# Überblick

**Multicast**

- Motivation
- Grundlagen
- Zustellungsgarantien
- Ordnungsgarantien
- Paxos

# Motivation

- Fehlertoleranz durch Replikation
  - Redundante Applikationsinstanzen auf unterschiedlichen Rechnern
  - Problemstellung: Replikatzustände müssen konsistent gehalten werden
- Aktive Replikation
  - Einsatz von gleichberechtigten, deterministischen Replikaten
  - Jedes Replikat führt alle Anfragen aus
  - Konsistenz durch Erstellung einer totalen Ordnung auf alle Anfragen
- Passive Replikation
  - Bestimmung eines Primärreplikats, das als einziges Anfragen ausführt
  - Aktualisierung der anderen Replikate mittels Zustandsänderungen
  - Konsistenz durch Einhaltung der Reihenfolge der Zustandsänderungen

$\Rightarrow$ Unabhängig von der Replikationsart: Mechanismus zum Senden von Nachrichten an die gesamte Replikatgruppe erforderlich

# Herausforderungen

- Multicast-Unterstützung durch das Kommunikationssystem
  - Vorteil: Geringere Komplexität der Replikations-/Anwendungsschicht
  - Beispiel: Teil eines Gruppenkommunikationssystems
  - Implementierungsvarianten
    - Auf Basis spezieller Netzwerkmechanismen (z. B. IP-Multicast) [Hier nicht betrachtet]
    - Mit Hilfe von Punkt-zu-Punkt-Verbindungen
- Herausforderungen
  - Zuverlässige Zustellung von Nachrichten trotz Fehlern
  - Bereitstellung von Ordnungsgarantien
  - Beweisbarkeit zugesicherter Eigenschaften
- Literatur

Christian Cachin, Rachid Guerraoui, and Luís Rodrigues
**Introduction to Reliable and Secure Distributed Programming (2nd ed.)**
*Springer*, 2011.

# Multicast

- Unterschiede zu Broadcast
  - Sender kennt die Empfänger seiner Nachricht
  - Explizite Anmeldung bei Eintritt in eine Multicast-Gruppe erforderlich
- Zentrale Operationen eines Kommunikationssystems
  - Senden (`multicast`)
    - Anwendung übergibt Nachricht an das Kommunikationssystem
    - Nachricht enthält Adressen aller designierten Empfänger
  - Ausliefern (`deliver`)
    - Kommunikationssystem übergibt Nachricht an die Anwendung
    - Einmal ausgelieferte Nachricht kann nicht zurückgenommen werden
- *Knoten*: Teilnehmer an einer Multicast-Gruppe
  - Übliche Synonyme: Prozess, Rechner, Prozessor,...
  - Im Folgenden: Unterscheidung im Kontext von Fehlern
    - *Fehlerhaft*: Knoten, der während der Beobachtungsphase ausfällt
    - *Korrekt*: Knoten, der nicht fehlerhaft ist

# Erkennung von Fehlern

- Grundansatz zur Realisierung von Fehlerdetektoren
  - Austausch von Heartbeat-Nachrichten zwischen Knoten
  - Überwachung der Heartbeat-Nachrichten mittels Timeouts
  - Auswertung des Ausbleibens von Heartbeat-Nachrichten
- Problem: Genauigkeit der Fehlererkennung
  - Synchrone Systeme
    - Bekannte obere Schranken für Ausführungs- und Übertragungszeiten
    - Ausbleiben einer Heartbeat-Nachricht ist Beleg für einen Fehler

    $\rightarrow$ Präzise Fehlererkennung möglich
  - Asynchrone Systeme
    - Keine oberen Schranken für Ausführungs- und Übertragungszeiten
    - Ausbleiben einer Heartbeat-Nachricht ist allenfalls Hinweis auf einen Fehler

    $\rightarrow$ Keine präzise Fehlererkennung möglich

$\Rightarrow$ **Die {Nicht-,}Verfügbarkeit eines Fehlerdetektors hat im Allgemeinen Einfluss auf das Design von Algorithmen** [Siehe später...]

