Συντονισμός και συμφωνία

Κατανεμημένα Συστήματα

2018-2019

http://www.cslab.ece.ntua.gr/courses/distrib

Πώς επικοινωνούν οι διεργασίες;

- Ένας προς έναν
  - Unicast
    - 1 -> 1
    - Point-to-point
- Ένας προς πολλούς
  - Multicast
    - 1 -> πολλούς
    - Επικοινωνία ομάδας (group communication)
  - Broadcast
    - 1-> όλους

Multicast μέσω hadrware

- Αν το hardware υποστηρίζει multicast
  - Τα μέλη της ομάδας ακούν σε δικτυακές διευθύνσεις

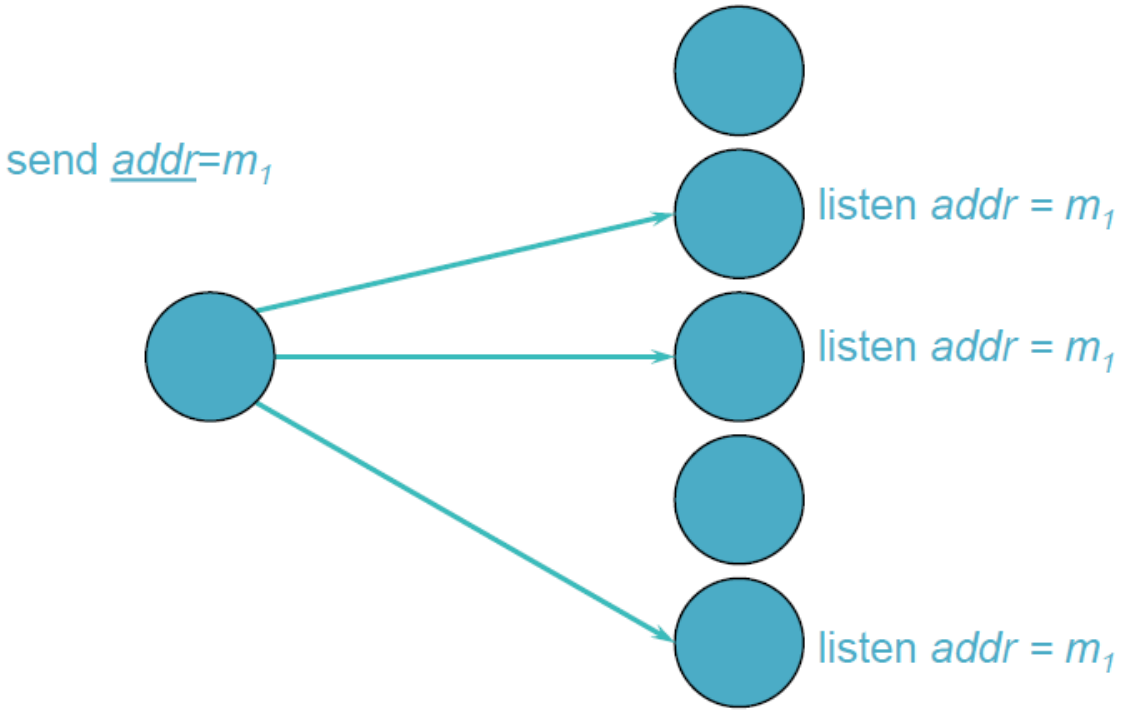

Hardware broadcast

- Αν το hardware υποστηρίζει μόνο broadcast
  - Φιλτράρονται οι εισερχόμενες multicast διευθύνσεις μέσω λογισμικού

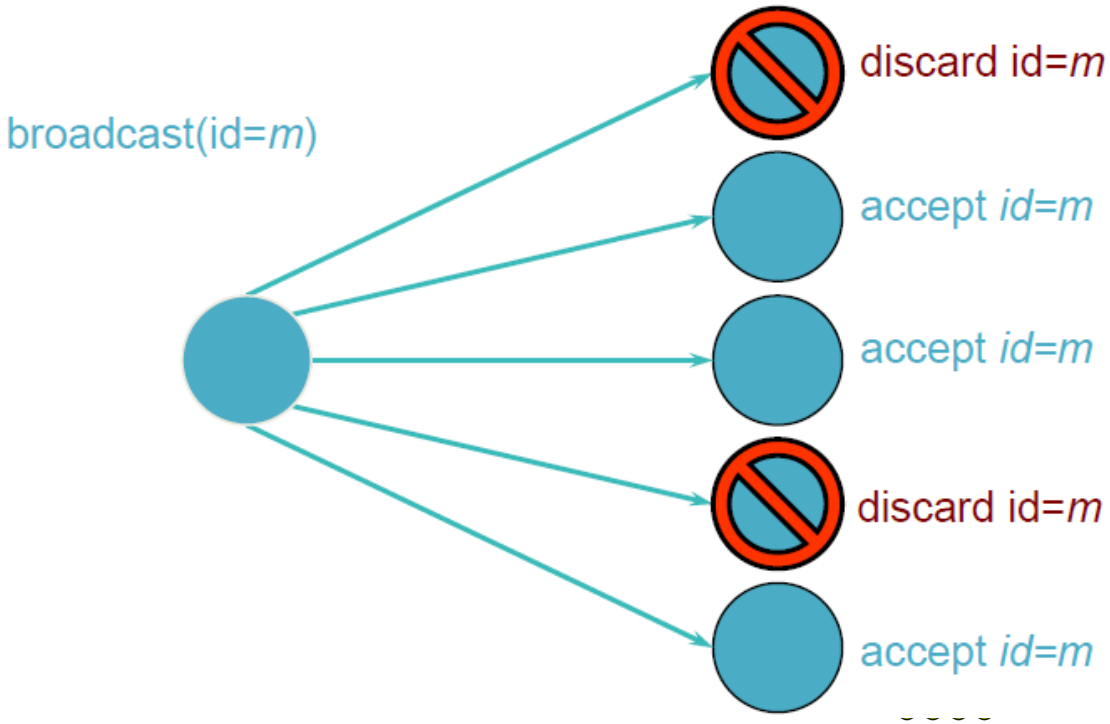

Software multicast

- Πολλαπλά unicasts
- Ο αποστολέας γνωρίζει τα μέλη της ομάδας

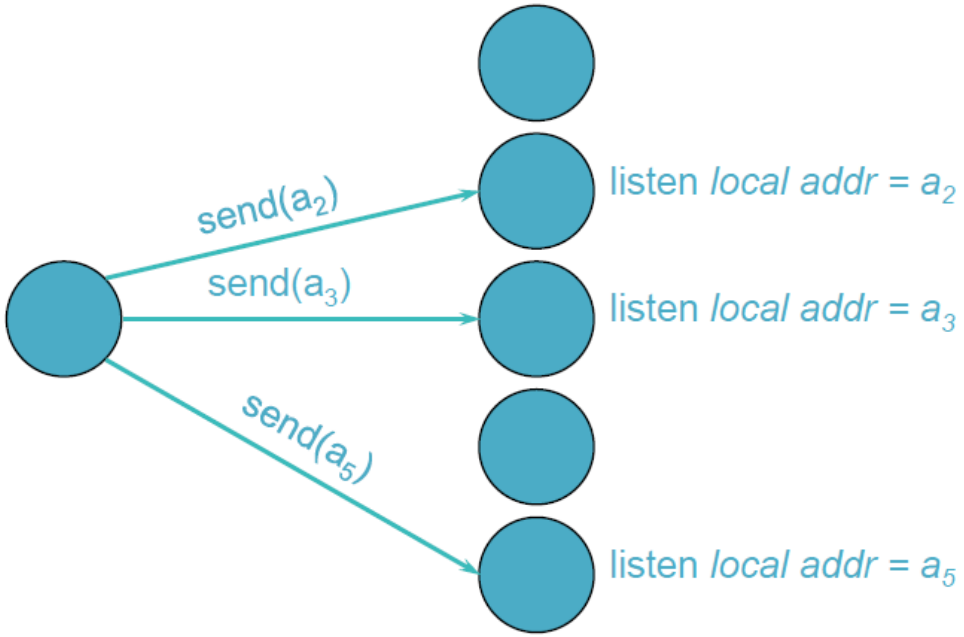

Μοντέλο συστήματος

- Multicast(g,m): στέλνει το m στην ομάδα g
- Receive(m): λήψη μηνύματος
- Deliver(m): παράδοση μηνύματος στο επίπεδο εφαρμογής
- Κάθε m φέρει
  - id αποστολέα: sender(m)
  - id της ομάδας παραληπτών group(m)

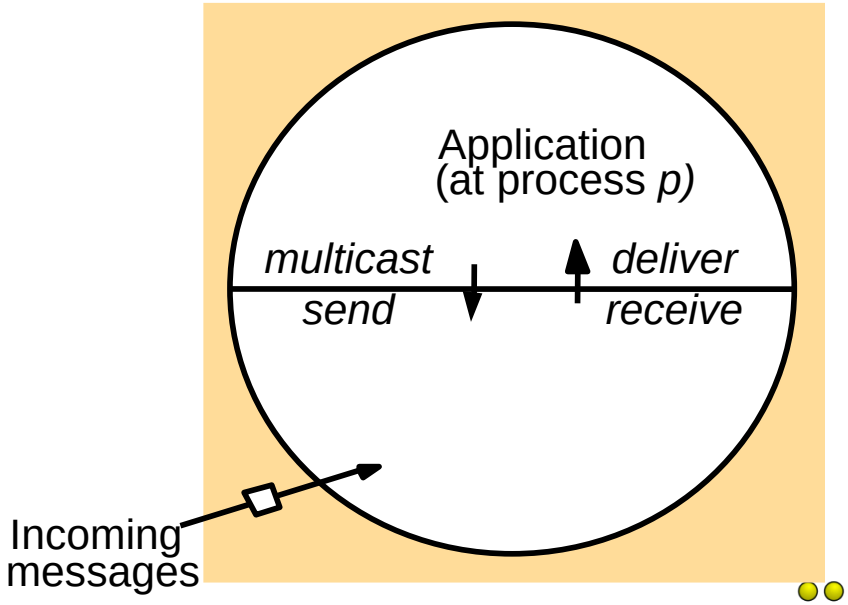

Βασικό multicast (B-multicast)

- Χρήση αξιόπιστου unicast
  - B-multicast(*g*,*m*): Για κάθε διεργασία *p* στο *g*, send(*p*,*m*)
  - receive(*m*): B-deliver(*m*) στο *p*
- Εγγύηση
  - Όλες οι διεργασίες που ανήκουν στο *g* τελικά λαμβάνουν όλα τα multicast μηνύματα…
  - … αρκεί ο αποστολέας να μην αποτύχει!

