ΕΛΛΗΝΙΚΗ ΔΗΜΟΚΡΑΤΙΑ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΡΗΤΗΣ

Δίκτυα Υπολογιστών

Μαρία Παπαδοπούλη

Τμήμα Επιστήμης Υπολογιστών
Πανεπιστήμιο Κρήτης

Χρηματοδότηση

- Το παρόν εκπαιδευτικό υλικό έχει αναπτυχθεί στα πλαίσια του εκπαιδευτικού έργου του διδάσκοντα.
- Το έργο «**Ανοικτά Ακαδημαϊκά Μαθήματα στο Πανεπιστήμιο Κρήτης**» έχει χρηματοδοτήσει μόνο τη αναδιαμόρφωση του εκπαιδευτικού υλικού.
- Το έργο υλοποιείται στο πλαίσιο του Επιχειρησιακού Προγράμματος «Εκπαίδευση και Δια Βίου Μάθηση» και συγχρηματοδοτείται από την Ευρωπαϊκή Ένωση (Ευρωπαϊκό Κοινωνικό Ταμείο) και από εθνικούς πόρους.

Σημείωμα αδειοδότησης

- Το παρόν υλικό διατίθεται με τους όρους της άδειας χρήσης Creative Commons Αναφορά, Μη Εμπορική Χρήση, Όχι Παράγωγο Έργο 4.0 [1] ή μεταγενέστερη, Διεθνής Έκδοση. Εξαιρούνται τα αυτοτελή έργα τρίτων π.χ. φωτογραφίες, διαγράμματα κ.λ.π., τα οποία εμπεριέχονται σε αυτό και τα οποία αναφέρονται μαζί με τους όρους χρήσης τους στο «Σημείωμα Χρήσης Έργων Τρίτων».

[1] http://creativecommons.org/licenses/by-nc-nd/4.0/

- Ως **Μη Εμπορική** ορίζεται η χρήση:
  - που δεν περιλαμβάνει άμεσο ή έμμεσο οικονομικό όφελος από την χρήση του έργου, για το διανομέα του έργου και αδειοδόχο
  - που δεν περιλαμβάνει οικονομική συναλλαγή ως προϋπόθεση για τη χρήση ή πρόσβαση στο έργο
  - που δεν προσπορίζει στο διανομέα του έργου και αδειοδόχο έμμεσο οικονομικό όφελος (π.χ. διαφημίσεις) από την προβολή του έργου σε διαδικτυακό τόπο

- Ο δικαιούχος μπορεί να παρέχει στον αδειοδόχο ξεχωριστή άδεια να χρησιμοποιεί το έργο για εμπορική χρήση, εφόσον αυτό του ζητηθεί.

.

Σκοποί ενότητας

- κατανόηση των θεμελιωδών αρχών του TCP:
  - Αξιόπιστη μεταφορά δεδομένων
  - Έλεγχος ροής
  - Έλεγχος συμφόρησης

Διαδικτυακά πρωτόκολλα επιπέδου μεταφοράς

- Αναξιόπιστη, χωρίς εγγύηση στη σειρά παράδοσης των πακέτων: UDP
  - Δε βελτιώνει τον “best-effort” χαρακτήρα του IP.
- Αξιόπιστη, με εγγύηση στη σειρά παράδοσης των πακέτων: TCP
  - **Έλεγχος συμφόρησης**
  - **Έλεγχος ροής**
  - Εγκαθίδρυση σύνδεσης
- ***Μη*** διαθέσιμες υπηρεσίες :
  - Εγγυήσεις καθυστέρησης
  - Εγγυήσεις bandwidth

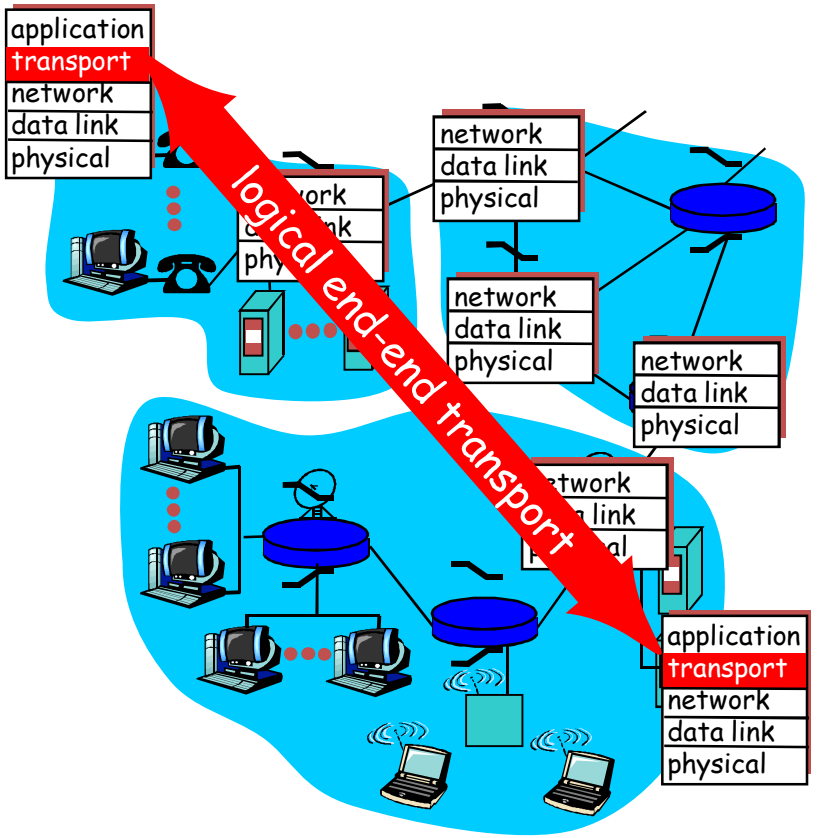

TCP

☞ Το TCP socket χαρακτηρίζεται από 4 πεδία:

- **source IP address**
- **source port number**
- **dest IP address**
- **dest port number**

☞ Ο παραλήπτης χρησιμοποιεί **και τα 4 πεδία για να προωθήσει το segment στο κατάλληλο socket**

- Ένας server host μπορεί να υποστηρίξει **πολλαπλά ταυτόχρονα** ("παράλληλα στον χρόνο") **TCP sockets**:
  - ☞ κάθε socket χαρακτηρίζεται από τη δική του 4-άδα
- Οι Web servers έχουν **διαφορετικά sockets για κάθε client** που συνδέεται
  - non-persistent HTTP έχουν διαφορετικά sockets για κάθε αίτημα

Συμφόρηση (congestion)

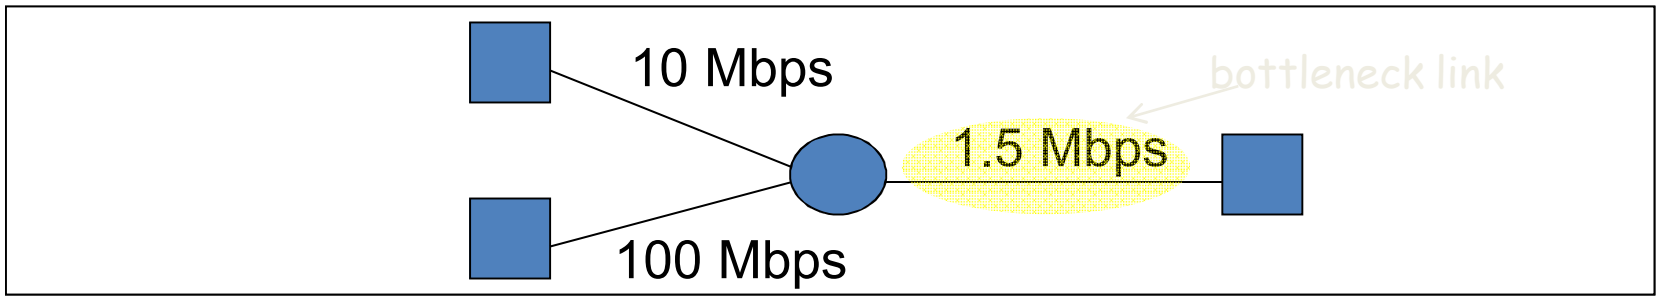

- Τα sources ανταγωνίζονται για τους πόρους του δικτύου, αλλά
  - δεν έχουν γνώση των πόρων του δικτύου (state of resource)
  - δεν ξέρουν την ύπαρξη η μία της άλλης
- Με αποτέλεσμα:
  - Πακέτα να χάνονται (λόγω buffer overflow στους δρομολογητές)
  - Μεγάλες καθυστερήσεις (αναμονή στις ουρές των buffers στους δρομολογητές)
  - throughput μικρότερο από το bottleneck link (1.5Mbps για την παραπάνω τοπολογία) → κατάρρευση λόγω συμφόρησης

