Consensus

Κατανεμημένα Συστήματα

2015-2016

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

Στόχος του consensus

- Επιτρέπει σε ομάδα διεργασιών να συμφωνήσουν σε ένα αποτέλεσμα
  - Όλες οι διεργασίες πρέπει να συμφωνήσουν στην ίδια τιμή
  - Η τιμή πρέπει να έχει υποβληθεί από τουλάχιστον μια διεργασία (ένας αλγόριθμος consensus δεν μπορεί απλώς να επινοήσει μια τιμή)

Έχουμε δει ήδη…

- Mutual exclusion
  - Συμφωνία για το ποιος έχει πρόσβαση σε κάποιον πόρο
- Αλγόριθμοι εκλογών
  - Συμφωνία για το ποίος αναλαμβάνει κάποιον ξεχωριστό ρόλο
- Άλλες χρήσεις consensus:
  - Διαχείριση group membership
  - Συγχρονισμός replicas
  - Commit για κατανεμημένα transaction
- Γενικό πρόβλημα consensus:
  - *Πώς ερχόμαστε σε ομόφωνη απόφαση για μια συγκεκριμένη τιμή;*

Ορισμός του προβλήματος

- Ν διεργασίες
- Κάθε διεργασία p έχει
  - Μεταβλητή εισόδου x_p : αρχικά 0 ή 1
  - Μεταβλητή εξόδου y_p : αρχικά b (b=undecided) – μπορεί να αλλάξει μια φορά μόνο
- Το πρόβλημα consensus: Ορισμός πρωτοκόλλου έτσι ώστε
  - Όλες οι σωστές διεργασίες να θέσουν τις μεταβλητές εξόδου τους 0 ή
  - Όλες οι σωστές διεργασίες να θέσουν τις μεταβλητές εξόδου τους 1
  - Υπάρχει τουλάχιστον μια αρχική κατάσταση που οδηγεί σε καθένα από τα παραπάνω αποτελέσματα

Μοντέλο συστήματος

- Οι διεργασίες αποτυγχάνουν μόνο με *crash-stop*
- Σύγχρονο σύστημα: Όριο σε
  - Καθυστερήσεις μηνυμάτων
  - Μέγιστος χρόνος για κάθε βήμα επεξεργασίας
- Ασύγχρονο σύστημα: δεν υπάρχουν τέτοια όρια
  - Π.χ. το Internet

Σύγχρονο σύστημα

- Κάθε διεργασία ξεκινά με αρχική τιμή εισόδου 0 ή 1
- Κάθε διεργασία κρατά το ιστορικό των τιμών που έχει λάβει
- Το πρωτόκολλο τρέχει σε γύρους
- Σε κάθε γύρο, όλοι στέλνουν με multicast το ιστορικό των τιμών
- Αφού τελειώσουν όλοι οι γύροι, διαλέγουμε την ελάχιστη τιμή

Σύγχρονο σύστημα

- Για κάθε σύστημα που αποτυγχάνουν το πολύ f διεργασίες, ο αλγόριθμος συνεχίζει σε f+1 γύρους (με timeout), χρησιμοποιώντας το βασικό multicast
- $Values^r_i$: Το σύνολο των προτεινόμενων τιμών που είναι γνωστές στην διεργασία P_i στην αρχή του γύρου r
- Initially $Values^0_i = \{\}$; $Values^1_i = \{v_i=x_p\}$

```
for round r = 1 to f+1 do
        multicast (Values^r_i)
        Values^(r+1)_i ← Values^r_i
        for each V_j received
                Values^(r+1)_i = Values^(r+1)_i ∪ V_j
        end
end
y_p= minimum(Values^(f+1)_i)
```

Γιατί δουλεύει;

- Ας υποθέσουμε ότι 2 σωστές διεργασίες p_i και p_j διαφέρουν στο τελικό σύνολο τιμών → proof by contradiction
- Ας υποθέσουμε ότι η p_i έχει μια τιμή v που δεν έχει η p_j
- Άρα η p_j δεν πρέπει να έχει λάβει την v σε κανένα γύρο
  - → Στον τελευταίο γύρο, κάποια τρίτη διεργασία p_k έστειλε v στην p_i και πέθανε πριν τη στείλει στην p_j.
  - → Οποιαδήποτε διεργασία που έστειλε v στον προτελευταίο γύρο πρέπει να πέθανε, αλλιώς θα είχαν λάβει και οι δύο p_k και p_j την τιμή v
  - → Προχωρώντας έτσι, σε καθέναν από τους προηγούμενους γύρους θα πρέπει να πέθαινε τουλάχιστον μια διεργασία
  - → Αλλά υποθέσαμε το πολύ f σφάλματα και f+1 γύρους ==> contradiction.

Ασύγχρονο σύστημα

- Τα μηνύματα μπορούν να έχουν αυθαίρετη καθυστέρηση και οι επεξεργασίες να είναι αυθαίρετα αργές
- Είναι αδύνατον να εγγυηθούμε ότι θα πετύχουμε consensus
  - Ακόμα και μια αποτυχία είναι ικανή να αποτρέψει συμφωνία
  - Μια αργή διεργασία δε διακρίνεται από μια διεργασία που έχει πεθάνει
- Η αδυναμία ισχύει για οποιοδήποτε πρωτόκολλο consensus
- Αποδείχτηκε από Fischer, Lynch και Patterson το 1983 (FLP)
  - Λύθηκε διαφωνία που υπήρχε για μια δεκαετία

Είμαστε καταδικασμένοι;

- Τα ασύγχρονα συστήματα δεν μπορούν να εγγυηθούν ότι θα έρθουν σε συμφωνία ακόμα και με αποτυχία μιας μόνο διεργασίας

- Κλειδί: “εγγύηση”
  - Δε σημαίνει ότι οι διεργασίες δεν μπορούν να έρθουν σε συμφωνία αν μια από αυτές αποτύχει
  - Επιτρέπει συμφωνία με κάποια πιθανότητα μεγαλύτερη από 0
  - Στην πράξη πολλά συστήματα επιτυγχάνουν consensus

- Πώς το ξεπερνάμε;

Τεχνικές για να ξεπεράσουμε το αδύνατο

- Τεχνική 1: κρύβουμε τις αποτυχίες (crash-stop)
  - Χρήση persistent storage και τοπικών checkpoints
  - Μετά από αποτυχία, επανεκκίνηση της διεργασίας και ανάνηψη από το τελευταίο checkpoint
  - Μπορεί να εισάγει αυθαίρετες καθυστερήσεις

- Τεχνική 2: χρησιμοποιούμε ανιχνευτές λαθών
  - Π.χ., αν μια διεργασία είναι αργή, θεωρούμε ότι έχει αποτύχει
  - Τότε τη σκοτώνουμε πραγματικά ή αγνοούμε τα μηνύματά της από εκείνο το σημείο και μετά (fail-silent)
  - Αυτό μετατρέπει το ασύγχρονο σε σύγχρονο σύστημα
  - Οι ανιχνευτές λαθών δεν είναι 100% ακριβείς και απαιτούν μεγάλο timeout για να έχουν μια λογική συμπεριφορά

Σκοπός ενός αλγορίθμου consensus

- Ανοχή σε σφάλματα
  - Δεν μπλοκάρει όταν η πλειονότητα των διεργασιών δουλεύουν
- Συμφωνία σε ένα αποτέλεσμα ανάμεσα σε ομάδα διεργασιών ακόμα κι αν:
  - Κάποιες διεργασίες πεθάνουν
  - Κάποια μηνύματα χαθούν, έρθουν εκτός σειράς ή πολλές φορές
  - Αν παραδοθούν, τα μηνύματα δεν αλλοιώνονται

Απαιτήσεις

- Ισχύς (validity)
  - Μπορούν να επιλεγούν μόνο τιμές που έχουν προταθεί
- Ομοιόμορφη συμφωνία
  - Δε γίνεται δύο κόμβοι να επιλέξουν διαφορετικές τιμές
- Ακεραιότητα (integrity)
  - Κάθε κόμβος μπορεί να επιλέξει μία μοναδική τιμή
- Τερματισμός
  - Κάθε κόμβος θα επιλέξει τελικά (eventually) μια τιμή

Paxos

- Ένας αλγόριθμος consensus
  - Ένας από τους πιο αποδοτικούς και κομψούς αλγορίθμους
  - Πασίγνωστος
- Τι γίνεται με το FLP (impossibility of consensus)?
  - Προφανώς δε λύνει το FLP
  - Βασίζεται σε ανιχνευτές σφαλμάτων για παράκαμψη

Η ιστορία

- Δημιουργήθηκε από τον Leslie Lamport
- Το abstract του paper
  - *“Recent archaeological discoveries on the island of Paxos reveal that the parliament functioned despite the peripatetic propensity of its part-time legislators. The legislators maintained consistent copies of the parliamentary record, despite their frequent forays from the chamber and the forgetfulness of their messengers. The Paxon parliament’s protocol provides a new way of implementing the state-machine approach to the design of distributed systems.”*

Η ιστορία

- Ο κόσμος αρχικά νόμιζε ότι πρόκειται για αστείο
- Ο Lamport δημοσίευσε τελικά το paper 8 χρόνια μετά τη συγγραφή του, το 1998 ("The Part-Time Parliament")
- Κανείς δεν το καταλάβαινε
- Ο Lamport έγραψε άλλο paper που εξηγεί το Paxos σε απλά Αγγλικά
  - Τίτλος: "Paxos Made Simple"
  - Abstract: "The Paxos algorithm, when presented in plain English, is very simple."
- Ακόμα κι έτσι, ο αλγόριθμος είναι δυσνόητος

Τελικά όμως…

- Πολλά πραγματικά συστήματα υλοποιούν το Paxos
  - Google Chubby
  - MS Bing cluster management
  - AWS
  - Cassandra
- Amazon CTO Werner Vogels (σε blog post “Job Openings in My Group”)
  - *“What kind of things am I looking for in you?”*
  - *“You know your distributed systems theory: You know about logical time, snapshots, stability, message ordering, but also acid and multi-level transactions. You have heard about the FLP impossibility argument. You know why failure detectors can solve it (but you do not have to remember which one diamond-w was). You have at least once tried to understand Paxos by reading the original paper.”*