Αξιόπιστο multicast (R-multicast)

- Όπως το B-multicast +

  όλες οι σωστές διεργασίες πρέπει να παραλάβουν το μήνυμα αν έστω και μια από αυτήν το παραλάβει

  … γιατί ο αποστολέας μπορεί να αποτύχει ενώ εκτελεί B-multicast

R-multicast: Στόχοι

- *Ακεραιότητα* (integrity): Μια σωστή (χωρίς σφάλματα) διεργασία *p* παραδίδει ένα μήνυμα *m* το πολύ μια φορά
  - Σωστή: Τηρεί το πρωτόκολλο και είναι ζωντανή

- *Συμφωνία* (agreement): Αν μια σωστή διεργασία παραδώσει μήνυμα *m*, τότε όλες οι υπόλοιπες σωστές διεργασίας στην ομάδα group(*m*) θα παραδώσουν τελικά το *m*
  - «όλα ή τίποτα»

- *Ισχύς* (validity): Αν μια σωστή διεργασία στείλει μήνυμα *m*, τότε θα παραδώσει και η ίδια το m τελικά

R-multicast

- Διατήρηση ιστορικού μηνυμάτων για εγγύηση παράδοσης το πολύ μια φορά
- Φροντίδα να πάρουν όλοι το μήνυμα
- Αφού επιβεβαιώσουν όλοι τη λήψη, τότε ενημερώνουμε την εφαρμογή

Αλγόριθμος

On initialization

Received := {};

For process p to R-multicast message m to group g

B-multicast(*g*,*m*);

(p∈g is included as destination)

On B-deliver(*m*) *at process q with g = group(m)*

if (*m* ∉ *Received*): **Integrity**

Received := *Received* ∪ *{m};*

if (*q* ≠ *p*):

B-multicast(*g*,*m*); **Agreement**

R-deliver(*m*) **Validity**

Διάταξη μηνυμάτων

- Σωστή σειρά

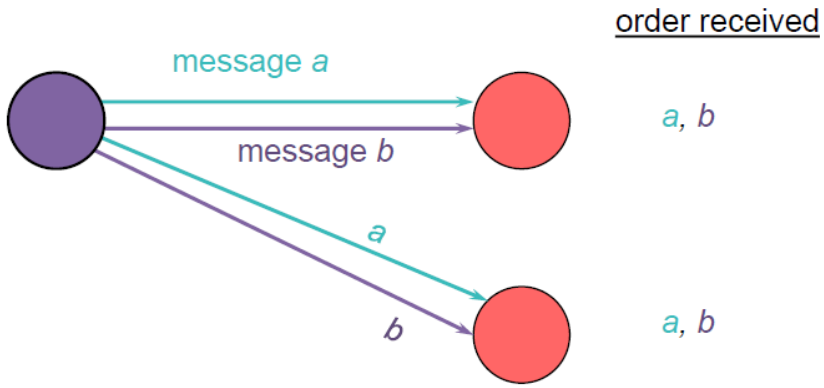

- Λάθος σειρά

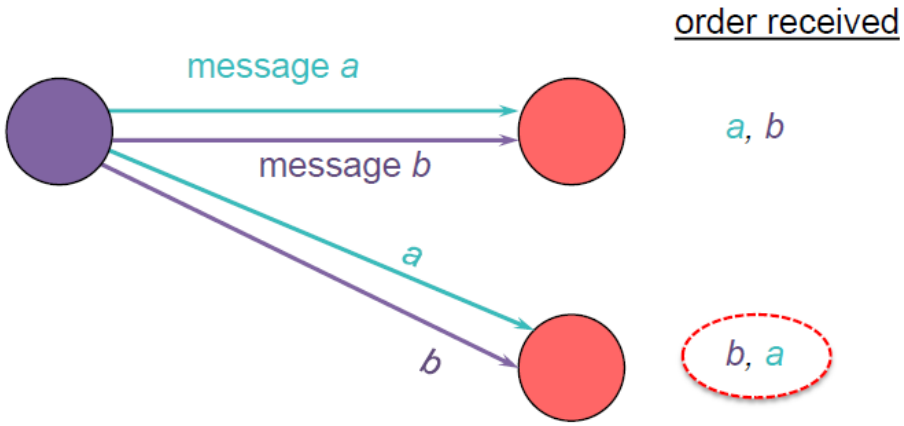

Διατεταγμένο multicast

- Κάθε διεργασία παραδίδει τα μηνύματα που έλαβε ανεξάρτητα από τις άλλες
- Το ερώτημα είναι, τι διάταξη ακολουθεί η κάθε διεργασία
- Τρείς τύποι διάταξης
  - FIFO
  - Αιτιώδης
  - Ολική

Διάταξη FIFO

- Η διάταξη της παράδοσης των μηνυμάτων ακολουθεί τη σειρά αποστολής τους από κάθε διεργασία

- Αν μια σωστή διεργασία στείλει multicast(*g*,*m*) και μετά multicast(*g*,*m'*), τότε κάθε σωστή διεργασία που παραδίδει το *m'* θα έχει παραδώσει ήδη το m

- Παράδειγμα:
  - P1: m0, m1, m2
  - P2: m3, m4, m5
  - P3: m6, m7, m8

- FIFO -> (m0, m3, m6, m1, m4, m7, m2, m5, m8)

Ολική διάταξη

- Κάθε διεργασία παραδίδει όλα τα μηνύματα με την ίδια σειρά
- Αν μια σωστή διεργασία παραδώσει το μήνυμα *m* πριν το *m'* (ανεξάρτητα από τους αποστολείς), τότε οποιαδήποτε άλλη σωστή διεργασία που παραδίδει το *m'* θα έχει παραδώσει ήδη το m
- Παράδειγμα
  - P1: m0, m1, m2
  - P2: m3, m4, m5
  - P3: m6, m7, m8
- Ολική διάταξη
  - P1: m7, m1, m2, m4, m5, m3, m6, m0, m8
  - P2: m7, m1, m2, m4, m5, m3, m6, m0, m8
  - P3: m7, m1, m2, m4, m5, m3, m6, m0, m8

Αιτιώδης διάταξη (causal)

- Η διάταξη της παράδοσης των μηνυμάτων σε κάθε διεργασία διατηρεί τις σχέσεις happened-before ανάμεσα σε όλες τις διεργασίες

- Αν multicast(*g*,*m*) → multicast(*g*,*m'*) τότε κάθε σωστή διεργασία που παραδίδει το *m'* θα έχει παραδώσει ήδη το m

- Παράδειγμα
  - P1: m0, m1, m2
  - P2: m3, m4, m5
  - P3: m6, m7, m8
  - Σχέσεις happened-before: m0 → m4, m5 → m8

- Causal -> (m0, m3, m6, m1, m4, m7, m2, m5, m8)

Παράδειγμα

Bulletin board: *os.interesting*		
Item	From	Subject
23	A.Hanlon	Mach
24	G.Joseph	Microkernels
25	A.Hanlon	Re: Microkernels
26	T.L'Heureux	RPC performance
27	M.Walker	Re: Mach
end		

- Αξιόπιστο Multicast : Κάθε χρήστης λαμβάνει όλα τα μηνύματα
- FIFO: Τα μηνύματα του ίδιου χρήστη εμφανίζονται με τη σειρά αποστολής
- Αιτιώδης διάταξη: Τα Re: μηνύματα μετά από αυτά στα οποία αναφέρονται
- Ολική διάταξη: Η αρίθμηση συνεπής

Αποστολή vs. Παράδοση

- Ο αλγόριθμος λήψης ενός multicast αποφασίζει πότε να παραδώσει ένα μήνυμα στη διεργασία

- Ένα μήνυμα που παραλαμβάνεται μπορεί:
  - **Να παραδοθεί αμέσως** (να τοποθετηθεί σε ουρά παράδοσης την οποία διαβάζει η διεργασία)
  - **Να τοποθετηθεί σε ουρά αναμονής (hold-back queue)** γιατί πρέπει να περιμένουμε για παλιότερο μήνυμα
  - **Να απορριφθεί** (διπλό ή παλιότερο μήνυμα που δε θέλουμε πια)

Αποστολή, παράδοση, αναμονή

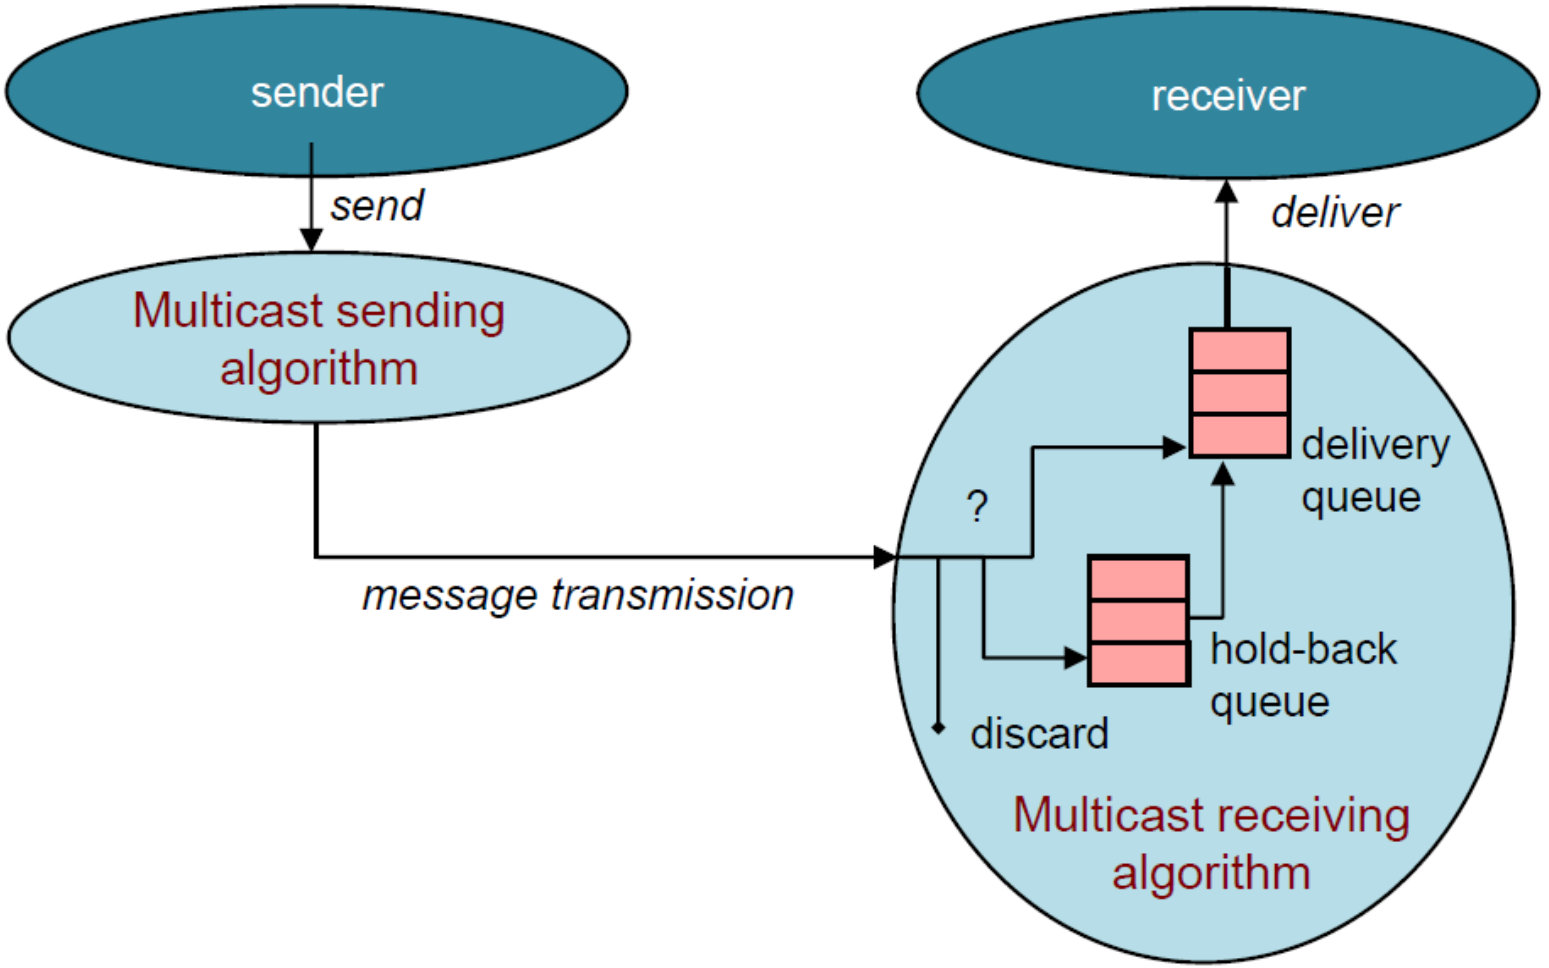

National Technical University of Athens
CSLab

Διάταξη FIFO

- Εξέταση μηνυμάτων από κάθε διεργασία με τη σειρά με την οποία εστάλησαν
  - Κάθε διεργασία κρατά έναν αύξοντα αριθμό για κάθε μια από τις άλλες διεργασίες
  - Όταν παραλαμβάνεται ένα μήνυμα, αν ο αύξων αριθμός του είναι:
    - Ο αναμενόμενος (επόμενος στη σειρά), το αποδεχόμαστε
    - Μεγαλύτερος από τον αναμενόμενο, το τοποθετούμε σε ουρά
    - Μικρότερος από τον αναμενόμενο, το απορρίπτουμε