# Fair-Loss-Punkt-zu-Punkt-Verbindung

- Grundidee
  - Modell einer unzuverlässigen Netzwerkverbindung zwischen zwei Knoten
  - Ausgangsbasis für die Modellierung komplexerer Verbindungen
- Eigenschaften
  - **Faire Verluste:** Eine von einem korrekten Knoten unendlich oft gesendete Nachricht wird vom Empfänger unendlich oft ausgeliefert
  - **Endliche Vervielfachung:** Eine von einem korrekten Knoten endlich oft gesendete Nachricht wird vom Empfänger endlich oft ausgeliefert
  - **Keine Erzeugung:** Nur gesendete Nachrichten werden ausgeliefert
- Bemerkungen
  - Einschränkende, aber realistische Annahmen über Unzuverlässigkeit
  - Betrachtung temporärer, gutmütiger Netzwerkfehler
    - Keine dauerhafte Netzwerkpartitionierung zwischen Sender und Empfänger
    - Wahrscheinlichkeit, dass eine gesendete Nachricht ausgeliefert wird, ist $> 0$

# Perfekte Punkt-zu-Punkt-Verbindung

- Eigenschaften
  - **Zuverlässige Auslieferung:** Falls Sender und Empfänger einer Nachricht korrekt sind, liefert der Empfänger die Nachricht letztendlich aus
  - **Keine Vervielfachung:** Eine Nachricht wird maximal einmal ausgeliefert
  - **Keine Erzeugung:** Nur gesendete Nachrichten werden ausgeliefert

- Realisierung
  - Ausgangsbasis: Fair-Loss-Punkt-zu-Punkt-Verbindung
  - Sendeseite
    - Wiederholte Übertragung einer zu sendenden Nachricht
    - Pausen zwischen einzelnen Übertragungen
  - Empfangsseite
    - Protokoll über bereits ausgelieferte Nachrichten
    - Erkennung und Unterdrückung von Duplikaten

$\Rightarrow$ **Baustein für Multicast-Implementierungen**

# Best-Effort-Multicast Eigenschaften

- Eigenschaften
  - **Gültigkeit:** Falls ein korrekter Knoten eine Nachricht $n$ sendet, dann liefert jeder korrekte Knoten die Nachricht $n$ letztendlich aus
  - **Keine Vervielfachung:** Eine Nachricht wird maximal einmal ausgeliefert
  - **Keine Erzeugung:** Falls ein Knoten die Nachricht $n$ eines Senders $k$ ausliefert, wurde $n$ auch zuvor von Knoten $k$ gesendet
- Bemerkungen
  - Vergleiche: Eigenschaften einer perfekten Punkt-zu-Punkt-Verbindung
  - Keine Aussagen über
    - Nachrichten, die von fehlerhaften Knoten gesendet wurden
    - das Ausliefern von Nachrichten auf fehlerhaften Knoten
  - Es kann von fehlerhaften Knoten gesendete Nachrichten geben, die nur von einem Teil der korrekten Knoten ausgeliefert werden

$\Rightarrow$ **Im Fehlerfall: Inkonsistenz zwischen korrekten Knoten möglich**

- Realisierung
  - Einsatz perfekter Punkt-zu-Punkt-Verbindungen
  - Sender verschickt Nachricht an alle Knoten
  - Ein Knoten liefert die Nachricht aus, sobald er sie bekommen hat

