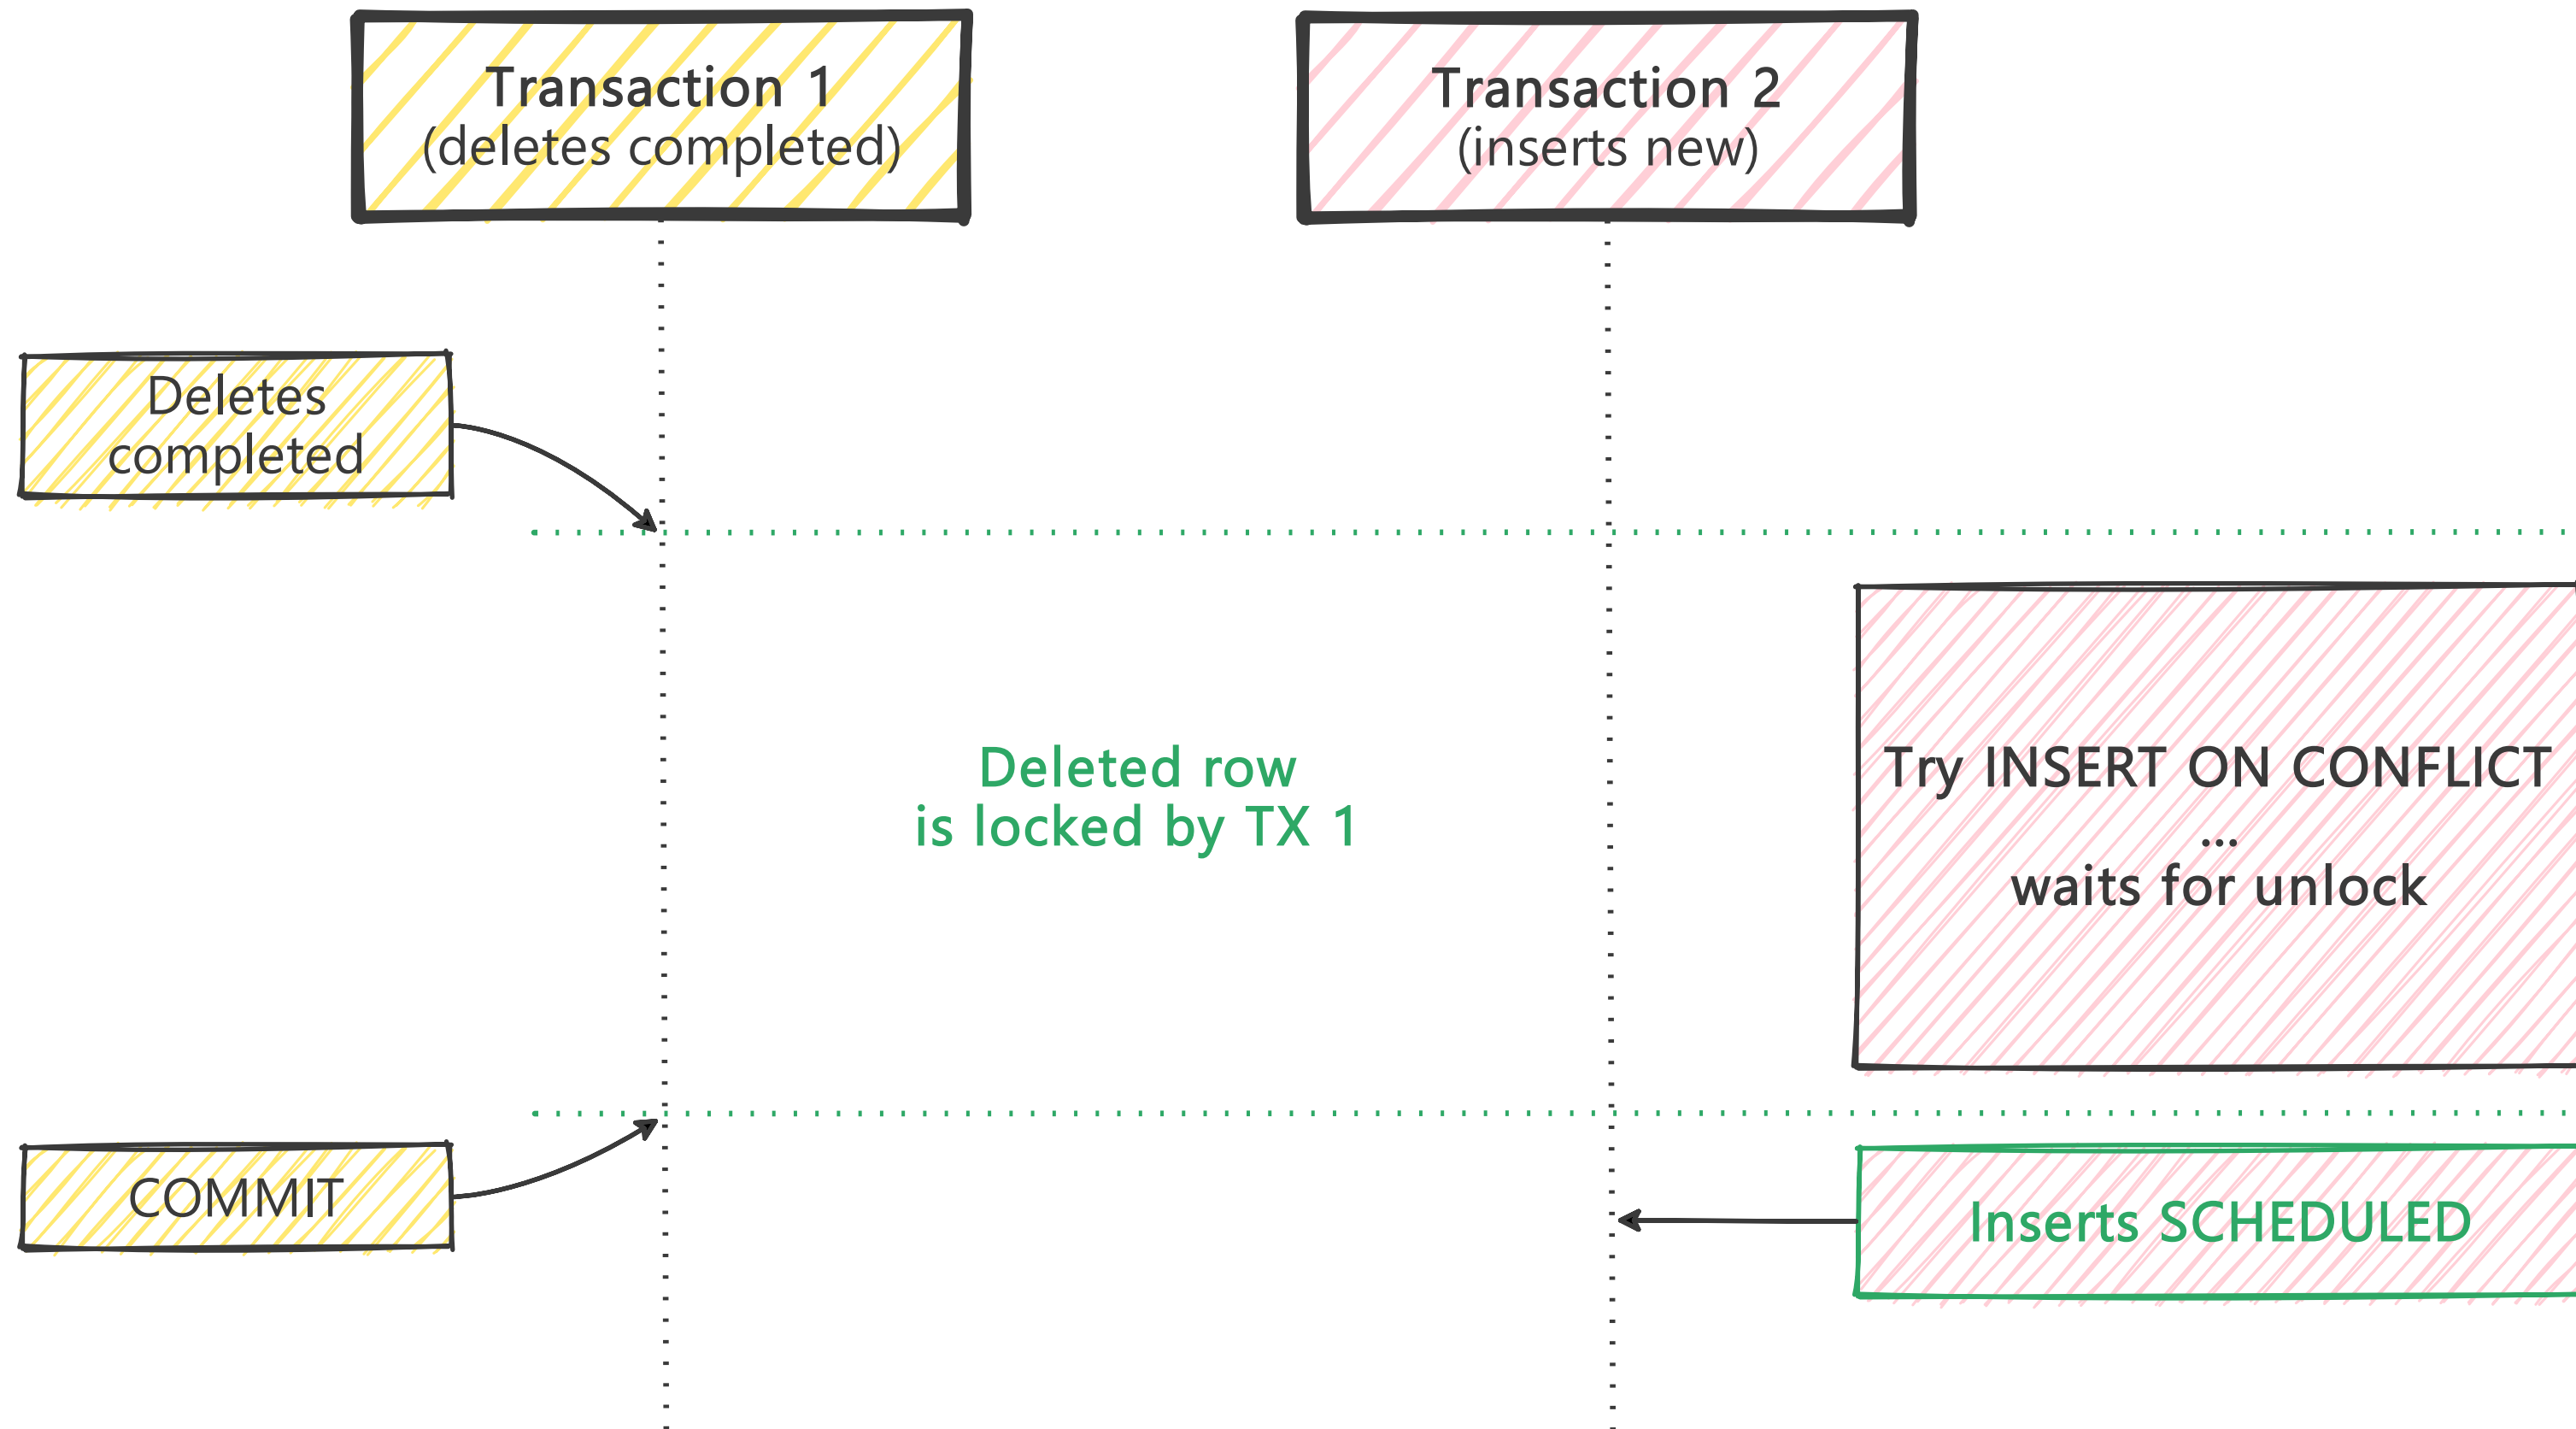
```
UPDATE jobby_jobs  
SET  
    "status" = SCHEDULED  
WHERE id IN (  
    SELECT id FROM jobby_jobs  
    WHERE  
        group_id = :completedJobGroupId  
        AND "status" = WAITING_PREV  
    ORDER BY scheduled_start_at  
    LIMIT 1  
);
```

```
-- Partial индекс (group_id, scheduled_start_at)  
WHERE group_id IS NOT NULL  
    AND status = WAITING_PREV
```


