Verteilte Betriebssysteme

4. Kapitel
# Gruppenkommunikation

Prof. Matthias Werner
Professur Betriebssysteme



## 4.1 Semantik

### Wiederholung

- **Multicast**: Nachricht geht an mehrere

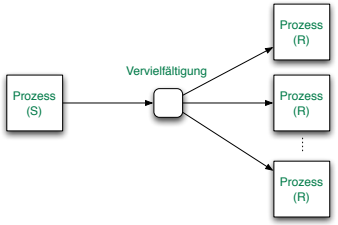


- **Combine**: Mehrere Nachrichten werden kombiniert

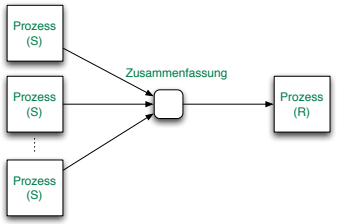






## Realisierung durch Brücken

- **Multicast**: Empfänger auf mehreren Rechnern

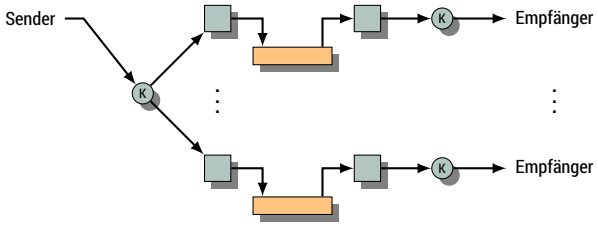


- **Combine**: Sender auf mehreren Rechnern

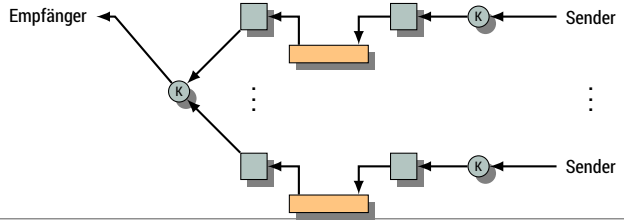






## Semantische Varianten (bei Multicast)

- Die Verteiltheit des Kanals macht es schwierig, die Semantik des lokalen Falls zu erhalten
- Es eröffnen sich weitere semantische Varianten, welche
  - die **Zuverlässigkeit** der Auslieferung
    und
  - die **Synchronisation** der beteiligten Prozesse betreffen

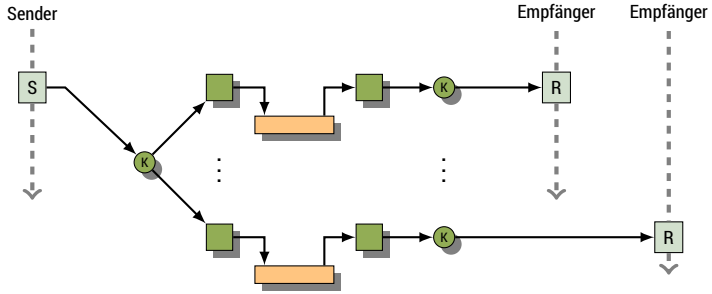

# Zuverlässigkeit der Zustellung

- **Unzuverlässiger Multicast**
  Es werden keinerlei Zusagen über den Erfolg der Zustellung gemacht
- **Zuverlässiger Multicast**
  Die Nachricht wird an **mindestens** einen Empfänger ausgeliefert, aber nicht notwendigerweise an alle
- **Atomarer Multicast**
  Die Nachricht wird entweder an **alle** Gruppenmitglieder erfolgreich ausgeliefert **oder** an **keinen**

**Achtung**

Mitunter sind die Definitionen in der Literatur anders. So definiert z.B. [CDK02, Kapitel 11] den zuverlässigen Broadcast als atomar, dafür gibt es dort einen Basis-Broadcast.