Υποθέσεις

- Το δίκτυο είναι ασύγχρονο με καθυστερήσεις στα μηνύματα
- Το δίκτυο μπορεί να χάσει μηνύματα ή να τα στείλει περισσότερες από μια φορές αλλά δεν μπορεί να τα αλλοιώσει
- Οι διεργασίες μπορεί να κρασάρουν (και να σταματήσουν)
- Οι διεργασίες έχουν *permanent storage* (δίσκο)
- Οι διεργασίες μπορούν να προτείνουν τιμές
- Ο στόχος είναι όλες οι διεργασίες να συμφωνήσουν σε μία από τις προτεινόμενες τιμές

Επιθυμητές ιδιότητες

- Safety
  - Μπορεί να επιλεγεί μόνο τιμή που έχει προταθεί
  - Επιλέγεται μια μόνο τιμή
  - Μια διεργασία μαθαίνει μια τιμή μόνο αν έχει επιλεγεί
- Liveness
  - Κάποια προτεινόμενη τιμή επιλέγεται τελικά (eventually)
  - Αν επιλεγεί μια τιμή, κάθε διεργασία τελικά θα τη μάθει

Η οπτική του χρήστη

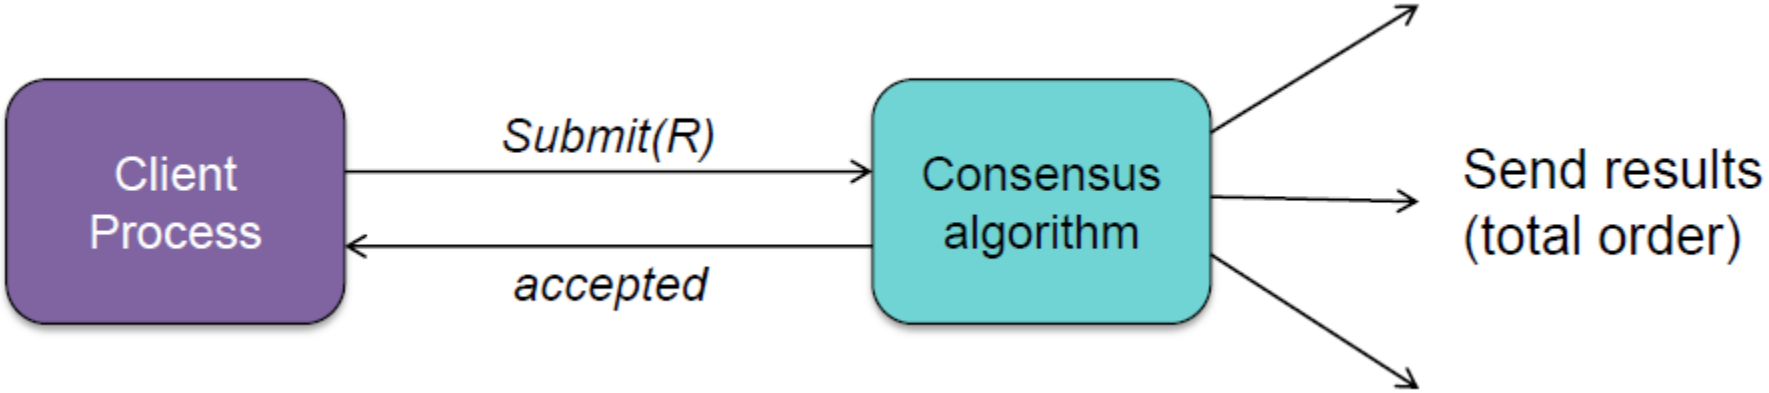

- while (submit_request(R) != ACCEPTED) ;
- Το R θα μπορούσε να είναι ένα key:value ζεύγος μιας βάσης

Οι παίκτες του Paxos

- **Client:**
  - Στέλνει ένα αίτημα
- **Proposers:**
  - Λαμβάνουν αίτημα από τον client και τρέχουν το πρωτόκολλο
  - Leader: Εκλεγμένος coordinator ανάμεσα στους proposers (δεν είναι απαραίτητος, απλώς απλοποιεί τη διάταξη μηνυμάτων και διασφαλίζει ότι δεν υπάρχει διαφωνία)
- **Acceptors:**
  - Πολλαπλές διεργασίες που θυμούνται το state του πρωτοκόλλου
  - Quorum = πλειονότητα από acceptors
- **Learners:**
  - Όταν οι acceptors συμφωνήσουν, ο learner εκτελεί το αίτημα ή/και στέλνει απάντηση στον client

Διαφορετικοί ρόλοι μπορεί να συνυπάρχουν στον ίδιο κόμβο

Τι κάνει το Paxos

- Κάθε πρόταση (αίτημα) έχει ένα ID.
  - (proposal #, value) == (N, V)
  - Ο αύξων αριθμός του proposal είναι καθολικά μοναδικός

- Τρεις φάσεις
  - Φάση prepare: ένας proposer learns previously-accepted proposals from the acceptors.
  - Φάση Propose: ένας proposer στέλνει proposal.
  - Φάση Learn: οι learners μαθαίνουν το αποτέλεσμα

Τι κάνει το Paxos

- Proposers
  - Πριν να προτείνει κάποιος proposer θα ρωτήσει τους acceptors αν έχει ήδη προταθεί κάποια άλλη τιμή
  - Αν ναι, ο proposer θα προτείνει την ίδια
  - Η συμπεριφορά είναι αλτρουιστική: Ο στόχος του κάθε proposer είναι η ομοφωνία, όχι να επιλεγεί η τιμή που προτείνει
- Acceptors
  - Ο στόχος είναι να επιλέξει το proposal με τον μεγαλύτερο αύξοντα αριθμό από όλους τους proposers
- Learners
  - Οι learners είναι παθητικοί και περιμένουν το αποτέλεσμα

1η φάση

- Ένας proposer επιλέγει τον αύξοντα αριθμό N του proposal του και στέλνει *prepare request* στους acceptors.
  - “Hey, have you accepted any proposal yet?”

- Ένας acceptor πρέπει να απαντήσει:
  - Αν έχει ήδη κάνει accept σε προτάσεις, την πρόταση με τον μεγαλύτερο αύξοντα αριθμό, μικρότερο του N
  - Μια υπόσχεση να μη δεχτεί πλέον κανένα proposal με αύξοντα αριθμό μικρότερο του N

2η φάση

- Αν ένας proposer λάβει απάντηση από την πλειοψηφία, τότε στέλνει *accept request* για το proposal (N, V).
  - V: Η τιμή του proposal με τον μεγαλύτερο αύξοντα αριθμό N (από αυτές που επεστράφησαν στην 1η φάση).
  - Αν δεν επεστράφη τίποτα στην φάση 1, η νέα προτεινόμενη τιμή

- Μετά τη λήψη του (N, V), οι acceptors είτε:
  - Το δέχονται
  - Το απορρίπτουν αν υπάρχει άλλο prepare request με N' μεγαλύτερο του N και έχει απαντήσει σε αυτό

3η φάση

- Οι learners πρέπει να μάθουν ποια τιμή επελέγη
- Ένας τρόπος: Κάθε acceptor απαντάει σε όλους τους learners
  - ακριβό
- Άλλος τρόπος: εκλογή “distinguished learner”
  - Οι Acceptors απαντούν σε αυτόν
  - Αυτός ενημερώνει τους υπόλοιπους
  - Επιρρεπές σε σφάλματα
- Μίξη των δύο: σύνολο από distinguished learners

Πρόβλημα

- *race condition για τα proposals.*
- Η P_0 ολοκληρώνει την φάση 1 με proposal number N_0
- Προτού η P_0 ξεκινήσει την φάση 2, η P_1 ξεκινά και ολοκληρώνει την φάση 1 με proposal number $N_1 > N_0$
- Η P_0 ολοκληρώνει την φάση 2, οι acceptors το απορρίπτουν
- Προτού η P_1 ξεκινήσει την φάση 2, η P_0 ξεκινά ξανά και ολοκληρώνει την φάση 1 με proposal number $N_2 > N_1$
- Η P_1 ολοκληρώνει την φάση 2, οι acceptors το απορρίπτουν
- …(συνεχίζεται επ’ άπειρον)

Λύση

- Λύση: εκλογή ενός διακεκριμένου proposer
- Αν ο proposer μπορεί να επικοινωνήσει επιτυχώς με την πλειονότητα των κόμβων, τότε το πρωτόκολλο εξασφαλίζει liveness.
  - δηλαδή, το Paxos έχει ανοχή σε $f < 1/2 * N$ σφάλματα

