

Macoun

Effizientes Offline-First-Sync: Ein Überblick

Daniel Alm (@daniel_a_a)

Sync:



New Task | Past 30 Days | No Filter | Search

Overview

Review

Details

Reports

Total time

150h
30h 2m per week

Most active weekdays

Most active hours

Time per Project

per Week

Week	Total Time
08/05 - 08/11	33h 5m
08/12 - 08/18	28h 5m
08/19 - 08/25	35h 5m
08/26 - 09/01	37h 25m
09/02 - 09/04	16h 31m

Productivity score

69%
Keep it up 😊

Most productive weekdays

Most productive hours

Applications

Application	Time
Xcode	32h 45m
Safari	31h 6m
Sketch	20h 13m
Slack	15h 45m
Mail	14h 0m
Pages	12h 40m
QuickTime Player	10h 0m
Messages	5h 15m
Keynote	3h 7m

Projects & Tasks

Project/Task	Time
Client: Acme Inc.	43h 20m
(App usage without a task)	34h 20m
Research for Secret Project	3h 0m
Meeting with Angela	2h 0m
Meeting with Tim	2h 0m
Meeting with Jony & Craig	1h 0m
Design iPhone Y	1h 0m
Client: MegaCorp	35h 30m
Communication	26h 0m
Media	22h 57m
News	5h 40m

Timing Sync: Eckdaten nach zwei Monaten

- **4000** Nutzer
- **5-20** Sync-Requests/Sekunde
- **36 GB** Datenbank
- **25,000,000** Tabellenzeilen in der Datenbank
- **400,000,000** synchronisierte Objekte
- **Eine** Beschwerde über Datenverlust

Ablauf

1. Vorüberlegungen
2. 2 ½ mögliche Ansätze
3. Praktische Umsetzung

Vorweg:

Guter Sync ist viel Arbeit

Anforderungen

- Resilienz
- Konsistenz
- Effizienz
- Wartbarkeit
- Offline-First

Vorüberlegungen

- Welche Datenstrukturen habe ich?
- Welche davon muss ich überhaupt synchronisieren?
- Welche Operationen auf diesen Strukturen muss ich abbilden?
- Welche Konflikte sind möglich? Wie löse ich die? Und wo/wann?
- Gibt es einen zentralen Server? Welche Aufgabe kommt diesem zu?

Beispielmodell: Projekt

```
class Project {  
  let id: Int64  
  let title: String  
  let children: [Project]  
}
```

```
let topLevelProjects: [Project] // Zum Speichern der Reihenfolge
```

Beispielmodell: Task

```
struct Task {  
  let id: Int64  
  let start: Date  
  let end: Date  
  let title: String  
  let project: Project?  
}
```

Mögliche Operationen: Project

- Erstellen
- Titel ändern
- Verschieben (anderes Elternprojekt, andere Listenposition)
- Löschen (was ist mit Unterprojekten (!?))

Mögliche Operationen: Task

- Erstellen
- Zeitraum ändern
- Titel ändern
- Projekt ändern (Achtung: Cross-Entity-Referenz!)
- Löschen

Die Ansätze

#1: Timestamps

- Repliziere Client-Datenmodell auf dem Server, mit Timestamps für jedes Objekt/jede Eigenschaft

Timestamps: Project

```
struct Project {  
    let id: Int64  
    let title: String  
    let parentID: Int64?  
    let position: UInt32  
  
    let createdAt: Date  
    let lastTitleChange: Date?  
    let lastParentOrPositionChange: Date?  
    let deletedAt: Date?  
}
```

