Verteilte Systeme

Jürgen Kleinöder

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)
www4.cs.fau.de

Sommersemester 2013

http://www4.cs.fau.de/Lehre/SS13/V_VS

Überblick

Wahlalgorithmen: Überblick

Problemstellung

- In verteilten Systemen kann es viele Situationen geben, die einen ausgewählten Knoten erfordern („Anführer")
  - Koordinator von verteilten Aktionen
  - Erzeugung von eindeutigen Token im System
  - ...
- Man möchte diesen Knoten automatisch bestimmen lassen
  - Initial bei Start des Systems
  - Zur Neukonfiguration des Systems nach Fehlern

Wahlalgorithmen: Überblick

Formale Anforderungen an einen Wahlalgorithmus

WA1 Eindeutigkeit: Es darf keine zwei Knoten P_1, P_2 im System geben, die sich beide als Anführer betrachten

WA2 Terminierung: In endlicher Zeit gibt es einen Knoten P_i, der sich als Anführer betrachtet

Wahlalgorithmen: Überblick

Varianten

- Alle Knoten erfahren vom Ende oder vom Ergebnis der Wahl
- Verschiedene Topologien: Ringe, Bäume, beliebige Netze
- Variable/unbekannte oder feste/bekannte Knotenanzahl?
- Nicht unterscheidbare Knoten oder Knoten mit eindeutigen IDs?

Erforderliche Randbedingung (für deterministische Wahl)

- Es muss möglich sein, die einzelnen Knoten voneinander zu unterscheiden (z.B. eindeutige Netzadresse)

Literatur zu Wahlalgorithmen

Wahl auf Ringen

- N. Lynch: Distributed Algorithms. Morgan Kauffmann Pub., 1996
- G. L. Lann: Distributed Systems - Towards a Formal Approach. In Information Processing 77, pp 155-160, IFIP, North-Holland, 1977
- E. Chang, R. Roberts: An Improved Algorithm for Decentralized Extrema-Finding in Circular Configurations of Processes, Comm. ACM, 22(5): 281-283, Mai 1979
- G. L. Peterson: An $O(n \log n)$ unidirectional distributed algorithm for the circular extrema problem. ACM Transactions on Programming Languages and Systems, pp 758-762, Oct. 1982

Wahl auf Bäumen und auf beliebigen Graphen

- F. Mattern: Verteilte Basisalgorithmen. Springer-Verlag, 1989

Wahl auf Ringen: Chang-Roberts-Algorithmus

Voraussetzung:

- Jeder Knoten besitzt eine eindeutige *ID*, auf welcher eine totale Ordnung definiert ist.

Ziel:

- Finde Knoten mit maximaler *ID*

Ablauf

- Beim Start des Wahlalgorithmus (in allen Knoten): Sende eigene Knoten-ID im Ring weiter, Knoten wird wählbar
- Bei Empfang einer *ID* i_{rx}:
  - Falls $i_{rx} >$ eigene *ID*: i_{rx} weitersenden; Knoten nicht mehr wählbar
  - Falls $i_{rx} =$ eigene *ID*: Falls wählbar: als Anführer gewählt (sonst: Nachricht ignorieren)
  - Falls $i_{rx} <$ eigene *ID*: Nachricht ignorieren