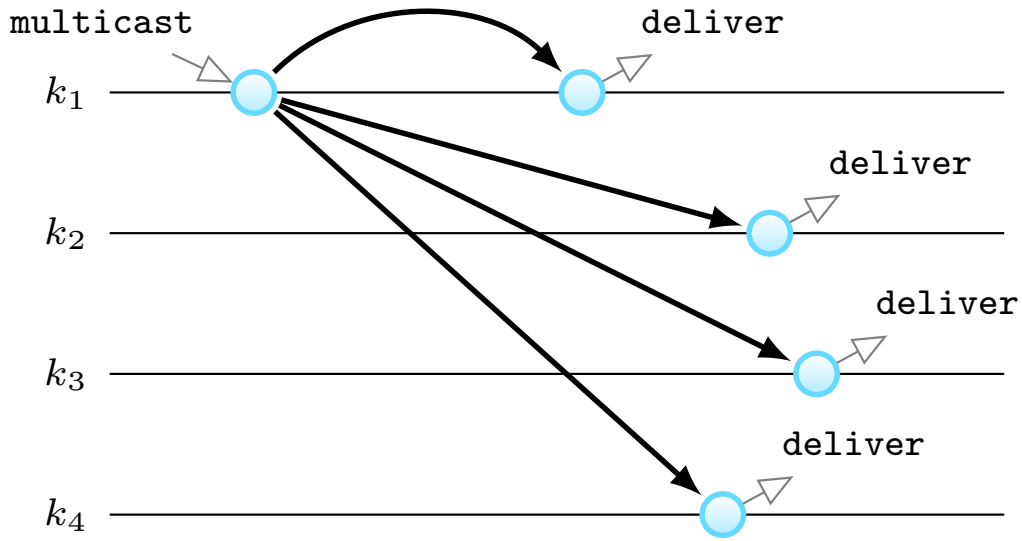


- Problemszenarien (Beispiele)
  - Sender fällt aus, bevor er die Nachricht an alle Knoten gesendet hat
  - Empfänger fällt aus, bevor er die Nachricht ausliefern konnte

- Eigenschaften

  [Grau: Identisch zum Best-Effort-Multicast]

  - **Gültigkeit:** Falls ein korrekter Knoten $k$ eine Nachricht $n$ sendet, dann liefert Knoten $k$ die Nachricht $n$ letztendlich auch aus
  - **Keine Vervielfachung:** Eine Nachricht wird maximal einmal ausgeliefert
  - **Keine Erzeugung:** Falls ein Knoten die Nachricht $n$ eines Senders $k$ ausliefert, wurde $n$ auch zuvor von Knoten $k$ gesendet
  - **Einigung:** Falls eine Nachricht $n$ von einem korrekten Knoten ausgeliefert wird, dann liefern letztendlich alle korrekten Knoten $n$ aus

- Bemerkungen
  - Konsistenz zwischen korrekten Knoten ist sichergestellt
  - Keine Aussage über fehlerhafte Knoten (vgl. Best-Effort-Multicast)

$\Rightarrow$ **Im Fehlerfall: Inkonsistenz zwischen korrekten Knoten und fehlerhaften Knoten möglich**

- Realisierung
  - Grundansatz wie bei Best-Effort-Multicast
  - Ein Empfänger leitet die Nachricht an alle anderen Knoten weiter