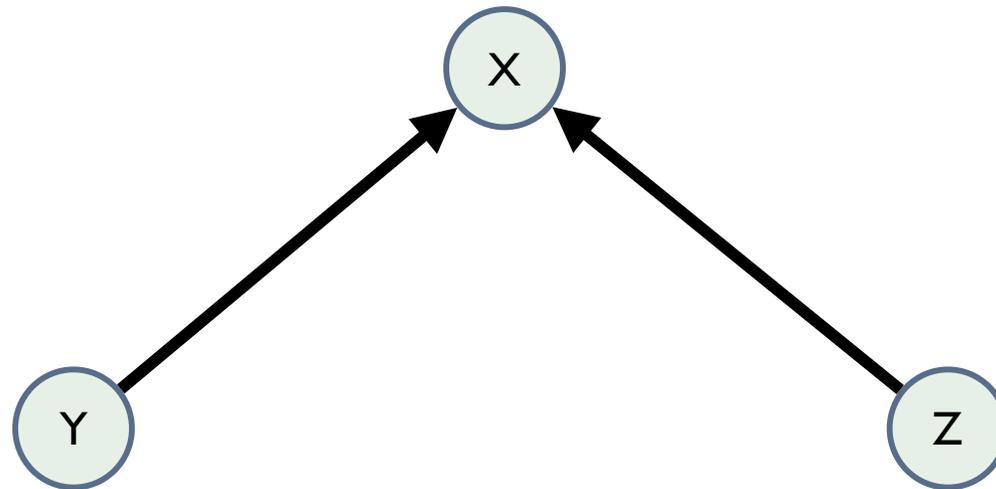
Timestamps: Task

```
struct Task {  
  let id: Int64  
  let start: Date  
  let end: Date  
  let title: String  
  let projectID: Int64?  
  
  let createdAt: Date  
  let lastDateRangeChange: Date?  
  let lastTitleChange: Date?  
  let lastProjectChange: Date?  
  let deletedAt: Date?  
}
```

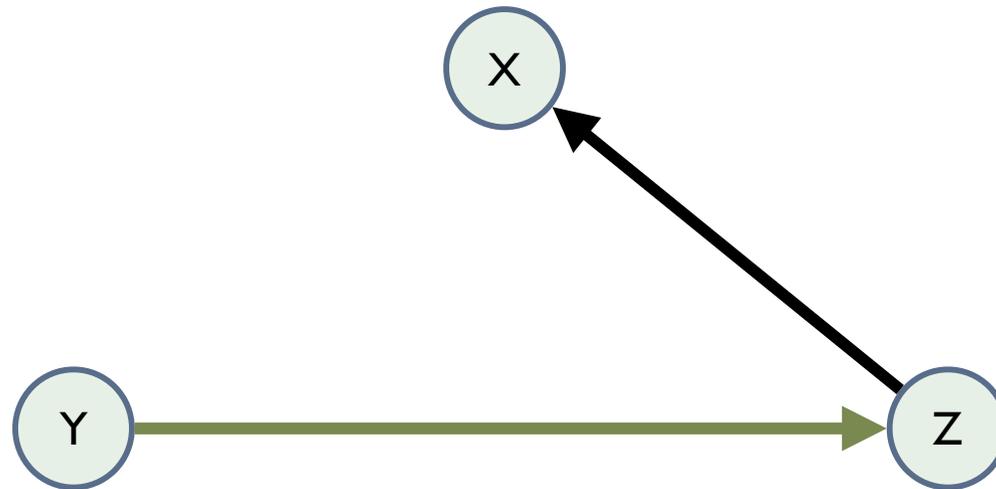
Timestamps: Probleme

- “Tombstones” notwendig, um Lösch-Operationen abzubilden
- Skaliert schlecht
- Viel Komplexität im Server
- Integration (“Merge”) bestehender Daten schwierig
- Konflikte

