Verteilte Betriebssysteme

7. Kapitel
Gegenseitiger Ausschluss

Prof. Matthias Werner
Professur Betriebssysteme

7.1 Grundlagen

- Koordination des exklusiven Zugriffs auf Ressourcen
  - Das Programmstück, das den Zugriff realisiert, heißt **kritischer Abschnitt** (critical section)
  - Beispiele für Ressourcen: Datei, Eventqueue, Drucker
- **Annahme**: Hat ein Prozess das Zugriffsrecht, so gibt er dieses nach endlicher Zeit wieder ab
- Meist: **Maximal ein** Prozess darf zugreifen
  - Manchmal auch Verallgemeinerung: maximal n Prozesse dürfen gleichzeitig zugreifen, oder unterschiedliche Zugreifer/Arten des Zugriffs ➡ Mehrsortenprobleme, Leser-Schreiber-Problem

Kontrollalgorithmen

- **Allgemein**: Gegenseitiger Ausschluss u.a. Koordinierungen werden in verteilten wie in nicht-verteilten Betriebssystemen gebraucht
  - Problem im verteilen BS schwieriger
- Was ist wenn Programme (Algorithmen) selbst verteilt sind?
- ➡ Algorithmen zur Feststellung/Herstellung des Zustandes von verteilten Algorithmen
- Unterscheidung „**Anwendungsalgorithmus**“ und „**Kontrollalgorithmus**“ (auch: Steueralgorithmus)

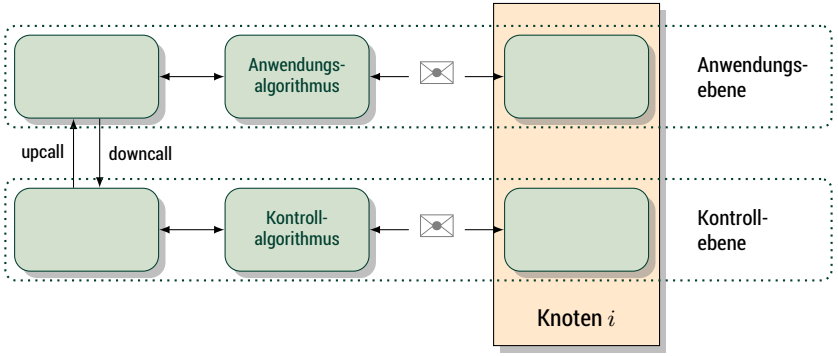

Anforderungen an eine Realisierung

- Kontrollalgorithmen müssen bestimmte Eigenschaften aufweisen
- **Sicherheit** (engl.: *safety*): Etwas nicht wieder gutzumachendes Schlechtes soll nie passieren
  - Hier: Zu jedem Zeitpunkt darf höchstens einem Prozess der Zugriff gestattet werden
- **Lebendigkeit** (engl.: *liveness*): Etwas das geschehen soll, geschieht schlussendlich auch
  - Hier: Gibt es mindestens einen Bewerber, muss einem der Bewerber der Zugriff nach endlicher Zeit gestattet werden
- Algorithmen müssen i.d.R. Sicherheit **und** Lebendigkeit erfüllen
- Fordert man **nur eines** von beiden, ist meist triviale Lösung möglich
  - textbfBeispiel: nur Sicherheit ➡ Zugriff wird immer verweigert
    nur Lebendigkeit ➡ Zugriff wird immer gewährt

Anforderungen an eine Realisierung (Forts.)

- Meist zusätzlich gefordert: **Fairness**
  - **Kein Verhungern**: Begehrt ein Prozess den Zugriff, muss ihm irgendwann (nach endlicher Zeit) der Zugriff gestattet werden
  - **Stärkere Fairnessanforderung**: Die Gewährung des Zugriffs berücksichtigt (auf die eine oder andere Weise) die Reihenfolge der Anforderungen

Leistungskriterien

- Zur Beurteilung der **Leistungsfähigkeit** eines Mechanismus für gegenseitigen Ausschluss können verschiedene Kriterien herangezogen werden
  - **Anzahl** n_m der versendeten Nachrichten pro CS (Nachrichtenkomplexität) ($n_m \rightarrow \min$)
  - **Abstimmungsverzögerung** d pro CS ($d \rightarrow \min$)
  - **Antwortzeit** t_r, d.h. Zeitspanne vom Anfordern des CS bis zum Verlassen ($t_r \rightarrow \min$)
  - **Durchsatz** T_P, d.h. Anzahl der Durchläufe durch einen CS pro Zeiteinheit ($T_P \rightarrow \max$)
- Im Folgendem Fokus auf Nachrichtenkomplexität und Abstimmungsverzögerung