Paxos εν δράση

- Ένας proposer εκλέγεται ως leader και δέχεται όλα τα requests

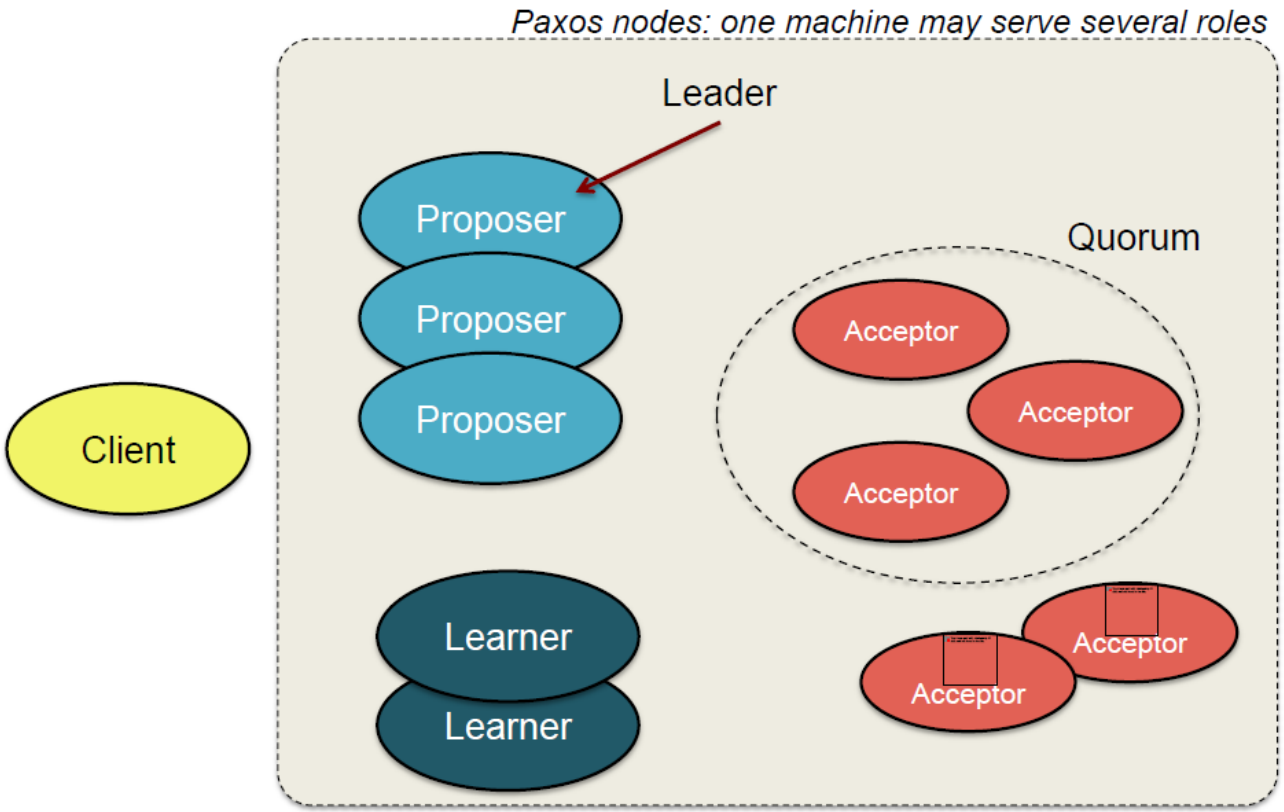

Phase 0

- Ο client στέλνει request στον proposer

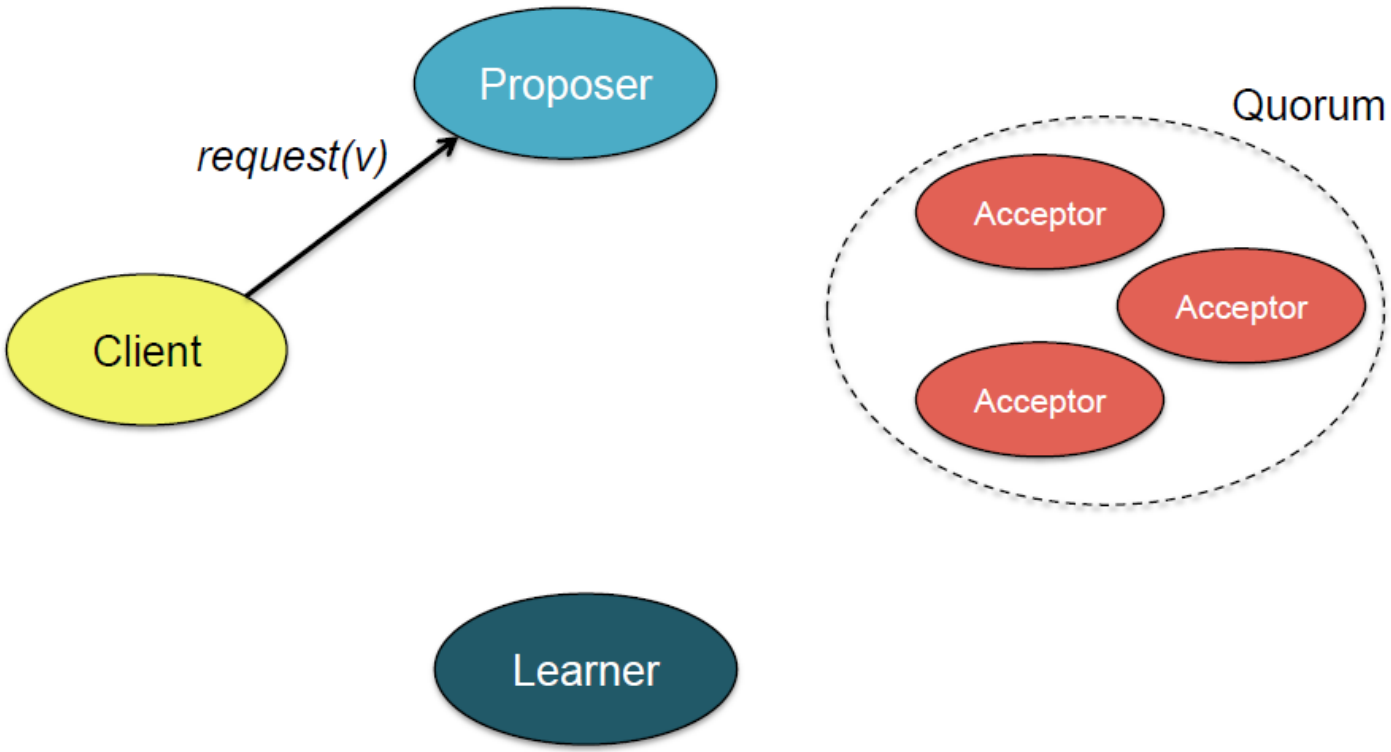

Phase 1a - PREPARE

- **Proposer: δημιουργεί ένα *proposal #N (N λειτουργεί σαν χρονοσφραγίδα Lamport),*** όπου το N είναι μεγαλύτερο από οποιοδήποτε προηγούμενο proposal number που χρησιμοποιήθηκε από τον proposer
- **Αποστολή σε quorum από Acceptors (όσους μπορεί να προσπελάσει – σίγουρα πλειονότητα)**

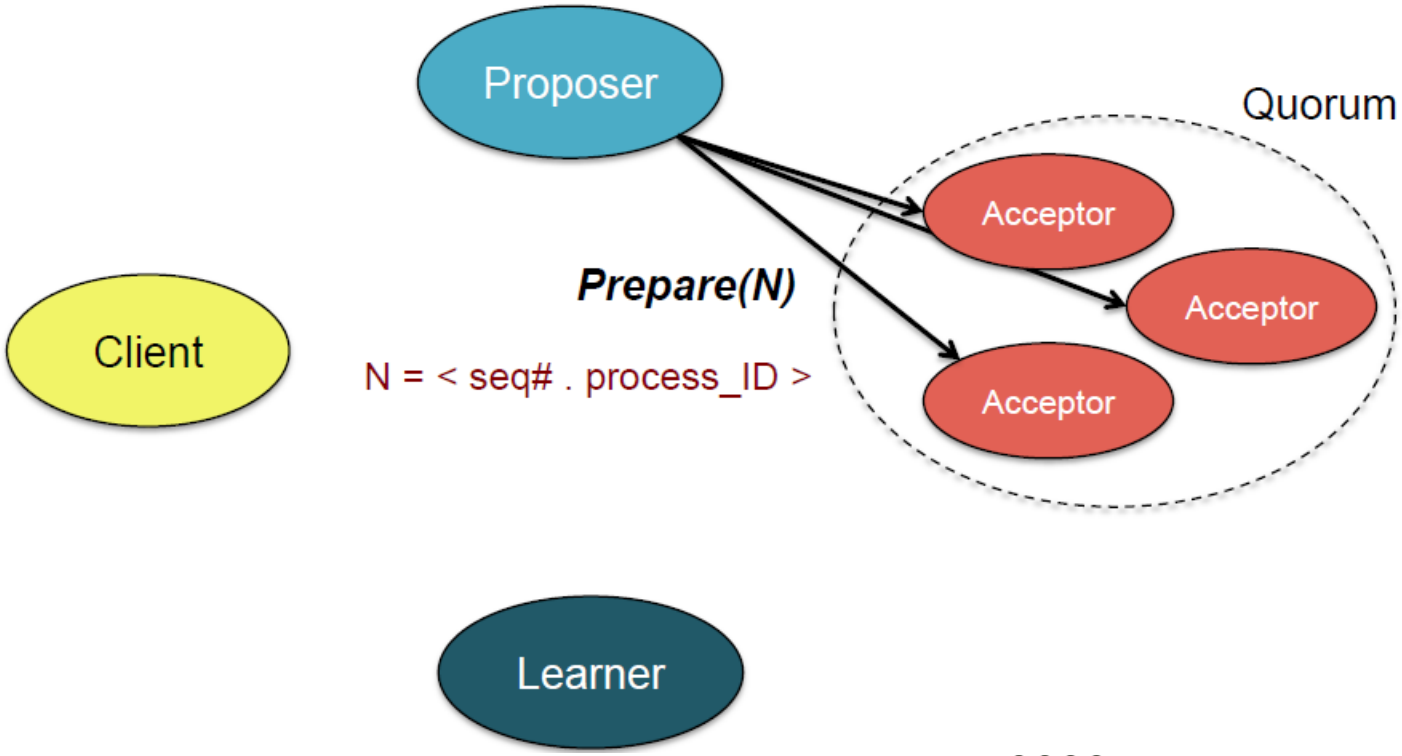

Phase 1a - PROMISE

- **Acceptor: αν το ID του proposal > οποιοδήποτε προηγούμενο proposal**
- Υπόσχεται να αγνοήσει όλα τα αιτήματα με ID < N και απαντάει με πληροφορίες για το πιο πρόσφατο proposal που έχει αποδεχτεί
- Αλλιώς το απορρίπτει