[CDK02] George Coulouris, Jean Dollimore und Tim Kindberg. *Distributed Systems: Concepts and Design*. 3. Aufl. Prentice Hall, 2002





# Zurückhalten beim Ersatzobjekt

- Um Atomarität (und Ordnung) beim Multicast zu erhalten, wird zwischen **Empfang** bei der empfängerseitigen Ersatzinstanz und der **Auslieferung** an den Empfänger unterschieden

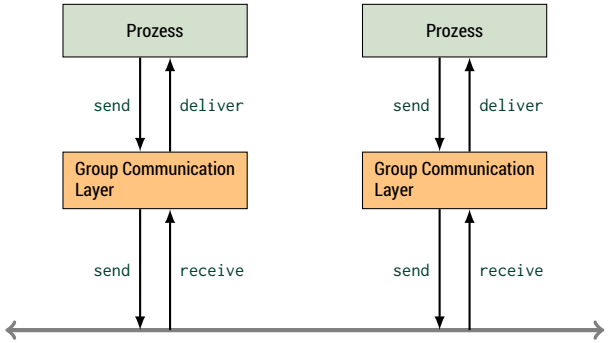






# Synchronisation

- Der atomare Multicast impliziert (bei synchronem Empfang) eine **Barrierensynchronisation**
- Auslieferung der Nachrichten auf den Zielseiten und Deblockieren der Empfänger erst, wenn
  1. überall die Nachrichten eingetroffen
     **und**
  2. alle Empfänger die Auslieferungsoperation gerufen haben
- Ansonsten kann ein Deblockieren stattfinden, wenn die Nachricht beim jeweiligen Empfänger angekommen ist





# 4.2 Ordnung

- Gegeben seien zwei überlappende Empfängergruppen $G_1$ und $G_2$, an die nacheinander jeweils eine Nachricht gesendet wird
- **Frage**:
  In welcher Reihenfolge kommen die Nachrichten bei den Empfängern an?
- Frage lässt sich verallgemeinern

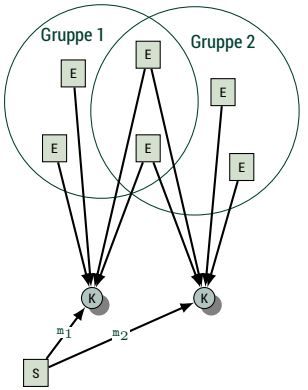

## Ereignishorizont

- Es gibt nicht notwendiger Weise eine „richtige“ Reihenfolge

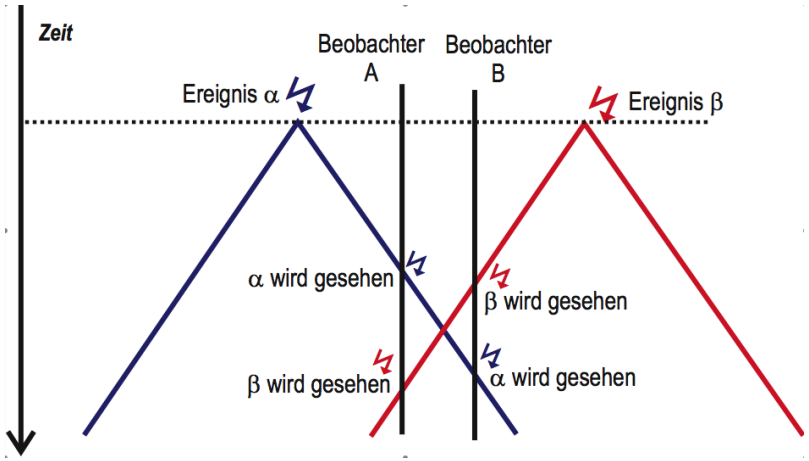






## Mögliche Ordnungsanforderungen

- Es gibt verschiedene mögliche Anforderungen an die Auslieferungsreihenfolge
  - Ungeordnete Auslieferung
  - FIFO (first in first out)
  - Kausale Ordnung
  - Vollständig sortierte (Auslieferungs-)Ordnung
  - Vollständig sortierte FIFO-Ordnung
  - Vollständig sortierte Kausalordnung (mitunter als globale Ordnung bezeichnet)