Wiederholung: Gegenseitiger Ausschluss in nichtverteilten Systemen

- In zentralen Systemen gibt es für die Realisierung eines gegenseitigen Ausschlusses Kernoperationen des BS
- Realisierung basiert letztendlich auf gemeinsamer Variable

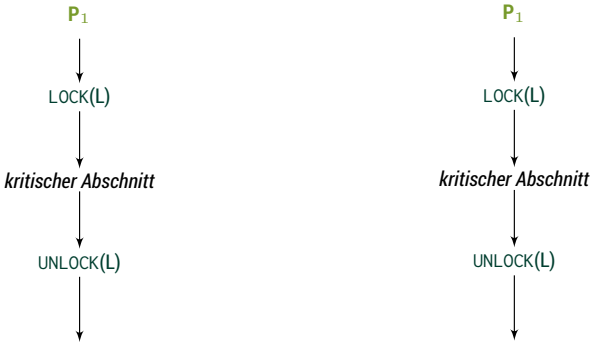

Wiederholung: Gegenseitiger Ausschluss in nichtverteilten Systemen (Forts.)

- Verschiedene Mechanismen bekannt (u.a. aus Betriebssysteme I):
  - Spinlock
  - Prozesslock
  - Semaphor
  - Monitor
- Mechanismen basieren auf atomarem Zugriff auf gemeinsamen Speicher (**atomares** Testen und Setzen einer Speicherzelle)
- Nicht gegeben in verteilten Systemen!
- Wie kann wechselseitiger Ausschluss in verteilten System realisiert werden?

Zentralisierte Lösung für verteilte Systeme

- Rückführung auf lokalen Fall:
  Ein Prozess ist bezüglich einer Ressource Koordinator (z.B. durch Auswahlalgorithmus, siehe späteres Kapitel)
- Alle Anforderungen und Freigaben werden dem Koordinator mitgeteilt
- Zuteilungen vergibt der Koordinator
- Leicht zu implementieren
- 3 Nachrichten pro Zugriff

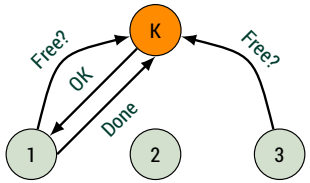

Verteilte Koordination

- Zentrale Lösungen sind einfach zu realisieren, haben aber auch Nachteile
  - „single point of failure“
  - Engpassgefahr (Flaschenhals)
  - Verzögerung: mindestens doppelte Nachrichtenlaufzeit
- Daher soll über verteilte Lösungen nachgedacht werden
- **Annahme**: im verteilten Fall existieren ebenfalls die Operationen LOCK und UNLOCK
- Zusätzlich können noch weitere Hilfsprozesse erforderlich sein

7.2 Broadcast-basierte Algorithmen

Broadcast Algorithmus von LAMPORT, 1978

- **Voraussetzungen**:
  - Verlustfreie FIFO-Kommunikationskanäle
  - Alle Nachrichten tragen eindeutige logische Zeitstempel ➡ siehe Kapitel **??** und 6
- **Grundidee**:
  - Jeder Prozess verwaltet eine nach Zeitstempeln geordnete Nachrichtenwarteschlange (Queue)
  - Anforderungen und Freigaben werden per Broadcast **an alle** gesendet

Broadcast Algorithmus von LAMPORT, 1978 (Forts.)

- **Anforderung abgeben**: Anforderung mit Zeitstempel in eigene Schlange einreihen und an alle senden
- **Anforderung empfangen**: Anforderung in eigene Schlange einreihen, Anfragebestätigung an anfragenden Prozess senden
- **Freigabe senden**: Anforderung aus eigener Schlange entfernen und Freigabe an alle senden
- **Freigabe empfangen**: Anforderung aus eigener Schlange entfernen
- Ein Prozess darf zugreifen, wenn
  - Eigene Anforderung ist **erste** Anforderung in eigener Schlange
  - Von **jedem** anderen Prozess wurde bereits eine Nachricht mit größerem Zeitstempel empfangen (z.B. die Anfragebestätigung)

Broadcast Algorithmus von LAMPORT, 1978 (Forts.)