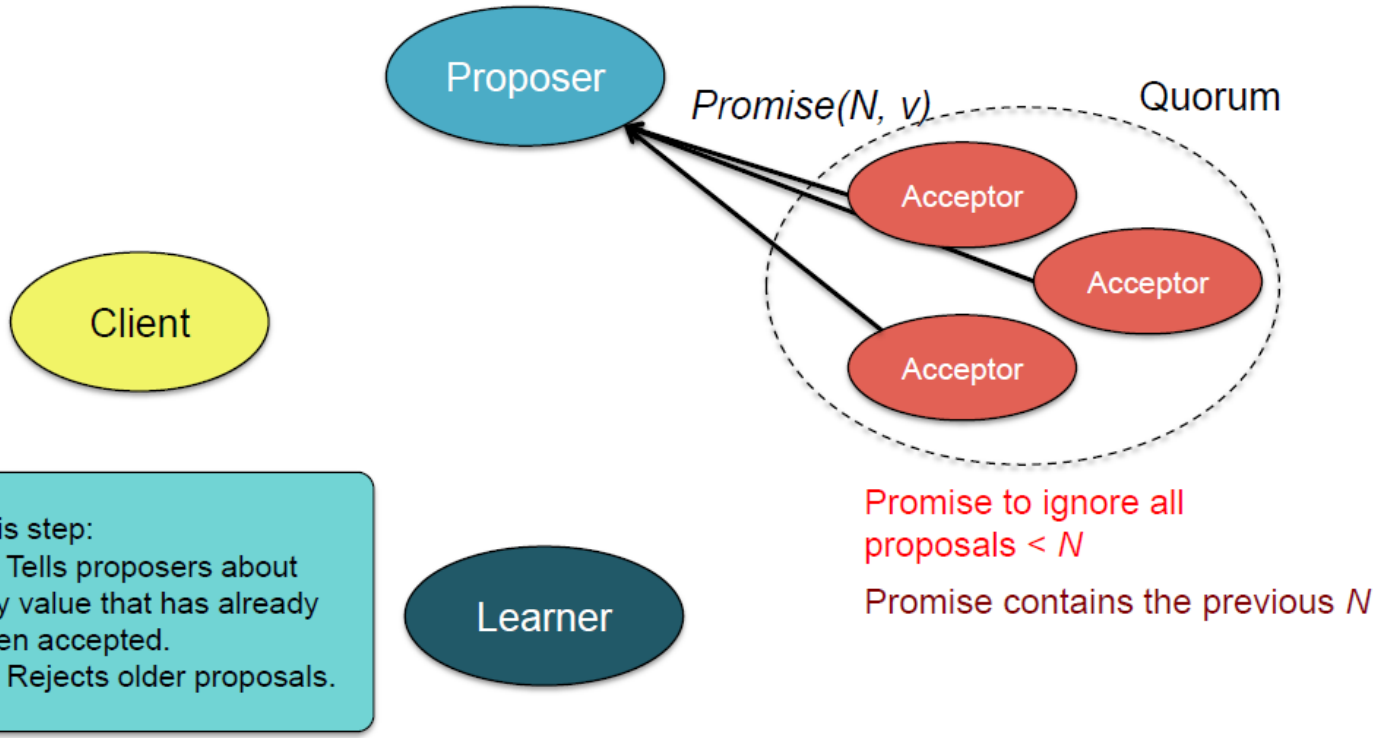

Phase 2a - ACCEPT

- **Proposer: αν ο proposer λάβει υπόσχεση από την πλειονότητα**
- Επισυνάπτει την τιμή *v στο proposal*
- Στέλνει ac***cept στο quorum με την επιλεγμένη τιμή***
- Αν η υπόσχεση ήταν για κάποιο άλλο {N, v}, ο proposer ΠΡΕΠΕΙ να το αποδεχτεί

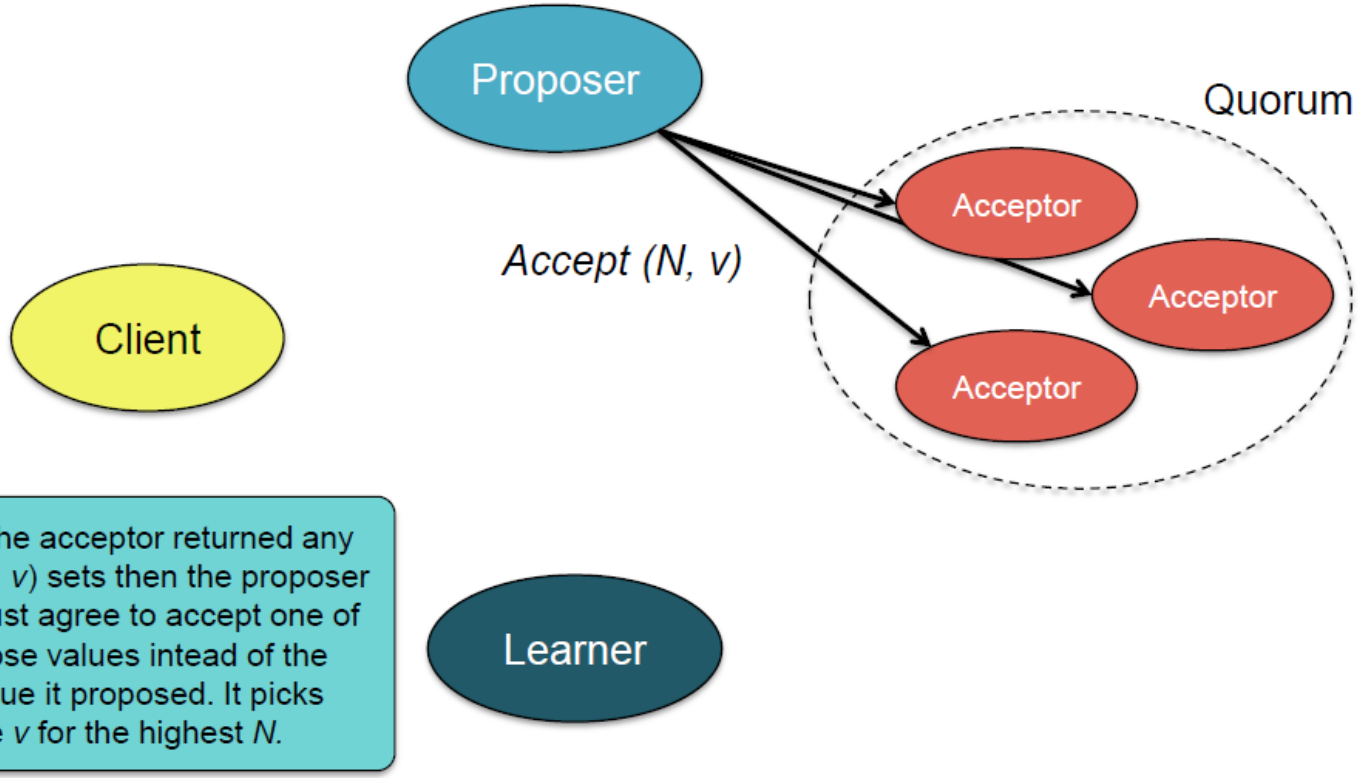

Phase 2b - ANNOUNCE

- **Acceptor: Αν η υπόσχεση ισχύει ακόμα, ανακοινώνει την τιμή *v***
- Στέλνει μήνυμα ***Accepted στον Proposer***
- Αλλιώς αγνοεί το μήνυμα (ή στέλνει *NACK)*