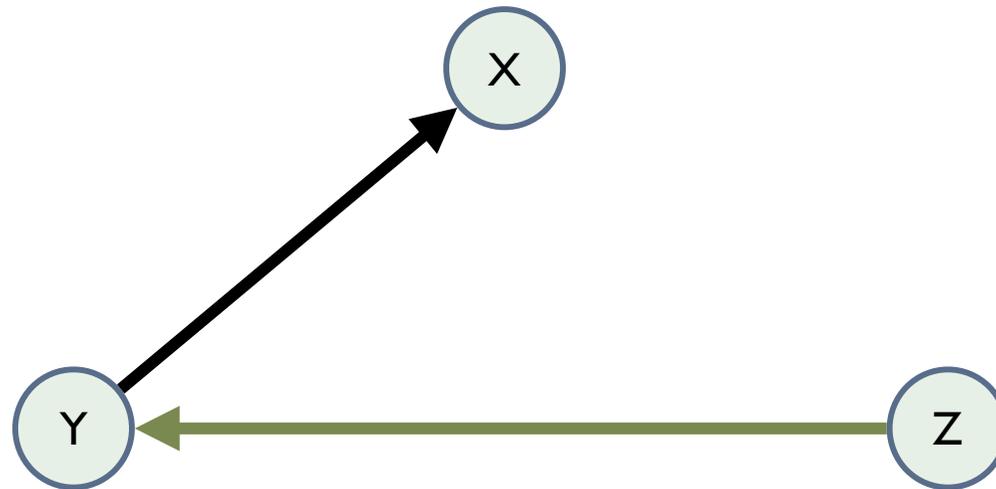
Beispiel: Konflikt



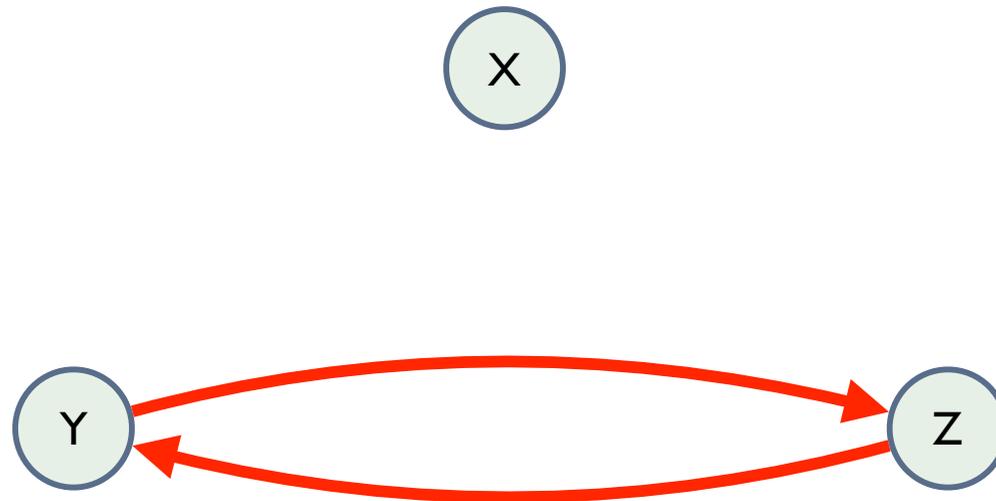
Beispiel: Konflikt (Gerät A)



Beispiel: Konflikt (Gerät B)



Beispiel: Konflikt (nach Sync)



#2: Operational Transformation

- Erfasse semantische Beschreibungen aller Änderungen
- Transformiere aufeinander folgende “gleichzeitige” Änderungen so, dass sie äquivalent sind: $A + T_A(B) = B + T_B(A)$
- Vorteil: potentiell sehr gute “Intentionstreue”
- Nachteil:

#3: Operation Log

- Semantische Beschreibung jeder Änderung
- In der *gleichen* Reihenfolge abgespielt, erhält man überall den selben Zustand
- Reihenfolge der Änderungen: z.B. Timestamp

Operation Log: Project

```
enum ProjectOperation {  
  case create(id: Int64, title: String, parentID: Int64?, pos: Int)  
  case setTitle(id: Int64, title: String)  
  case moveToParent(id: Int64, parentID: Int64?, pos: Int)  
  case delete(id: Int64)  
}
```

Operation Log:Task

```
enum TaskOperation {  
  case create(id: Int64, startDate: Date, endDate: Date, title: String,  
projectID: Int64?)  
  case setDateRange(id: Int64, startDate: Date, endDate: Date)  
  case setTitle(id: Int64, title: String)  
  case setProject(id: Int64, projectID: Int64?)  
  case delete(id: Int64)  
}
```

Und jetzt?

