Raft简介

分布式系统一致性协议

Dylan 周

2016-07

讨论范围

- 分布式系统一致性
- 如何解决此类问题
- 通俗易懂Raft讲解
  - 动画介绍
  - 核心行为
- 要点总结

一致性问题

- 分布式系统一致性
  - 安全性（safty）
  - 活性（liveness）
- Replication特性系统
  - 分布式系统（CAP理论）
  - 日志或者数据的复制

Raft特性

- 对象：Replication系统
- 条件：大多数Node存活即服务可用
- 容忍：失败模式，容许数据延迟和丢失
- 主观：算法设计易懂，便于生产实现

Raft概念

- Follower（追随者 F）
- Candidate（候选人 C）
- Leader （领导者 L）

- Term （时期）时间轴上阶段
- Node （节点) 泛指replication特性服务
- Repli-State-Machine（复制状态机）

Raft概述

- Leader election
  - 选择节点集合中的某一个作为集群leader
  - 探测崩溃，选举出新的leader
- Log replication
  - 从clients接收commands，应用操作到系统
  - 写副本数据到其他的节点
- Safety
  - 只有最新的认可数据的server才能是leader

Raft特点

- 强化Leader角色概念
- Leader选举
- 角色状态转换

选举动画

- http://thesecretlivesofdata.com/raft/

流程分析

- Leader选举
  1. 初始都是follower
  2. 收不到leader或者candidate的请求（选举超时）开始触发选举
  3. F增加他的term num并且转变为候选者状态
  4. F投票自己并且请求其他投票自己
  5. F结果有三类：