Одновременное создание и завершение




Одновременное создание и завершение



Одновременное создание и завершение



Одновременное создание и завершение




Плюсы и минусы подхода с подменной статуса

- ➔ **Стабильно высокая производительность запуска задач**
- ➔ Утяжеляется INSERT, а значит и бизнес-транзакция приложения
- ➔ +1 UPDATE для завершения задач (но не всегда) и +1 индекс
- ➔ Необходимо использовать триггер для создания записей через ORM

Подход на основе смещений


Подход на основе смещений

- ✓ Моноotonно возрастающий ключ
- ✓ Чтение в порядке увеличения значения ключа
- ✓ Чтение с позиции последней обработанной записи
- ✓ Таблица с сообщениями INSERT-only



Удаление через партиции по дате

- ✓ Таблица топика партицирована по дате создания сообщений
- ✓ Старые сообщения удаляются через DROP TABLE для партиции






**Как масштабировать
и распараллеливать
обработку?**


Параллелизм через партиции по ключу

- ✓ Поле `partition_num` в таблице топика
- ✓ Вычисляется как хэш от бизнесового `group_id`
- ✓ Связанные сообщения всегда в одной партиции
- ✓ Разные партиции обрабатываются параллельно



Параллелизм через партиции по ключу

- ✓ Поле `partition_num` в таблице топика
- ✓ Вычисляется как хэш от бизнесового `group_id`
- ✓ Связанные сообщения всегда в одной партии
- ✓ Разные партии обрабатываются параллельно



Владение консьюмеров партициями

```
CREATE TABLE topic_consumer (  
  id INT GENERATED ALWAYS AS IDENTITY PRIMARY KEY,  
  
  -- Связь между партициями и группами консьюмеров  
  topic_name TEXT NOT NULL,  
  partition_num INT NOT NULL,  
  consumer_group_id TEXT NOT NULL,  
  
  -- Идентификатор текущего владельца партиции в группе  
  owner_server_id TEXT DEFAULT NULL,  
  
  -- Номер последней обработанной данной консьюмер-группой записи  
  -- из данной партиции данного топика  
  current_offset ??????  
)
```