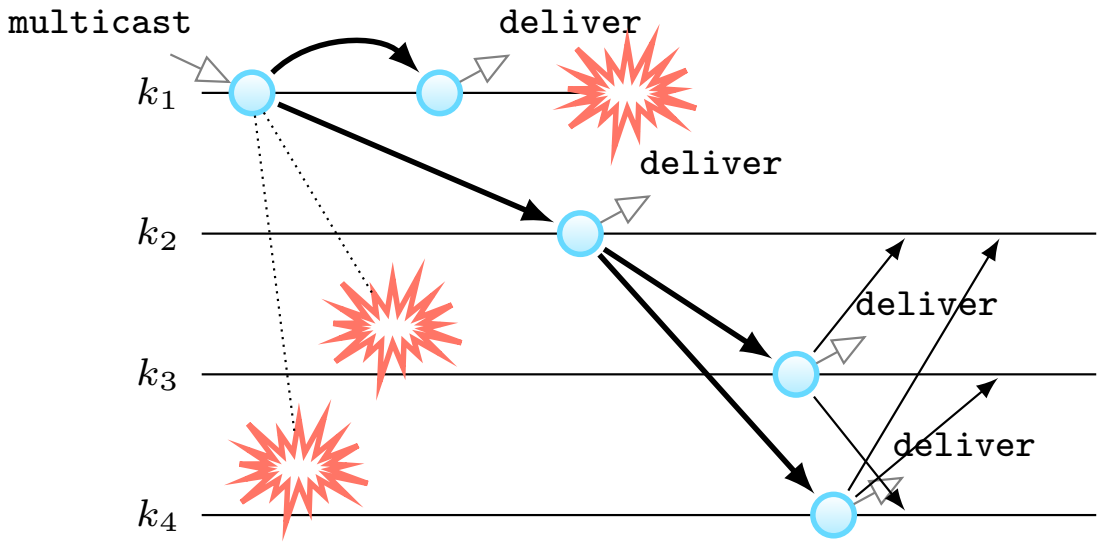


- Varianten: Weiterleitung der Nachrichten an andere Knoten
  - unmittelbar nach ihrem Empfang (*Eager*)
  - nach der Erkennung eines Knotenausfalls (*Lazy*)

- Beispielszenario
  - Fehlerhafter Knoten sendet Nachricht
  - Nachricht erreicht keinen korrekten Knoten
  - Nachricht wird von mindestens einem fehlerhaften Knoten ausgeliefert

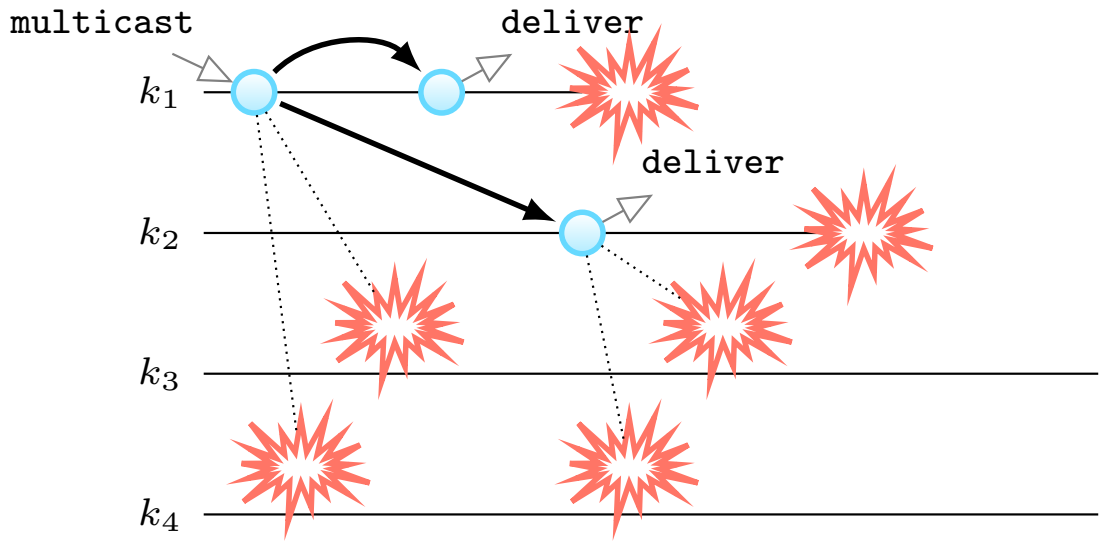


- Problem
  - `deliver` könnte zu einer Aktion (z. B. Antwort an Client) geführt haben
  - Korrekte Knoten werden diese Aktion niemals durchführen

# Uniformer zuverlässiger Multicast — Eigenschaften

- Eigenschaften

  [Grau: Identisch zum zuverlässigen Multicast]

