

Tolerance chyb a shoda v DS

Paralelní a distribuované systémy, přednáška 9

Tomáš Urbanec

Katedra informatiky PŘF UPOL

2.12.2025

Co nás čeká?

1. Shoda v DS s chybami

- Základní pohled
- Raft
- Paxos
- Byzantské chyby podruhé
- Některá omezení

2. Konzistence a replikace

- Konzistence a její typy
- Metody replikace
- Některá omezení

Shoda v distribuovaném systému

Shoda v DS

Základy

- Systém se musí shodnout na výsledku, stavu, další akci, ...
- Bez chyb → triviální.
- S chybami? Záleží na okolnostech.
 - Typy chyb,
 - Model detekce,
 - ...

Skupiny

Shoda v DS

- Zavedení redundance.
- Úlohu uzlu převezme skupina uzlů.
 - Protokol primární-záloha
 - Hierarchická skupina
 - Pracuje primární (zázpisy)
 - Výpadek primárního → záloha převezme roli
 - Protokol replikovaného zápisu
 - 'Plochá' skupina,
 - Všichni stejná role,
 - Nemají kritický bod,
 - ... ale nutná koordinace.
- Skupina je odolná vůči chybám, pokud všechny bezchybné procesy vykonávají stejné operace ve stejném pořadí.

Algoritmus Flooding consensus

Shoda v DS

- Základní algoritmus pro shodu.
- Omezení na fail-stop model.
- Shoda se hledá v navazujících kolech.
 - V každém kole si uzly mění návrhy.
 - Každý uzel z návrhu vybere volbu deterministicky a všichni stejně
 - Pokud nikdo nedostane všechny odpovědi, začne nové kolo.
 - Všichni dostanou všechny odpovědi → volba → konec.
 - Někdo dostane všechny odpovědi a rozešle volbu → čekající přeberou volbu → konec.
 - (tabule)
- Existuje více variant. Základní myšlenka obdobná.

Byzantské chyby podruhé

Shoda v DS

- Co s byzantskými chybami?
- Idea problému
 - n -generálu se musí domluvit
 - m z nich je zrádných
 - Co s tím?
- Základní řešení
 - (tabule 2, 3, 4, ... generálové)
 - $n > 3 \cdot m$
 - Exponenciální počet zpráv
- Jiná řešení
 - Mají další předpoklady a omezení.
 - HoneyBadgerBFT (dig. podpisy) $\rightarrow n > 2 \cdot m$
 - Blockchain (cena) $\rightarrow n > 2 \cdot m$
 - MinBFT (speciální HW) $\rightarrow n > m + 1$
 - Kryptografické protokoly (důvěra) $\rightarrow n > m + 1$

Raft algoritmus

Shoda v DS

- Ongaro, Osterhout, 2014
 - Fail-noisy model.
 - Shoda v DS ve formě replikovaného logu operací.
- uzly ve stejném stavu.
- Moderní, často používaný.
 - 'Náhrada Paxosu' (dále).
 - Skupina má lídra.
 - Stavy uzlů: Lídr, následovník, kandidát.
 - Koncepty: volba lídra, replikace logu, provedení operace.
 - Většinové kvórum ($n > 2 \cdot m$).
 - (tabule)
 - Vizualizace: <https://raft.github.io>

Paxos algoritmus

Shoda v DS

- Lamport, 1989. Mnoho variant.
- Fail-noisy model.
- Často používaný, ale komplikovaný ($\rightarrow$ raft).
- Více typů procesů (client, proposer, leader, learner, acceptor).
- Vnitřní dělení uzlů (proposer + acceptor + learner).
- Většinové kvórum ($n > 2 \cdot m$).
- Předpoklady:
 - 1 asynchronní DS.
 - 1 nespolehlivé spoje.
 - Chybné zprávy detekovatelné.
 - Operace deterministické.
 - Nemáme náhodné chyby.
- (tabule - zjednodušená verze)

Shoda v DS

Omezení

- Shoda není vždy možná.
- Potřebujeme:
 - synchronní systém,
 - nebo omezený čas na zprávu a pořadí zpráv,
 - nebo multicast.
- A co když máme v DS více menších DS?
- A každý má jiné chyby?
- Třeba byzantské?
- ...