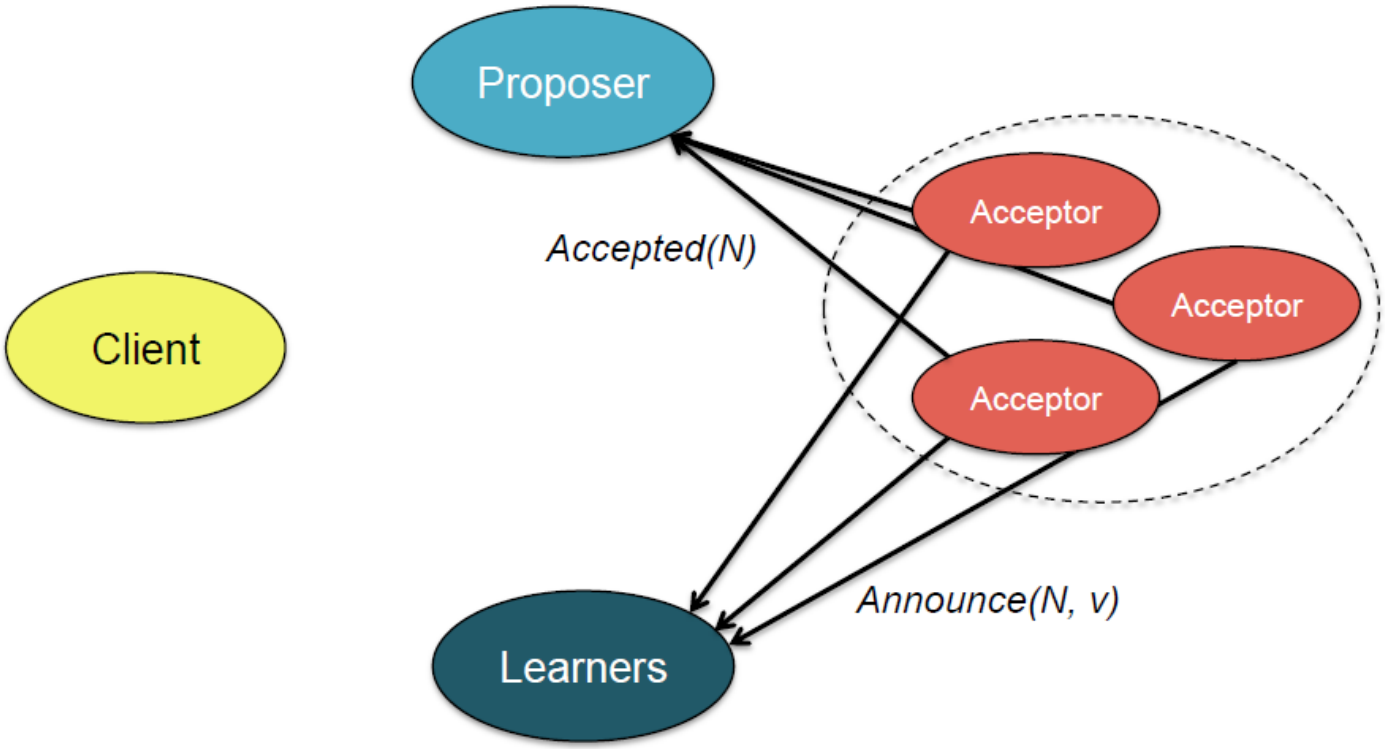

Phase 3

- **Learner: Απαντά στον client και κάνει τη δουλειά που πρέπει**

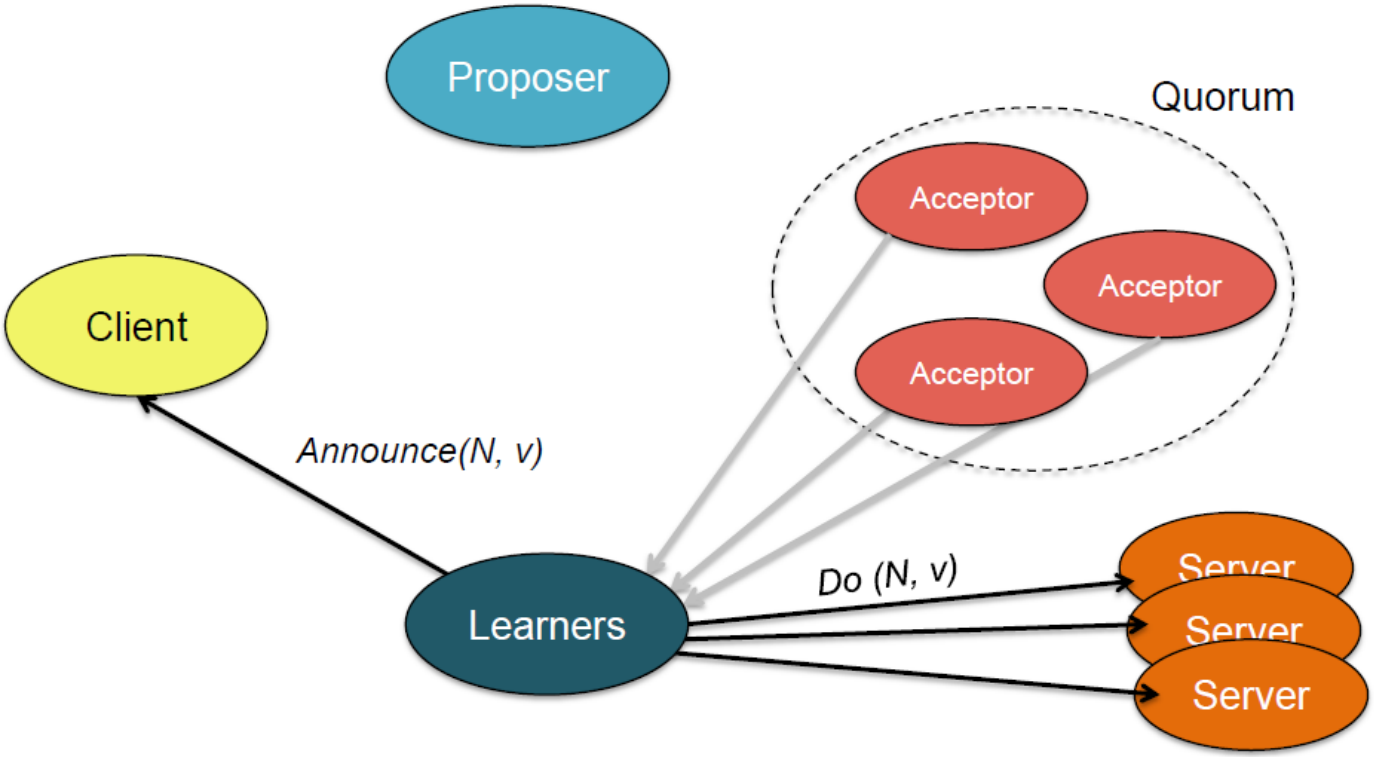

Παράδειγμα 1: phase 0

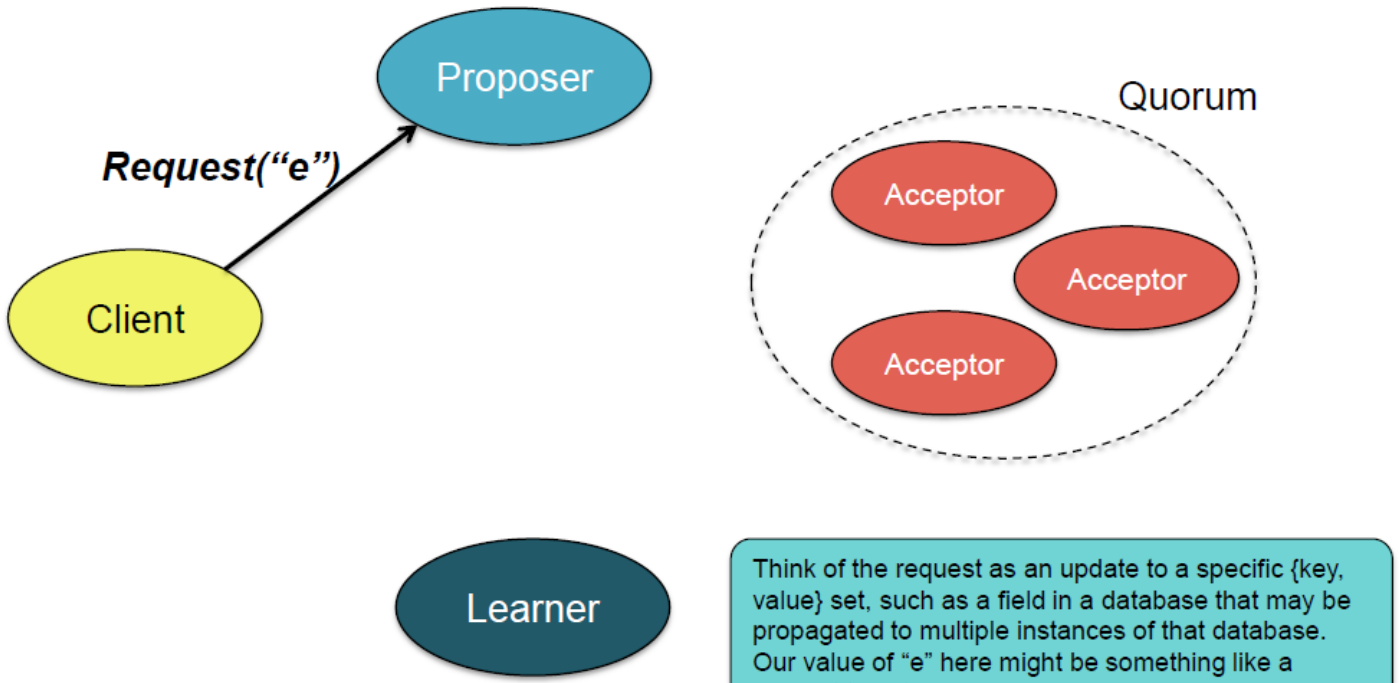

Phase 1a

- **Proposer:** διαλέγει id 5

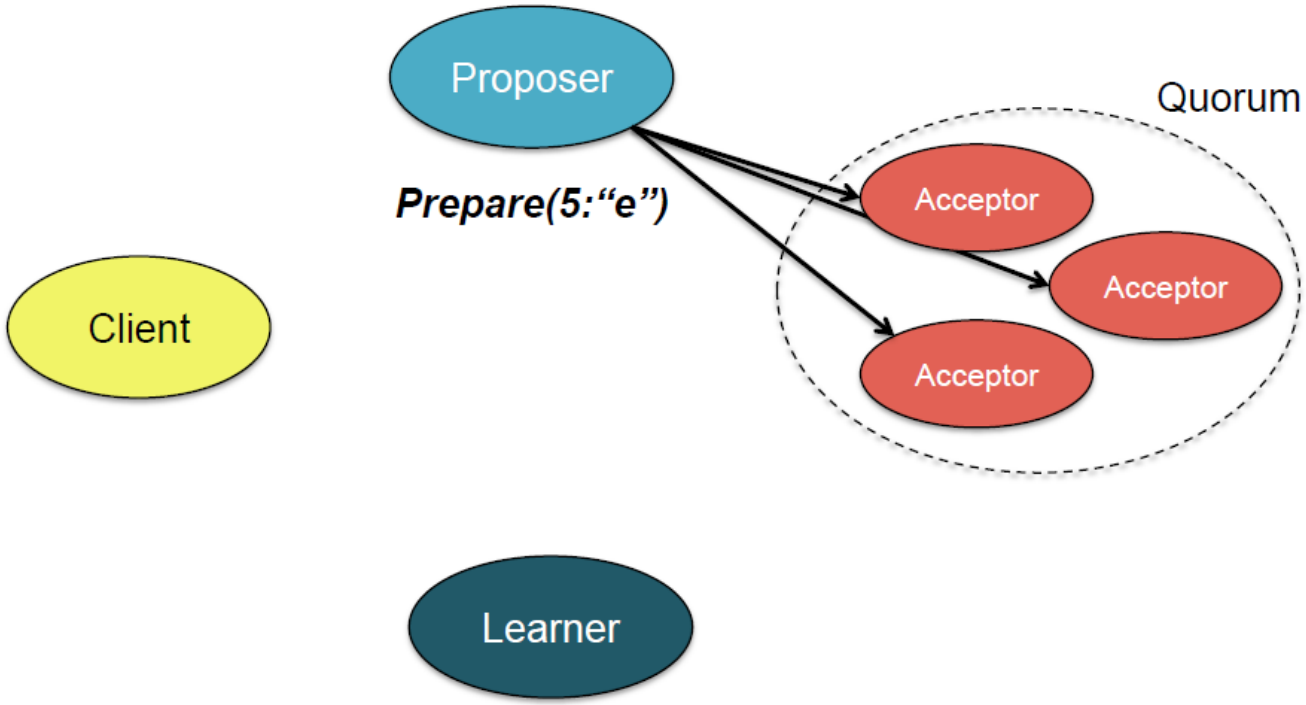

Phase 1b

- **Acceptor:** Αν το 5 είναι το μεγαλύτερο id που έχει δει, στέλνει υπόσχεση να μη δεχτεί μικρότερα ids