Chang-Roberts-Algorithmus

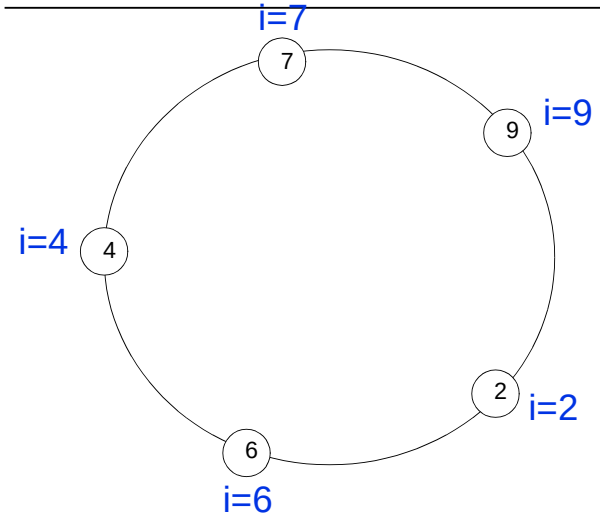

Chang-Roberts-Algorithmus

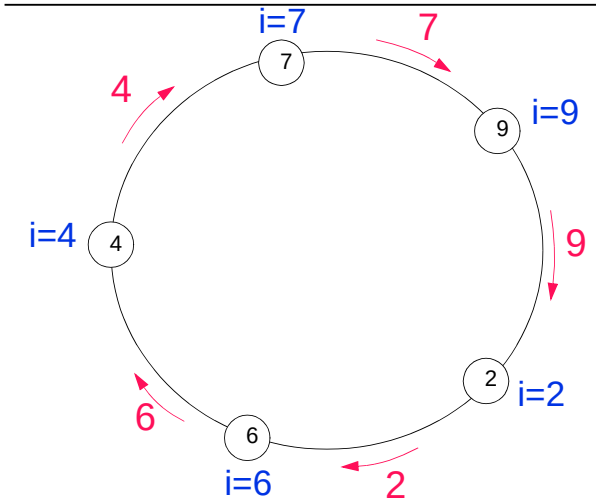

Chang-Roberts-Algorithmus

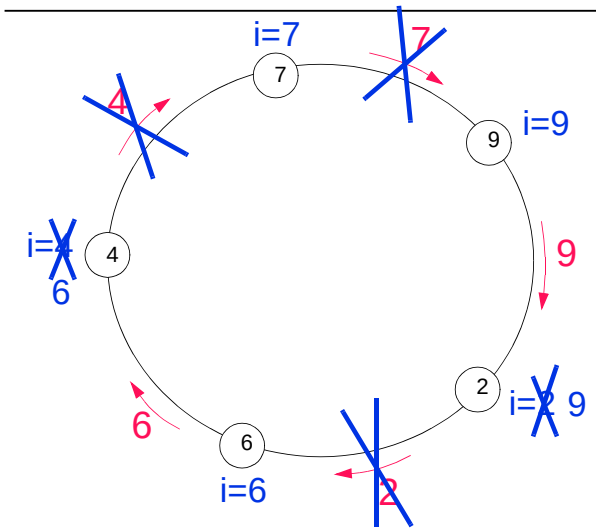

Chang-Roberts-Algorithmus

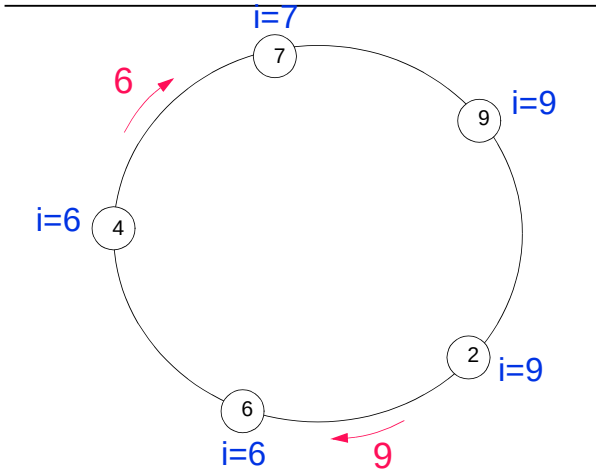

Chang-Roberts-Algorithmus

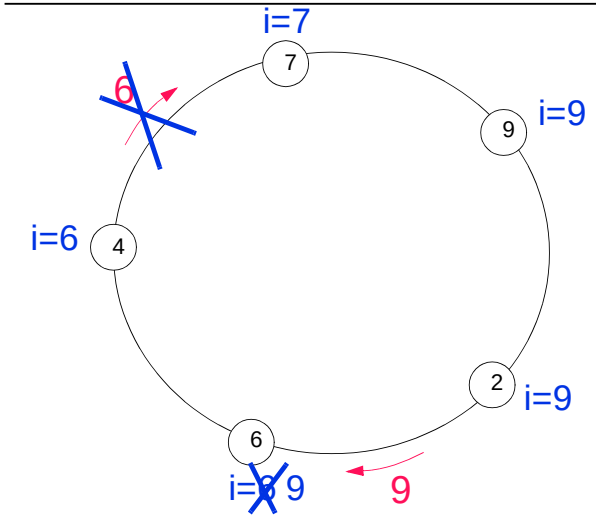

Chang-Roberts-Algorithmus

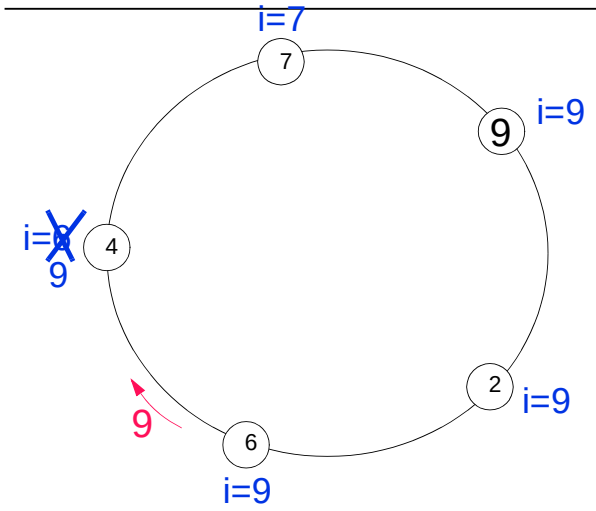

Chang-Roberts-Algorithmus

Eigenschaften

- Nach spätestens *N* Schritten gibt es einen Knoten, der sich für den Anführer hält
- Kein anderer Knoten hält sich je für den Anführer

Erweiterung

- Sobald ein Knoten als Anführer bestimmt ist, kann er dies durch spezielle Mitteilungs-Nachrichten allen anderen Knoten im Ring mitteilen
- Erst mit dieser Erweiterung wird eine Terminierung des Algorithmus erreicht (alle anderen Knoten warten sonst weiterhin auf Nachrichten)

Chang-Roberts-Algorithmus

Begründung der Korrektheit – Eindeutigkeit

- Initial wird eine Nachricht mit einer bestimmten *ID* nur vom Knoten mit dieser *ID* erzeugt
- Diese *ID* wird von weiteren Knoten nur dann weitergereicht, wenn deren eigene *ID* kleiner ist. Insbesondere: Der Knoten mit der größten *ID* reicht keine anderen *IDs* weiter
- Ein Knoten kann nur dann gewählt werden, wenn dessen *ID* alle Knoten durchlaufen hat
- Dies ist nach dem zweiten Punkt nur für die größte vorhandene *ID* möglich, es kann also maximal einen Anführer geben

Chang-Roberts-Algorithmus

Begründung der Korrektheit – Terminierung

- Eine Nachricht mit der größten *ID* wird gemäß Spezifikation von jedem Knoten weitergereicht.
- Nach *N* Nachrichten ist die größte *ID* wieder beim Ursprungsknoten angekommen; unter der Annahme, dass jede Nachricht in endlicher Zeit beim Empfänger ankommt, ist der Knoten mit größter *ID* in endlicher Zeit ermittelt