- Wir haben das Problem “reduziert” auf:
 - Erfassung (inkl. Serialisierung)
 - Synchronisation
 - Wiedergabe (inkl. Deserialisierung) der Operationen

Erfassung

- Alle Änderungen werden von einer zentralen Stelle aus ausgeführt
 - Alternative/Ergänzung: Übergebe jeder mutierenden Methode ein Logger-Objekt, dem wir die zu erfassenden Änderungen mitteilen
- Serialisierung: Protocol Buffers

Synchronisation der Operationen

- **CRDT: “Conflict-Free Replicated Data Type”**
- Beispiel: “Grow-only Set”
 - Kennt nur eine Operation: Objekt hinzufügen
 - Einfachste Synchronisation: gebe alle bekannten Werte weiter
 - Erklärung: https://bit.ly/crdt_app

Synchronisation: Upload

- Client: “Hier sind alle Operationen, von denen ich noch nicht sicher weiß, dass sie hochgeladen (und angekommen!) sind”
- Server: “Alles klar, die hochgeladenen Operationen haben jetzt IDs 130, 140”
- Client speichert die IDs für die hochgeladenen Operationen

Synchronisation: Download

- Client: “Bitte gib mir alle Operationen ab Stand ID 123, abgesehen von den folgenden: 130, 140”
- Server: “Hier sind Operationen 127, 135, 142. Du bist jetzt auf Stand ID 150”
- Client: speichert neue Operationen und merkt sich “Stand ID 150”

Wiedergabe

- Gruppiere Operationen nach Objekt-Typ, sortiere nach Timestamp
- Spiele für jeden Objekt-Typ dessen Operationen nacheinander ab
- Mögliche Konflikte:
 - Einzelne Eigenschaften: “Last Edit Wins”
 - Hierarchie-Bedingungen: überspringe Operationen, die einen ungültigen Zustand erzeugen würden

Praktische Umsetzung

Optimierung: Cachen des aktuellen Zustands

- Wiedergabe des *gesamten* Logs nach jedem Sync wäre zu viel Arbeit
- Lösung: speichere aktuellen Stand im normalen Datenmodell, wende nur die neuen Änderungen auf diesen Stand an

Problem: Out-of-Order-Änderungen

- Beginne bei Stand x
- Wende Operation A an. Neuer Stand: $(x + A)$
- Synchronisation mit Server ergibt Operation B, die vor A stattfand
- Können Stand $((x + A) + B)$ berechnen, benötigen aber $(x + B + A)$
- Problem: wie kommen wir von $(x + A)$ zurück zu $(x + B + A)$?

Lösung: “Idempotente” Operationen

- Einfach, wenn $(x + B + A) = ((x + A) + B + A)$ für **alle** möglichen Operations-Sequenzen A, B
- Normalerweise der Fall bei “Last Edit Wins”
- Gegenbeispiel: Hierarchien, da dort die Operationen nicht auf einzelne Felder beschränkt sind

Integration bestehender Daten

- Wie synchronisieren wir Daten, die schon vor dem Sync vorhanden waren?
- Lösung: Erstelle ein Diff von aktuellem Sync-Datensatz und neuem Client, hänge alle Objekte im Diff als “Add”-Operationen ans Operation Log an
- Achtung: hier keine Fehler machen!