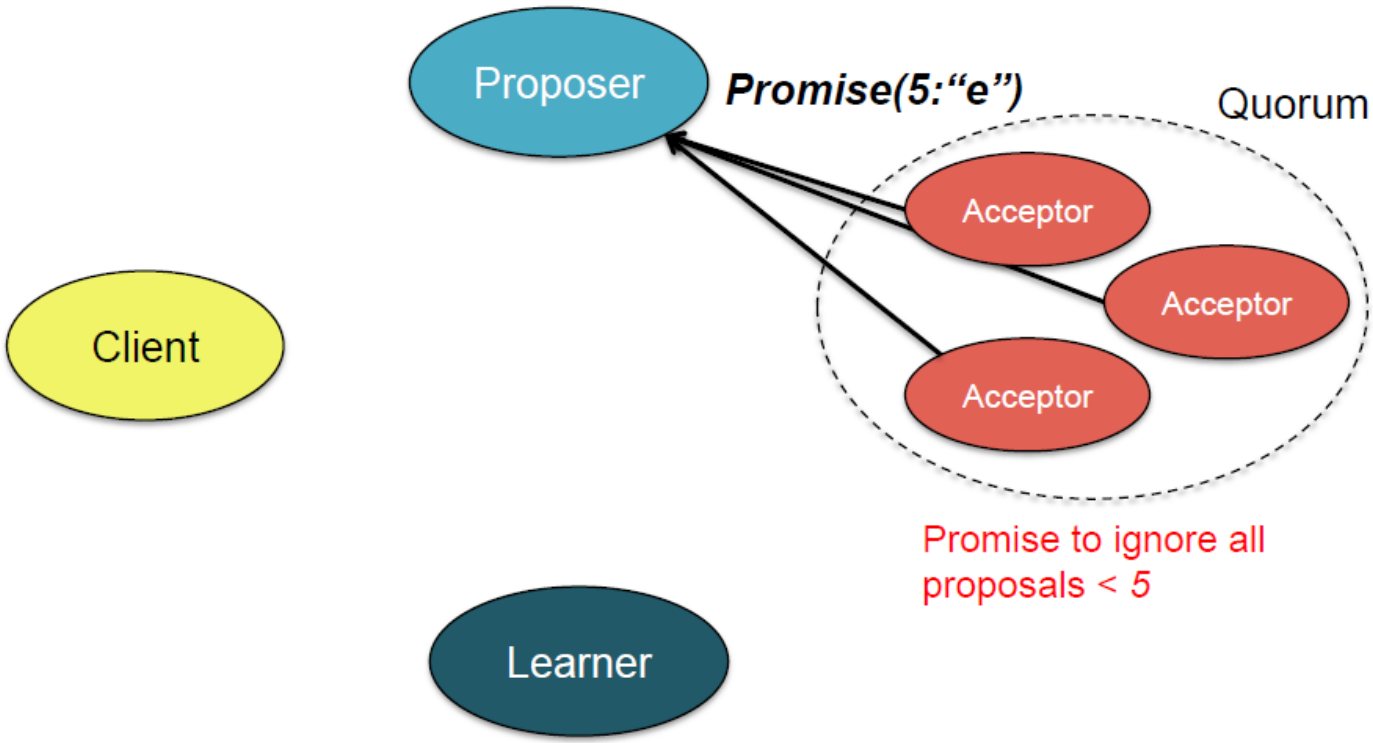

Phase 2a

- **Proposer:** λαμβάνει υπόσχεση από την πλειονότητα των acceptors
- Πρέπει να δεχτεί αυτό το <id, value>