Κατάρρευση λόγω συμφόρησης (Congestion Collapse)

- Ορισμός: Αύξηση στο φόρτο δικτύου οδηγεί σε μείωση της χρήσιμης δουλειάς που γίνεται
- Πολλές πιθανές αιτίες
  - Πλαστές επαναμεταδόσεις πακέτων βρίσκονται ακόμα σε εξέλιξη
    - Κλασική κατάρρευση λόγω συμφόρησης
    - Πώς μπορεί να συμβεί αυτό με τη διατήρηση των πακέτων
    - Λύση: καλύτεροι timers και TCP έλεγχος συμφόρησης
  - Μη παραδοθέντα πακέτα
    - Τα πακέτα καταναλώνουν πόρους και γίνονται drop κάπου αλλού στο δίκτυο
    - Λύση: έλεγχος συμφόρησης για ΌΛΗ την κίνηση

TCP: Επισκόπηση

RFCs: 793, 1122, 1323, 2018, 2581

- σημείο-προς-σημείο:
  - Ένας αποστολέας, ένας παραλήπτης

  (σε αντίθεση με το multicasting)
- αξιόπιστο, **σε σειρά** ροή των *byte:*
  - Η εφαρμογή από επάνω θα "παραλάβει" τα πακέτα στη σωστή σειρά
- pipelined:
  - Ο TCP έλεγχος συμφόρησης & ροής θέτουν το μέγεθος παραθύρου
  - Πολλά πακέτα μπορούν να έχουν σταλθεί παράλληλα και να μην έχουν γίνει ACKed
- *Buffers αποστολής & παραλαβής*

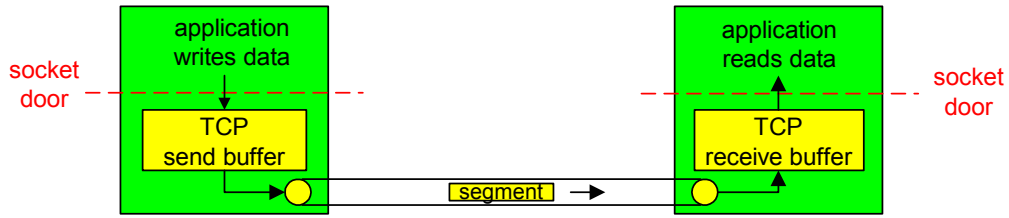

- Πλήρως αμφίδρομα δεδομένα:
  - Ροή δεδομένων και προς τις δύο κατευθύνσεις στην ίδια σύνδεση
  - MSS: maximum segment size

  (μέγιστο μέγεθος του segment)
- συνδεσιστρεφές:
  - χειραψία (ανταλλαγή μηνυμάτων ελέγχου) αρχικοποιούν την κατάσταση του αποστολέα και του παραλήπτη πριν την ανταλλαγή δεδομένων
- Ελεγχόμενη ροή:
  - Ο αποστολέας **δεν θα «κατακλύσει»** τον παραλήπτη