## Beliebige Auslieferungsreihenfolge

- Der atomare Multicast allein verlangt keine bestimmte Auslieferungsreihenfolge
- Lediglich die Atomarität muss (für fehlerfreie Prozesse) gewährleistet sein

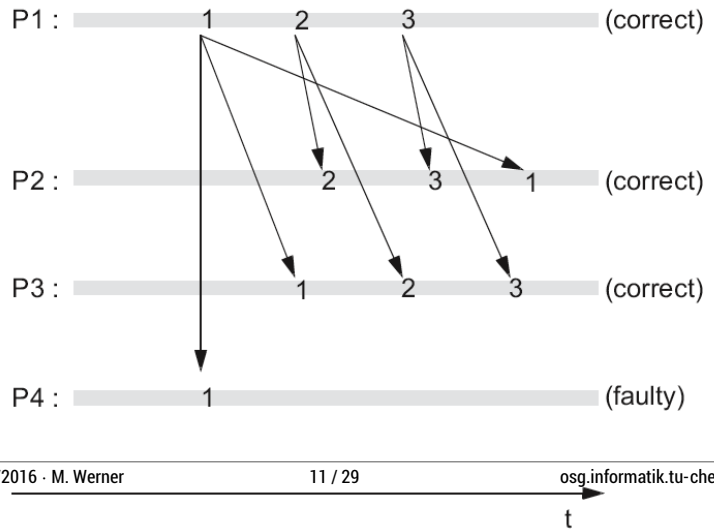






## FIFO-Ordnung

**FIFO-Ordnung**

Wenn ein korrektes Mitglied `multicast(`$m_1$`)` vor `multicast(`$m_2$`)` ausführt, dann führt kein korrektes Mitglied `deliver(`$m_2$`)` durch, bevor es nicht $m_1$ ausgeliefert hat.

- **Idee**:
  - Nachricht wird in der Regel in einem **Kontext** abgearbeitet
  - Eine per Multicast gesendete Nachricht sollte bei jedem Empfänger den gleichen Kontext (senderbezogen) vorfinden
  - **Beispiel:** File-Öffnen vor File-Schreiben

## Kausale Ordnung

- FIFO-Ordnung bezieht sich nur auf einzelnen Sender
- **Aber:**
  Bei komplexeren Kontexten (Abhängigkeit von mehreren Sendern) nicht hinreichend
- **Beispiel:** Ein Empfänger kann aufgrund der empfangenen Nachricht $\texttt{m}_1$ selbst wieder eine Nachricht $\texttt{m}_2$ senden, die bei einem dritten Mitglied (bei FIFO) vor $\texttt{m}_1$ ausgeliefert wird
- Um solche Fälle beschreiben zu können, wird (potentielle) Kausalität über die **Happened-before-Relation** beschrieben





## Happened-before-Relation

- Zwei Ereignisse $e_1$ und $e_2$ erfüllen die **Happened-before-Relation** (auch: „happens before“ oder „happen before“), bezeichnet mit $e_1 \prec e_2$, wenn Folgendes gilt:
  1. $e_1$ und $e_2$ treten bei einem Gruppenmitglied (d.h. lokal) genau in dieser Reihenfolge auf;
     oder
  2. $e_1$ ist ein `multicast`-Ereignis einer Nachricht und $e_2$ die zugehörige Auslieferung;
     oder
  3. Es gibt ein Ereignis $e_0$, so dass $e_1 \prec e_0$ und $e_0 \prec e_2$
- **Sprachregelung**: $e_2$ ist von $e_1$ **kausal abhängig**
- Alternative Schreibweise: $e_1 \rightarrow e_2$





## Happened-before-Relation (Forts.)

- Die Happened-before-Relation ist:
  - **Transitiv:** $(a \prec b) \wedge (b \prec c) \Rightarrow a \prec c$
  - **Irreflexiv:** Es gibt kein $a$ mit $a \prec a$
  - **Asymmetrisch:** $(a \prec b) \Rightarrow \neg(b \prec a)$
- Zwei Ereignisse $a$ und $b$, $a \neq b$ sind voneinander **kausal unabhängig**, wenn weder $a \prec b$ noch $b \prec a$ gilt
  - Man schreibt: $a \parallel b$
  - Die Relation „$\parallel$“ ist reflexiv, aber nicht transitiv