Chang-Roberts-Algorithmus

Komplexitätsbetrachtung

- Annahmen zur Analyse der Zeitkomplexität
  - Lokale Aktionen benötigen keine Zeit, gesendete Nachrichten kommen jeweils innerhalb einer maximalen Nachrichtenlaufzeit an
- Worst-Case-Betrachtung:
  - Zeit: $O(N)$ Nachrichtenlaufzeiten
  - Nachrichten: $O(N^2)$
    (Man ordnet die *IDs* absteigend an, dann ergibt sich $\sum_{i=1}^{N} i = n(n+1)/2$)
- Betrachtung des mittleren Werts:
  - Annahme: Alle möglichen Verteilungen der IDs sind gleichwahrscheinlich, IDs mit Werten von $1..N$
  - Zeit: unverändert $O(N)$
  - Es kann gezeigt werden: $O(N \log N)$ (Siehe Literatur)

Chang-Roberts-Algorithmus

Weitere Optimierungen möglich?

- Theoretische Erkenntnis (siehe Literatur): $O(N \log N)$ ist untere Schranke für die Nachrichtenkomplexität!
- Geht es besser als $O(N^2)$ im worst-case?

Chang-Roberts-Algorithmus – bidirektional

Einfache randomisierte Variante

- Jeder Knoten würfelt initial einen Wert aus $0, 1$ und sendet seinen Wert entsprechend zum linken oder zum rechten Nachbarn weiter
- Normaler Chang-Roberts-Algorirthmus wird ausgeführt; alle Nachrichten werden dabei in dem Umlaufsinn weitergereicht, in dem sie bei einem Knoten ankommen

Eigenschaften

- Worst-case beträgt immer noch $O(N^2)$ Nachrichten, tritt aber mit geringerer Warscheinlichkeit auf
- Mittlere Nachrichtenzahl ist günstiger, aber noch aufwendiger zu berechnen und asymptotisch immer noch $O(N \log N)$

Anmerkungen zur Wahl auf Ringen

- Mögliche Probleme in der Praxis
  - Nachrichtenverluste
  - Rechnerausfälle
  - Mehrfache Ausführung
  - Doppelt vergebene IDs
- Konsequenz

Einfache algorithmische Idee in einem einfachen Systemmodell muss in der Realität ggf. in komplexere Algorithmen eingebettet werden, um den realen Randbedingungen gerecht zu werden

.