Optimierung: Kompression

- Viele ähnliche Einträge
 - ⇒ Kompression kann erhebliche Vorteile bringen
- Insbesondere bei der Integration bestehender Daten
- Weniger effizient für “neue”, im laufenden Betrieb erstellte Daten
 - Einträge können auch nachträglich zusammengefasst werden, ist aber kompliziert

Problem: Cross-Entity-Konflikte

- Device A erstellt Task in Projekt X
- Device B löscht Projekt X
- Lösung: Nach dem Anwenden (aber vor Abschluss des Syncs!) auf Konflikte prüfen

Problem: Lookup Tables

- Beispiel: Lookup Table zur Deduplizierung von Task-Titeln
- IDs von identischen Einträgen unterscheiden sich von Gerät zu Gerät
- Lösung: Lookup-Table nicht synchronisieren, Daten im Operation Log denormalisieren

Änderungen am Datenmodell

- Lösung: veraltete Clients syncen entweder gar nicht mehr, oder erkennen inkompatible Log-Einträge an deren Versionsnummer

Server-Stack

- Swift/Vapor
 - SwiftGRPC hinter Google Cloud Endpoints zur Kommunikation
 - Docker-Container via Kubernetes Engine auf Google Cloud
 - Datenbank: PostgreSQL (Google Cloud SQL)
 - Authentifizierung: zufällige Refresh Tokens + JWT
-
- Alternative: CloudKit

Timeline: Timing Sync

- Januar: Refactoring/Zentralisieren aller DB-Änderungen
- Februar: Erweitern dieser Klasse um Logging
- Februar/März: SwiftGRPC überarbeitet
- März: Hochladen/Anwenden von Sync, mit Fake-Server getestet
- April: Sync-Server in Vapor/SwiftGRPC
- Mai + Juni: Deployment, erste Beta, Feintuning
- Anfang Juli: Release

Vorteile

- Sehr robust
- Log besteht nur aus BLOBs
 - ⇒ effizient
 - ⇒ einfacher Server-Code
 - ⇒ wartbar
 - ⇒ Kompression + Verschlüsselung einfach umzusetzen
- Relativ gut komplett zu testen

Nachteile

- Gelöschte Daten und alte Änderungen belegen immer noch Platz
- Benötigt lokalen Cache, da kein „Random Access“ möglich
 - Nicht tragbar, wenn bei jedem Sync alles neu abgespielt wird
- Team-Funktionen schwer umsetzbar
- Cross-Entity-Konflikte müssen individuell gelöst werden
- Benötigt einen zentralen Server

Zusammenfassung

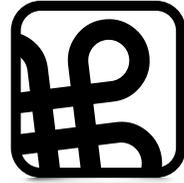
- Jede Sync-Problemstellung ist anders
 - Vorher angestellte Überlegungen sparen euch später viel Zeit
- Vorsicht bei Feld-basierter Synchronisation
- Versucht möglichst viel Nutzerintention zu erhalten

Fragen?

via Twitter: @daniel_a_a

(Vorträge bewerten bitte nicht vergessen!)

Vielen Dank



Macoun

Konflikt: überlappende Tätigkeiten und App-Aktivitäten

- Immer nur eine Tätigkeit zu jeder Zeit (dürfen nicht überlappen)
 - App-Aktivitäten zählen nicht, wenn Tätigkeit zur gleichen Zeit
- Bisher:
 - Bestehende Tätigkeit gelöscht und ersetzt
 - App-Aktivitäten haben Eigenschaft *taskID*

Konflikt: überlappende Tätigkeiten und App-Aktivitäten

- Für Sync:
 - Auf unterschiedlichen Geräten gleichzeitig erstellte Tätigkeiten dürfen überlappen (passiert extrem selten)
 - *taskID* wird zur Laufzeit “berechnet”

Beispiel-Server: Upload

```
func uploadOperationLog(session: SyncUploadOperationLogSession) throws  
-> Status? {  
    while true {  
        guard let message = try session.receive() else { return .ok }  
        var newEntry = message.operationLogEntry  
        newEntry.metadata.serverTimestamp = Date().timeIntervalSince1970  
        newEntry.metadata.serverID = operationLogEntries.count  
        operationLogEntries.append(newEntry)  
  
        var response = Timing_UploadOperationLogResponse()  
        response.receivedLocalID = newEntry.metadata.localID  
        response.resultingServerID = newEntry.metadata.serverID  
        response.resultingServerTimestamp =
```