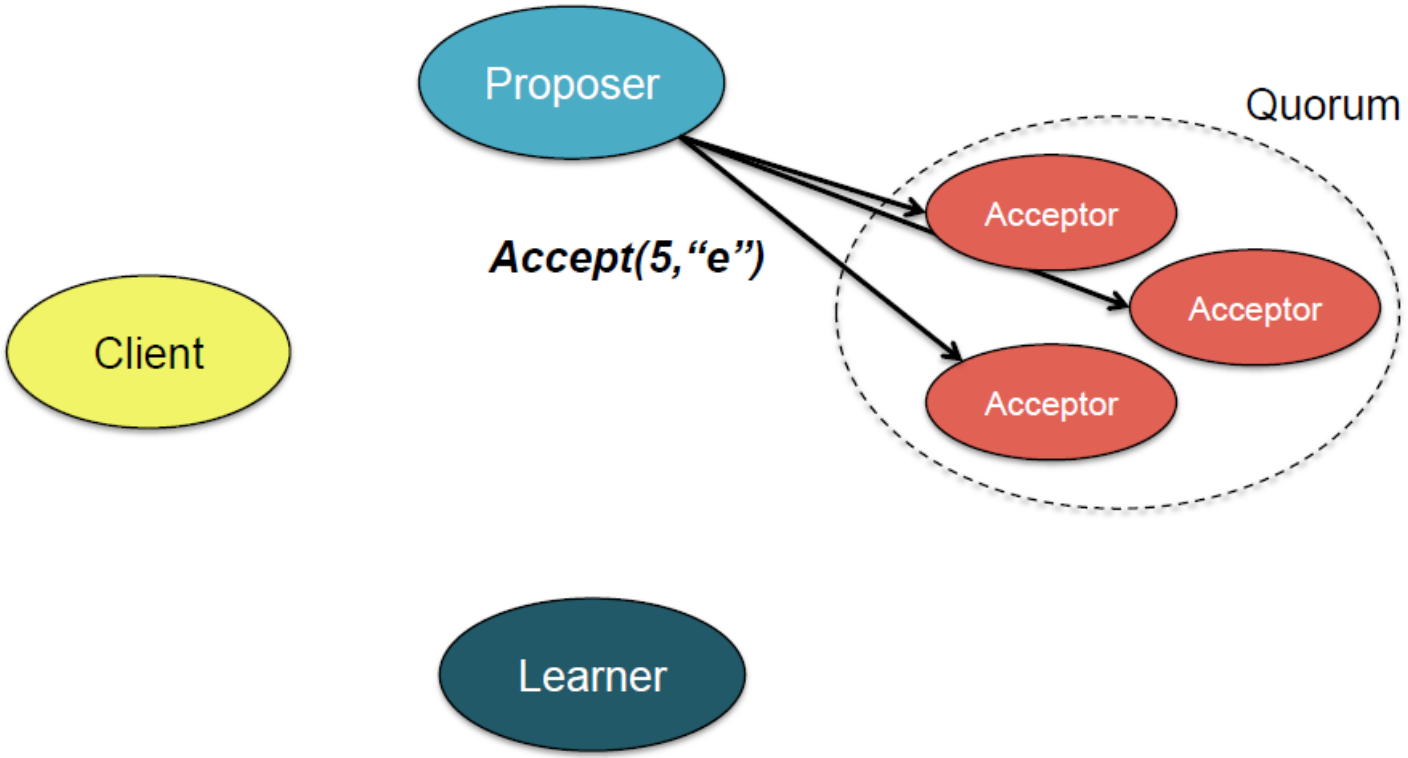

Phase 2b

- **Acceptor:** ανακοινώνουν απόφαση

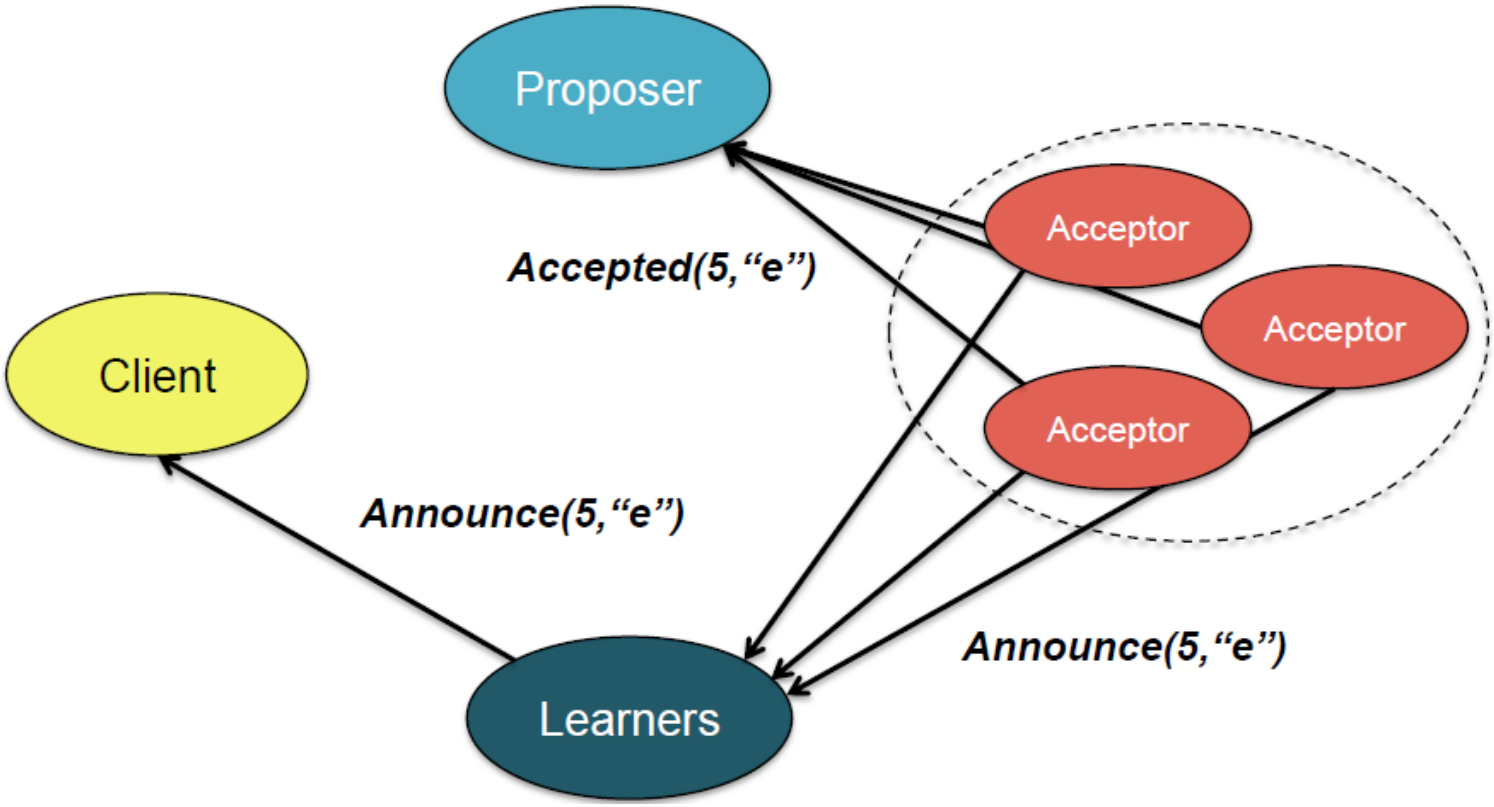

Παράδειγμα 2 – Phase 0

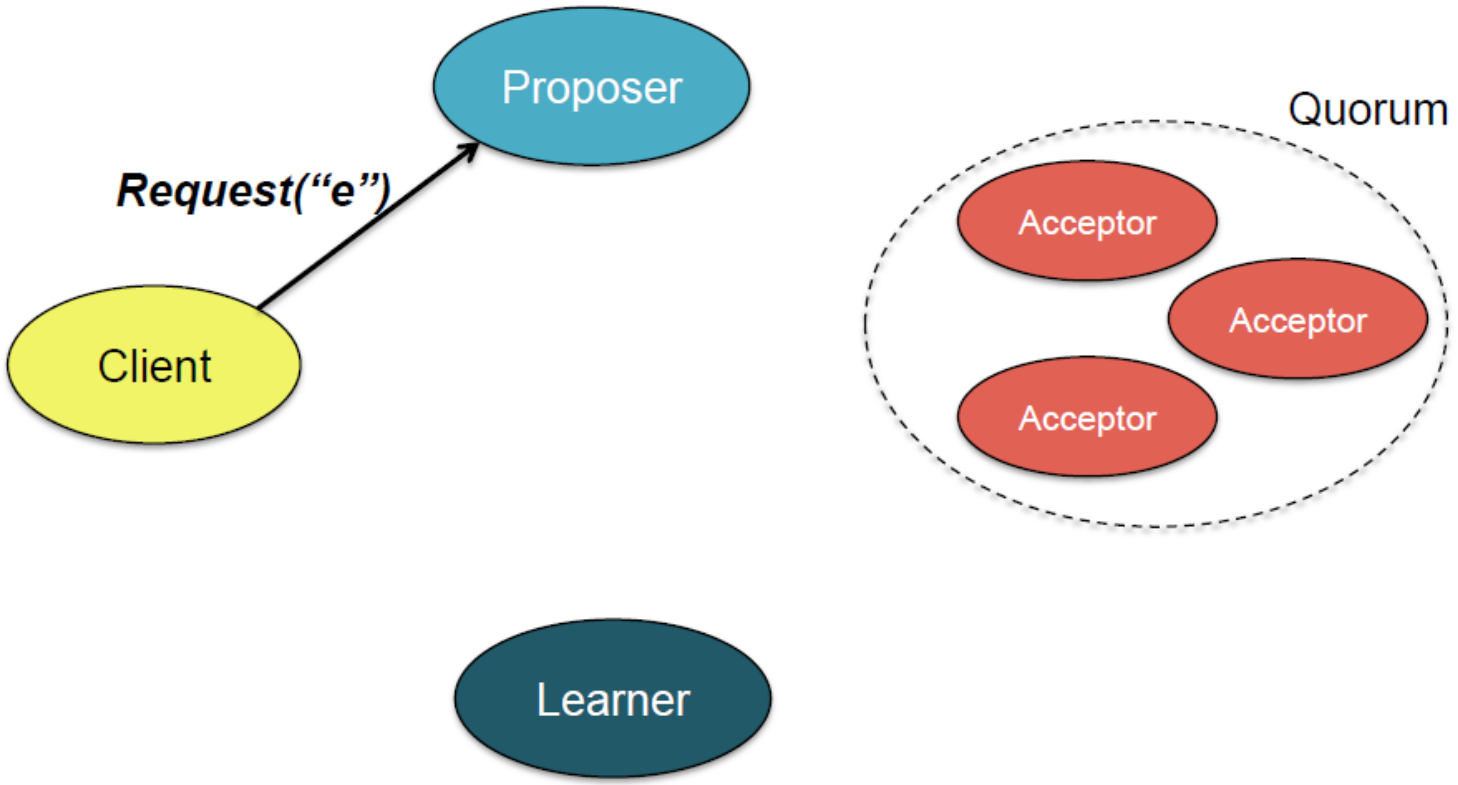

Phase 1a

- **Proposer:** Διαλέγει id 5

Ένας acceptor λαμβάνει proposal με μεγαλύτερο id ΠΡΙΝ από το συγκεκριμένο μήνυμα PREPARE

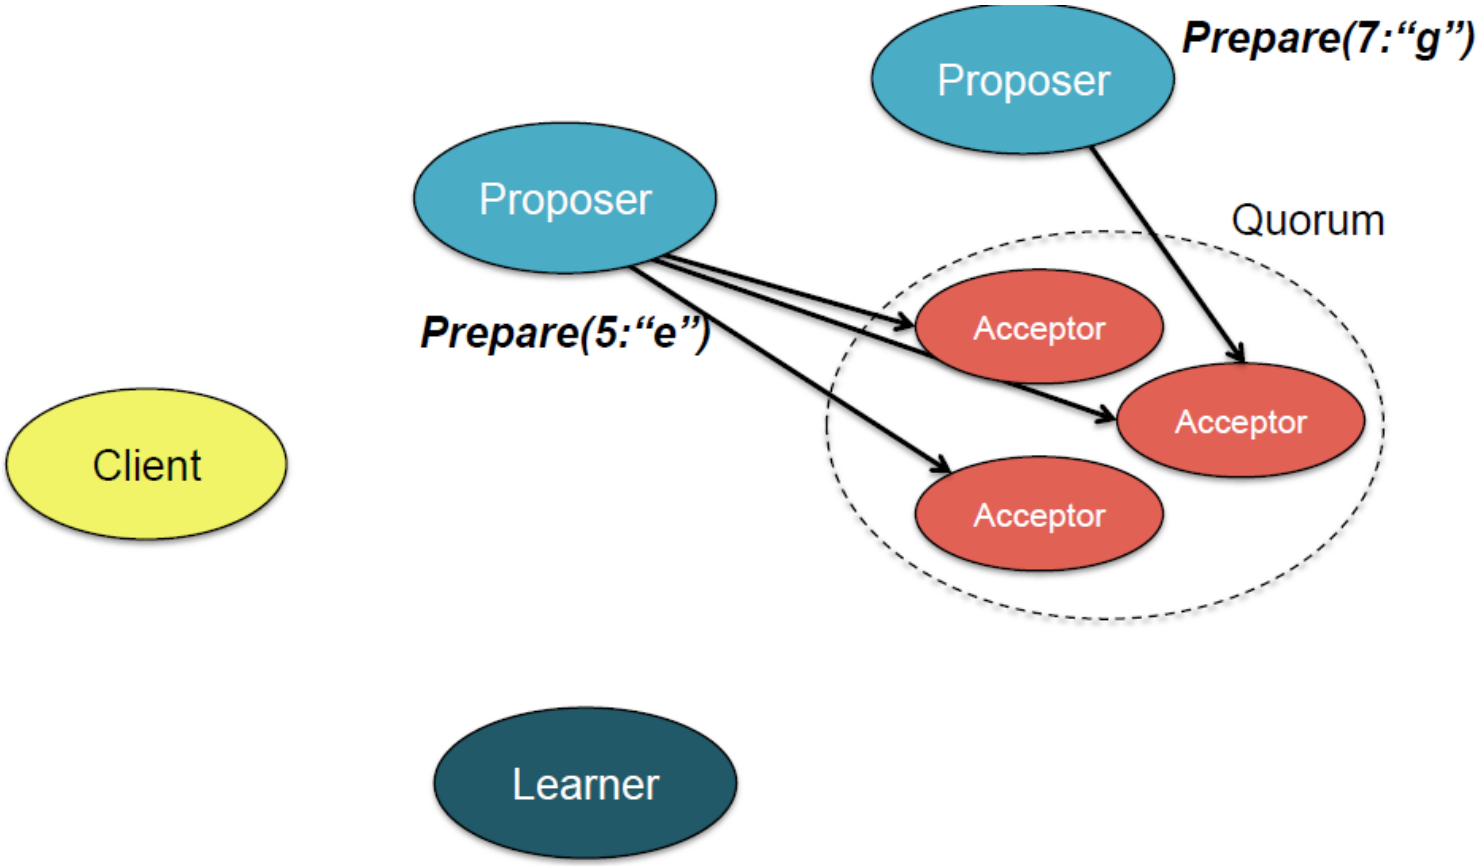

Phase 1b

- **Acceptor:** Καθένας στέλνει υπόσχεση για το μεγαλύτερο id που έχει λάβει

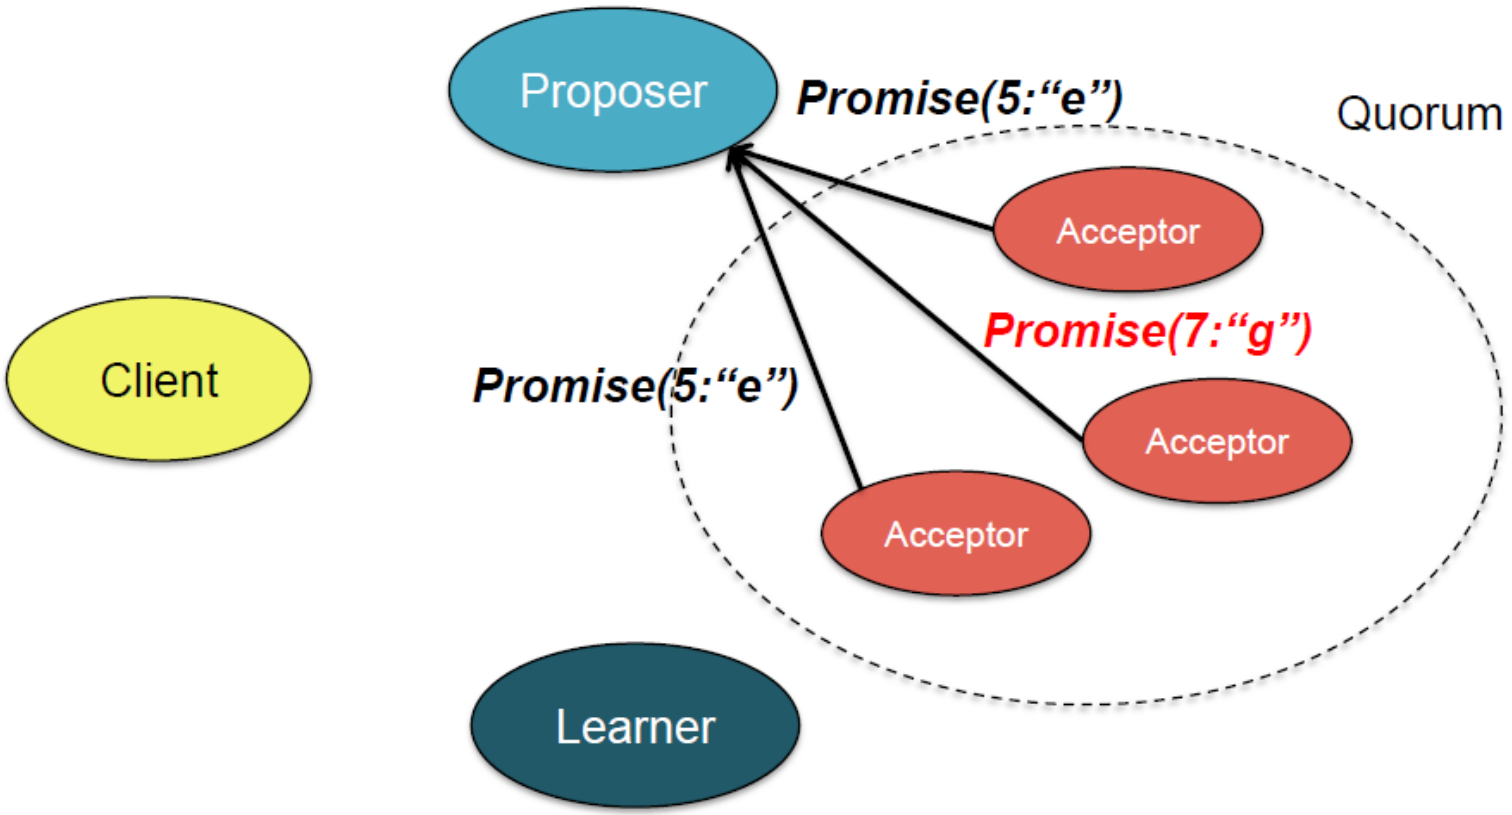

Phase 2a

- **Proposer:** Αν δεχτεί promise για μεγαλύτερο id ΠΡΕΠΕΙ να αλλάξει γνώμη και να αποδεχτεί την τιμή με το μεγαλύτερο id από οποιονδήποτε acceptor