流程分析

- Leader选举-选举结果

1. 得到大多数票赢得选举
2. 其他F成为leader
3. 没有获胜者

选举约定

- 所有的node在同一个时间阶段（term）只会是三种状态中的之一

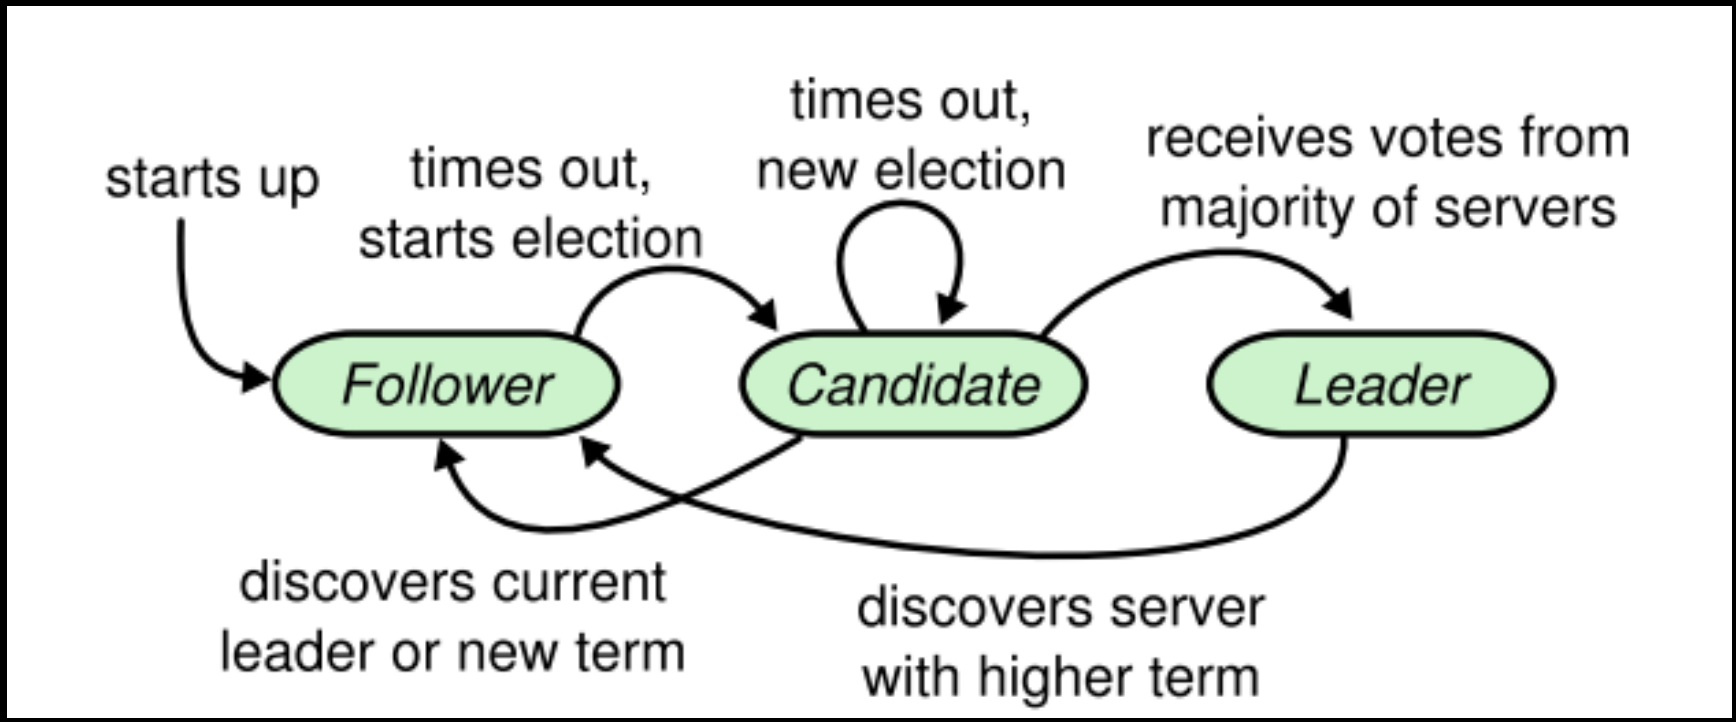

选举约定

- Term是一个不定的时间长度，不会重叠，每个term最多一个leader, 可能没有，成功选举后leader带领cluster直到term结束