  - **Gültigkeit:** Falls ein korrekter Knoten $k$ eine Nachricht $n$ sendet, dann liefert Knoten $k$ die Nachricht $n$ letztendlich auch aus
  - **Keine Vervielfachung:** Eine Nachricht wird maximal einmal ausgeliefert
  - **Keine Erzeugung:** Falls ein Knoten die Nachricht $n$ eines Senders $k$ ausliefert, wurde $n$ auch zuvor von Knoten $k$ gesendet
  - **Uniforme Einigung:** Falls eine Nachricht $n$ von **irgendeinem** Knoten ausgeliefert wird, dann liefern letztendlich alle korrekten Knoten $n$ aus

- Bemerkungen
  - Einschränkung der im Fehlerfall möglichen Inkonsistenz
  - Keine Aussage über Nachrichten, die von fehlerhaften Knoten stammen

$\Rightarrow$ **Eine durch die Auslieferung einer Nachricht ausgelöste Aktion wird letztendlich von allen korrekten Knoten ausgeführt**

- Realisierung
  - Grundansatz wie beim zuverlässigen Multicast
  - Ein Knoten wartet auf Bestätigungen, bevor er eine Nachricht ausliefert

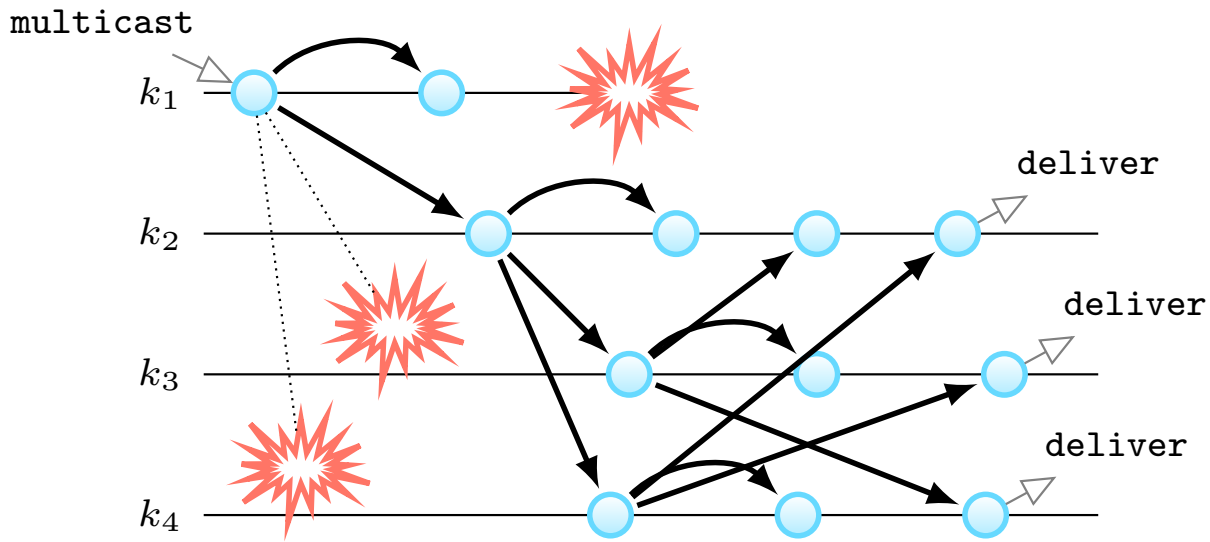


- Varianten
  - Warten auf Bestätigungen aller korrekten Knoten [→ erfordert Fehlerdetektor]
  - Warten auf $\lceil \frac{K+1}{2} \rceil$ Bestätigungen [Annahme: $K$ Knoten insgesamt, max. $\lfloor \frac{K-1}{2} \rfloor$ fehlerhaft]