Replikace a konzistence

Redundance, replikace a konzistence

Základy

- Redundance – již známe (více vzájemně nahraditelných uzlů)
- Replikace – již tušíme (raft jako replikace stavu)
- Konzistence – repliky musí být shodné (dále)

Replikace:

- Důvody
 - zvýšení spolehlivosti (redundance),
 - zvýšení výkonu.
- Zahrnuje redundanci (replika přežije pád 'originálu'), ale nabízí více (geografická dostupnost, rozložení zátěže, ...).
- Problémy s konzistencí (úprava jedné repliky? propagace?).
 - Problém výkonu → replikace → synchronizace replik
→ problém výkonu?
- Př. Kešování, CDN (Content Deliver Network), ...
- Př. DNS

Konzistence

Základy

- ≈ jednotlivé uzly DS reagují (dostatečně) stejně.
- Typicky nás zajímá výsledek proložených write a read operací.
 - Více typů: silná, eventuální, sekvenční, kauzální, ...
 - Silná (striktní) konzistence
 - Jako kdyby byly změny propagovány okamžitě.
 - Všichni reagují stejně.
 - Sekvenční konzistence
 - Výsledný stav odpovídá nějakému sekvenčnímu pořadí operací.
 - Pořadí stejné v rámci jednotlivých procesů.

Konzistence

Základy

- Kauzální konzistence
 - Pokud a potenciálně předchází b ($a \rightarrow b$), pak všichni vidí nejprve výsledek a a pak výsledek b .
 - U konkurenčních (nekauzálních) párů operací je to jedno.
 - (tabule)
- Eventuální konzistence
 - Jednou dostaneme aktuální data, ale ne nutně hned.
 - Typické kešování.
 - Tj. povolujeme read-write konflikty.
 - Co s write-write konflikty?
 - slabá: neřešíme,
 - silná: skončí ve stejném stavu (CRDT, spec. datové struktury → nepotřebujeme shodu)

Raft

Metody replikace

- Už známe.
- Bavili jsme se o shodě na operaci. . .
- . . . přitom se nám replikoval log leadera (jeho stav).

Řetězová replikace

Metody replikace

- Řetězec uzlů: hlava, . . . , ocas
- Zápisy na hlavu, čtení na ocase
- Zápis se propagují od hlavy k ocasu
- Zápis klientovi potvrzuje ocas
- → silná konzistence
- Nutná správa řetězce (tolerance chyb, centrální uzel)
- Selhání (fail-stop model):
 - Hlavy: náhrada následníkem
 - Ocasu: náhrada předchůdcem
 - Uzel uprostřed: řeší centrální uzel
 - Centrální uzel: nutná replikace!
- Konceptně jiné:
 - Nemáme leadera.
 - Při čtení reaguje ocas rovnou (vše je potvrzeno).
 - Jeden pomalý uzel degraduje celý systém → latence.

CAP teorém

Omezení

- Uvažujme DS s replikací dat (DB, obecně data store)
- Pozorování: síťovým problémům se nelze vyhnout.
- Tj. rozpadu sítě (partitioning) se nelze vyhnout.
- Když nastane rozpad (P) můžeme zachovat:
 - dostupnost (Availability),
 - nebo konzistenci (Consistency),
 - (ale ne obojí).
- (tabule)

PACELC teorém

Omezení

- CAP teorém je nepříjemný. . .
- . . . ale k rozpadu nemusí dojít.
- Tj. můžeme mít C i A!
- . . . ale . . .
- I když nemáme P, tak (Else) musíme volit mezi
 - Latencí (Latency)
 - Konzistencí (C)
- (tabule)
- PA/EL, PA/EC, PC/EL, nebo PC/EC?
- PostgreSQL (distr.) PC/EC, NoSQL (distr.) barvitě

CALM teorém

Omezení

- „consistency as logical monotonicity“
- Nedívejme se na vlastnosti systému, ale na vlastnosti programu.
- Kdy lze (distribuovaný) program implementovat bez synchronizace a zachovat konzistenci?
- Když je monotónní:
 - Pokud přidáme data na vstup, tak dostaneme stejný nebo rozšířený výstup.
 - Tj. žádné přepisy nebo ubírání.
 - Ano: přidávání do seznamu, sjednocení, ...
 - Ne: Maximum/minimum, množinový rozdíl, ...
 - (tabule)
- Program má konzistentní implementaci bez distribuované synchronizace, právě tehdy když je monotónní.

Changelog