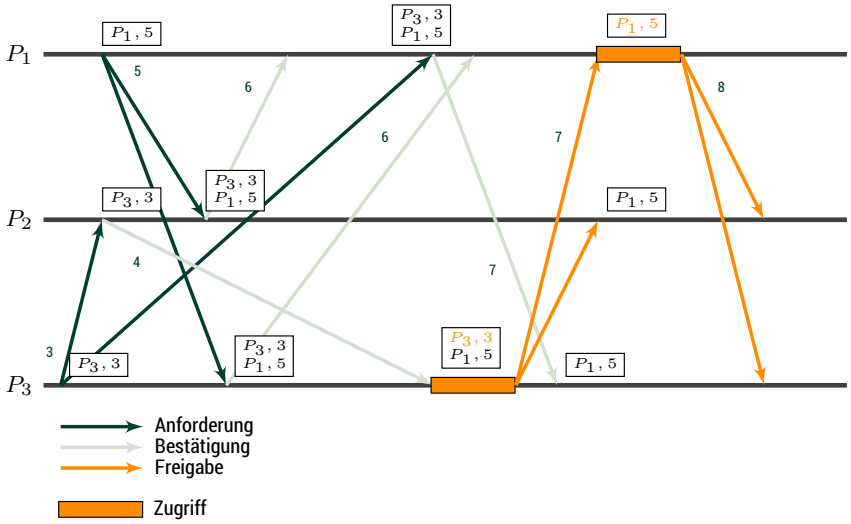

Broadcast Algorithmus von LAMPORT, 1978 (Forts.)

- Früheste Anforderung ist **global eindeutig**, nachdem von allen anderen Prozessen eine Nachricht mit größerem logischen Zeitstempel empfangen wurde
- **Nachrichtenkomplexität**:
  - Versenden der Anforderung an $(n-1)$ Prozesse
  - $(n-1)$ Prozesse versenden eine Bestätigung
  - Versenden der Freigabe an $(n-1)$ Prozesse
  - ➡ $3(n-1)$ Nachrichten pro Zugriff insgesamt ➡ bei Broadcast-Nachrichten gleich gut wie zentralisierte Lösung, sonst schlechter
- **Abstimmungsverzögerung**:
  - eine Nachrichtenlaufzeit ➡ besser als bei zentralisierter Lösung

Verbesserter Broadcast Algorithmus

- RICART und AGRAWALA, 1981
- Benötigt keine FIFO-Kanäle
- Benötigt nur $2(n-1)$ Nachrichten pro Zugriff
- **Grundidee**:
  - **Anforderung** (mit Zeitstempel) an alle anderen $(n-1)$ Prozesse senden
  - Zugriff, nachdem $n-1$ Einwilligungen **für diese Anforderung** erhalten wurden
  - ➡ jede Anforderung muss eine eindeutige ID haben
- **Bei Eintreffen einer Anfrage**:
  - Einwilligung **sofort** schicken, wenn
    - wenn nicht selbst beworben
      oder
    - Sender „ältere Rechte“ (erkennbar am logischen Zeitstempel) hat
    - Bei gleichen Zeitstempeln entscheidet die Knoten-ID
  - Ansonsten Einwilligung erst **nach Beendigung** des eigenen Zugriffs schicken

Verbesserter Broadcast Algorithmus (Forts.)