Παράδειγμα: FIFO Multicast

*(do **NOT** be confused with vector timestamps)*

"Accept" = Deliver

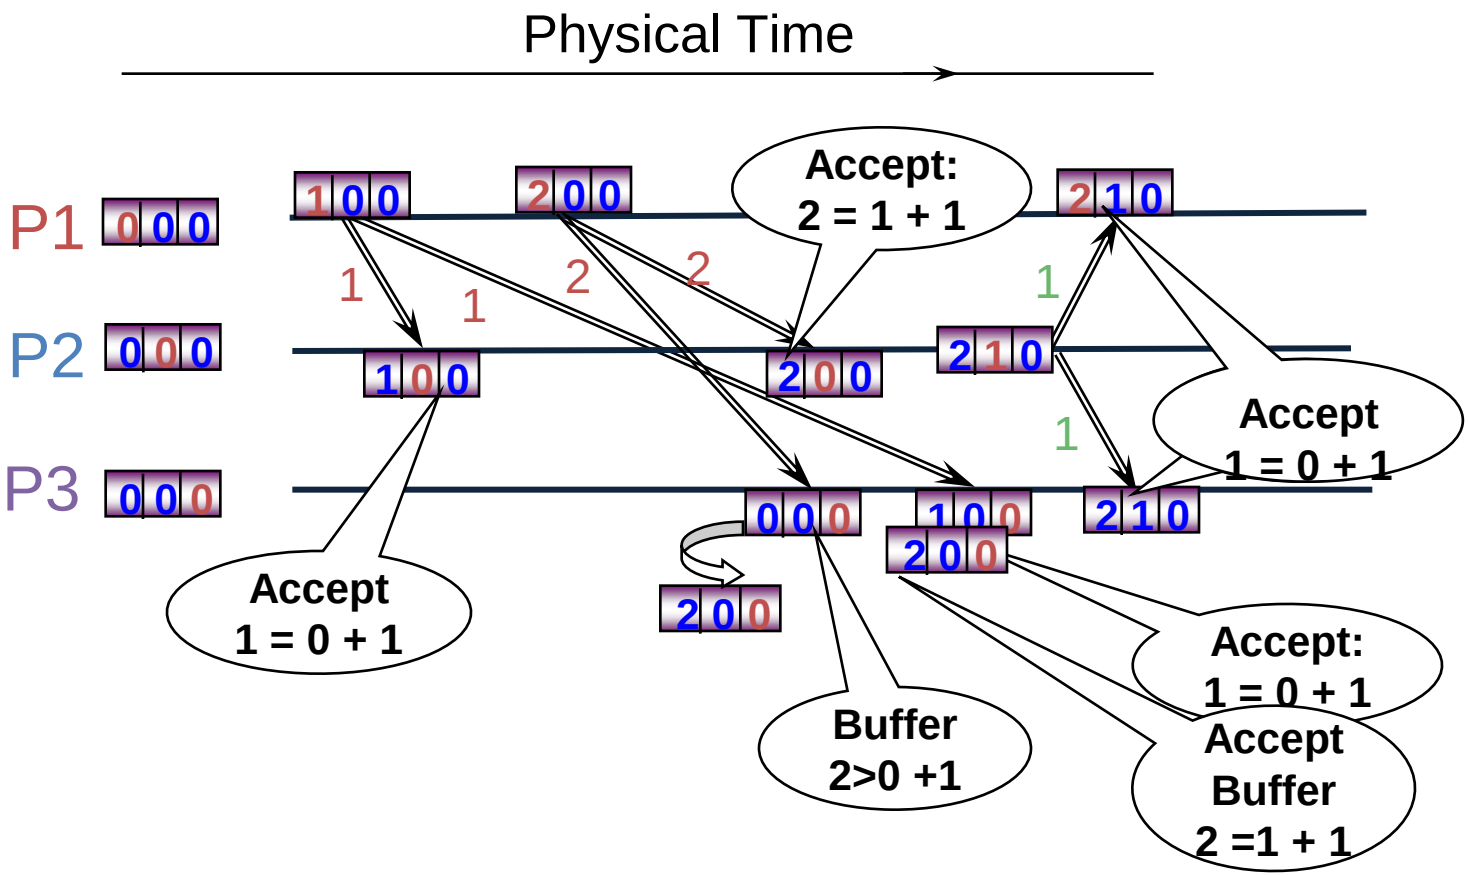

National Technical University of Athens CSLab

Ολικά διατεταγμένο multicast

- Με τη χρήση sequencer
  - Ένας ειδικό sequencer διατάσσει όλα τα μηνύματα
  - Όλοι οι υπόλοιποι ακολουθούν
- Το σύστημα ISIS
  - Παρόμοιο με τον sequencer, αλλά η ευθύνη κατανέμεται σε όλους τους αποστολείς

Αλγόριθμος με χρήση sequencer

- Κάθε μήνυμα m που αποστέλλεται με multicast φέρει ένα μοναδικό id
- Το μήνυμα αποστέλλεται σε όλες της διεργασίες της ομάδα και στον sequencer
- Ο sequencer
  - κρατά έναν αύξοντα αριθμό (sequence number) που χρησιμοποιεί για να δίνει αυξανόμενους και συνεχόμενους αριθμούς στα μηνύματα
  - Ανακοινώνει τους sequence numbers στέλνοντας με multicast μήνυμα order
- Τα μηνύματα παραμένουν στην ουρά μέχρι να μπουν σε σειρά τα sequence numbers τους

Αλγόριθμος ISIS

- Οι διεργασίες συμφωνούν συλλογικά σε sequence number για κάθε μήνυμα
- Οι διεργασίες απαντούν σε ένα multicast με μια *πρόταση* για το sequence number
  - Το μέγιστο όλων των συμφωνημένων sequence numbers
  - Μεγαλύτερο από όλα τα sequence numbers που είχαν προτείνει οι ίδιες στο παρελθόν
- Αποθηκεύουν το μήνυμα σε ουρά προτεραιότητας hold-back
  - Μηνύματα διατεταγμένα ανά sequence number
- Ο αποστολέας επιλέγει τη συμφωνημένη προτεραιότητα και ξαναστέλνει multicast με αυτήν
  - το μέγιστο όλων των προτεινόμενων προτεραιοτήτων
- Κατά τη λήψη της τελικής προτεραιότητας
  - Το μήνυμα μαρκάρεται προς παράδοση
  - Παραδίδονται μηνύματα προς παράδοση από την αρχή της ουράς προτεραιότητας

Αλγόριθμος ISIS

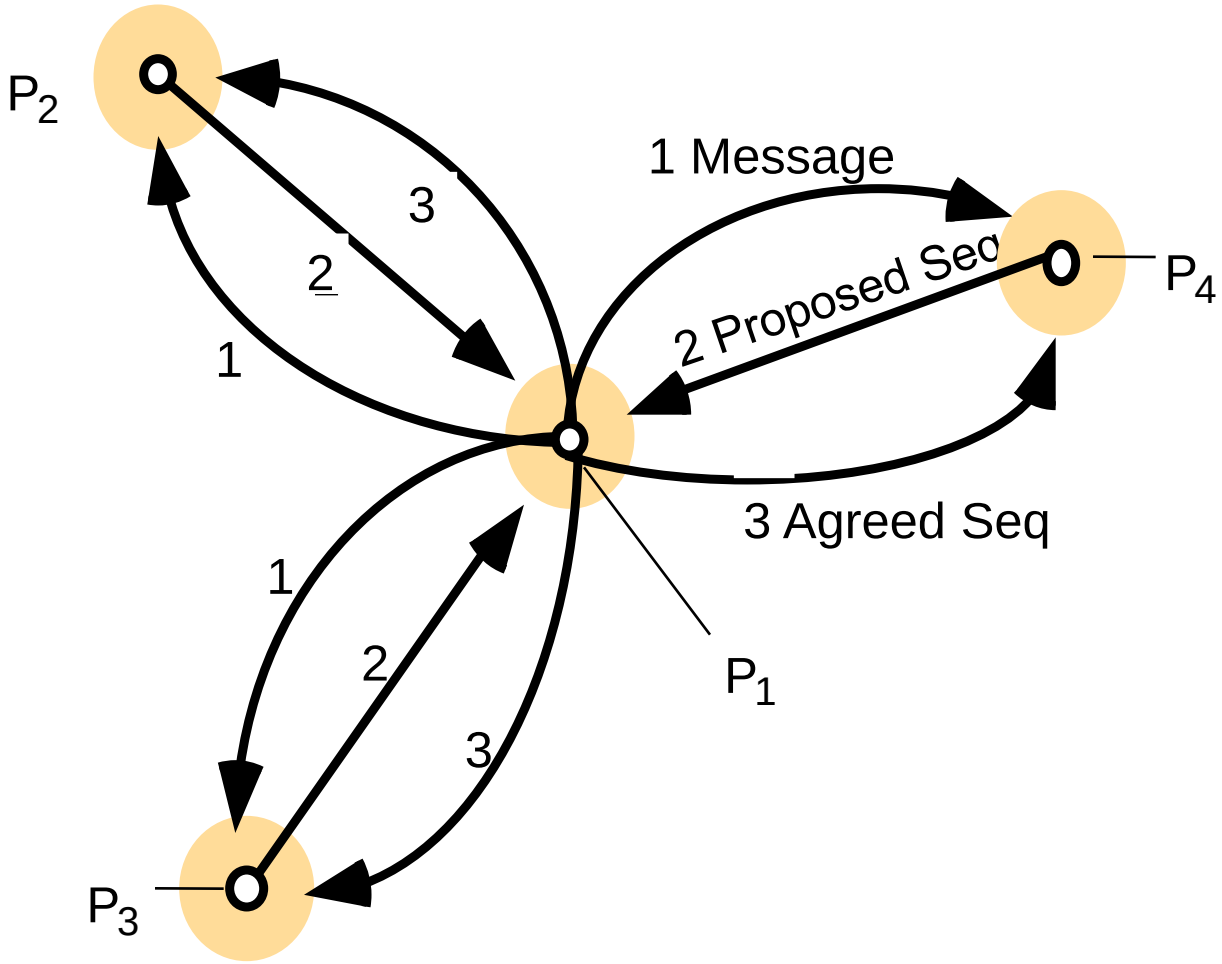

Αιτιώδης διάταξη: παράδειγμα

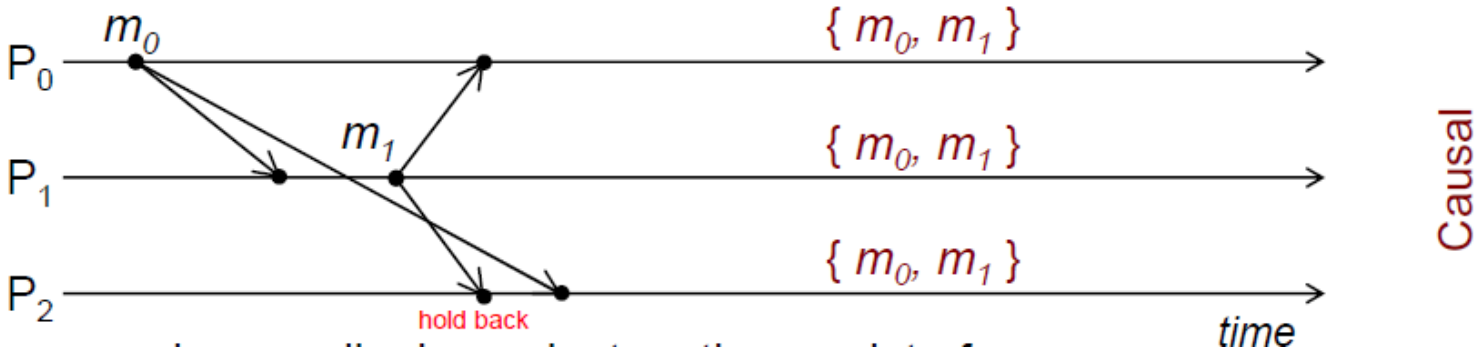

- *Το m1 εξαρτάται από τη λήψη του m0*
- Έτσι, το *m1 πρέπει να παραδοθεί μετά την παράδοση του m0*