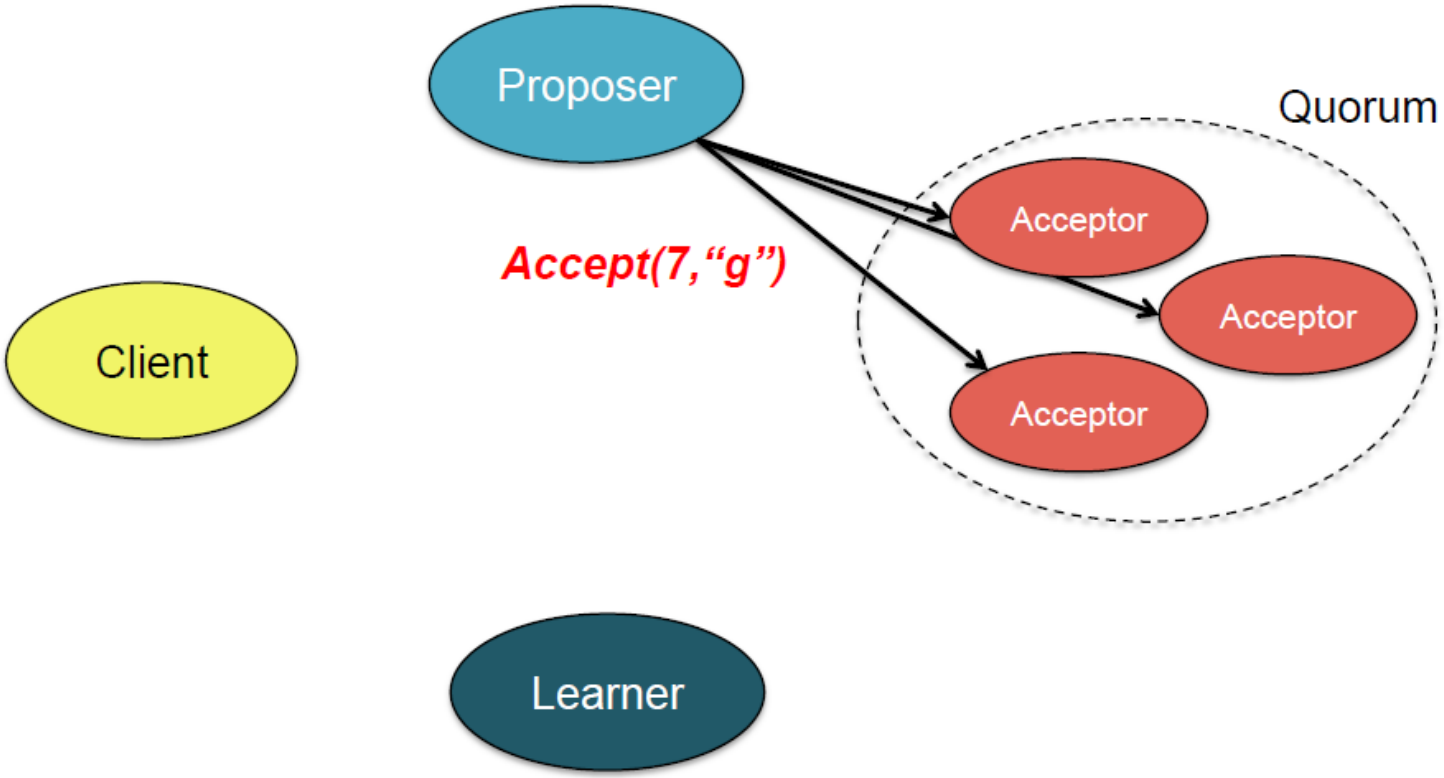

Phase 2b

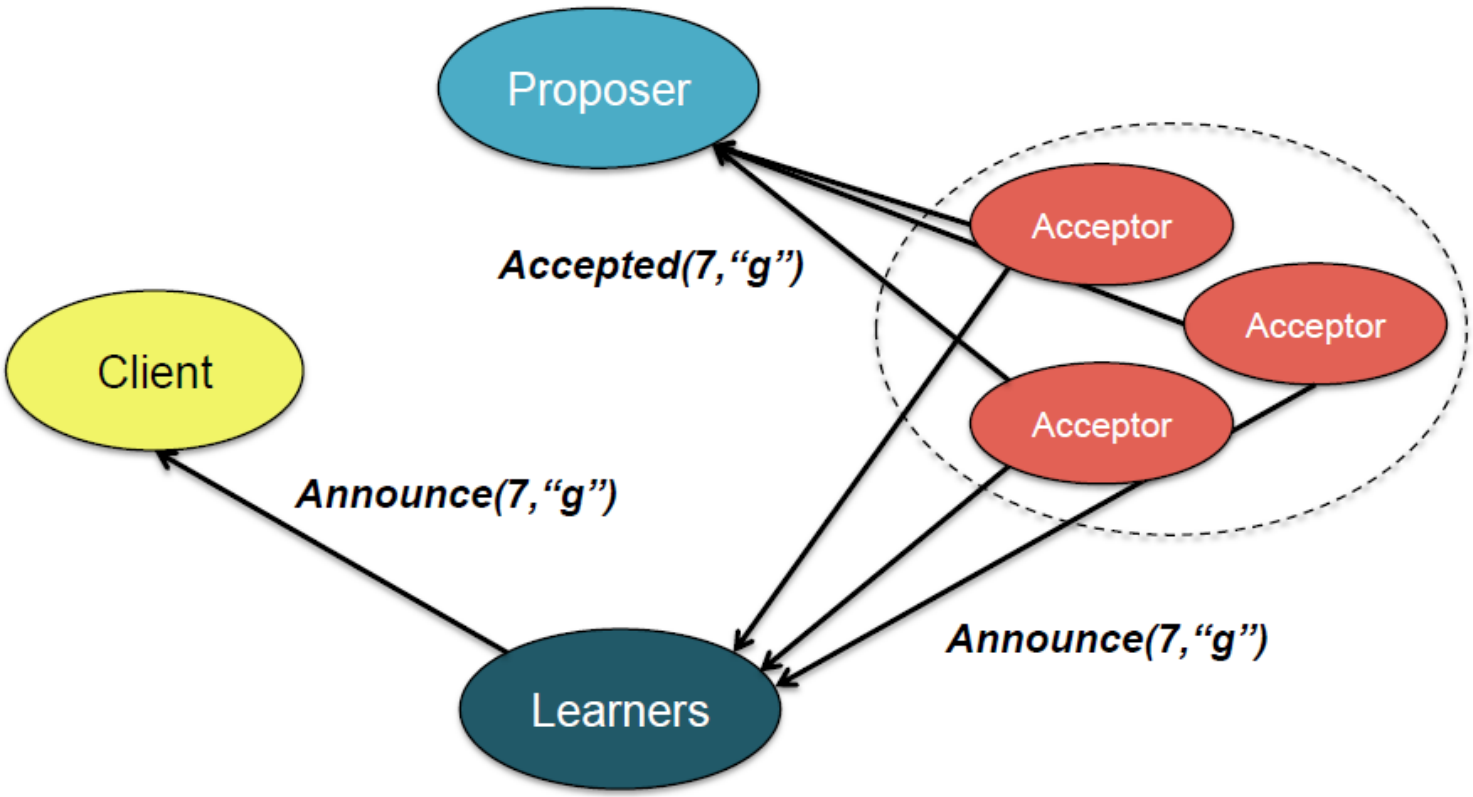
Proposer
Acceptor
Acceptor
Acceptor
Accepted(7,"g")
Client
Announce(7,"g")
Announce(7,"g")
Learners

Συνέχισε να προσπαθείς

- Ένα proposal N μπορεί να αποτύχει γιατί
  - Ένας acceptor μπορεί να έχει δώσει υπόσχεση να αγνοήσει όλα τα proposals με id μικρότερο κάποιου M >N
  - Ένας proposer δε λαμβάνει quorum από απαντήσεις είτε στη φάση 1b είτε στη φάση 2b
- Ο αλγόριθμος τότε πρέπει να ξαναξεκινήσει με μεγαλύτερο proposal id

Επιμύθιο

- Το Paxos μας επιτρέπει να διασφαλίσουμε συνεπή ολική διάταξη σε σύνολο από events
  - Events = εντολές, ενέργειες, ενημερώσεις κατάστασης
- Κάθε κόμβος θα έχει την τελευταία κατάσταση ή κάποια προηγούμενη εκδοχή της
- Χρησιμοποιείται σε:
  - Cassandra lightweight transactions
  - Google Chubby lock manager / name server
  - Google Spanner, Megastore
  - Microsoft Autopilot cluster management service from Bing
  - VMware NSX Controller
  - Amazon Web Services

Σύνοψη του Paxos

- Για να κάνεις αλλαγή στο σύστημα:
  - Λες στον *proposer το event που θες να προσθέσεις*
    - *Αυτά τα αιτήματα μπορεί να συμβούν ταυτόχρονα*
    - *Leader = εκλεγμένος proposer. Δεν είναι απαραίτητος για τη λειτουργία του Paxos, αλλά είναι βελτιστοποίηση για διασφάλιση μοναδικής πηγής από αύξοντες αριθμούς στα proposals*
  - Ο proposer επιλέγει το επόμενο event ID και ζητά από τους acceptors να το φυλάξουν
    - Αν οποιοσδήποτε acceptor έχει δει μεγαλύτερο event ID, απορρίπτει την πρόταση και επιστρέφει το event ID αυτό
    - Ο proposer προσπαθεί ξανά με μεγαλύτερο event ID
  - Όταν η πλειονότητα των **acceptors αποδεχτούν το proposal, τα event στέλνονται στους** learners για να αρχίσουν να ενεργούν (π.χ., να ενημερώσουν την κατάσταση του συστήματος)
    - Fault tolerant: χρειαζόμαστε *2k+1 servers για k fault tolerance*