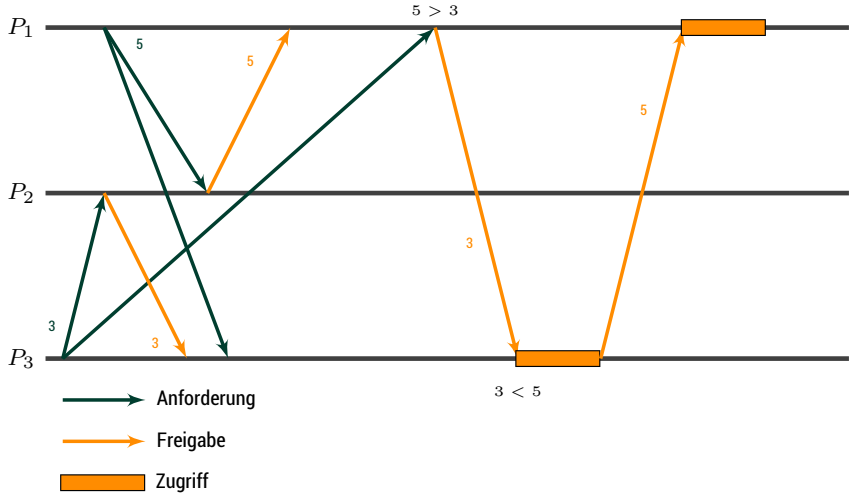

- Nummern an der Einwilligungsnachricht zeigen Zeitstempel der zugehörigen Anforderung, nicht der Nachricht selbst

7.3 Quorum-basierende Algorithmen

Bessere Algorithmen?

- Ist eine Lösung möglich, die mit
  - **weniger Nachrichten** pro Zugriff auskommt
    und
  - die trotzdem die **Last gleichmäßig** auf alle Prozesse verteilt?
- Gibt es eine Lösung, bei der
  - **nicht alle Prozesse** an jeder Koordination beteiligt werden
    und
  - die trotzdem die **Last gleichmäßig** auf alle Prozesse verteilt?

Prozessgitter-Algorithmus

- MAEKAWA, 1985
- Die n Prozesse werden in einem quadratischen Gitter der Maße $\sqrt{n} \times \sqrt{n}$ angeordnet
- Ein Prozess P_i muss eine bestimmte Menge von Prozessen (seine **Bewilligungsmenge** $\mathbb{R}_i$) vor dem Zugriff um Erlaubnis fragen
- Für alle Paare von Prozessen P_i und P_j sind deren $\mathbb{R}_i$ und $\mathbb{R}_j$ so angeordnet, dass sie mindestens zwei Prozesse gemeinsam haben

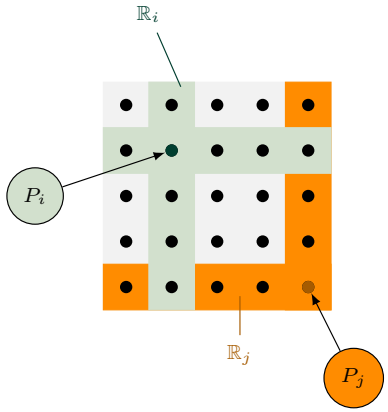

Prozessgitter-Algorithmus (Forts.)

- Bewilligungsmengen haben[1] die Mächtigkeit $2\sqrt{n} - 1$
- **Nachrichtenkomplexität**:
  - Anfrage an $2(\sqrt{n} - 1)$ Prozesse senden
  - $2(\sqrt{n} - 1)$ Prozesse senden Einwilligung
  - Freigabe an $2(\sqrt{n} - 1)$ Prozesse senden
  - ➡ $6(\sqrt{n} - 1)$ Nachrichten insgesamt pro Zugriff
- **Problem**: Es können Verklemmungen auftreten
  - Durch die Einführung weiterer Nachrichtentypen vermeidbar
  - Erhöht die Nachrichtenkomplexität nur um konstanten Faktor

Gibt es eine andere Anordnung der Prozesse, bei der die Mächtigkeit der Bewilligungsmengen kleiner ist?

[1] inklusive des „Antragsstellers“

Dreieckige Anordnung

- In einem quadratischen Gitter haben zwei verschiedene Bewilligungsmengen mindestens je zwei Prozesse gemeinsam
- Ein **einziger** gemeinsamer Prozess wäre aber ausreichend!
- **Lösung**:
  - Prozesse werden in einem Dreieck angeordnet
  - Bewilligungsmengen haben ungefähr die Mächtigkeit $\sqrt{2n}$
- **Problem**: Einwilligung mancher Prozesse wird häufiger benötigt als die anderer!
  - Prozess 15 kommt nur in **einer** Bewilligungsmenge vor
  - Prozess 1 kommt in **neun** Bewilligungsmengen vor