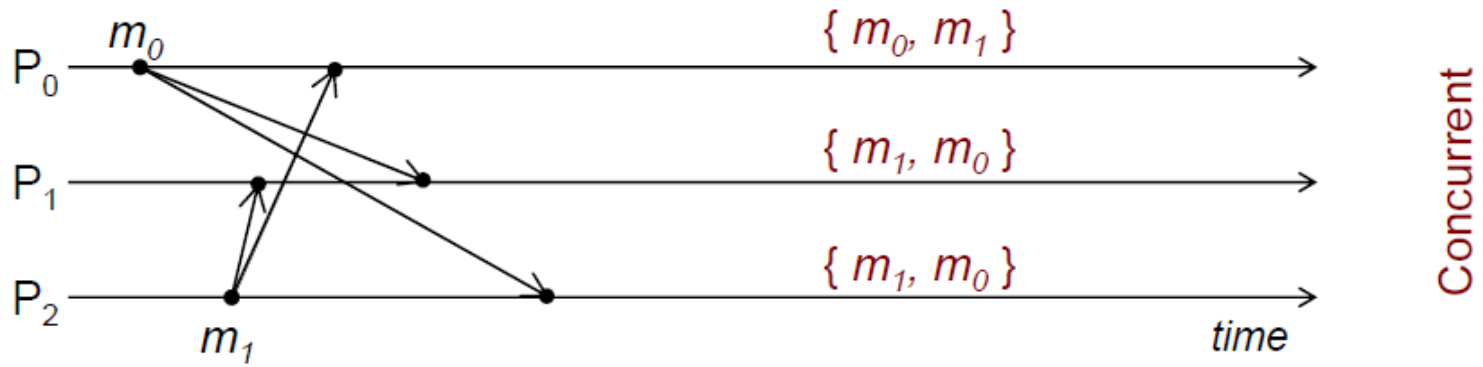

- *Το m0 και το m1 δεν έχουν αιτιώδη σχέση (ταυτόχρονα).*
- Οποιαδήποτε διεργασία μπορεί να τα παραδώσει σε οποιαδήποτε σειρά

Αιτιώδης διάταξη

- Κάθε διεργασία διατηρεί διανυσματικό ρολόι
  - Κάθε μετρητής αναπαριστά τον αριθμό των μηνυμάτων που έχουν ληφθεί από κάθε άλλη διεργασία

- Κατά το multicast, η διεργασία-αποστολέας αυξάνει τον μετρητή της και επισυνάπτει το διάνυσμα στο μήνυμα

- Κατά τη λήψη ενός μηνύματος multicast ο παραλήπτης περιμένει μέχρι να ικανοποιηθεί η αιτιώδης διάταξη, δλδ:
  - Να έχει παραδώσει όσα μηνύματα έχει στείλει ο αποστολέας στο παρελθόν
  - Να έχει παραδώσει όλα τα μηνύματα που είχε παραδώσει ο αποστολέας πριν την αποστολή του multicast

Αλγόριθμος

- Η διεργασία Pa λαμβάνει μήνυμα από την Pb
  - Κάθε διεργασία διατηρεί ένα διάνυσμα προτεραιότητας **(παρόμοιο με διανυσματική χρονοσφραγίδα)**
  - Το διάνυσμα ανανεώνεται με κάθε αποστολή και λήψη multicast
    - Κάθε τιμή= # του πιο πρόσφατου μηνύματος από τη διεργασία που προηγείται του event
- Αλγόριθμος
  - Όταν η Pb στέλνει μήνυμα
    - **Αυξάνει τη δική του τιμή και στέλνει το διάνυσμα** Vb[b] = Vb[b] + 1 με το μήνυμα
  - Όταν η Pa **λάβει μήνυμα από την Pb**
    - Τσεκάρει αν το μήνυμα ήρθε με σειρά FIFO από την Pb

      $Vb[b] == Va[b] + 1$?
    - Τσεκάρει ότι το μήνυμα δεν εξαρτάται από κάτι που δεν έχει δει ακόμα η Pa

      $\forall i, i \neq b: Vb[i] \leq Va[i]$?
    - Αν ικανοποιούνται και οι δύο συνθήκες, το Pa παραδίδει το μήνυμα
    - Αλλιώς το κρατά σε αναμονή μέχρι να ικανοποιηθούν οι συνθήκες

Παράδειγμα

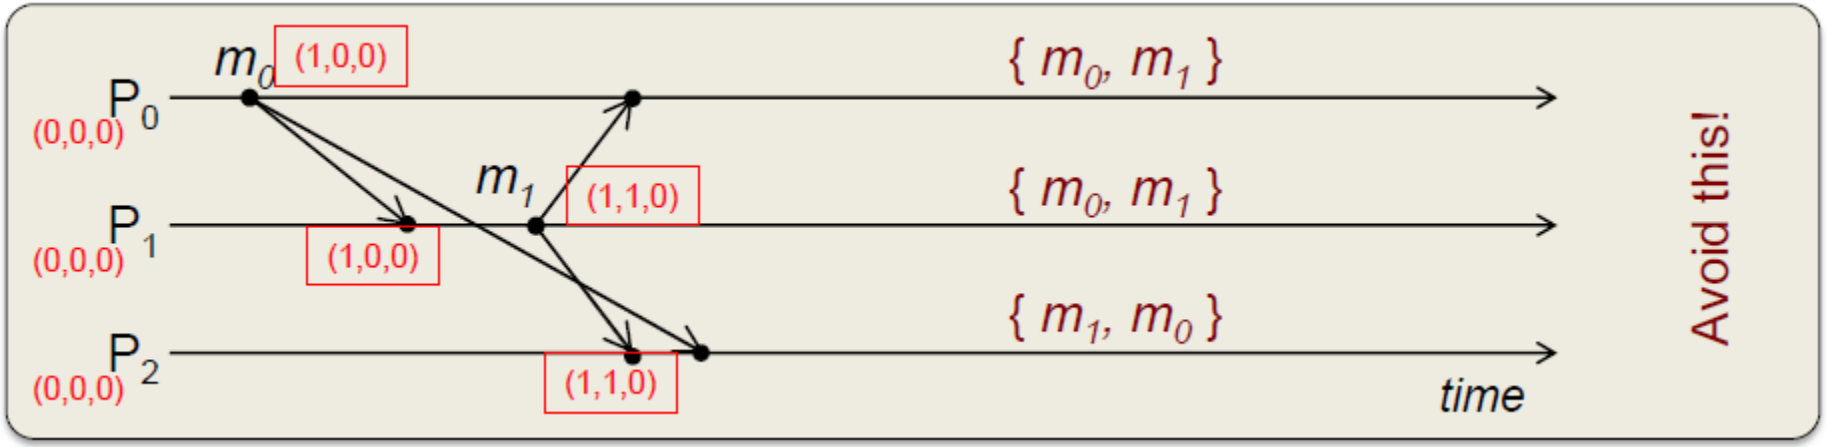

- Η P2 λαμβάνει μήνυμα m1 από την P1 με V1=(1,1,0)

  (1) Είναι σε σειρά FIFO από την P1?

  Σύγκριση τοπικού διανύσματος στην P2: V2=(0,0,0) με το διάνυσμα του μηνύματος από την P1, V1=(1,1,0)

  Ναι: V2[1] = 0, V1[1] = 1 ⇒ sequential order

  (2) Είναι V1[i] ≤ V2[i] για όλα τα υπόλοιπα i?

  Σύγκριση των διανυσμάτων : V2=(0,0,0) vs. V1=(1,1,0)

  No. V1[0] > V2[0] (1 > 0)

  Οπότε m1 σε αναμονή στην P2

Παράδειγμα

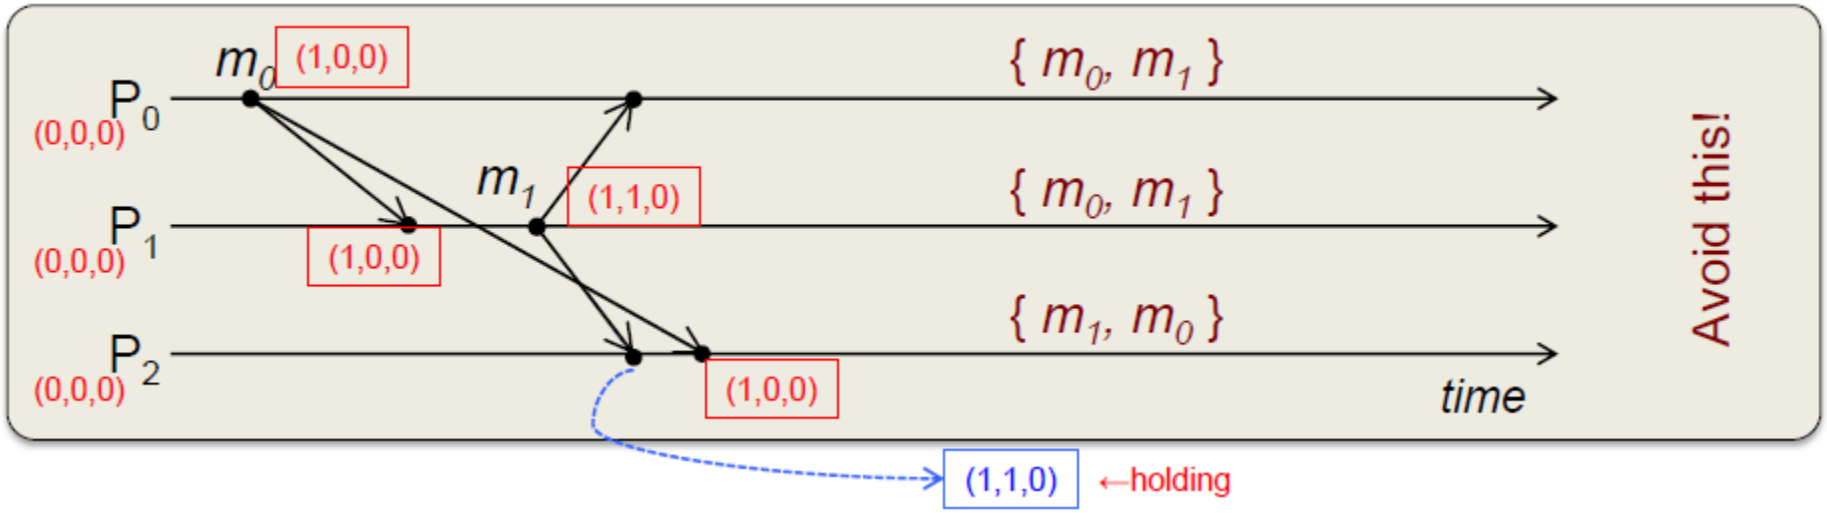

- Η P2 λαμβάνει το m0 από την P0 με V=(1,0,0)

  (1) Είναι σε σειρά FIFO από την P0?

  Σύγκριση τοπικού διανύσματος στην P2: V2=(0,0,0) με το V0=(1,0,0) από την P0

  Ναι: V2[0] = 0, V0[0] = 1 ⇒ sequential

  (2) Είναι V0[i] ≤ V2[i] για όλα τα υπόλοιπα i?

  Ναι, (0 ≤ 0), (0 ≤ 0).

  Παράδοση m0.

  Τώρα τσέκαρε την ουρά αναμονής. Μπορεί να παραδοθεί το m1?