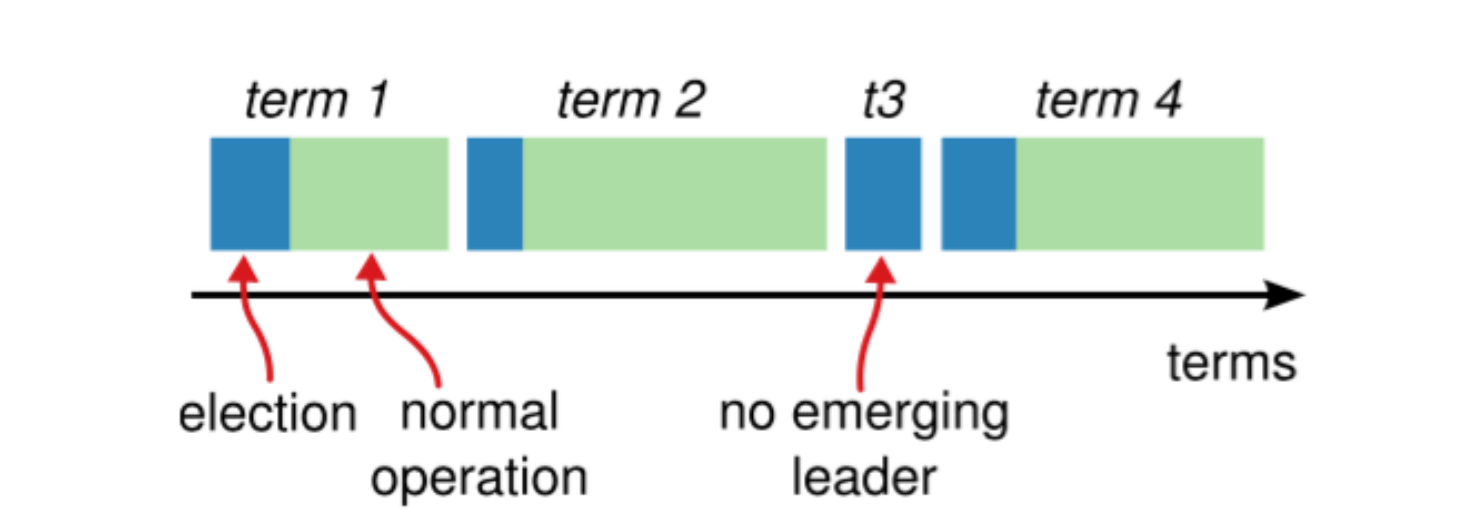

数据复制动画

- http://thesecretlivesofdata.com/raft/

数据复制

- Log Repilcation
  1. Client发送数据请求
  2. Leader接收到请求
  3. L发出append请求（记录数据）
  4. L收到大多数回复，返回给client状态
  5. L下个心跳给定commit给follower
  6. 如果传递失败会leader会不断重试