Δομή TCP segment

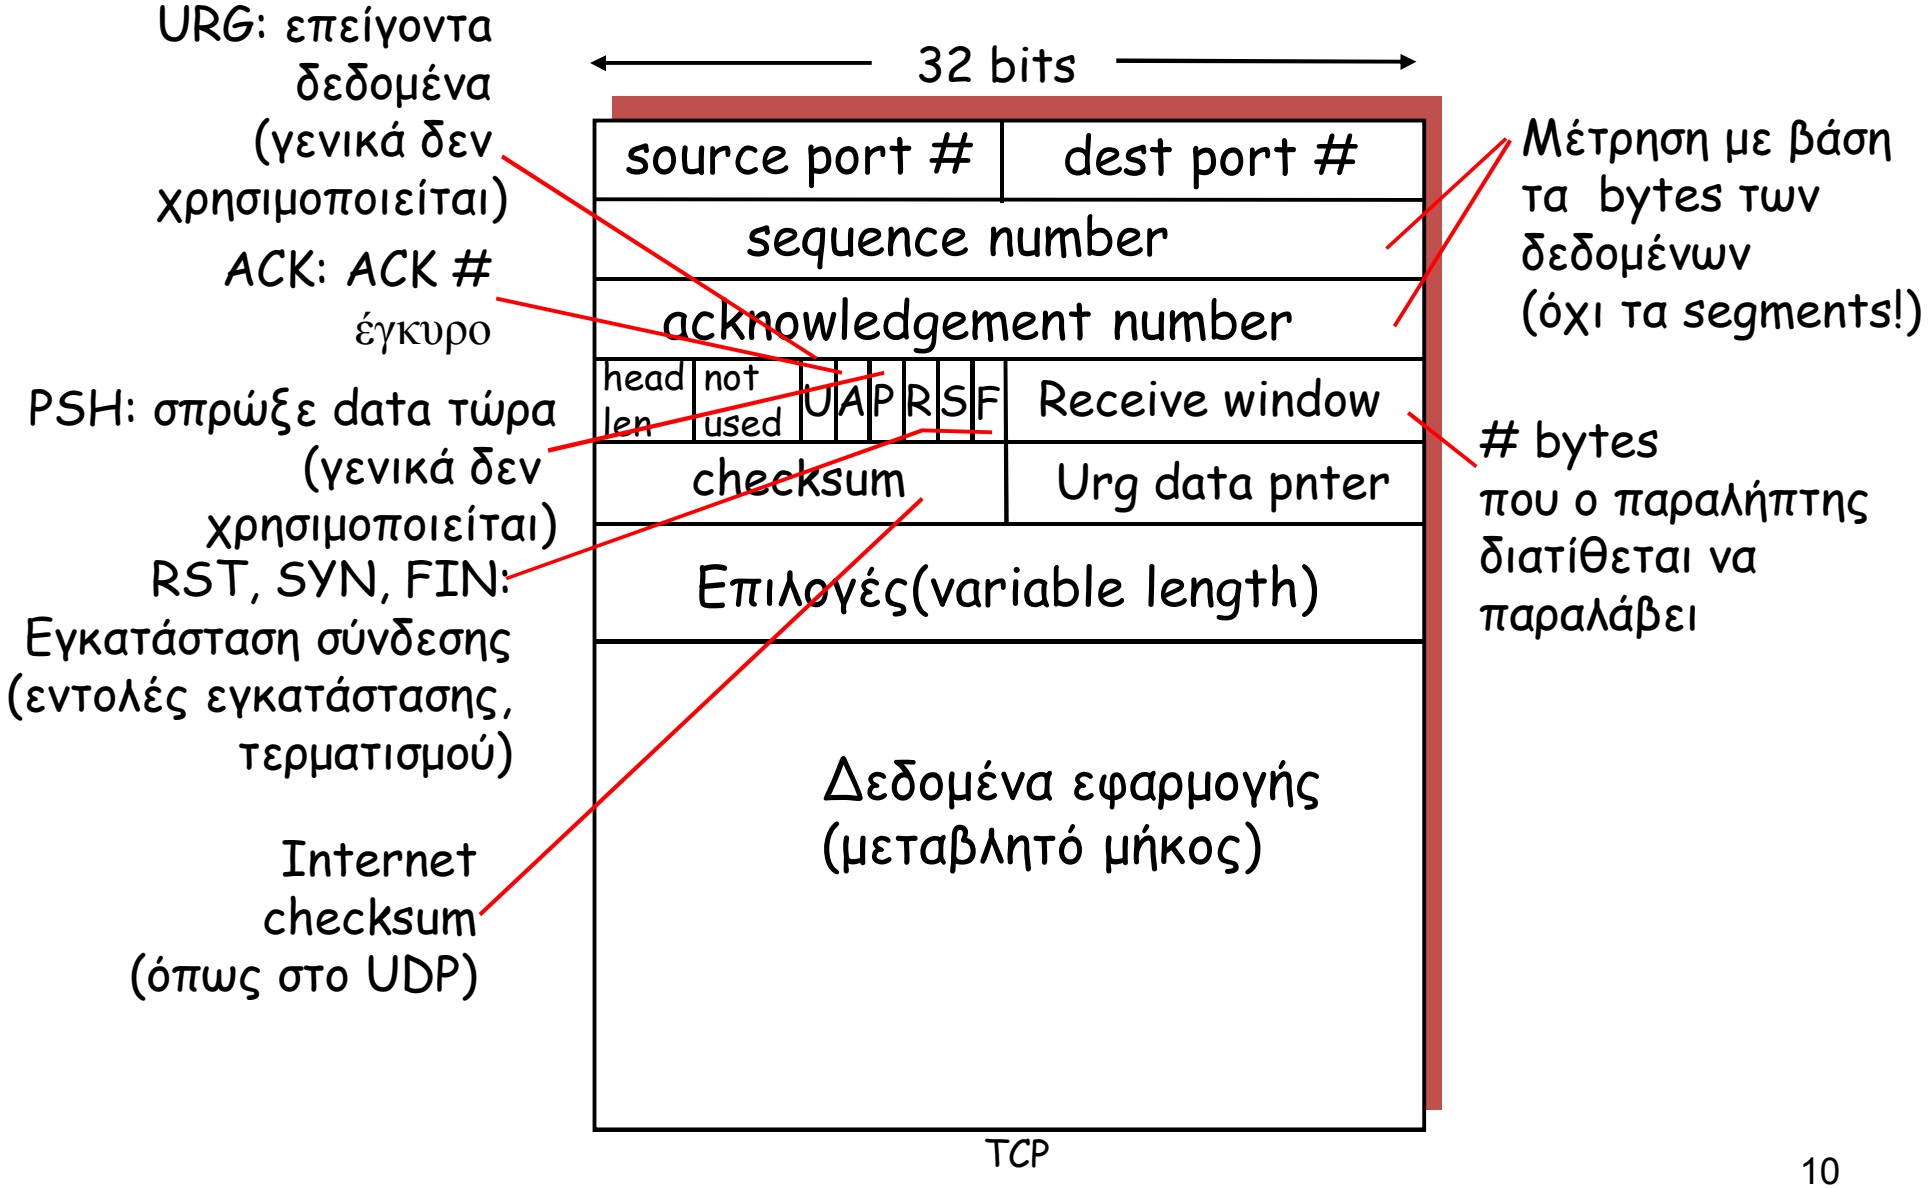

Sequence Number Space

- ☞κάθε byte στη ροή των bytes είναι αριθμημένο
  - 32 bit τιμή
  - Κάνει wrap around
  - Η αρχική τιμή επιλέγεται τη στιγμή εκκίνησης
- Το TCP διασπάει τη ροή δεδομένων σε πακέτα
  - Το μέγεθος πακέτου περιορίζεται από το μέγιστο μέγεθος segment (MSS)
- Κάθε πακέτο έχει ένα **sequence number (αριθμό σειράς)**
  - **Προσδιορίζει που βρίσκεται στη ροή δεδομένων**

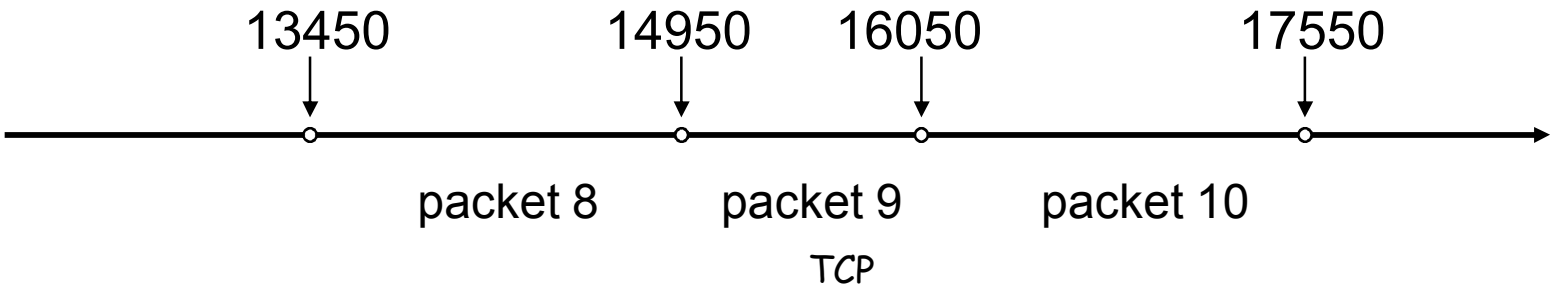

TCP σύνδεση: χειραψία σε 3 βήματα

Βήμα 1: ο client host στέλνει τοTCP SYN segment στον server

- Προσδιορίζει τον αρχικό αριθμό σειράς (seq #)
- **καθόλου δεδομένα**

Βήμα 2: ο server host λαμβάνει το SYN, απαντάει με SYNACK segment

- **Ο server δεσμεύει buffers**
- Προσδιορίζει τον αρχικό αριθμό σειράς

Βήμα 3: ο client λαμβάνει SYNACK, απαντάει με ACK segment, **που μπορεί να περιέχει και δεδομένα**

Εγκαθίδρυση σύνδεσης: χειραψία σε 3 βήματα

- Κάθε πλευρά ειδοποιεί την άλλη για τον αρχικό αριθμό σειράς (seq #) που θα χρησιμοποιήσει για την αποστολή
  - Γιατί να μην επιλέξουμε απλά το 0;
    - Πρέπει να αποφύγει την επικάλυψη με προηγούμενο πακέτο
    - Θέματα ασφάλειας
- Κάθε πλευρά επιβεβαιώνει τον αριθμό σειράς της άλλης
  - SYN-ACK: αριθμός σειράς επιβεβαίωσης + 1
- Μπορεί να συνδυάσει το δεύτερο SYN με το πρώτοACK

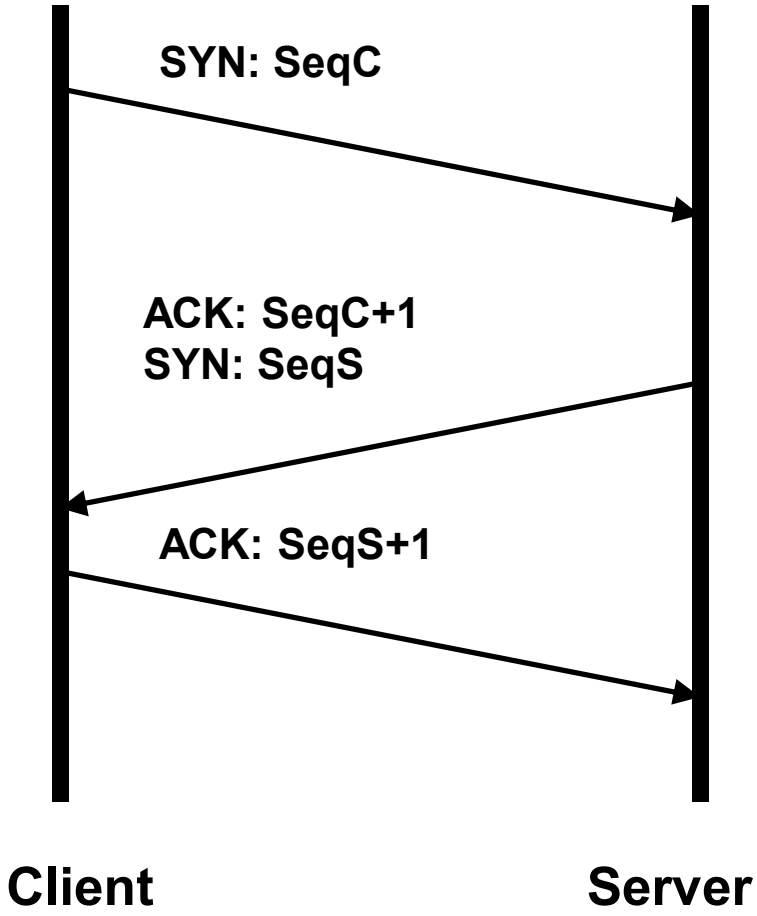

Διαχείριση TCP σύνδεσης

Υπενθύμιση:

Οι TCP sender, receiver εγκαθιδρύουν σύνδεση πριν ανταλλάξουν segments δεδομένων

- αρχικοποίηση μεταβλητών τουTCP :
  - seq. #s
  - **buffers, πληροφορίες ελέγχου ροής** (e.g. **`RcvWindow`**)

- *client:* ξεκινάει τη σύνδεση

```
Socket clientSocket = new
 Socket("hostname","port number");
```

- *server:* αποδέχεται επικοινωνία από τον client

```
Socket connectionSocket =
 welcomeSocket.accept();
```

Βήμα 1: ο client host στέλνει τοTCP SYN segment στον server

- Προσδιορίζει τον αρχικό αριθμό σειράς (seq #)
- **καθόλου δεδομένα**

Βήμα 2: ο server host λαμβάνει το SYN, απαντάει με SYNACK segment

- **Ο server δεσμέυει buffers**
- Προσδιορίζει τον αρχικό αριθμό σειράς

Βήμα 3: ο client λαμβάνει SYNACK, απαντάει με ACK segment, **που μπορεί να περιέχει και δεδομένα**

Διαχείριση TCP σύνδεσης(συνέχεια)

Κλείσιμο μίας σύνδεσης:

Ο client κλείνει το socket:

```
clientSocket.close();
```

Βήμα 1: το τερματικό σύστημα του client στέλνει TCP FIN segment ελέγχου στον server

Βήμα 2: ο server λαμβάνει το FIN, απαντάει με ACK. Κλείνει την σύνδεση, **στέλνει FIN**

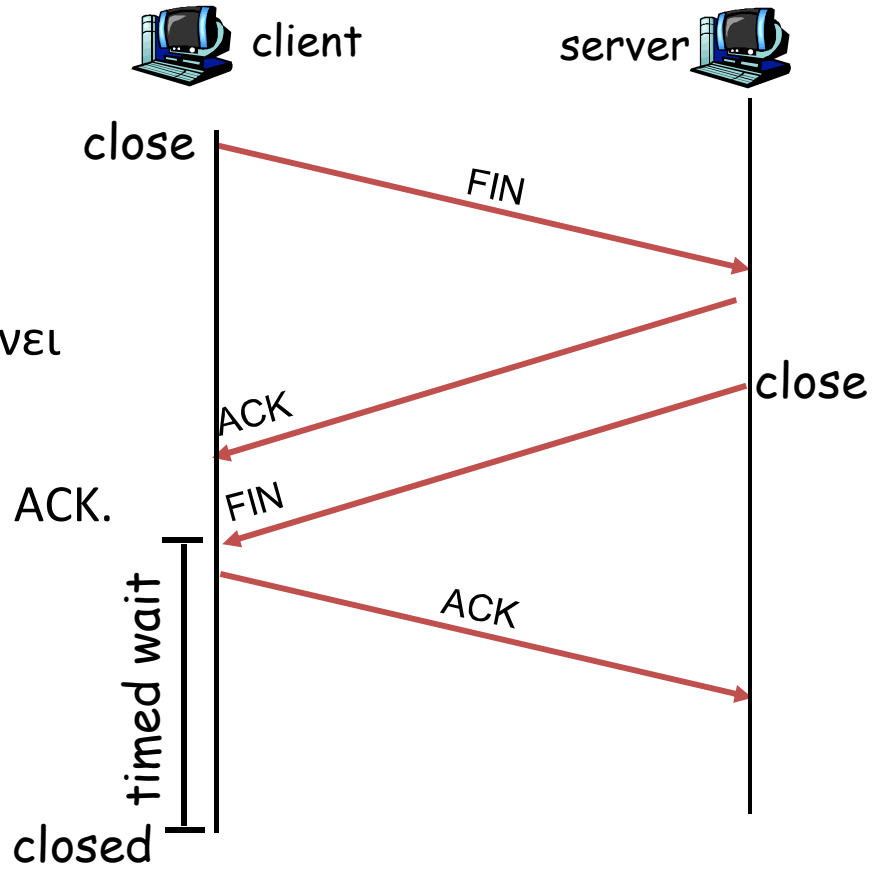

Διαχείριση TCP σύνδεσης(συνέχεια)

Βήμα 3: ο client λαμβάνει το FIN, απαντάει με ACK

- Μπαίνει σε χρονισμένη αναμονή - θα απαντήσει με ACK στα FINs που λαμβάνει

Βήμα 4: ο server, λαμβάνει το ACK. Η σύνδεση έκλεισε.

Σημείωση: με μικρές μετατροπές, μπορεί να γίνει διαχείριση ταυτόχρονων FINs.

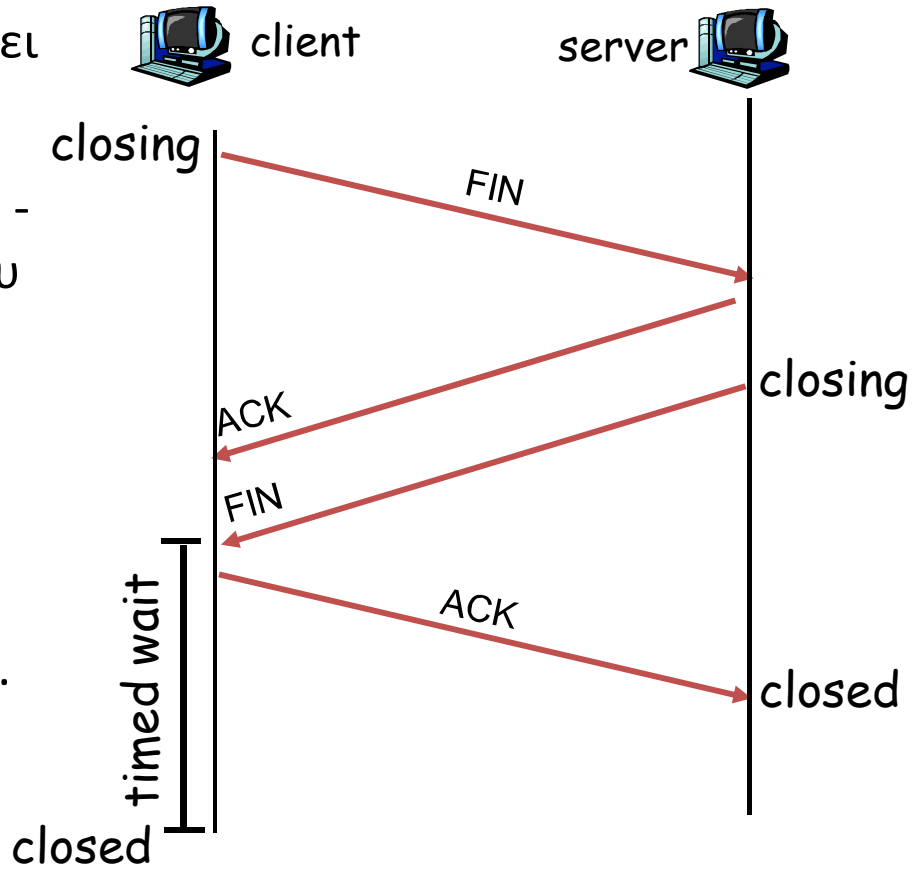

Κλείσιμο σύνδεσης

- Οποιαδήποτε πλευρά μπορεί να ξεκινήσει το κλείσιμο της σύνδεσης
  - Στέλνει FIN σήμα
  - "Δε θα στείλω άλλα δεδομένα"
- Η άλλη πλευρά μπορεί να συνεχίσει να στέλνει δεδομένα
  - «Ημι-ανοιχτή» σύνδεση
  - Πρέπει να συνεχίσει να επιβεβαιώνει
- Επιβεβαίωση του FIN
  - Επιβεβαίωση με sequence number + 1