Παράδειγμα

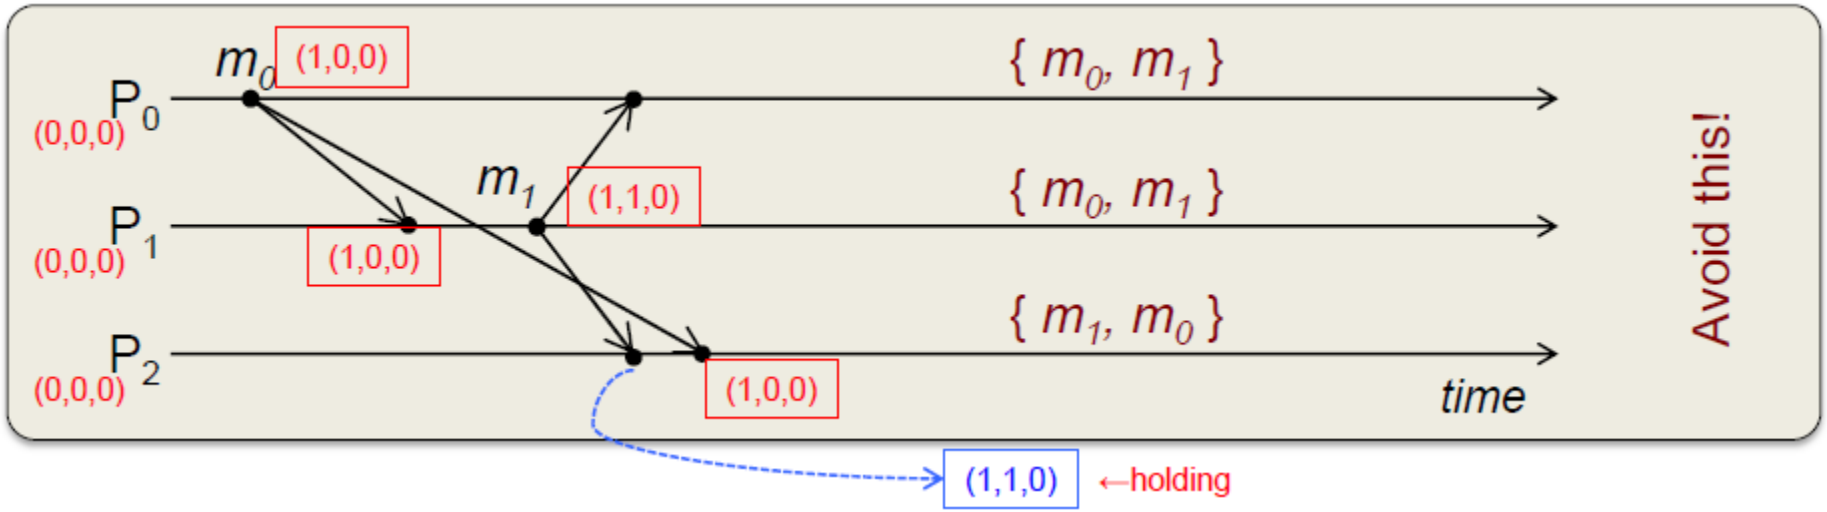

(1) Είναι το m1 που βρίσκεται σε αναμονή σε σειρά FIFO ?

Σύγκριση του τωρινού V στην P2: V2=(1,0,0) με το V του μηνύματος σε αναμονή από την P1, V1=(1,1,0)

Ναι: V2[1] = 0, V1[1] = 1 ⇒ sequential

- (2) Είναι V1[i] ≤ V2[i] για όλα τα υπόλοιπα i?

  Τώρα ναι. Στοιχείο 0: (1 ≤ 1), στοιχείο2: (0 ≤ 0)

  Παράδοση m1

- Πιο αποδοτικό από ολική διάταξη
- Δεν υπάρχει ανάγκη για sequencer.
- Δεν υπάρχει ανάγκη για acks

Κατανεμημένος συντονισμός

- Τεχνικές για συντονισμό της εκτέλεσης ανάμεσα σε διεργασίες
- Μία διεργασία μπορεί να πρέπει να περιμένει μια άλλη
- Κοινός πόρος (κρίσιμο τμήμα) απαιτεί αποκλειστική προσπέλαση

Γιατί θέλουμε αμοιβαίο αποκλεισμό

- Οι servers της τράπεζάς σας είναι στο cloud. Γίνονται δύο ταυτόχρονες καταθέσεις των $1.000 στον λογαριασμό σας από διαφορετικά ATMs.
  - Και τα δύο ATMs διαβάζουν το αρχικό ποσό των $1.000 από τον server της τράπεζας
  - Και τα δύο ATMs προσθέτουν $1.000 στο ποσό αυτό (τοπικά στο κάθε ATM)
  - Και τα δύο γράφουν το τελικό ποσό στον server
  - Τι θα γίνει;

Γιατί θέλουμε αμοιβαίο αποκλεισμό

- Τα ATMs πρέπει να έχουν αμοιβαία αποκλειόμενη προσπέλαση στις πληροφορίες του λογαριασμού στον server (ή στον κώδικα που αλλάζει τιμές δεδομένων στον λογαριασμό)

Αμοιβαίος αποκλεισμός

- Κρίσιμο τμήμα
  - Ένα κομμάτι κώδικα (σε όλους τους clients) το οποίο πρέπει να εκτελείται από έναν το πολύ client κάθε στιγμή
- Λύση:
  - Σημαφόροι, mutex, κλπ. σε κεντρικά συστήματα
  - Πρωτόκολλα βασισμένα στην ανταλλαγή μηνυμάτων σε κατανεμημένα συστήματα:
    - enter() είσοδος στο κρίσιμο τμήμα
    - AccessResource() προσπέλαση του πόρου
    - exit() έξοδος από το κρίσιμο τμήμα
- Απαιτήσεις για κατανεμημένο αμοιβαίο αποκλεισμό:
  - **Safety** – Το πολύ μία διεργασία μπορεί να εκτελεί το κρίσιμο τμήμα σε κάθε χρονική στιγμή
  - **Liveness** – Κάθε αίτημα για εκτέλεση του κρίσιμου τμήματος τελικά ικανοποιείται
  - **Διάταξη** – Τα αιτήματα ικανοποιούνται με τη σειρά που γίνονται

Κεντρικό σύστημα: mutex

- Για τον συγχρονισμό της πρόσβασης σε κοινές δομές δεδομένων από πολλαπλά νήματα

  Δύο διεργασίες μπορούν να εκτελέσουν τα παρακάτω:

```
lock()
        while true:                    // each iteration atomic
                if lock not in use:
                        label lock in use
                        break
unlock()
        label lock not in use
```

Χρήση mutex

```
mutex L= UNLOCKED;

ATM1:
        lock(L); // είσοδος στο
                 // κρίσιμο τμήμα
        διαβάζω το υπόλοιπο του
        λογαριασμού μου;
        προσθέτω την κατάθεση;
        ενημερώνω το υπόλοιπο;
        unlock(L); // έξοδος
```

```
extern mutex L;

ATM2:
    lock(L); // είσοδος στο
             // κρίσιμο τμήμα
    διαβάζω το υπόλοιπο του
    λογαριασμού μου;
    προσθέτω την κατάθεση;
    ενημερώνω το υπόλοιπο;
    unlock(L); // exit
```

Σε κατανεμημένα συστήματα

- Υποθέτουμε ότι υπάρχει συμφωνία για το πώς αναφερόμαστε σε έναν πόρο
  - Περνάει το αναγνωριστικό μαζί με τα αιτήματα (*lock("printer"), lock("table:employees") κλπ)*
- Σκοπός
  - Δημιουργία αλγορίθμου που επιτρέπει σε μια διεργασία να επεξεργαστεί ένα αίτημα και
  - Να αποκτήσει αποκλειστική πρόσβαση σε έναν πόρο που είναι διαθέσιμος στο δίκτυο

Υποθέσεις

- Για όλους τους αλγορίθμους που θα εξετάσουμε κάνουμε τις ακόλουθες υποθέσεις:
  - Κάθε ζεύγος διεργασιών συνδέεται μέσω αξιόπιστου καναλιού (π.χ. TCP).
  - Τα μηνύματα παραδίδονται στους παραλήπτες με FIFO διάταξη
  - Οι διεργασίες δεν αποτυγχάνουν

Κριτήρια Επίδοσης

- **Bandwidth**: Ο συνολικός αριθμός μηνυμάτων που αποστέλλονται σε κάθε εισαγωγή και έξοδο από το κρίσιμο τμήμα

- **Client delay**: Η καθυστέρηση που προκαλείται από μια διεργασία σε κάθε εισαγωγή ή έξοδο από το κρίσιμο τμήμα (όταν δεν υπάρχει άλλη διεργασία που να εκτελεί το κρίσιμο τμήμα ή να βρίσκεται σε αναμονή)

- **Synchronization delay**: Το χρονικό διάστημα ανάμεσα στην έξοδο μιας διεργασίας από το κρίσιμο τμήμα και την εισαγωγή της επόμενης διεργασίας σε αυτό (όταν υπάρχει μόνο μια διεργασία σε αναμονή).

Κατηγορίες αλγορίθμων

- Κεντρικοί
  - Μια διεργασία αποκτά πρόσβαση σε έναν πόρο όταν της το επιτρέπει ένας κεντρικός συντονιστής (κεντρικός έλεγχος)
- Με σκυτάλη
  - Μια διεργασία αποκτά πρόσβαση σε έναν πόρο αν έχει σκυτάλη (token) που της το επιτρέπει (Δακτύλιος με σκυτάλη)
- Με συμφωνία
  - Μια διεργασία αποκτά πρόσβαση σε έναν πόρο μέσω κατανεμημένης συμφωνίας (Ricart & Agrawala)

Κεντρικός Έλεγχος

- Μια διεργασία έχει εκλεγεί ως συντονιστής (coordinator)

1. *Αίτηση για πρόσβαση*
2. *Αναμονή για απάντηση*
3. *Λήψη άδειας*
4. *Πρόσβαση σε κρίσιμο τμήμα*
5. *Έξοδος*

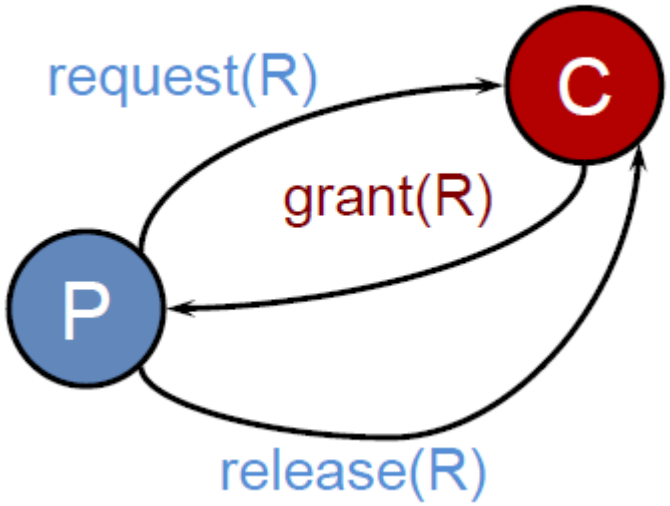

Κεντρικός Έλεγχος

- Αν κάποια άλλη διεργασία ζητήσει τον πόρο τότε:
  - Ο συντονιστής δεν αποκρίνεται μέχρι να απελευθερωθεί ο πόρος
  - Διατηρεί ουρά
- Τα αιτήματα εξυπηρετούνται με σειρά FIFO