流程约定

- Log entry（数据）特性
  1. Log index
  2. Term num
  3. Command
- Log持久化存储
- Entry大多数存储成功则为commited

流程约定

- Index和term相同那么之前的entry都是相同的
- 某个entry commited 那么之前的都是commited

一致性检查

- 匹配检查：Append操作带上上一个entry的index和term
- 迭代重试：如果不匹配，重试前一条，直到成功

选举示例

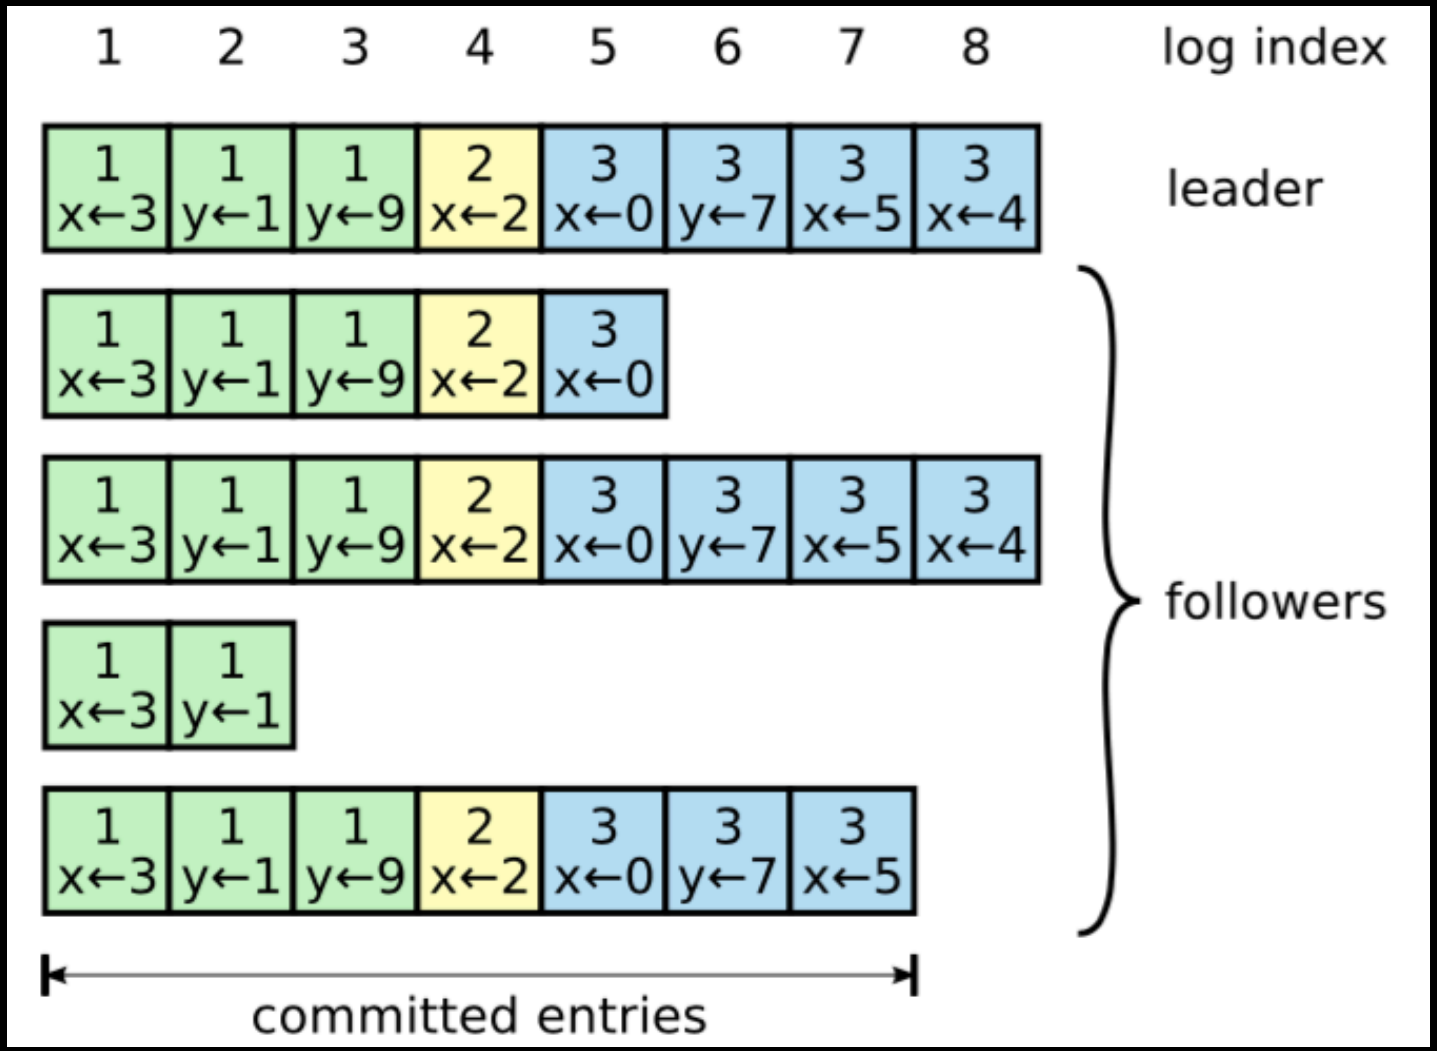
1 2 3 4 5 6 7 8
log index
1 x←3 | 1 y←1 | 1 y←9 | 2 x←2 | 3 x←0 | 3 y←7 | 3 x←5 | 3 x←4
leader
1 x←3 | 1 y←1 | 1 y←9 | 2 x←2 | 3 x←0
1 x←3 | 1 y←1 | 1 y←9 | 2 x←2 | 3 x←0 | 3 y←7 | 3 x←5 | 3 x←4
1 x←3 | 1 y←1
1 x←3 | 1 y←1 | 1 y←9 | 2 x←2 | 3 x←0 | 3 y←7 | 3 x←5
followers
committed entries