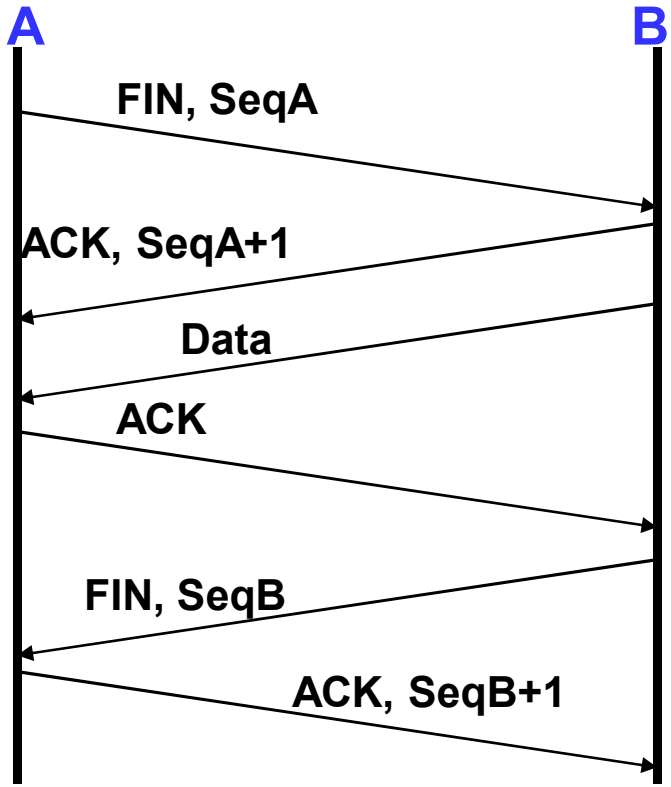

Υπολογισμός του Round-trip time & του timeout

- Μηχανισμός που καθορίζει πόσο να περιμένει ο αποστολέας μέχρι να ξαναστείλει το πακέτο
- Ο timer (εάν ήδη δεν “τρέχει” για κάποιο άλλο segment) ξεκινά όταν το segment “παραδίδεται” στο IP επίπεδο
- Όταν ο timer λήξει, το segment ξαναστέλνεται και το TCP ξεκινά ξανά τον timer

☞ Το TCP του sender διατηρεί πληροφορία για το παλιότερο unacknowledged byte

Έλεγχος ροής του TCP

- ☞ Το TCP είναι ένα πρωτόκολλο κυλιόμενου παραθύρου (sliding window)
  - Για μέγεθος παραθύρου ***n,*** μπορεί να στείλει έως και ***n*** bytes χωρίς να λάβει επιβεβαίωση
  - Όταν τα δεδομένα επιβεβαιωθούν τότε το παράθυρο μετακινείται προς τα μπρος
- Κάθε πακέτο δημοσιεύει ένα μέγεθος παραθύρου
  - Προσδιορίζει τον **αριθμό των bytes για τα οποία έχει χώρο**
- Το original TCP στέλνει πάντα ολόκληρο το παράθυρο
  - **Ο έλεγχος συμφόρησης τώρα το περιορίζει αυτό**