# FIFO-Ordnung

- Eigenschaft
  - *FIFO: First In, First Out*
  - **FIFO-Auslieferung:** Falls ein Knoten eine Nachricht $n_1$ vor einer Nachricht $n_2$ sendet, dann liefert ein korrekter Knoten nur dann $n_2$ aus, wenn er zuvor bereits $n_1$ ausgeliefert hat
- Bemerkungen
  - FIFO-Eigenschaft bezieht sich jeweils auf die Nachrichten eines Knotens
  - Keine Aussage über die Reihenfolge, in der von unterschiedlichen Knoten gesendete Nachrichten ausgeliefert werden
- Beispiel für Realisierung
  - Nachrichtenversand per (uniformem) zuverlässigem Multicast
  - Nachrichten tragen senderspezifische Sequenznummern
  - Einhaltung der Reihenfolge bei Auslieferung der Nachrichten

# Totale Ordnung

- Eigenschaft
  - Annahmen
    - $n_1$ und $n_2$ sind zwei beliebige Nachrichten
    - $k_1$ und $k_2$ sind zwei beliebige korrekte Knoten, die $n_1$ und $n_2$ ausliefern
  - **Totale Ordnung:** Falls Knoten $k_1$ Nachricht $n_1$ vor Nachricht $n_2$ ausliefert, dann liefert Knoten $k_2$ auch $n_1$ vor $n_2$ aus
- Bemerkungen
  - Totale Ordnung bezieht sich auf sämtliche ausgelieferten Nachrichten
  - Zentraler Baustein replizierter Systeme
  - Problemstellung orthogonal zu FIFO-Ordnung
- Mögliche Realisierung
  - (Uniformer) zuverlässiger FIFO-Multicast als Basis
  - Wahl eines Anführerknotens [Neuwahl nach Ausfall des aktuellen Anführers]
  - Anführer bestimmt die globale Auslieferungsreihenfolge aller Nachrichten

- *Paxos*-Protokoll
  - Entwickelt Ende der 1980er, Papierveröffentlichung 1998
  - Einigungsprotokoll zur Replikation deterministischer Zustandsmaschinen
  - Tolerierung von Replikatausfällen
- Varianten (Beispiele)
  - *Cheap Paxos* Einsparung von Ressourcen
  - *Fast Paxos* Reduzierung der Latenz
  - *Byzantine Paxos* Tolerierung willkürlicher Fehler
- Literatur

Leslie Lamport
**The Part-time Parliament**
*ACM Transactions on Computer Systems, 16(2):133–169*, 1998.

Jonathan Kirsch and Yair Amir
**Paxos for System Builders: An Overview**
*Proceedings of the 2nd Workshop on Large-Scale Distributed Systems and Middleware (LADIS '08), S. 14–19*, 2008.

# Protokoll nach [Kirsch et al.]

- Architektur
  - $2f + 1$ Replikate zur Tolerierung von bis zu $f$ Replikatausfällen
  - Vorbereitung: Wahl eines Anführerreplikats (hier: Replikat $R_1$)
- Protokollinstanz: Zuweisung einer Sequenznummer zu einer Anfrage
  - REQUEST Client sendet Anfrage an Anführerreplikat
  - PROPOSE Anführer schlägt {Sequenznummer, Anfrage} vor
  - ACCEPT Andere Replikate nehmen Vorschlag an
  - REPLY Beantwortung der Anfrage nach Erhalt von $f$ ACCEPTs