Владение консьюмеров партициями

```
CREATE TABLE topic_consumer (  
  id INT GENERATED ALWAYS AS IDENTITY PRIMARY KEY,  
  
  -- Связь между партициями и группами консьюмеров  
  topic_name TEXT NOT NULL,  
  partition_num INT NOT NULL,  
  consumer_group_id TEXT NOT NULL,  
  
  -- Идентификатор текущего владельца партиции в группе  
  owner_server_id TEXT DEFAULT NULL,  
  
  -- Номер последней обработанной данной консьюмер-группой записи  
  -- из данной партиции данного топика  
  current_offset ??????  
)
```

Владение консьюмеров партициями

```
CREATE TABLE topic_consumer (  
  id INT GENERATED ALWAYS AS IDENTITY PRIMARY KEY,  
  
  -- Связь между партициями и группами консьюмеров  
  topic_name TEXT NOT NULL,  
  partition_num INT NOT NULL,  
  consumer_group_id TEXT NOT NULL,  
  
  -- Идентификатор текущего владельца партиции в группе  
  owner_server_id TEXT DEFAULT NULL,  
  
  -- Номер последней обработанной данной консьюмер-группой записи  
  -- из данной партиции данного топика  
  current_offset ??????  
)
```

Захват партиций консьюмером группы

```
-- Захватить N партиций в указанных топиках
UPDATE topic_consumer
SET owner_server_id = :myServerId
WHERE id IN (
    SELECT id FROM topic_consumer
    WHERE
        topic_name = :topicName
        AND consumer_group_id = :myConsumerGroup
        AND owner_server_id IS NULL
    LIMIT N
    FOR UPDATE SKIP LOCKED
)
RETURNING *;

-- Освободить партицию – аналогично установить owner_server_id = NULL
```

Перераспределение партиций в группе

```
// Фоновый процесс перераспределения партиций по необходимости
while (serverWorking)
{
    int totalServers = await GetAliveServersCount(consumerGroupId);
    int totalPartitions = await GetPartitionsCount(topicName);
    int fairCount = (int)Math.Ceiling((decimal)totalPartitions / totalServers);

    if (myPartitionsCount < fairCount)
    {
        await TryCapture(fairCount - myPartitionsCount);
    }
    else if (myPartitionsCount > fairCount)
    {
        await ReleasePartitions(myPartitionsCount - fairCount);
    }

    await Task.Delay(pause);
}
```

Перераспределение партиций в группе

```
// Фоновый процесс перераспределения партиций по необходимости
while (serverWorking)
{
    int totalServers = await GetAliveServersCount(consumerGroupId);
    int totalPartitions = await GetPartitionsCount(topicName);
    int fairCount = (int)Math.Ceiling((decimal)totalPartitions / totalServers);

    if (myPartitionsCount < fairCount)
    {
        await TryCapture(fairCount - myPartitionsCount);
    }
    else if (myPartitionsCount > fairCount)
    {
        await ReleasePartitions(myPartitionsCount - fairCount);
    }

    await Task.Delay(pause);
}
```



**Что использовать в качестве
монотонно возрастающего
ключа сообщений?**


Моноotonно возрастающий ключ

Статья от Oscar Dudycz о проблемах
с sequence и способе решения
«How Postgres sequences issues can impact
your messaging guarantees»