Έλεγχος ροής με παράθυρο: αποστέλλουσα πλευρά

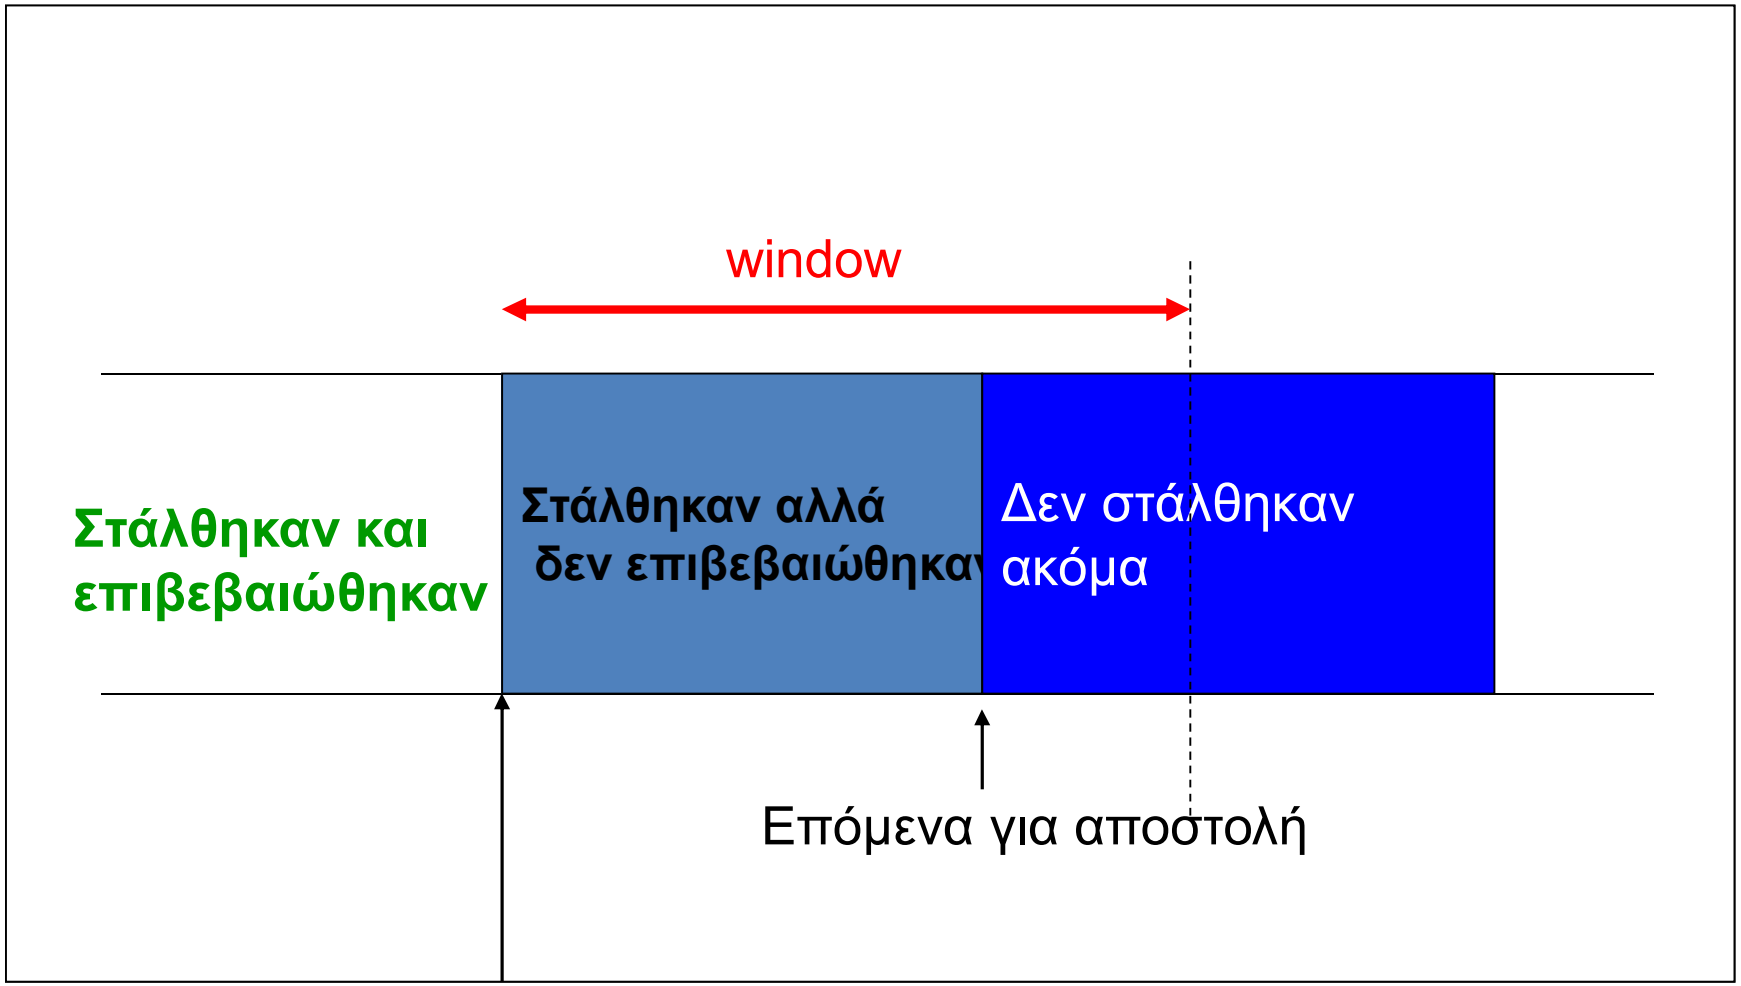

Έλεγχος ροής με παράθυρο: αποστέλουσσα πλευρά

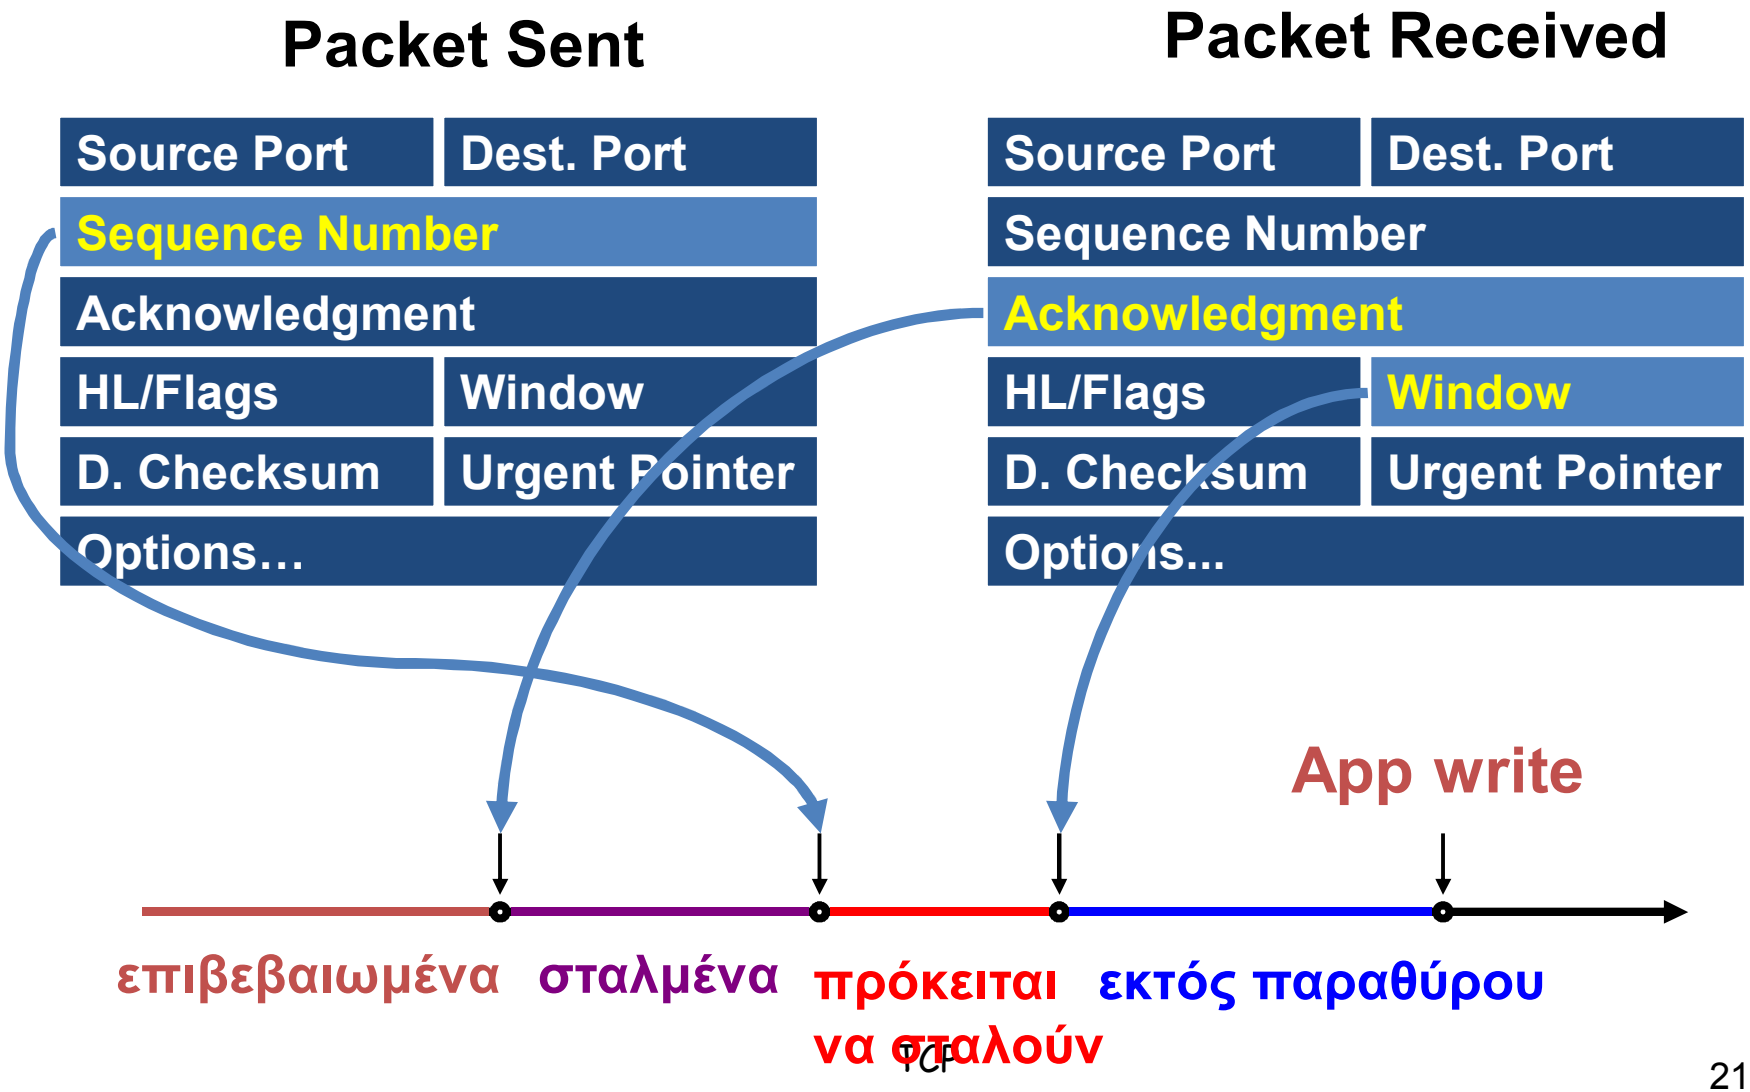

Έλεγχος ροής με παράθυρο: λαμβάνουσα πλευρά

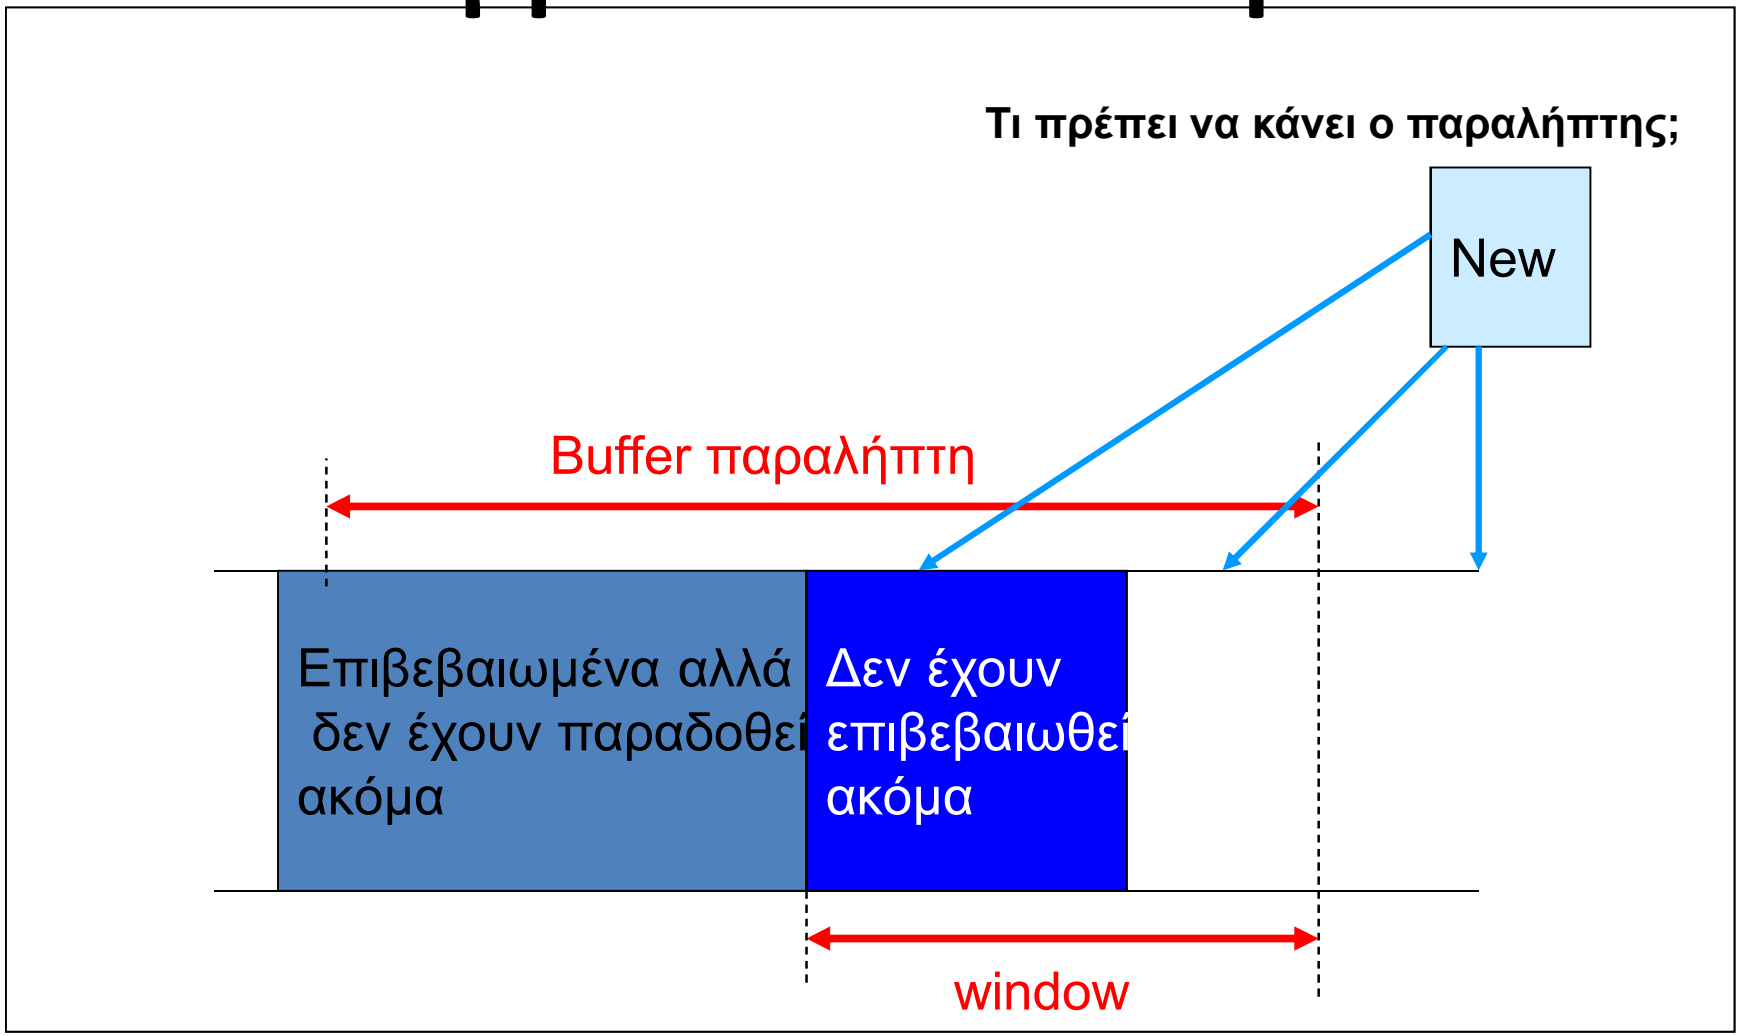

Ερωτήσεις για τον έλεγχο ροής

- What happens if window is 0?
  - ☞Receiver updates window when application reads data
  - – What if this update is lost?
- TCP Persist state
  - ☞ Sender **periodically sends 1 byte packets**
  - – Receiver responds with ACK even if it can't store the packet
  - – Σε κάποια στιγμή το **Receive Window του Receiver θα είναι ≠0**, θα φανεί στο ACK και ο Sender θα ξέρει ότι μπορεί να στείλει δεδομένα

Performance Considerations

- The window size can be controlled by receiving application
  - Can change the socket buffer size from a *default* (e.g. 8Kbytes) to a *maximum* value (e.g. 64 Kbytes)
- The window size field in the TCP header limits the window that the receiver can advertise

TCP seq. #'s and ACKs

Seq. #'s:

☞ byte stream "number" of first byte in segment's data

ACKs:

- **seq # of next byte expected from other side**
- **cumulative ACK**

☞ TCP only acknowledges bytes up to the ***first missing*** byte in the stream

? Q: how receiver handles out-of-order segments

A: TCP spec doesn't say - **up to implementor**

Ο παραλήπτης έχει τις παρακάτω δύο γενικές επιλογές

- αμέσως "πετά" τα segments που έφτασαν με λάθος σειρά, ή
- "κρατά" τα segments που ήρθα με λάθος σειρά και περιμένει τα λάβει πακέτα με τα bytes που "χάθηκαν/δεν έφτασαν" να καλύψουν τα κενά

TCP seq. #'s and ACKs

Seq. #'s:

- byte stream "number" of first byte in segment's data

ACKs:

- **seq # of next byte expected from other side**
- cumulative ACK

Q: how receiver handles out-of-order segments

A: TCP spec doesn't say

- up to implementor

Ο παραλήπτης:

- αμέσως "πετά" τα segments που έφτασαν με λάθος σειρά, ή
- "κρατά" τα segments που ήρθα με λάθος σειρά και περιμένει τα λάβει πακέτα με τα bytes που "χάθηκαν/δεν έφτασαν" να καλύψουν τα κενά

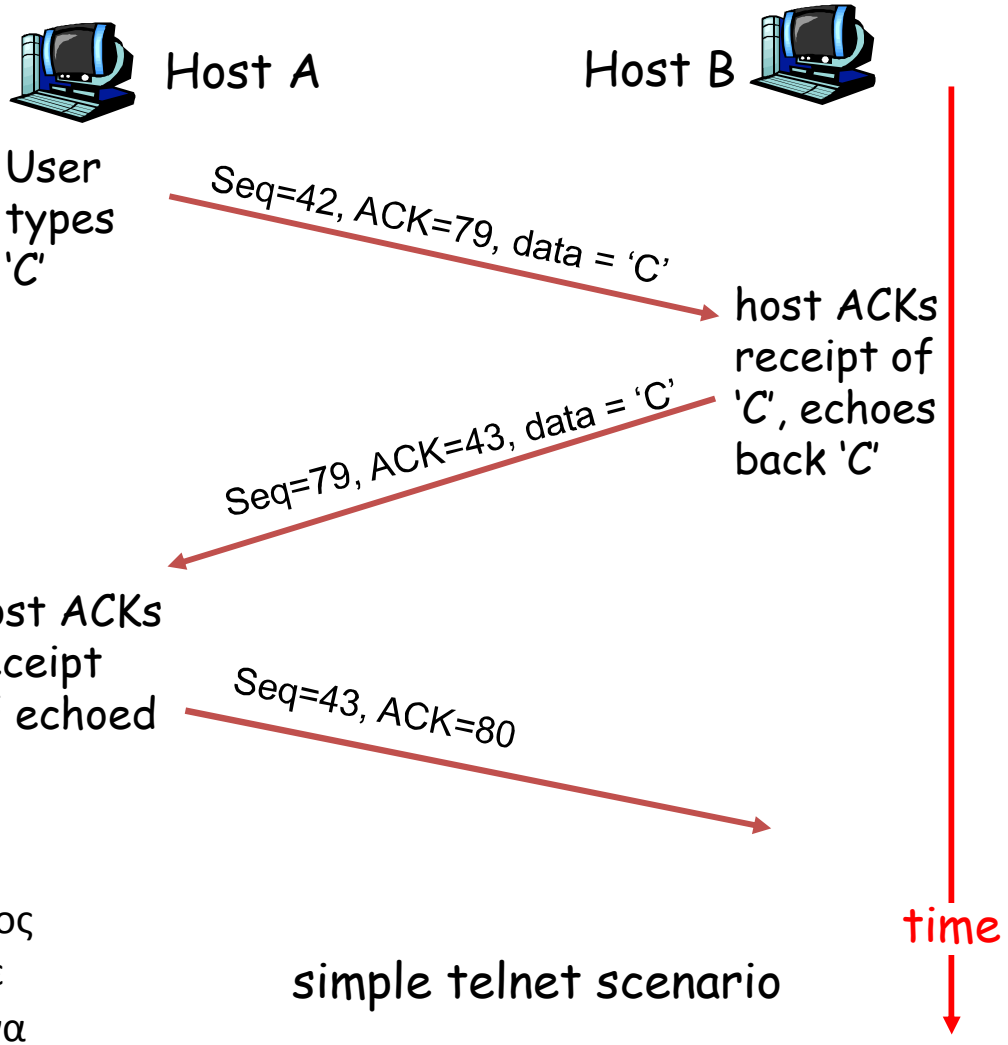

simple telnet scenario

TCP Round Trip Time and Timeout

Q: how to set TCP timeout value?