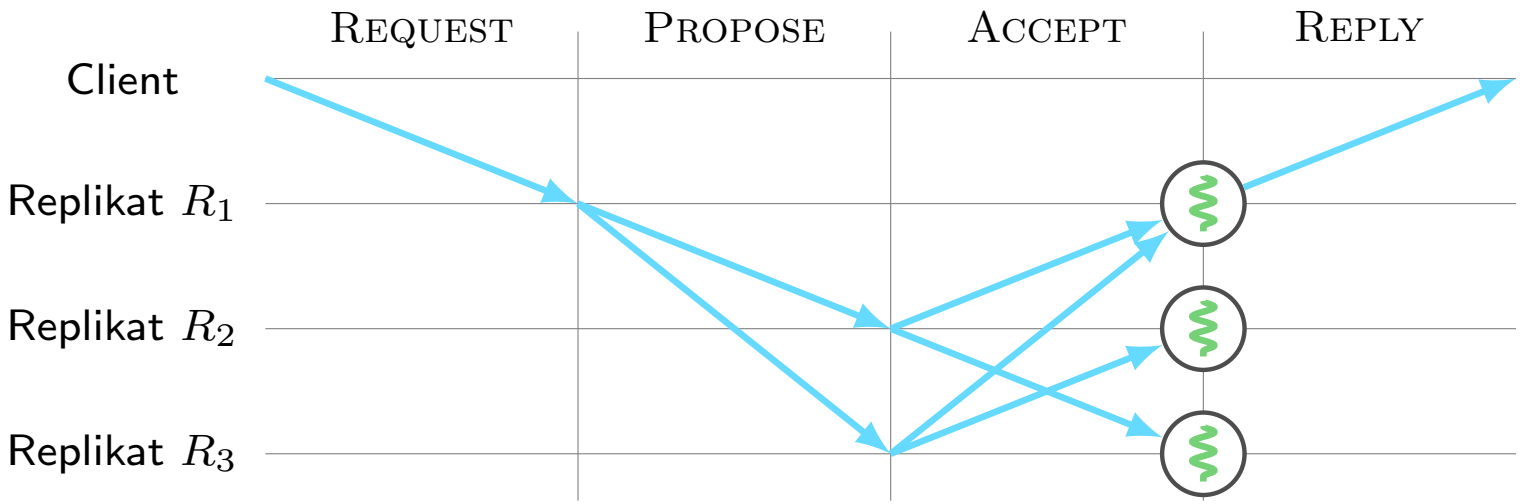


- Anführerwechsel
  - Anlass: Trotz neuer Anfragen werden keine neuen Instanzen gestartet
  - Mögliche Implementierung
    - Neuer Anführer ($\rightarrow$ Replikat mit nächsthöherer ID) schlägt Wechsel vor
    - Andere Replikate stimmen dem Vorschlag zu
      - Bericht über Anfragen, für die sie ein PROPOSE/ACCEPT geschickt haben
      - Ab sofort: Ignorieren von PROPOSE-Nachrichten des alten Anführers
    - Wechsel beendet, sobald $f$ andere Replikate dem neuen Anführer folgen
    - Neuer Anführer startet Instanzen für bekannte Anfragen neu
- Sicherungspunkte
  - Probleme
    - Ohne zusätzliche Maßnahmen müssten beim Wechsel des Anführers sämtliche bisherigen Protokollinstanzen wiederholt werden
    - Langsame Replikate haben keine Chance aufzuholen
  - Ansatz: Regelmäßige Erzeugung von Anwendungssicherungspunkten
    - Verwerfen von Informationen über ältere Protokollinstanzen
    - Bereitstellung des Sicherungspunkts auf Anfrage eines anderen Replikats

- Parallelisierung von Protokollinstanzen
  - Ansatz
    - Anführer schickt neues PROPOSE während frühere Instanzen noch laufen
    - Beschränkung der maximalen Anzahl gleichzeitig ausgeführter Instanzen
    - Instanzen können in unterschiedlicher Reihenfolge fertig werden
    - Berücksichtigung der Sequenznummern bei Bearbeitung der Anfragen
  - Vorteile
    - Keine Wartezeiten beim Eintreffen von Anfragen
    - Steigerung des Durchsatzes
  - Nachteil: Erhöhter Aufwand für Konsistenzwahrung bei Anführerwechsel
- Einigung mehrerer Anfragen pro Protokollinstanz (*Batching*)
  - PROPOSE enthält {Sequenznummer, $\text{Anfrage}_1$, $\text{Anfrage}_2$, $\text{Anfrage}_3$, ...}
  - Bearbeitung der Anfragen nach ihrer Position im PROPOSE
  - Vorteil: Reduzierung des Aufwands je zu einigender Anfrage
  - Nachteil: Verzögerung von Anfragen