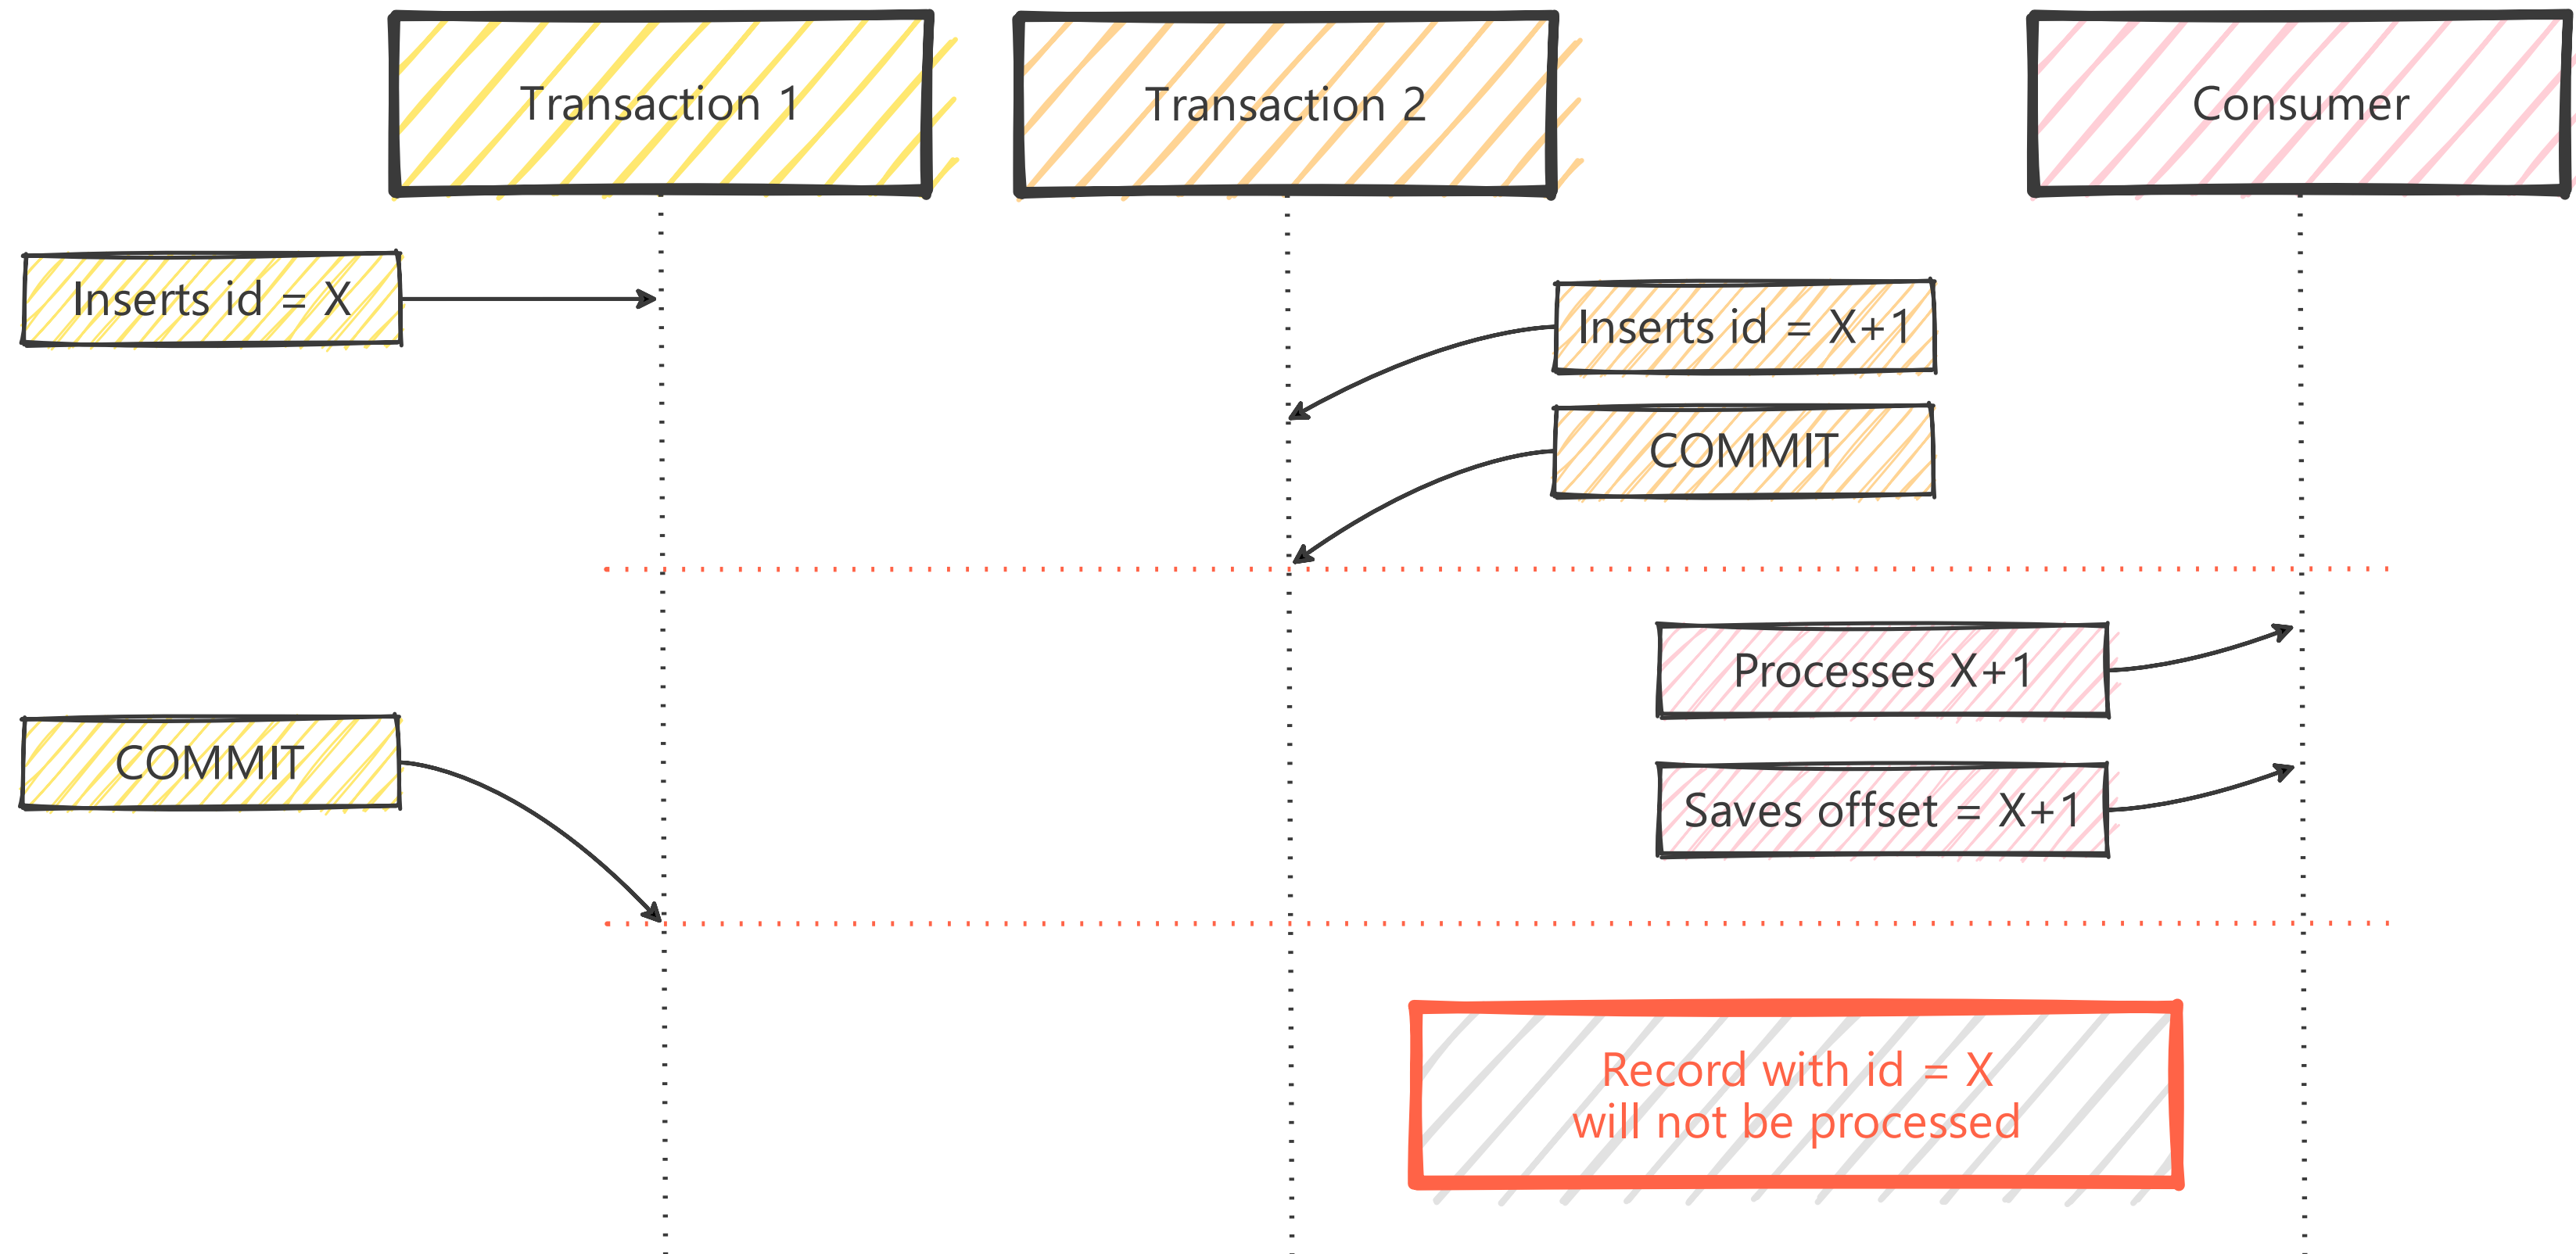


- Timestamp - **ненадёжно**
- Sequence - ???

Параллельная вставка двух записей



Параллельная вставка двух записей



Комбинация sequence и xid8

```
-- pg_current_xact_id() возвращает текущий идентификатор транзакции


-- Добавим к записям outbox 64-битный id транзакции,
-- в которых они были созданы
ALTER TABLE messages
ADD COLUMN
    tx_id xid8 NOT NULL DEFAULT pg_current_xact_id()
```

Комбинация sequence и xid8


```
-- Минимальный xid8 ещё не завершённых транзакций:
-- pg_snapshot_xmin(pg_current_snapshot())

SELECT * FROM messages
WHERE
    topic_name = :topicName
    AND partition_num = :partitionNum
    AND id > :lastProcessedId
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())
ORDER BY id
LIMIT :processingBatchSize
```

Параллельная вставка двух записей



Параллельная вставка двух записей



Чтение по составному смещению

```
-- (tx_id, seq_id) – составной номер записи  
-- (lastProcessedTxId, lastProcessedId) – последняя обработанная
```

```
SELECT * FROM messages  
WHERE  
    topic_name = :topicName  
    AND partition_num = :partitionNum  
    AND (tx_id, seq_id) > (:lastProcessedTxId, :lastProcessedId)  
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())  
ORDER BY (tx_id, seq_id) ASC  
LIMIT :processingBatchSize;
```