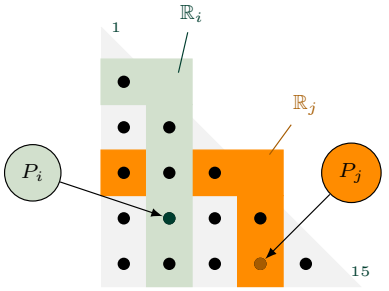

Bildung der Bewilligungsmenge

Gleiche Spalte und die Zeile eins überhalb als oberster Knoten der Spalte

Lösung zur Lastbalancierung

- **Ansatz**: Zwei unterschiedlichen Schemata
  - S1: Gleiche Spalte und Zeile eins über obersten Knoten der Spalte (nach oben und nach links)
  - S2: Gleiche Zeile und Spalte eins weiter rechts als rechtester Knoten der Zeile (nach rechts und nach unten)
- **Eigenschaften**
  - Jede Bewilligungsmenge überschneidet sich mit jeder Bewilligungsmenge des **gleichen** Schemas
  - Jede Bewilligungsmenge des **einen** Schemas überschneidet sich mit jeder Bewilligungsmenge des **anderen** Schemas
  - Alle Prozesse kommen **gleich oft** in S1∪S2 vor
- Alternierende (oder auch zufällige) Nutzung der beiden Schemata ➡ Lastbalancierung

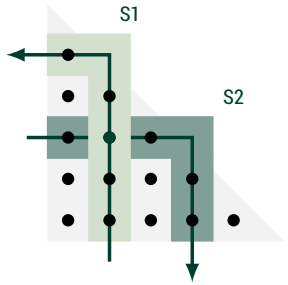

7.4 Token-basierte Verfahren

- **Topologie**: Die am gegenseitigen Ausschluss beteiligten Knoten bilden eine bestimmte Topologie, z.B. einen logischen Ring
  - Alternativ wird tatsächliche Topologie genutzt
- Es gibt genau eine Zugriffsberechtigung (Token), die entlang der Topologie weitergegeben wird

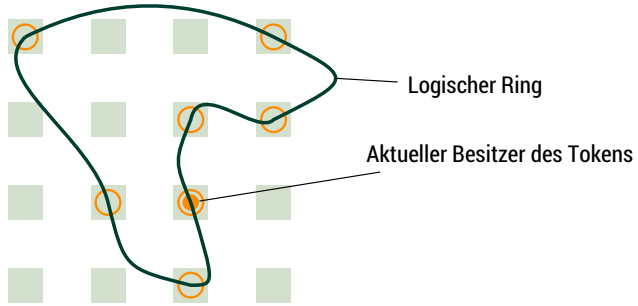

Einfache Token Ring-Lösung

- Le Lann, 1977
- Prozesse werden in logischem Ring angeordnet
- Eigenes Token für jede Ressource
- Zugriff wird durch zirkulierendes Token gesteuert
- Bewerber wartet mit Zugriff, bis ihn das Token erreicht
- Zugreifender Prozess leitet bei Freigabe das Token weiter
- Prozess ohne Zugriffsabsicht leitet das Token direkt weiter

Einfache Token Ring-Lösung (Forts.)

- **Vorteile**
  - Einfacher, korrekter, fairer Algorithmus
  - Keine Verklemmungen
  - Kein Verhungern
  - Prioritäten sind möglich
- **Probleme**
  - Token ist ständig unterwegs, unter Umständen nutzlos
  - ➡ Nachrichtenzahl pro Anforderung nicht beschränkt
  - Bei großer Anzahl von Prozessen lange Wartezeit

Lift-Algorithmus

- **Alternative Idee**: Verwendung eines **Spannbaums**
- **Vorteil**: Keine nebenläufigen Pfade
- **Problem**: Wie erhält man einen Spannbaum
  ➡ **Echo-Algorithmus**

Exkurs: Echo-Algorithmus

- Der Echo-Algorithmus wird zur **Konstruktion von Spannbäumen** genutzt
- Er kann auf beliebigen, zusammenhängenden Kommunikationstopologien eingesetzt werden
- Angewendet u.a. in Algorithmen zu
  - Gegenseitigem Ausschluss (hier 🙂)
  - Terminierungsproblem
  - Auswahlproblem

Exkurs: Echo-Algorithmus (Forts.)