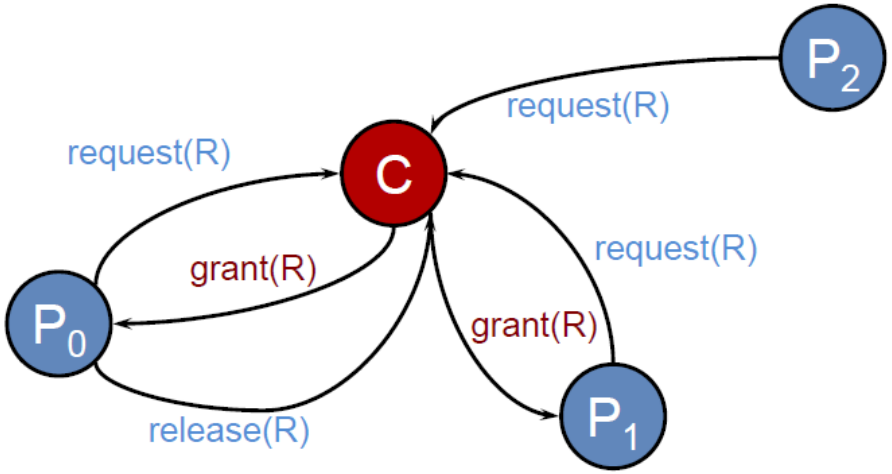

Αποτίμηση αλγορίθμου

- Bandwidth
  - Απαιτούνται 3 μηνύματα ανά είσοδο/έξοδο
- Client delay
  - Ένα round trip time (αίτημα + άδεια)
- Synchronization delay
  - Ένα round trip time (έξοδος + άδεια)

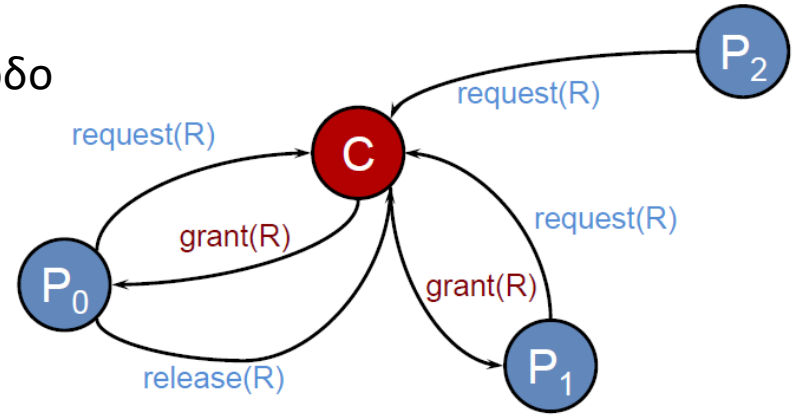

\+ Δικαιοσύνη: Τα αιτήματα υφίστανται επεξεργασία με τη σειρά

\+ Ευκολία υλοποίησης και επαλήθευσης

\- Η διεργασία δεν μπορεί να ξεχωρίσει αν μπλοκάρεται από συντονιστή που έχει σφάλμα

\- Ο κεντρικός εξυπηρετητής μπορεί να αποτελέσει bottleneck

Αλγόριθμος δακτυλίου

- Μπορεί να επιβληθεί κάποια διάταξη
- Οι διεργασίες είναι οργανωμένες σε λογικό δακτύλιο
- Κάθε διεργασία επικοινωνεί με τη γειτονική της

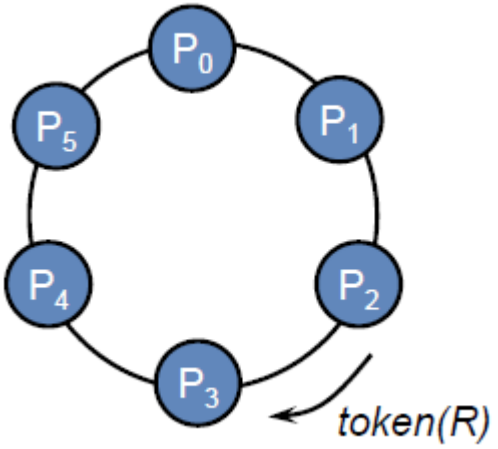

- Αρχικοποίηση
  - Η διεργασία 0 παίρνει σκυτάλη για τον πόρο R
- Η σκυτάλη κυκλοφορεί γύρω από τον δακτύλιο
  - Από την Pi στην P(i+1)mod N
- Όταν η διεργασία παίρνει τη σκυτάλη
  - Ελέγχει αν χρειάζεται τον πόρο
  - Αν όχι, στέλνει τη σκυτάλη στην επόμενη
  - Αν ναι, προσπελάζει τον πόρο
- Κρατά τη σκυτάλη μέχρι να ολοκληρώσει

Αποτίμηση αλγορίθμου

- Bandwidth: 1 μήνυμα ανά έξοδο
- Client delay: 0 με N μηνύματα
- Synchronization delay: ανάμεσα σε 1 και N-1 μηνύματα

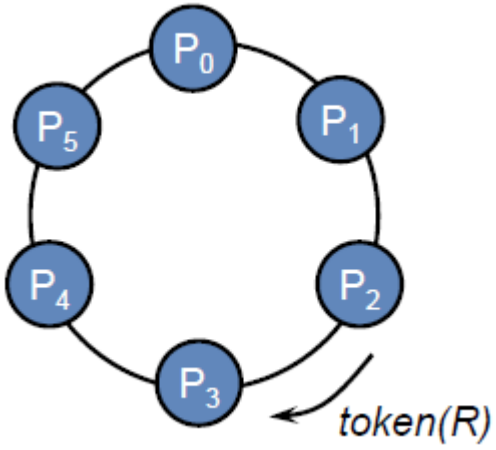

- Μόνο μια διεργασία τη φορά έχει τη σκυτάλη
  + Ο αμοιβαίος αποκλεισμός είναι εγγυημένος
- Η διάταξη είναι καλά ορισμένη (όχι απαραίτητα FIFO)
  + Δεν μπορεί να προκληθεί Starvation
- Αν η σκυτάλη χαθεί (π.χ., η διεργασία πεθάνει)
  - Θα πρέπει να δημιουργηθεί ξανά
  - Η ανίχνευση της απώλειας είναι δύσκολη (η σκυτάλη χάθηκε ή χρησιμοποιείται από κάποια άλλη διεργασία;)

Αλγόριθμος Ricart & Agrawala

- Κατανεμημένος αλγόριθμος που χρησιμοποιεί αξιόπιστο multicast και λογικά ρολόγια
- Όταν μια διεργασία θέλει να εισέλθει στο κρίσιμο τμήμα:
  1. Συνθέτει μήνυμα που περιέχει:
     - Αναγνωριστικό (machine ID, process ID)
     - Όνομα του πόρου
     - Χρονοσφραγίδα (π.χ., Lamport)
  2. Στέλνει με αξιόπιστο multicast αίτημα σε όλες της διεργασίες της ομάδας
  3. Περιμένει μέχρι να λάβει άδεια από όλους
  4. Εισέρχεται στο κρίσιμο τμήμα/χρησιμοποιεί τον πόρο

Συνέχεια

- Για να εισέλθει στο κρίσιμο τμήμα
  - θέτει την κατάστασή του σε wanted
  - στέλνει με multicast αίτημα σε όλες τις διεργασίες (συμπεριλαμβάνοντας χρονοσφραγίδα)
  - Περιμένει μέχρι όλες οι διεργασίες να στείλουν απάντηση
  - Αλλάζει την κατάστασή του σε held και μπαίνει στο κρίσιμο τμήμα
- Κατά τη λήψη αιτήματος <Ti, pi> στην pj:
  - Αν η κατάστασή της είναι held ή η κατάσταση είναι wanted & (Tj, pj)<(Ti,pi)), βάλε το αίτημα σε ουρά
  - αλλιώς απάντησε στην pi
- Κατά την έξοδο από το κρίσιμο τμήμα
  - Άλλαξε την κατάσταση σε release και απάντησε στο πρώτο αίτημα στην ουρά

Παράδειγμα

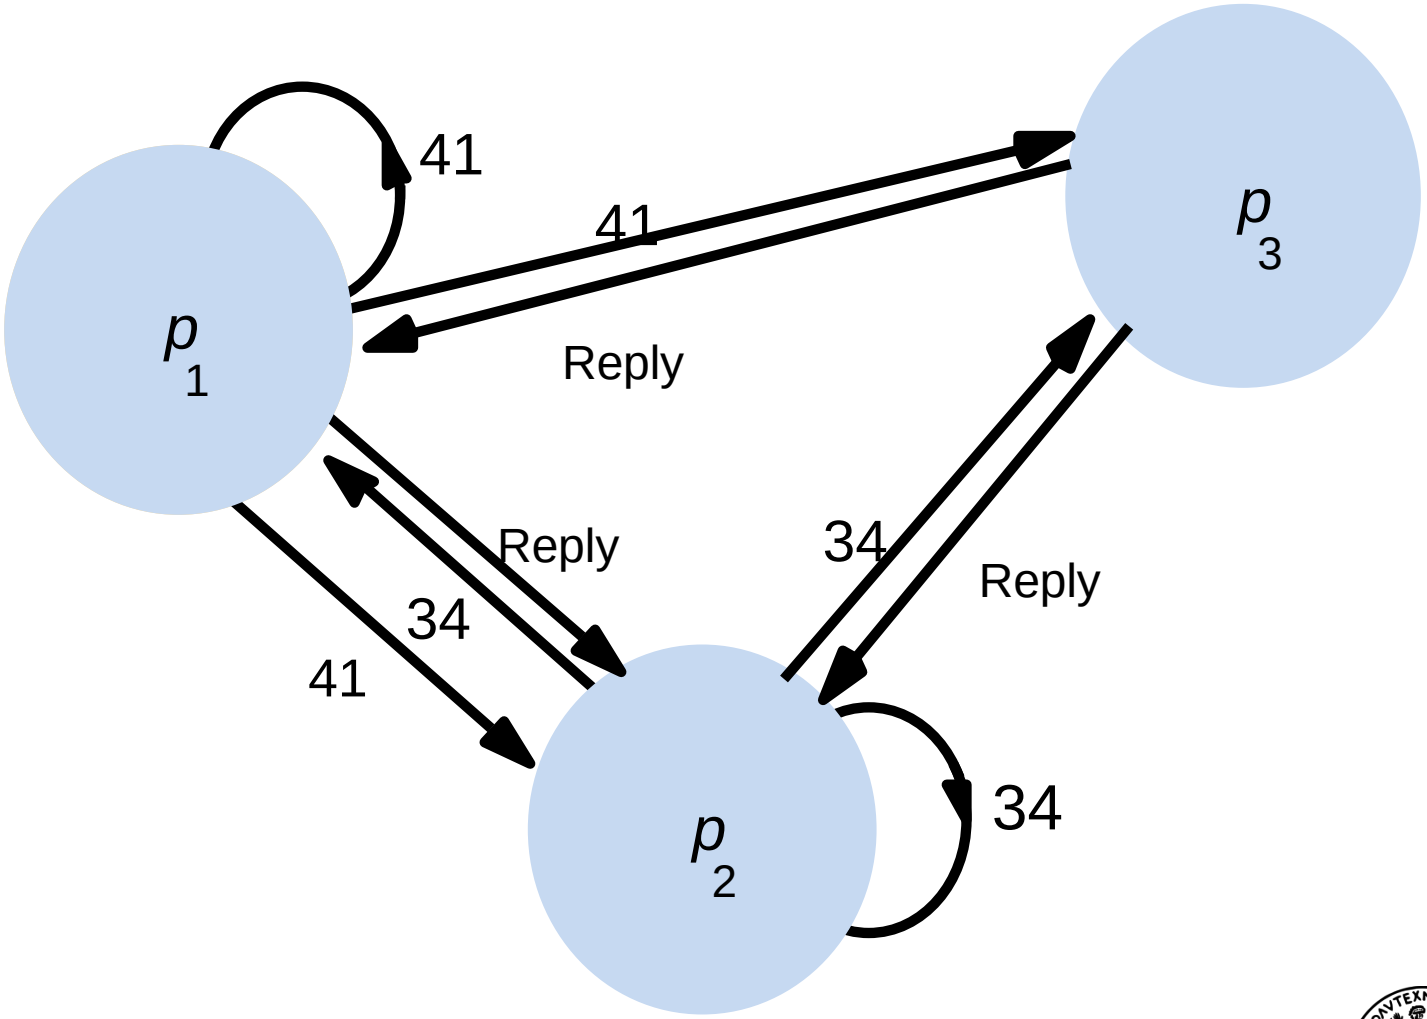

Αποτίμηση

- Bandwidth:
  - 2(N-1) μηνύματα ανά εισαγωγή
  - N-1 unicasts για το multicast request + N-1 απαντήσεις
- Client delay
  - Ένα RTT
- Synchronization delay
  - Ο χρόνος μετάδοσης ενός μηνύματος