Чтение по составному смещению

-- (tx_id, seq_id) – составной номер записи
-- (lastProcessedTxId, lastProcessedId) – последняя обработанная

```
SELECT * FROM messages
WHERE
    topic_name = :topicName
    AND partition_num = :partitionNum
    -- Берём записи после последней обработанной
    AND (tx_id, seq_id) > (:lastProcessedTxId, :lastProcessedId)
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())
ORDER BY (tx_id, seq_id) ASC
LIMIT :processingBatchSize;
```

Чтение по составному смещению

```
-- (tx_id, seq_id) – составной номер записи
-- (lastProcessedTxId, lastProcessedId) – последняя обработанная


SELECT * FROM messages
WHERE
    topic_name = :topicName
    AND partition_num = :partitionNum
    AND (tx_id, seq_id) > (:lastProcessedTxId, :lastProcessedId)
    -- Учитываем только транзакции заведомо старше тех что ещё не коммитились
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())
ORDER BY (tx_id, seq_id) ASC
LIMIT :processingBatchSize;
```

Чтение по составному смещению

-- (tx_id, seq_id) – составной номер записи
-- (lastProcessedTxId, lastProcessedId) – последняя обработанная

```
SELECT * FROM messages
WHERE
    topic_name = :topicName
    AND partition_num = :partitionNum
    AND (tx_id, seq_id) > (:lastProcessedTxId, :lastProcessedId)
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())
-- Сортировка по составному ключу
ORDER BY (tx_id, seq_id) ASC
LIMIT :processingBatchSize;
```

Чтение по составному смещению



Чтение по составному смещению

```
SELECT * FROM messages
WHERE
    topic_name = :topicName
    AND partition_num = :partitionNum
    AND (tx_id, seq_id) > (:lastProcessedTxId, :lastProcessedId)
    AND tx_id < pg_snapshot_xmin(pg_current_snapshot())
ORDER BY (tx_id, seq_id) ASC LIMIT :processingBatchSize;

-- Составной индекс (topic_name, partition_num, tx_id, seq_id)

-- Если таблица партицирована по topic_name и/или partition_num,
-- то эти поля из индекса можно убрать

-- Может быть полезно в WHERE ограничение на created_at,
-- если есть партии по этому ключу
```

Возможные проблемы

Доклад на JVM Day 2025 об альтернативном подходе от Алексея Кашина
«Надёжно отправляем события в Apache Kafka.
От CDC до паттерна Transactional Outbox»



- ➔ Нет аналогичных механизмов для отличных от PostgreSQL СУБД
- ➔ Чужая длинная транзакция **может остановить обработку очереди**
- ➔ Решение 1 – не допускать длинных транзакций, аналитические запросы – только на репликах
- ➔ Решение 2 – альтернативный подход с исключением недавно добавленных записей по `created_at` (имеет фиксированный лаг, не даёт 100% гарантии)



Батчинг и асинхронная загрузка сообщений


Пакетное чтение и обработка




Асинхронная загрузка следующего батча



Независимость работы с БД и обработки



Диспетчер команд и монитор



Channel

<https://habr.com/ru/articles/508726/>



- Очередь в оперативной памяти
- Потокбезопасная
- Оптимизирована
(lock-free, минимизация аллокаций)
- Предоставляет неблокирующий метод ожидания новых записей

Обработка команд в компонентах

```
var channel = Channel.CreateUnbounded<Command>();  
// channel.Writer делаем доступным другим компонентам  
  
// Запускаем поток-обработчик (или несколько потоков)  
_ = Task.Run(async () =>  
{  
    while (!stoppingToken.IsCancellationRequested)  
    {  
        var channelIsAvailable = await channel.Reader.WaitToReadAsync(stoppingToken);  
        if (!channelIsAvailable)  
            break;  
  
        while (!stoppingToken.IsCancellationRequested  
            && _channel.Reader.TryRead(out var command))  
        {  
            await HandleCommand(command);  
        }  
    }  
});
```

Обработка команд в компонентах

```
var channel = Channel.CreateUnbounded<Command>();
// channel.Writer делаем доступным другим компонентам

// Запускаем поток-обработчик (или несколько потоков)
_ = Task.Run(async () =>
{
    while (!stoppingToken.IsCancellationRequested)
    {
        var channelIsAvailable = await channel.Reader.WaitToReadAsync(stoppingToken);
        if (!channelIsAvailable)
            break;

        while (!stoppingToken.IsCancellationRequested
            && _channel.Reader.TryRead(out var command))
        {
            await HandleCommand(command);
        }
    }
});
```