- Zustand von Knoten wird durch Farben beschrieben
- Initial sind alle Knoten **weiß**
- Der eindeutige Initiator wird **rot** und schickt rote Nachrichten (**Explorer**) an alle seine Nachbarn

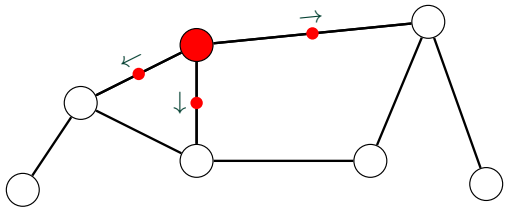

Exkurs: Echo-Algorithmus (Forts.)

- Ein weißer Knoten, der einen Explorer empfängt, wird selber rot, merkt sich diese „erste“ Kante (**Aktivierungskante**) und schickt Explorer an alle seine anderen Nachbarn
- Wird ein Explorer von einem roten Knoten empfangen, wird der Explorer nicht weitergeleitet („verschluckt“)

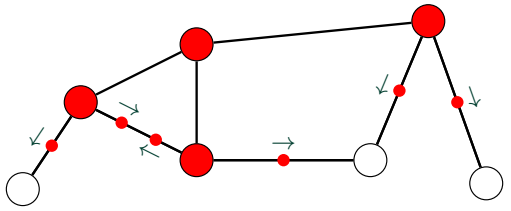

Exkurs: Echo-Algorithmus (Forts.)

- Ein roter Knoten, der über **alle** seine Kanten einen Explorer oder ein Echo erhalten hat wird **grün** und sendet ein grünes **Echo** über seine Aktivierungskante, die auch grün wird
- **Blätter** senden beim Empfang eines Explorers sofort ein Echo zurück

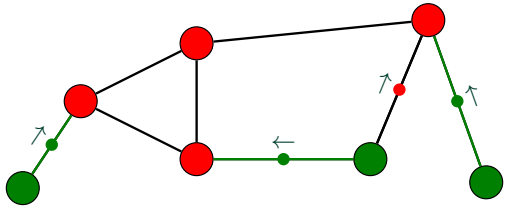

Exkurs: Echo-Algorithmus (Forts.)

- Nach und nach werden alle Knoten und ein Teil der Kanten grün
- Der Algorithmus terminiert, wenn der Initiator über alle seine Kanten ein Echo oder einen Explorer empfangen hat

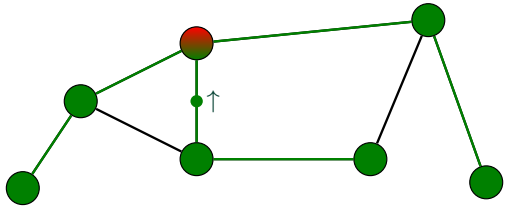

Echo-Algorithmus – Eigenschaften

- Über jede Kante laufen genau zwei Nachrichten
  - Entweder ein Explorer und ein gegenläufiges Echo oder zwei gegenläufige Explorer
- Paralleles Traversieren eines (zusammenhängenden ungerichteten) Graphen mit $2e$ Nachrichten
- Der Echo-Algorithmus ist ein **Wellenalgorithmus**
  - **Hinwelle**: Rot werden
    ➡ Verteilen einer Information an alle Knoten
  - **Rückwelle**: Grün werden
    ➡ Einsammeln von Information von allen Knoten

Echo-Algorithmus – Eigenschaften (Forts.)

- Echo-Kanten bilden einen **Spannbaum**
- Je nach Nachrichtenlaufzeit sieht der Spannbaum anders aus, weil schnelle gegenüber langsamen Kanten bevorzugt werden

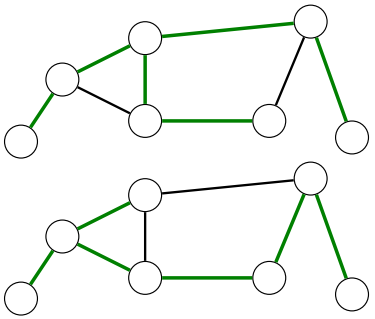

Verbesserung des Echo-Algorithmus?