- Πιο ακριβός αλγόριθμος σε bandwidth
- *Ν σημεία σφάλματος*
+ Μικρότερο synchronization delay (1 μήνυμα)
+ Βελτιώσεις: Αν η διεργασία που μπήκε τελευταία στο critical section δεν έχει λάβει άλλα αιτήματα;

Αλγόριθμοι Εκλογής

Γιατί χρειάζονται;

- Όταν θέλουμε μια διεργασία να παίξει έναν συγκεκριμένο ρόλο
  - Συντονιστή για αμοιβαίο αποκλεισμό
  - Τον root σε ομάδα από NTP servers

Παραδοχές

- Οποιαδήποτε διεργασία μπορεί να ξεκινήσει διαδικασία εκλογής
- Κάθε διεργασία μπορεί να ξεκινήσει το πολύ μια διαδικασία εκλογής τη φορά
- Πολλές διεργασίες μπορούν να ξεκινήσουν διαδικασία εκλογής ταυτόχρονα
  - *Όλες πρέπει να αποφασίσουν για έναν μοναδικό, κοινό αρχηγό*
  - *Το αποτέλεσμα δεν εξαρτάται από το ποια διεργασία ξεκίνησε τη διαδικασία εκλογής*
- Τα μηνύματα τελικά θα παραδοθούν

Ορισμός προβλήματος

- Στο τέλος του πρωτοκόλλου εκλογής επιλέγεται ως αρχηγός η ζωντανή διεργασία με το μεγαλύτερο αναγνωριστικό
  - Παράδειγμα αναγνωριστικού: CPU speed, load, disk space, ID
  - Πρέπει να είναι μοναδικό και να μπορεί να διαταχθεί
- Κάθε διεργασία έχει μια μεταβλητή *elected*.
- Η εκτέλεση του αλγορίθμου πρέπει πάντα στο τέλος να εγγυάται
  - Safety: $\forall$ σωστή p: (*elected* = (q: μια συγκεκριμένη σωστή διεργασία με τη μεγαλύτερη τιμή αναγνωριστικού))
  - Liveness: $\forall$ election: (η διαδικασία τερματίζει) & $\forall$ σωστή διεργασία p: η μεταβλητή *elected* του p είναι τελικά διάφορη του $\perp$

Εκλογή δακτυλίου

- Ν διεργασίες οργανώνονται σε λογικό δακτύλιο
  - η p_i επικοινωνεί με την $p_{i+1 \bmod N}$.
  - Όλα τα μηνύματα στέλνονται δεξιόστροφα γύρω από τον δακτύλιο
- Για την έναρξη της διαδικασίας εκλογής
  - Η διεργασία στέλνει μήνυμα *election* μαζί με το id της
- Κατά τη λήψη μηνύματος (*election*, id) μια διεργασία με myID
  - Αν id > my ID: προωθεί το μήνυμα
    - Θέτει την κατάστασή της σε *participating*
  - Αν id < my ID: στέλνει (*election*, my ID)
    - Skip αν η κατάσταση είναι ήδη *participating*
    - Θέτει την κατάσταση σε *participating*
  - Αν id = my ID: η διεργασία εξελέγη αρχηγός και στέλνει μήνυμα *elected*
    - *Το μήνυμα elected* προωθείται μέχρι να φτάσει ξανά στον αρχηγό.

Αποτίμηση

- Ποιο είναι το χειρότερο σενάριο;
  - Το μεγαλύτερο id έχει η διεργασία που βρίσκεται ακριβώς πριν τη διεργασία που ξεκίνησε τη διαδικασία εκλογής
  - 3N-1 μηνύματα
- Παράδειγμα :
  - Η διαδικασία ξεκίνησε από τη διεργασία 17
  - Το μεγαλύτερο id μέχρι τώρα είναι το 24
  - Ο τελικός αρχηγός είναι η διεργασία με id 33

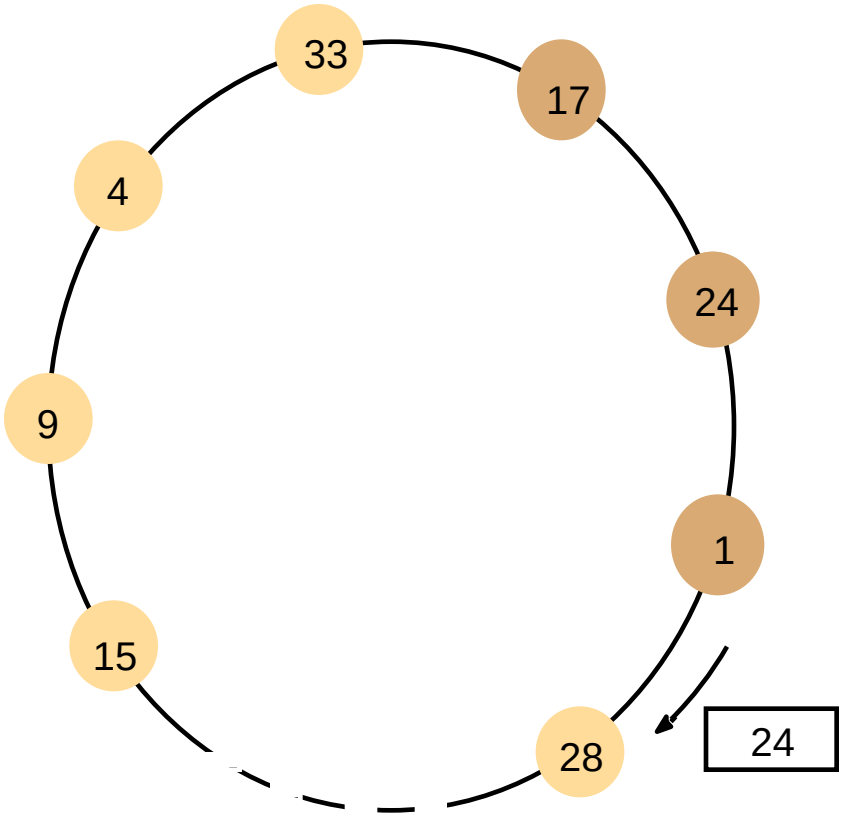

Παράδειγμα

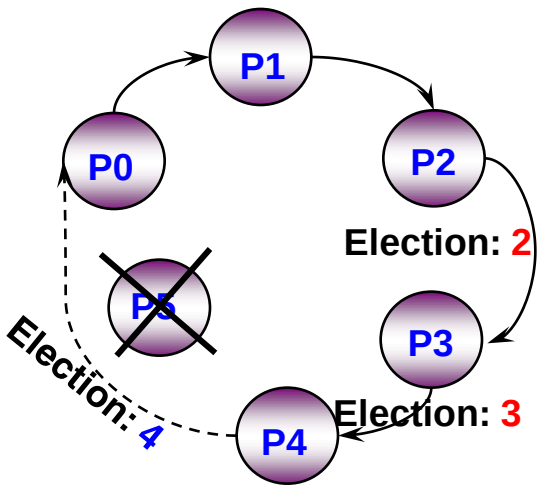

1. Η P2 ξεκινά εκλογή μετά την αποτυχία της P5

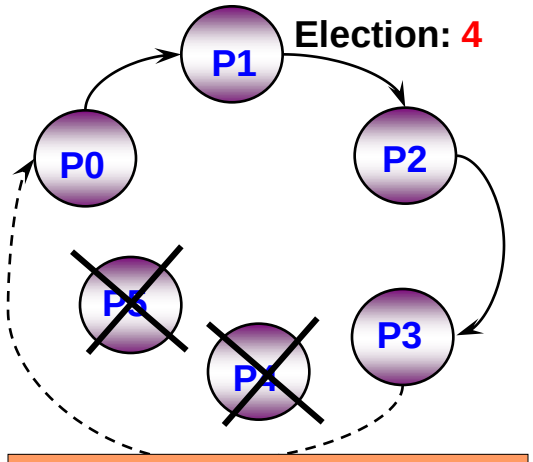

2. Η P2 λαμβάνει μήνυμα election και η P4 πεθαίνει

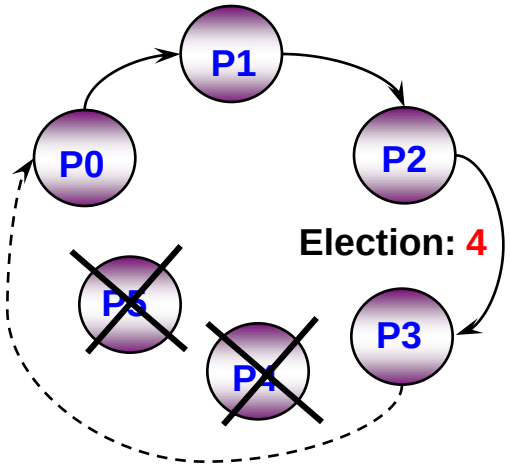

3. Το μήνυμα election: 4 προωθείται για πάντα

Αν μια διεργασία πεθάνει κατά τη διάρκεια εκτέλεσης,
ο αλγόριθμος μπορεί να μην τερματίσει ποτέ

Τροποποιημένη εκλογή δακτυλίου

- Το μήνυμα *election* καταγράφει όλα τα ids των κόμβων που το προώθησαν, όχι μόνο το μεγαλύτερο
  - Κάθε διεργασία προσθέτει το id της στη λίστα
- Μόλις το μήνυμα περάσει όλον τον κύκλο, αποστέλλεται ένα νέο μήνυμα *coordinator*
  - Επιλέγεται ο κόμβος με το μεγαλύτερο id στο μήνυμα *election*
  - Κάθε κόμβος προσθέτει το id του στο μήνυμα *coordinator*
- Όταν το μήνυμα *coordinator* επιστρέψει στον εκκινητή της διαδικασίας
  - Η εκλογή έχει επιτύχει αν το id του νέου αρχηγού είναι μέσα στη λίστα των ids
  - Αλλιώς ξεκινάει νέα διαδικασία εκλογής