Wahl auf Bäumen

Grundidee:

Traversieren des kompletten Baumes, um den Knoten mit der größten *ID* zu ermitteln

- Sequentielles Traversieren möglich
- Paralleles Traviersieren bietet sich für verteilte Systeme an

Sequentielles Traversieren

Bekanntes *depth first*-Vorgehen wie bei lokalen Datenstrukturen:

```
class Node implements NodeRemote {

 ArrayList<Node> children = ...;
 int id = ...;

 int findMax() {
  int maxVal = id;
  Iterator<Node> it = children.iterator();

  while(it.hasNext()) {
   int val = it.next().findMax();
   if ( val > maxVal )
     maxVal = val;
  }
  return maxVal;
}
```

Paralleles Traversieren

Zeitgewinn durch Parallelisierung

- Sequentiell: Bei N Knoten $2(N-1)$ Kommunikationsschritte!

Wellenverfahren

- *Explosionswelle* durchläuft den Baum bis zu den Blättern
- *Echowelle* läuft wieder zurück und bestimmt Anführer
  $\Rightarrow$ teilweise Überlappung mit Explosionswelle möglich
- *Informationswelle* kann alle Knoten über das Ergebnis der Wahl informieren

Wahl auf Bäumen

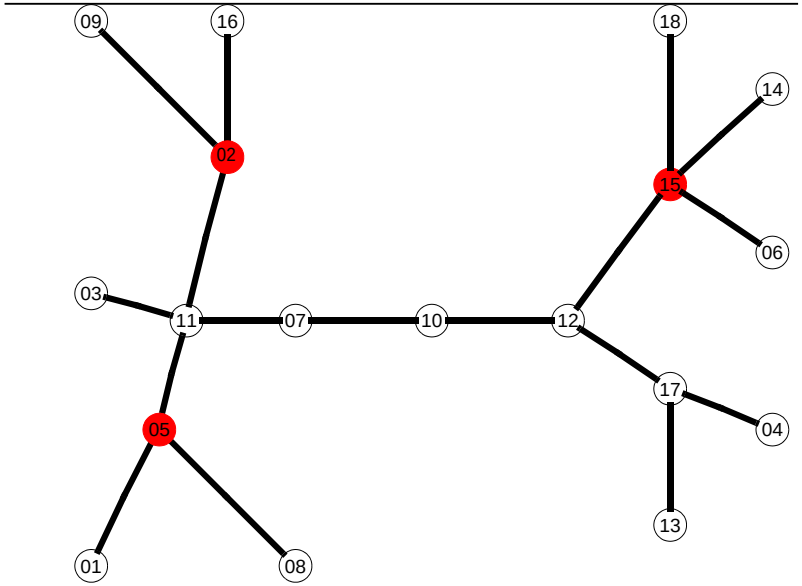

Wahlalgorithmus für Bäume

- Ein Starter sendet Explosionsnachrichten in alle Richtungen

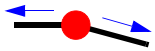

- Ein innerer Knoten, der erstmals eine Explosionsnachricht empfängt, sendet wiederum Explosionsnachrichten in alle anderen Richtungen aus

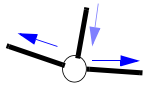

- Ein Blattknoten, der eine Explosionsnachricht erhält, sendet eine Echonachricht mit seiner ID zurück

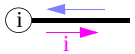

Wahlalgorithmus für Bäume

- Ein innerer Knoten mit k Kanten, der auf $k-1$ Kanten Echonachrichten erhalten hat, sendet auf der übrigen Kante eine Echonachricht mit dem Maximum aller *IDs*

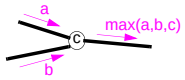

- Erhält ein Knoten nach Versenden seiner eigenen Echonachricht eine weitere Echonachricht, so ist das Maximum beider *IDs* die höchste ID-Nummer im Netz