同步数据实例

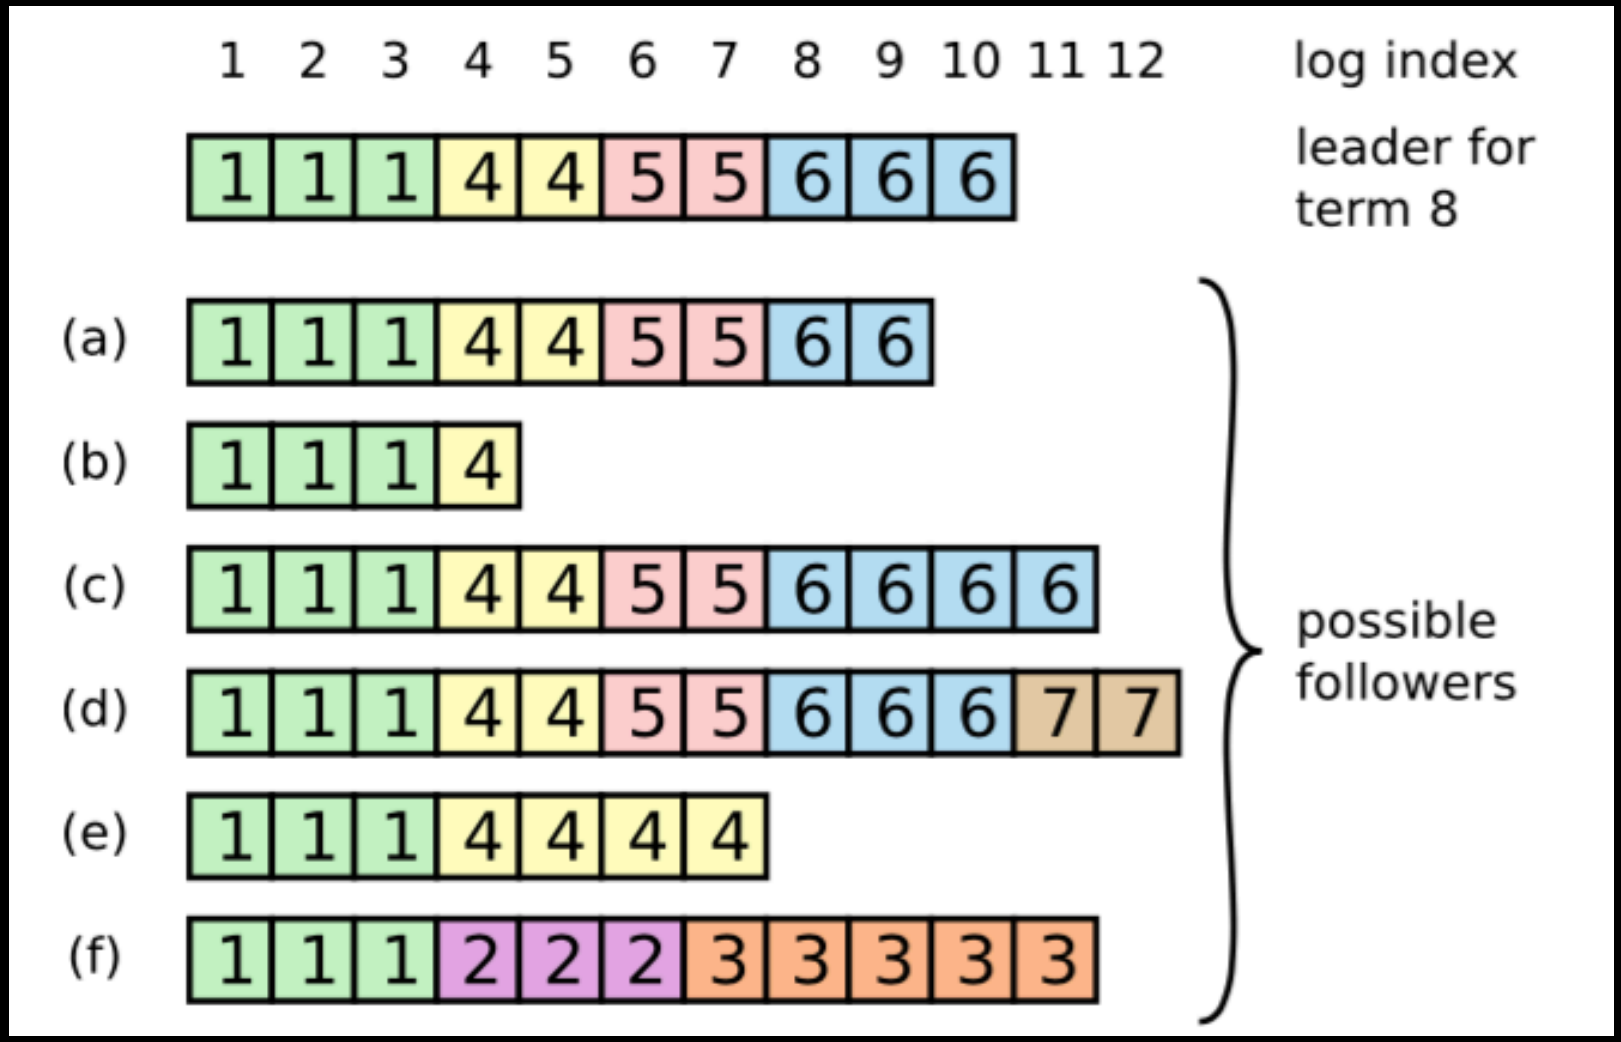
1 2 3 4 5 6 7 8 9 10 11 12
log index
1 1 1 4 4 5 5 6 6 6
leader for term 8
(a) 1 1 1 4 4 5 5 6 6
(b) 1 1 1 4
(c) 1 1 1 4 4 5 5 6 6 6 6
(d) 1 1 1 4 4 5 5 6 6 6 7 7
(e) 1 1 1 4 4 4 4
(f) 1 1 1 2 2 2 3 3 3 3 3
possible followers

核心总结

- Leader election
  - 心跳和超时来探测崩溃
  - 随机超时时间简化选举投票
  - 每个时期最多一个被选举
- Log replication
  - 从clients接收commands，应用到系统
  - 写副本数据到其他的节点，覆盖不一致信息
  - 内建的一致性检查，简化数据不同的处理方式
- Safety
  - 只有选举出来的leaders才有所有的提交数据记录
  - 只有最新提交数据的node才能是leader

Q&A

- 演示：http://thesecretlivesofdata.com/raft/
- Paper：https://raft.github.io/raft.pdf