- **Idee**: Vermeide den Besuch von Knoten, von denen bekannt ist, dass sie von anderen Explorern besucht werden
- Zusammen mit einem Explorer wird eine Menge von Tabuknoten $\mathbf{Z}$ verschickt und empfangen
- Die vom Initiator verschickte Tabumenge ist $\mathbf{Z} =<$ Nachbarn vom Initiator $> \cup <$ Initiator $>$
- Explorer nur an die Menge von Nachbarn $\mathbf{Y}$ schicken, die nicht in $\mathbf{Z}$ sind
  - Dabei wird die neue Tabumenge $\mathbf{Z}' = \mathbf{Z} \cup \mathbf{Y}$ angehängt
- **Vorteil**: Einsparung von Nachrichten
- **Nachteile**:
  - Nachrichtenlänge $\mathcal{O}(n)$
  - Nachbaridentität muss bekannt sein

Lift-Algorithmus

Zurück zum Lift-Algorithmus: Nutzung des Spannbaums

- Kanten des Spannbaums haben einen **Zustand** (Richtung)
  - Sie können jeweils in eine von zwei Richtungen zeigen
- Selektive Weiterleitung von Zugriffsanforderungen in Richtung Token (anstatt Senden an alle anderen Prozesse)
  - Token wandert **entgegen der Kantenrichtung** und **dreht** dabei die Richtung jeder durchlaufenen Kante um
  - Prozess, der Token will, sendet Anforderung über seine **ausgehende** Kante
- Hat ein Prozess Anfrage erhalten, sendet er **einmalig** dem Token eine Anforderung hinterher
  - Weitere Anfragen werden „gemerkt“

Lift-Algorithmus (Forts.)

- Empfängt ein Prozess das Token...
  - darf er bei eigener Anforderung zugreifen
  - leitet er es in **eine** der anfordernden Richtungen weiter
  - gibt es noch weitere (gemerkte) Anforderungen aus anderen Richtungen, so schickt er dem Token eine Anforderung **hinterher**
- Um Fairness zu gewährleisten, darf ein Prozess **nicht beliebig oft** eine gleiche anfordernde Richtung nicht bedienen

Lift-Algorithmus (Forts.)

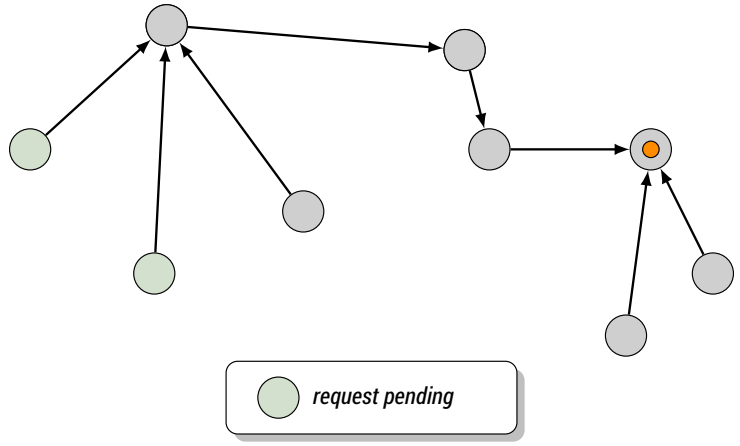

Lift-Algorithmus (Forts.)

- **Invariante**: Von jedem Prozess aus führt ein gerichteter Pfad zum Token
- In einem k-ären balancierten Baum ist die maximale Weglänge zwischen beliebigen Prozessen $\mathcal{O}(\log_k n)$
- Entsprechend werden nur $\mathcal{O}(\log_k n)$ Nachrichten pro Zugriff gebraucht
- **Startzustand**: Sieger einer Auswahl (siehe später) bekommt das Token und startet einen Echo-Algorithmus, um einen Spannbaum mit auf ihn gerichteten Kanten zu erzeugen
- Verfahren lässt sich so auf beliebige zusammenhängende Topologien verallgemeinern

Literatur

[RA81] G. Ricart und A. K. Agrawala. „An Optimal Algorithm for Mutual Exclusion in Computer Networks“. In: *Communications of the ACM* 24.1 (1981), S. 9–17

[Mae85] M. Maekawa. „$\sqrt{n}$ Algorithm for Mutual Exclusion in Decentralized Systems“. In: *ACM Transactions on Computer Systems* 3.2 (1985), S. 145–159

[LW97] W. S. Luk und T. T. Wong. „Two New Quorum Based Algorithms for Distributed Mutual Exclusion“. In: *17th International Conference on Distributed Computing Systems (ICDCS '97)*. 1997, S. 100–107

[SK85] I. Suzuki und T. Kasami. „A distributed mutual exclusion algorithm“. In: *ACM Transactions on Computer Systems* 3.4 (1985), S. 344–349