Παράδειγμα

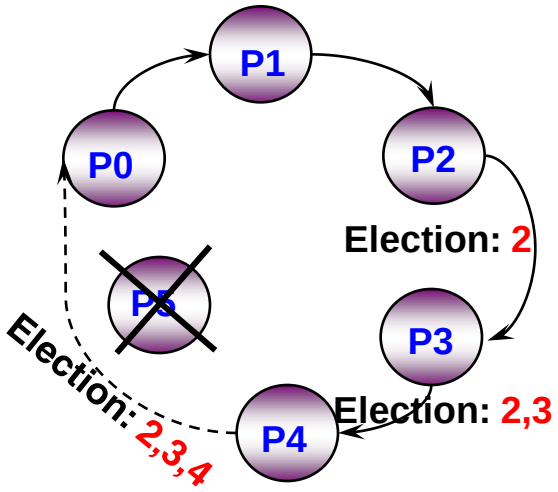

1. Η P2 ξεκινά εκλογή

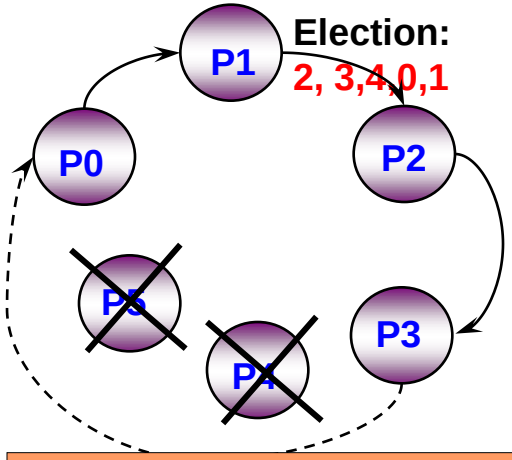

2. Η P2 λαμβάνει μήνυμα election και η P4 πεθαίνει

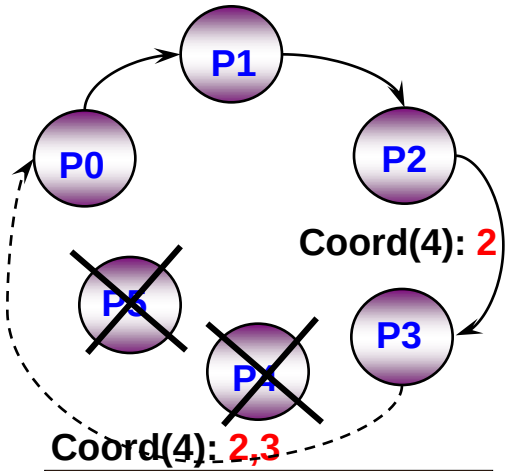

3. Η P2 επιλέγει την 4 και ανακοινώνει

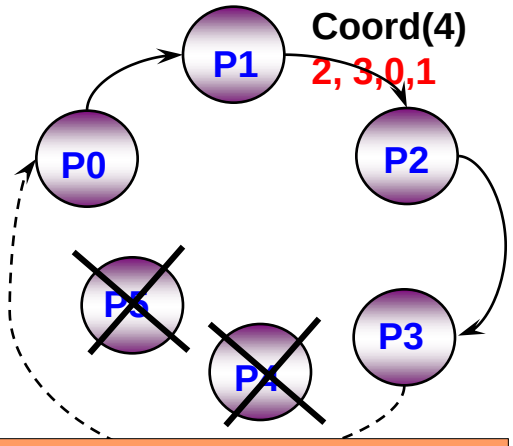

4. Η P2 λαμβάνει το μήνυμα coord χωρίς το id 4

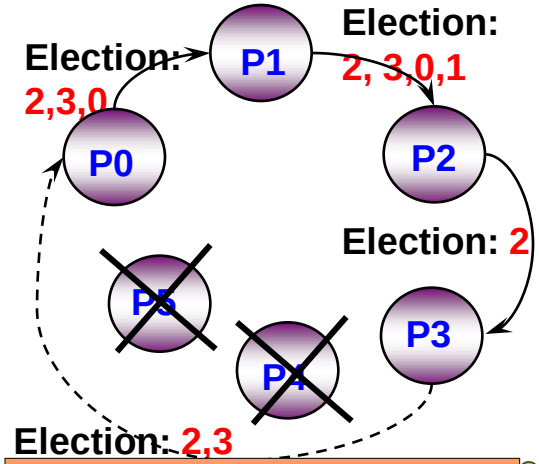

5. Η P2 ξεκινά τη διαδικασία ξανά

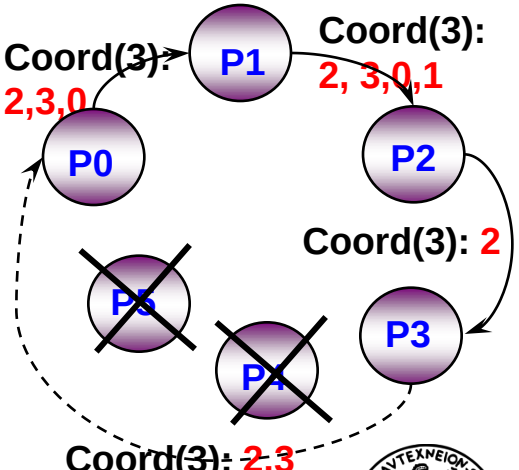

6. Τελικά εκλέγεται η P3

Αποτίμηση

- Πόσα μηνύματα;
  - 2N
  - Όμως μεγαλύτερα σε μέγεθος
- Αν πεθάνει ο εκκινητής;
  - Ο επόμενος κόμβος βλέπει ότι το μήνυμα πέρασε από όλον τον δακτύλιο
  - Ξεκινά καινούρια εκλογή

Αλγόριθμος bully

- Υποθέσεις
  - Σύγχρονο σύστημα (δλδ υπάρχουν όρια στο χρόνο μετάδοσης ενός μηνύματος)
  - Χρησιμοποιεί timeouts για να ανιχνεύσει σφάλματα σε διεργασίες
  - Κάθε διεργασία γνωρίζει όλες τις υπόλοιπες διεργασίες στο σύστημα (επομένως και τα ids τους)

Αλγόριθμος bully

- 3 τύποι μηνυμάτων
  - *election* – εκκίνηση διαδικασίας εκλογής
  - *answer* – επιβεβαίωση της λήψης
  - *coordinator* – ανακήρυξη αρχηγού

- Έναρξη διαδικασίας
  - Ο εκκινητής στέλνει μήνυμα *election* σε όλες τις διεργασίες με id μεγαλύτερο από το δικό του
  - Αν δεν απαντήσει κανείς μέχρι το timeout: ανακηρύσσεται αρχηγός
  - Αν κάποιος απαντήσει, περιμένει για το μήνυμα *coordinator*
    - Επανεκκινεί τη διαδικασία μετά από timeout

- Κατά τη λήψη μηνύματος *election*
  - Αποστολή *answer*
  - Εκκίνηση νέας διαδικασίας εκλογής

Παράδειγμα

answer=OK

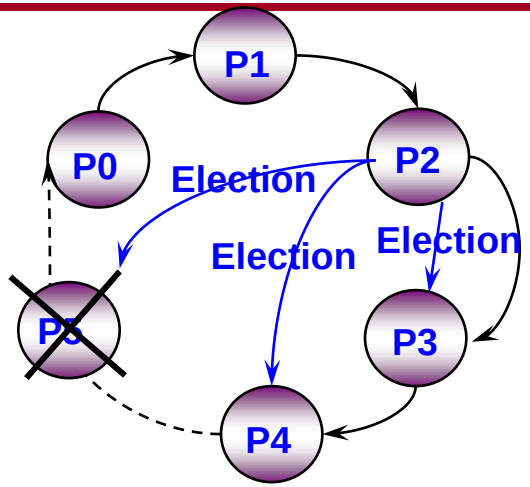

1. Η P2 ξεκινά εκλογή

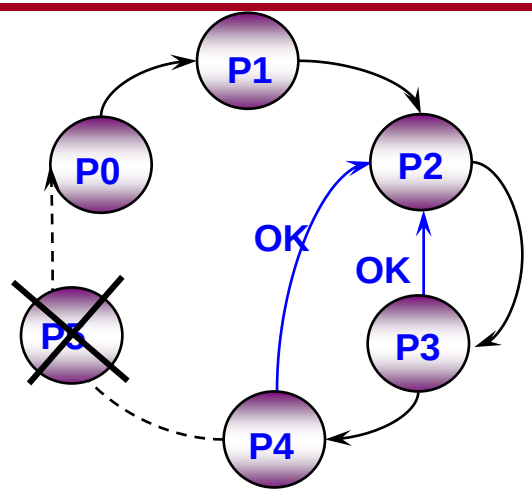

2. Η P2 λαμβάνει απάντηση

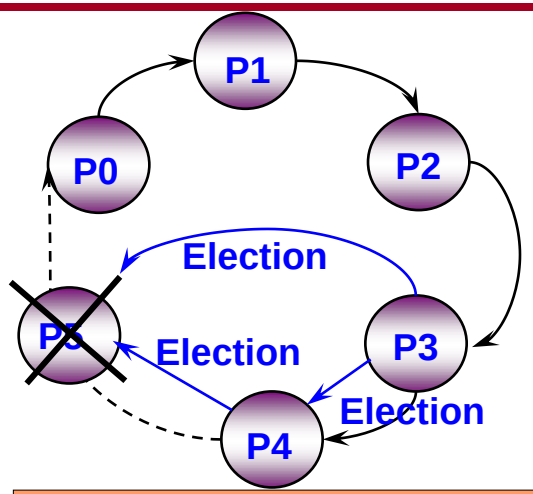

3. Οι P3 & P4 ξεκινούν εκλογή

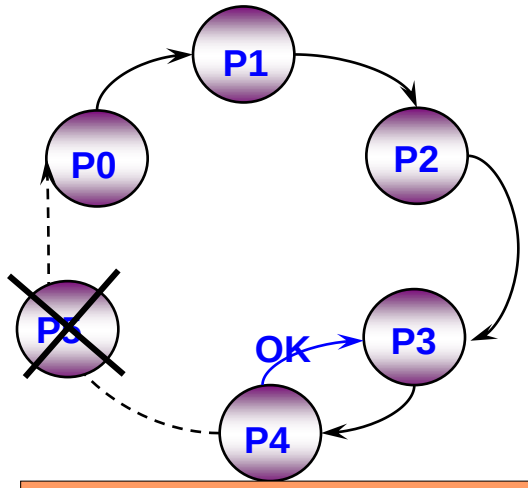

4. Η P3 λαμβάνει απάντηση

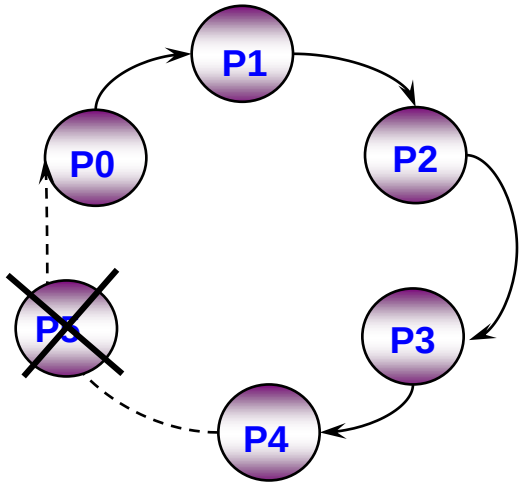

5. Η P4 δε λαμβάνει απάντηση

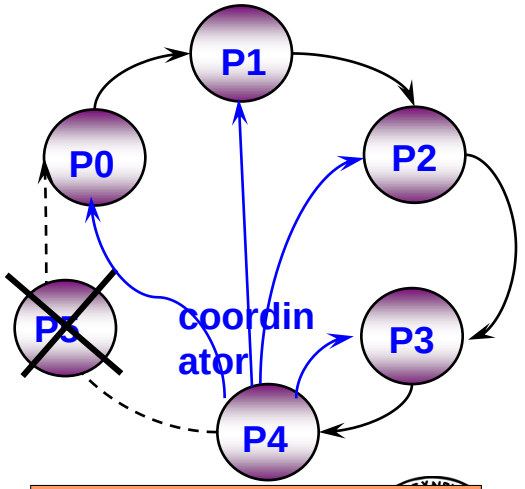

5. Η P4 ανακηρύσσεται αρχηγός

Αποτίμηση

- Best case scenario: Η διεργασία με το δεύτερο μεγαλύτερο id αντιλαμβάνεται ότι ο συντονιστής έχει πεθάνει και εκλέγει τον εαυτό της
  - N-2 μηνύματα *coordinator*
- Worst case scenario: Η διεργασία με το μικρότερο id ανιχνεύει ότι ο συντονιστής έχει πεθάνει
  - N-1 διεργασίες ξεκινούν εκλογή ταυτόχρονα, καθεμιά από τις οποίες στέλνει μηνύματα στις διεργασίες με μεγαλύτερο id
  - Η επιβάρυνση σε μηνύματα είναι $O(N^2)$.
- Πόσο να θέσουμε το timeout;
  - $2T + T_{process}$

Ανακεφαλαίωση

- Group communication
  - Multicast για FIFO διάταξη
  - Multicast για ολική διάταξη
    - Sequencer
    - ISIS
  - Multicast για αιτιώδη διάταξη
    - Χρησιμοποιεί vector timestamps

- Αμοιβαίος αποκλεισμός
  - Κεντρικός έλεγχος
  - Δακτύλιος με σκυτάλη
  - Αλγόριθμος Ricart and Agrawala

- Ο συντονισμός σε κατανεμημένα συστήματα απαιτεί συχνά εκλογή αρχηγού
  - Αλγόριθμος δακτυλίου
  - Αλγόριθμος τροποποιημένου δακτυλίου
  - Αλγόριθμος bully