Обработка команд в компонентах

```
var channel = Channel.CreateUnbounded<Command>();  
// channel.Writer делаем доступным другим компонентам  
  
// Запускаем поток-обработчик (или несколько потоков)  
_ = Task.Run(async () =>  
{  
    while (!stoppingToken.IsCancellationRequested)  
    {  
        var channelIsAvailable = await channel.Reader.WaitToReadAsync(stoppingToken);  
        if (!channelIsAvailable)  
            break;  
  
        while (!stoppingToken.IsCancellationRequested  
            && _channel.Reader.TryRead(out var command))  
        {  
            await HandleCommand(command);  
        }  
    }  
});
```

Обработка команды чтения сообщений

```
ValueTask HandleReadMessagesCommand(ReadMessagesCommand command)
{
    // Если партиция уже не наша - игнорируем команду
    if (!IsPartitionCaptured(command.Partition))
        return;

    // Если другой поток уже загружает - игнорируем команду
    if (IsLoadingInProgress(command.Partition))
        return;

    // Записываем в LocalState факт того что начали загрузку записей
    SetReadingInProgress(command.Partition))

    // Отправляем команду на чтение из БД
    _dbChannel.Write(new ReadMessagesCommand(...))
}
```

Обработка команды чтения сообщений

```
ValueTask HandleReadMessagesCommand(ReadMessagesCommand command)
{
    // Если партиция уже не наша - игнорируем команду
    if (!IsPartitionCaptured(command.Partition))
        return;

    // Если другой поток уже загружает - игнорируем команду
    if (IsLoadingInProgress(command.Partition))
        return;

    // Записываем в LocalState факт того что начали загрузку записей
    SetReadingInProgress(command.Partition))

    // Отправляем команду на чтение из БД
    _dbChannel.Write(new ReadMessagesCommand(...))
}
```

Обработка загруженных сообщений

```
ValueTask HandleLoadedMessagesCommand(LoadedMessagesCommand command)
{
    if (command.Messages.Count == 0)
    {
        // Партиция пуста – повторяем чтение после паузы
        Task.Run(() => {
            await Task.Delay(pause);
            _channel.Writer(new ReadMessagesCommand(command.Partition, command.Offset));
        });
    }
    else
    {
        ...
    }
}
```

Обработка загруженных сообщений

```
ValueTask HandleLoadedMessagesCommand(LoadedMessagesCommand command)
{
    ...
    else
    {
        AddToLocalCache(command.Partition, command.Messages);

        // Если обработчик не обрабатывает сейчас прошлые сообщения
        if (!IsHandlerInProgress(command.Partition))
        {
            // Отправляем в обработку из кэша
            await _handlerChannel.Write(new HandleMessagesCommand(...));
            SetHandlerInProgress(command.Partition)

            // Читаем в кэш следующие при необходимости
            await _channel.Write(new ReadMessagesCommand(...));
        }
    }
}
```

Topiqueue

Прототип библиотеки реализующей
описанный Kafka inspired подход
с Event Loop моделью

GitHub

<https://github.com/fornit1917/topiqueue>









Бенчмарки

Вставка и обработка 1000 сообщений

1 поток / партиция, HandlerBatch = 1




Вставка и обработка 1000 сообщений 10 потоков / партиций, HandlerBatch = 1




Вставка и обработка, HandlerBatch = 1

Нагрузка на CPU в Postgresql





Вставка и обработка, HandlerBatch=10

Нагрузка на CPU в Postgresql



Вставка и обработка 1000 сообщений 10 потоков / партиций, HandlerBatch = 10



ИТОГИ И ВЫВОДЫ

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

Сообщения не связаны
между собой

Просто распараллеливается
и масштабируется

К параллелизму
сложно добавить упорядоченность

VS

Подход на основе смещений

Эффективная работа с БД
(INSERT ONLY подход)

Сообщения жёстко связаны

Сложно распараллеливать
и масштабировать

Упорядоченность из коробки

Подход на основе статусов

Нагрузка на БД
(SELECT + UPDATE + DELETE)

Сообщения не связаны
между собой

Просто распараллеливается
и масштабируется

К параллелизму возможно
добавить упорядоченность*

VS

Подход на основе смещений

Эффективная работа с БД
(INSERT ONLY подход)

Сообщения жёстко связаны

Возможно добавить
параллелизм и масшт-ть*

Упорядоченность из коробки

Сильные и слабые стороны

Подход на основе статусов

- ➔ Честный параллелизм
- ➔ Гибкость в отложенной обработке отдельных записей
- ⚠ Создает мёртвые кортежи, провоцирует VACUUM



Подход на основе смещений

- ➔ Легче для БД (не провоцирует тяжелый VACUUM)
- ➔ Сверхэффективная пакетная обработка
- ⚠ Сложность повторной отложенной обработки
- ⚠ Высокий latency при ребалансировке партиций



Что выбрать

Личные рекомендации

Подход на основе статусов

Использовать с большинстве случаев
если не упираетесь в ресурсы БД



Подход на основе смещений


Использовать в экстремально нагруженных сценариях
когда критически важна высокая пропускная
способность при низких расходах ресурсов БД



Примеры реализаций



Jobby



Topiqueue



https://t.me/dev_and_more



Спасибо!