## Kausale Ordnung

**Kausale Ordnung**

Gilt $\texttt{multicast}(\texttt{m}_1) \prec \texttt{multicast}(\texttt{m}_2)$, dann führt kein korrektes Gruppenmitglied $\texttt{deliver}(\texttt{m}_2)$, ehe es $\texttt{m}_1$ ausgeliefert hat.

- Auch: **Kausalordnung**
- Kausale Ordnung ist stärker als FIFO:
  Jede kausale Ordnung ist auch FIFO geordnet, Umkehrung gilt jedoch nicht
- Kausalität ist hier hypothetisch:
  - Jede **mögliche** Kausalität wird bewahrt
  - Es ist möglich, dass kausal geordnete Ereignisse gar nicht tatsächlich (semantisch) voneinander abhängig sind

## Kausale Ordnung (Forts.)

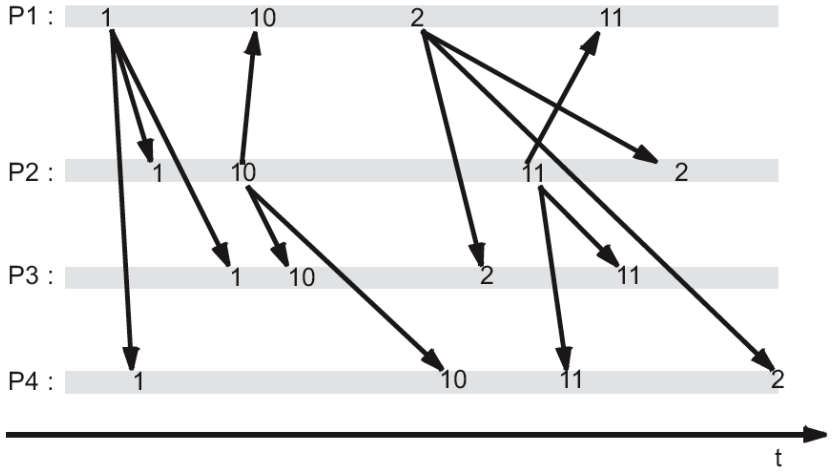


- Kausale Ordnung wird bei logischen Uhren genutzt (➡ nächstes Kapitel).





## Vollständig sortierter Multicast

**Vollständig sortierter Multicast**

Wenn die beiden korrekten Mitglieder P und Q die Nachrichten $m_1$ und $m_2$ ausliefern, dann liefert P die Nachricht $m_1$ genau dann vor $m_2$ aus, wenn Q dies auch tut.

- Mit anderen Worten: korrekte Prozesse liefern die gleiche Sequenz von Nachrichten aus
- **Beachte**: Es wird keine Aussage über die Sequenz an sich gemacht; insbesondere kann die Kausalität verletzt sein
- Ein Multicast mit vollständig sortierter Ordnung wird manchmal auch „Multicast mit totaler (Auslieferungs-)ordnung“ oder „Atomarer Multicast“ genannt
  - Letzteres ist etwas irreführend, da schon der ungeordnete Multicast atomar ist (Ganz-oder-gar-nicht-Semantik)





## Vollständig sortierter Multicast (Forts.)

- Beispiel:

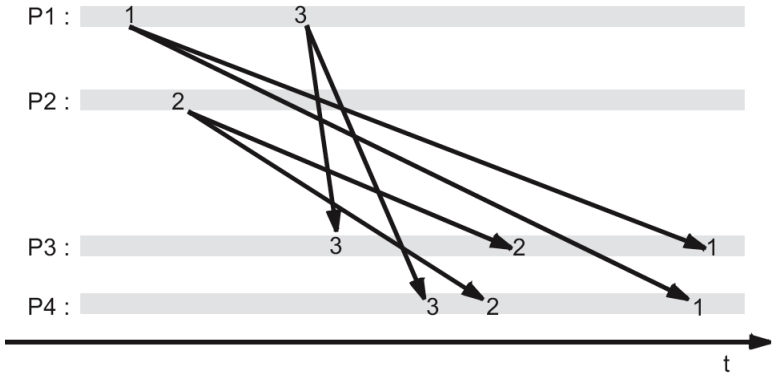






## Vollständig sortierte FIFO- und Kausal-Ordnungen

- Eigenschaften können kombiniert werden:
- **Vollständig sortierte FIFO-Ordnung**
  - Eine Ordnung, die sowohl first-in-first-out geordnet als auch vollständig sortiert ist
- **Vollständig sortierte Kausal-Ordnung**
  - Eine Ordnung, die sowohl kausal geordnet als auch vollständig sortiert ist
  - Häufig wird von **totaler Ordnung** (nicht nur bei der Auslieferung) oder globaler Ordnung gesprochen
  - Eng verwandt mit dem **Schnappschussproblem** ➡ späteres Kapitel

## Beispiel für vollständig sortierte FIFO-Ordnung

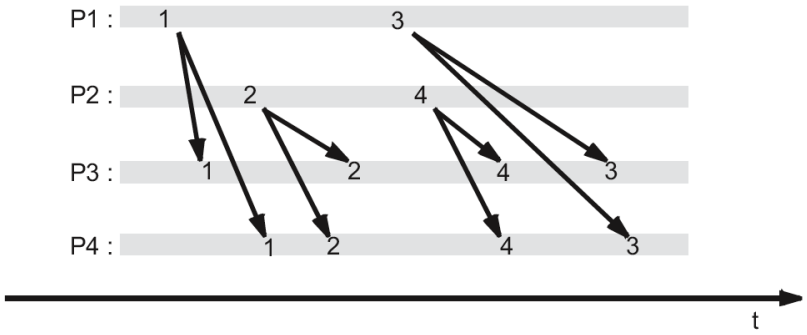






## Ordnung der Ordnungen

- Die Ordnungen können selbst nach der Stärke ihrer Anforderungen geordnet werden

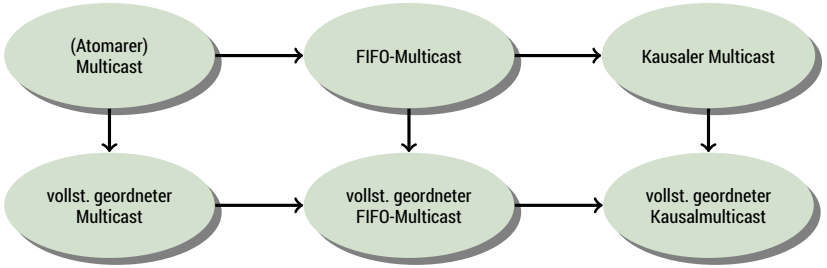






## 4.3 Implementierung

- Es gibt viele Systeme, die Gruppenkommunikation nutzen/realisieren
  - ISIS, Horus, Ensemble – Cornell University
  - **Transis** – Hebrew University
  - **Cactus** – Arizona State University
  - **JavaGroups** – open source
  - **Phoenix** – EPFL
  - **DCS** – IBM Haifa





## ISIS

- Entwickelt an der Cornell University Ihaka 1987 (KENNETH P. BIRMAN)
- Kommunikationschicht (Toolkit) oberhalb UNIX, später Mach, Chorus und anderer OS

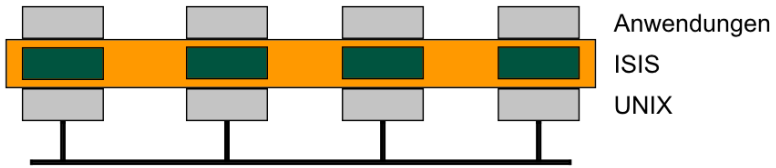


- Kommerzielle Anwender des Isis Toolkits:
  - New York Stock Exchange, Swiss Exchange
  - French Air Traffic Control System
  - AEGIS radar control and communications