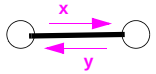

  - Muss lediglich ein beliebiger Anführer bestimmt werden, so kann man jetzt einfach einen der beiden Knoten auswählen
  - Ansonsten kann man in einer Informationswelle alle Knoten über die ermittelte höchste ID informieren

Wahl auf Bäumen

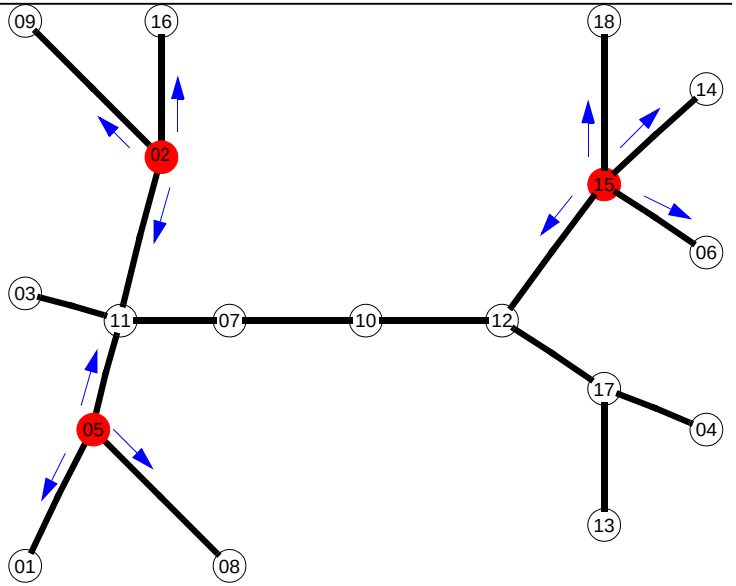

Wahl auf Bäumen

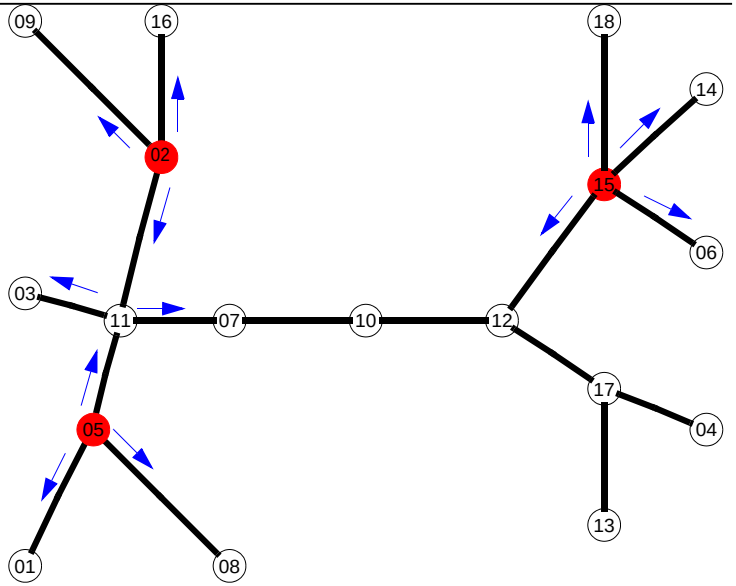

Wahl auf Bäumen

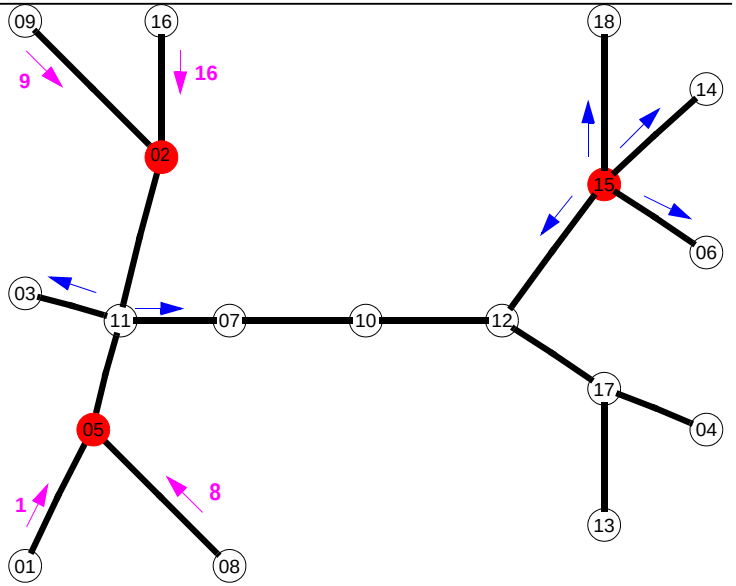

Wahl auf Bäumen

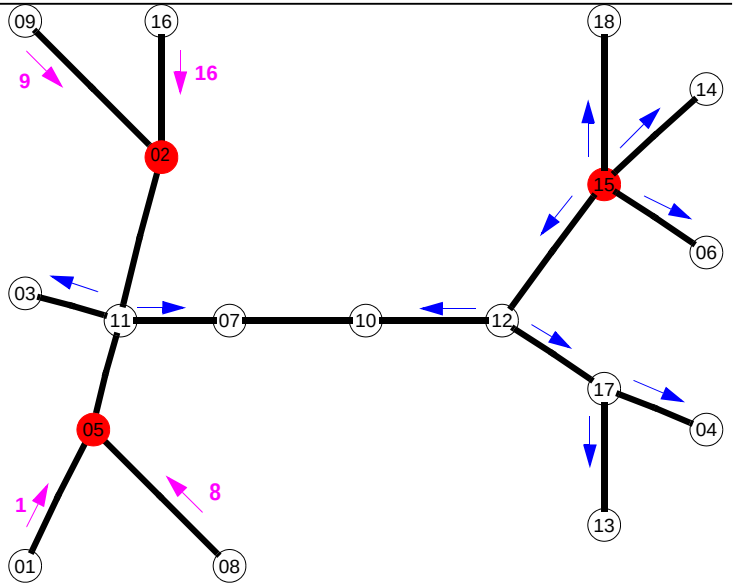

Wahl auf Bäumen

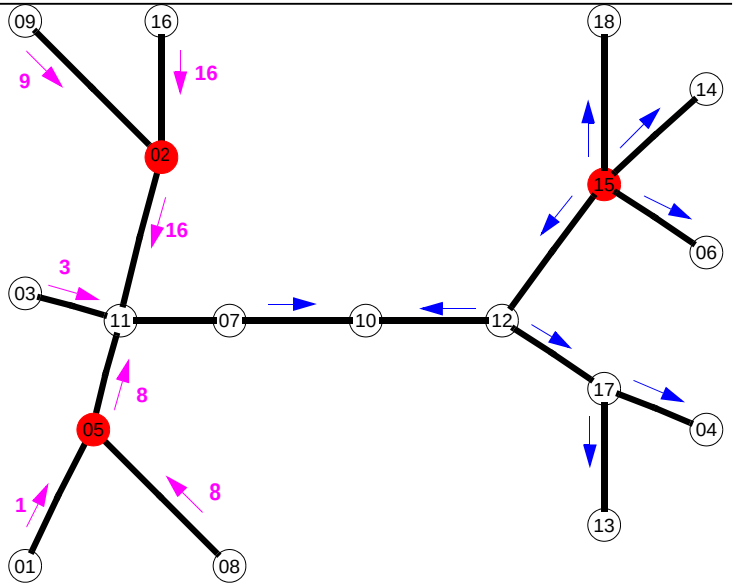

Wahl auf Bäumen

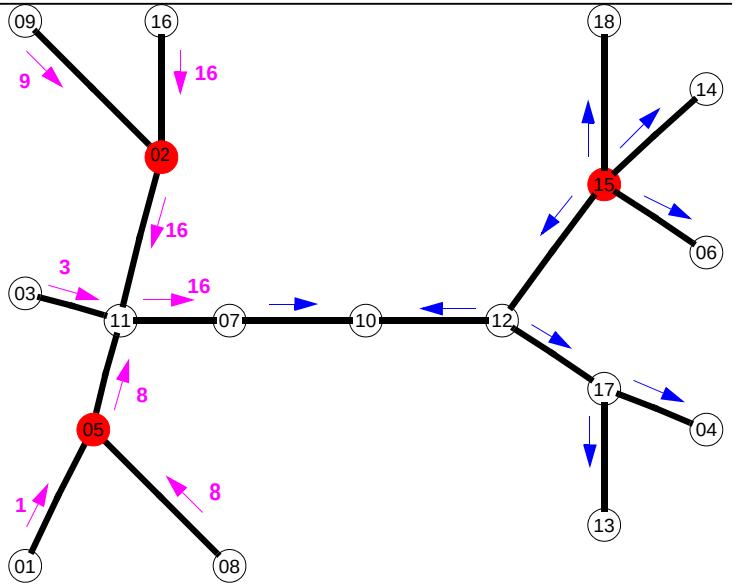

Wahl auf Bäumen

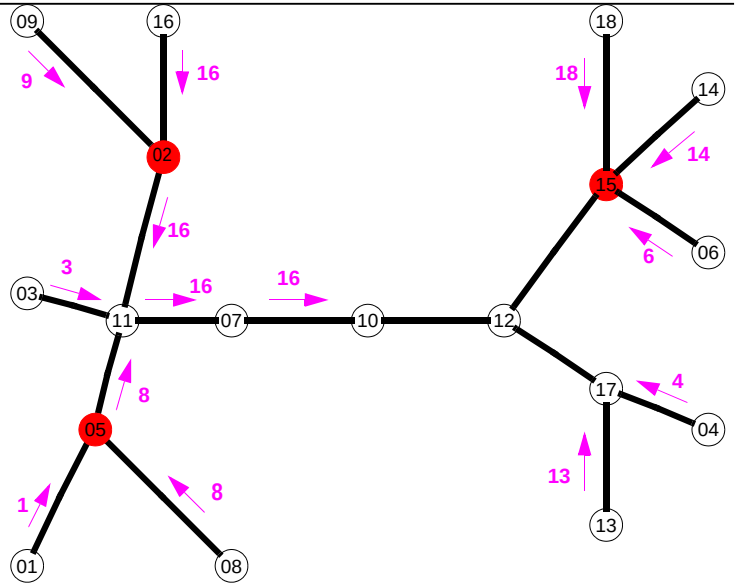

Wahl auf Bäumen

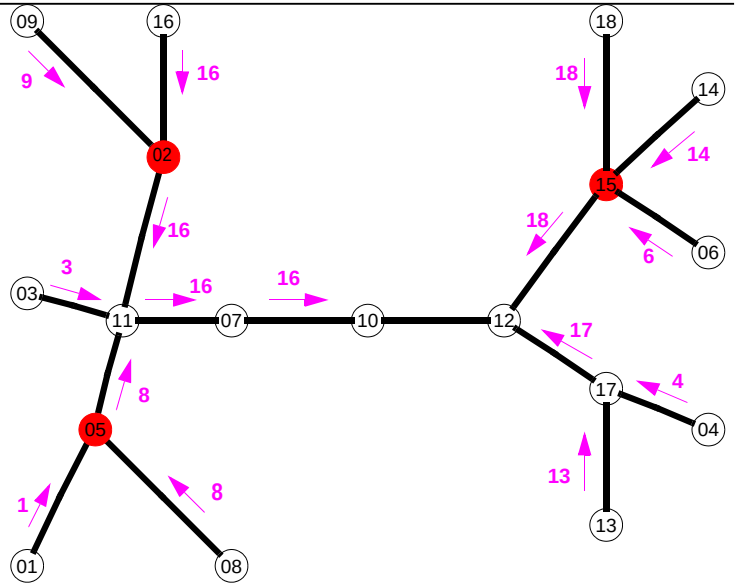

Wahl auf Bäumen

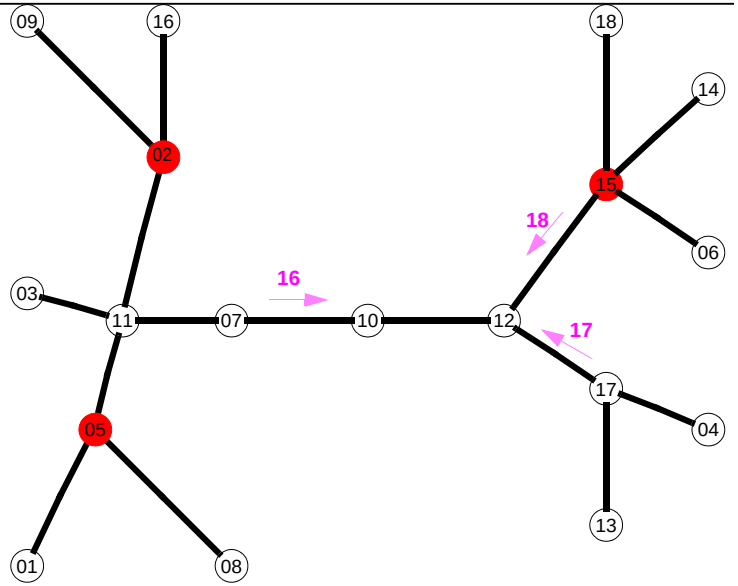

Wahl auf Bäumen

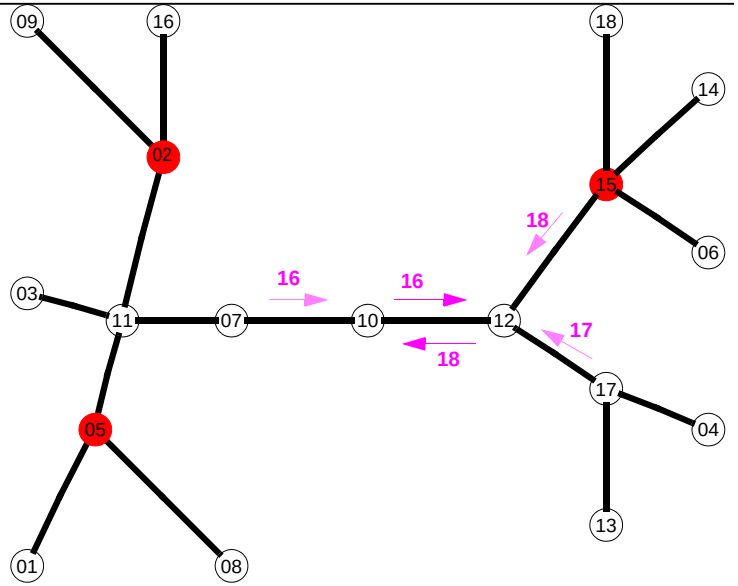

Wahl auf Bäumen

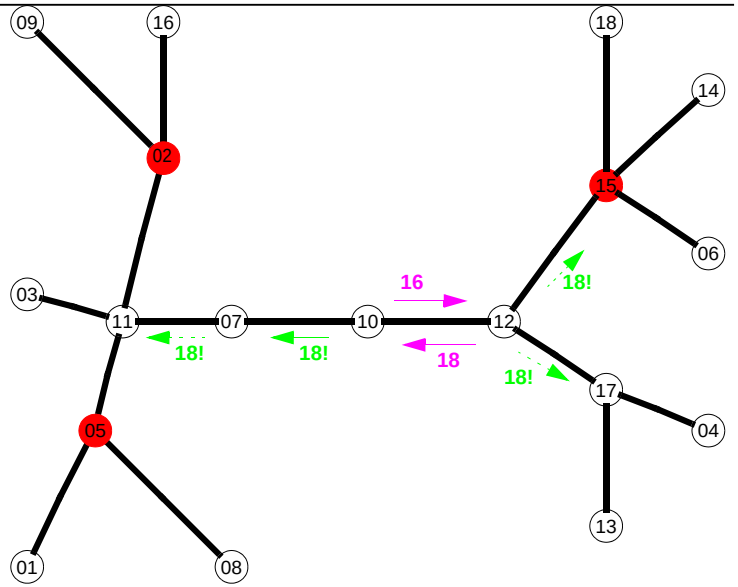

Wahl auf Bäumen: Zusammenfassung

- Initiierung des Algorithmus durch Start-Welle (Election-Welle)
- Bildung von gerichteten Baumkanten in einer Echo-Welle; dabei Informationssammlung (z.B. größte ID) möglich
- Es kann genau eine Kante geben, bei der Echo-Nachrichten in beiden Richtungen laufen
  - Gewinner kann durch gesammelte Information ermittelt werden
  - oder: Auswahl eines der beiden Knoten an dieser Kante als Gewinner

Wahl auf beliebigen Topologien

Sequentielle Traversierung des Netzes

- Pfadverfahren
- Kantenfärbungsverfahren

Parallele Traversierung des Netzes

- Echo/Election-Algorithmus
- ... und Varianten davon

Konstruktion eines virtuellen Baums auf dem Netz

Wahl auf beliebigen Topologien

- Wahlalgorithmen auf beliebigen Topologien: Algorithmen für Baumstrukturen + Zyklenerkennung
- Explorer- und Echowelle, ggf. Informationswelle
- Konstruktion eines virtuellen Baumes
- Verschiedene Varianten möglich:
  - Sequentielle Traversierung einfach, aber hoher zeitlicher Aufwand
  - Parallele Traversierung komplexer, aber wesentlich geringere Zeitkomplexität