## ISIS (Forts.)

- Das ISIS Toolkit bietet
  - **Multicast-Protokolle**
  - Erhaltung der Gruppensicht
  - Zustandsübertragung
- ISIS bietet folgende Multicast-Protokolle
  - **CBCAST** (kausal geordneter Multicast)
  - **ABCAST** (total geordneter Multicast)
    (**Achtung**: Semantik wurde zwischen den Versionen geändert!)
  - Verschiedene andere Protokolle (in unterschiedlichen Versionen)
- Basiskommunikation:
  - UDP/IP
  - Nachrichten werden bestätigt (*acknowledged*) und gegebenenfalls erneut gesendet ➡ zuverlässige Übertragung
  - Nutzung IP-Multicast wenn vorhanden (z.B. Ethernet), sonst Punkt zu Punkt





## CBCAST-Protokoll

- Ordnung durch (Sende-)**Ereigniszähler** (Zeitstempel)
  - Jeder Prozess $P_i$ $(i = 1, \ldots, n)$ besitzt einen Vektor $\vec{v}_i$
  - $\vec{v}_i = (v_{i,1}, \ldots, v_{i,n})$
  - Alle Prozesse starten mit einem Nullvektor

### Senden durch $P_i$

- Lokalen Zähler inkrementieren: $v_{i,i} = v_{i,i} + 1$
- $\vec{v}_i$ wird an Nachricht angehangen

### Empfangen durch $P_j$

- Lokale Nachrichten (d.h., $i = j$) werden sofort ausgeliefert
- Alle anderen Nachrichten werden solange zurückgehalten, bis folgende Kriterien erfüllt sind:
  1. Nachricht muss die nächste in einer Sequenz von $P_i$ sein, d.h., $v_{i,i} \overset{!}{=} v_{j,i} + 1$
  2. Alle kausal vorhergehenden Nachrichten die an $P_i$ gesendet wurden, sollten bei $P_j$ ausgeliefert sein, d.h. $v_{j,k} \overset{!}{\geq} v_{i,k}$





## ABCAST-Protokoll

- Ursprünglich nur totale Ordnung, in späteren Versionen totale Kausalordnung
- **Idee: Zentraler Sequenzer**
  ABCAST nutzt CBCAST-Nachrichten, die aber als ABCAST-Nachrichten gekennzeichnet sind
- In der Gruppe wird ein **Token-Halter** gewählt
  - Der Token-Halter empfängt ABCAST-Nachrichten und liefert sie bei sich kausal geordnet aus
  - Vom Token-Halter gesendete Nachrichten enthalten die Ordnungsnummer der Nachricht innerhalb der totalen Ordnung
  - Von Zeit zu Zeit sendet der Token-Halter eine sogenannte **Sets-order-Nachricht**, die die Sequenz-Nummer für eine oder mehrere von ihm empfangene ABCAST-Nachrichten enthält





## ABCAST-Protokoll (Forts.)

- Mitglieder, die keine Token-Halter sind, verzögern ABCAST-Nachrichten, bis
  - sie die entsprechende Sets-order-Nachricht empfangen haben
  - sie alle ABCAST-Nachrichten, auf die in der Sets-order-Nachricht bezug genommen wird, empfangen haben
  - sie alle kausal vorhergehenden CBCAST-Nachrichten ausgeliefert haben
- Das Token kann weitergegeben werden
  - **Vorteil**: Wenn (fast) nur Token-Halter ABCAST-Nachrichten versenden, sind keine (wenig) Sets-order-Nachrichten notwendig

## Literatur



[Mul93] Sape J. Mullender. *Distributed Systems*. ACM Press, 1993, Abschnitte 5.3 und 5.4


[BSS91] Kenneth Birman, André Schiper und Pat Stephenson. „Lightweight causal and atomic group multicast“. In: *ACM Transactions on Computer Systems* 9.3 (Aug. 1991), S. 272–314. ISSN: 0734-2071