- longer than RTT
  - ☞ but RTT varies
- too short ⇨ premature timeout
  - ☹ unnecessary retransmissions
- too long: slow reaction to segment loss

Q: how to estimate RTT?

- **`SampleRTT`**: measured time from segment transmission until ACK receipt
  - ☞Αγνοεί segments που έχουν φτάσει με retransmissions
- **`SampleRTT`** will vary, want estimated RTT "smoother"
  - **average several recent measurements**, not just current **`SampleRTT`**

TCP Round Trip Time and Timeout

EstimatedRTT = (1- α)*EstimatedRTT + α*SampleRTT

- Exponential weighted moving average
- influence of past sample decreases exponentially fast
- typical value: $\alpha = 0.125$

Example RTT estimation:

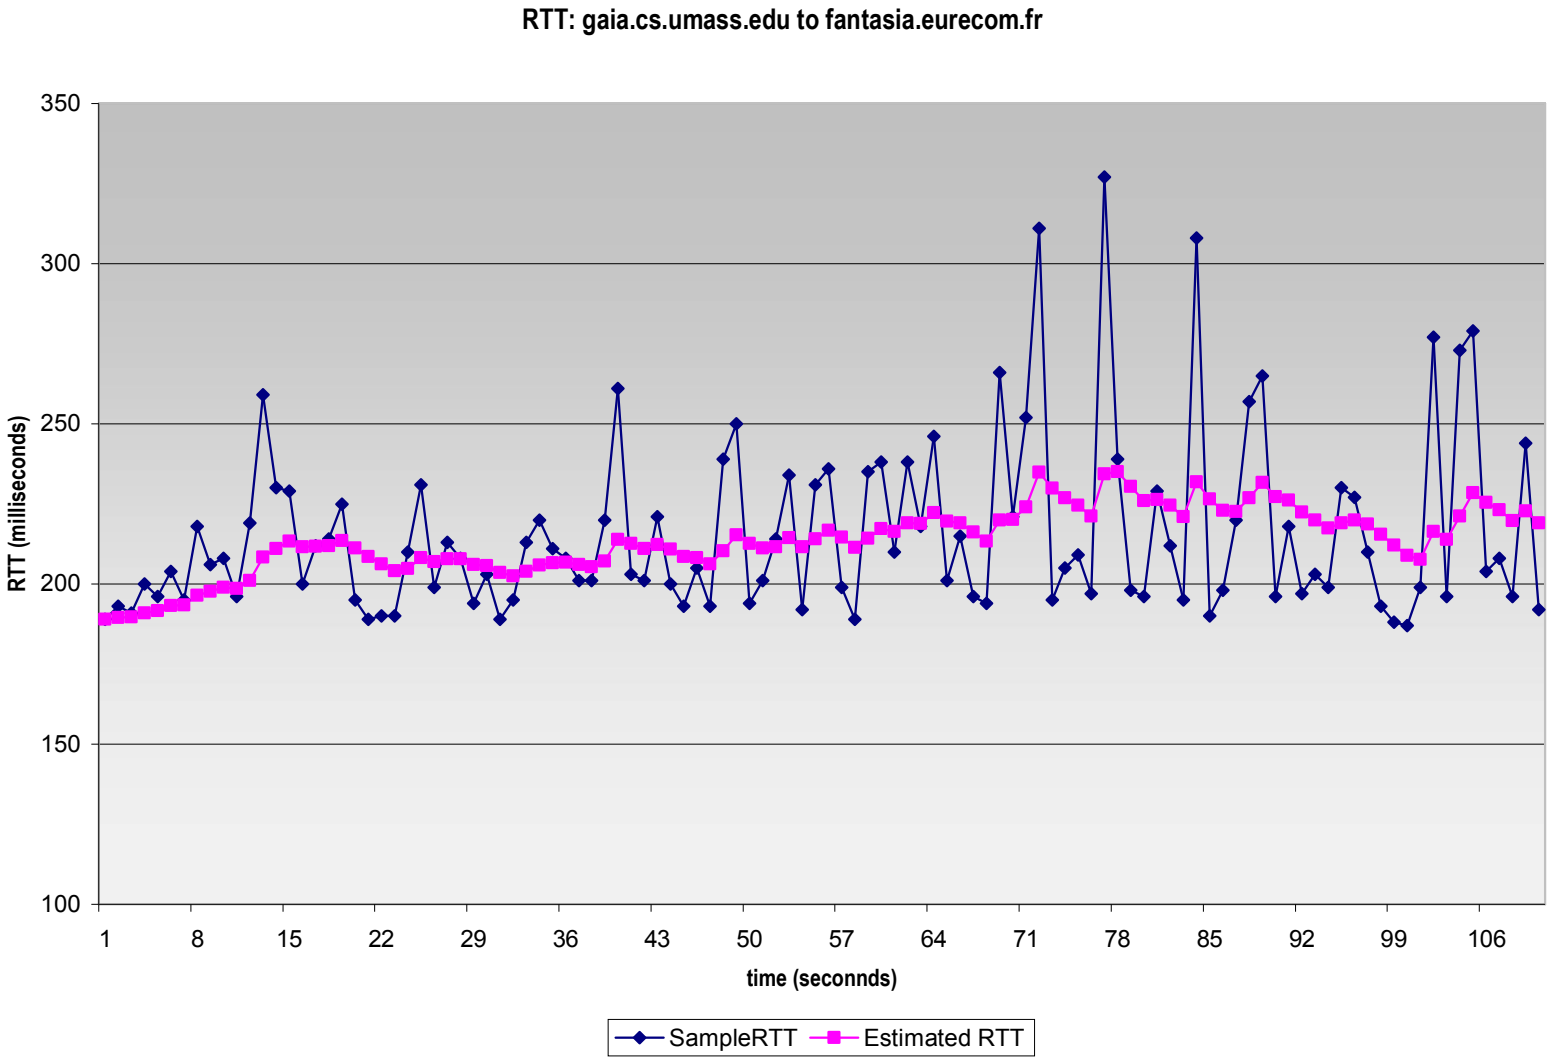

TCP Round Trip Time and Timeout

Setting the timeout

- **EstimtedRTT** plus "safety margin"
  - large variation in **EstimatedRTT ->** larger safety margin
- first estimate of how much SampleRTT deviates from EstimatedRTT:

DevRTT = (1-β)*DevRTT +
β*|SampleRTT-EstimatedRTT|

(typically, β = 0.25)

Then set timeout interval:

TimeoutInterval = EstimatedRTT + 4*DevRTT

TCP reliable data transfer

- TCP creates rdt service on top of IP's unreliable service
- Pipelined segments
- Cumulative acks
- TCP uses single retransmission timer

- **Retransmissions are triggered by:**
  - timeout events
  - duplicate acks
- Initially consider simplified TCP sender:
  - ignore duplicate acks
  - ignore flow control, congestion control

TCP sender events:

Data received from application:

- Δημιουργεί segment με seq #

seq # is byte-stream αριθμός του πρώτου data byte στο segment

- Αρχίζει τον timer, εάν δεν "τρέχει" ήδη

Ο timer κάθε φορά αντιστοιχεί στο ***παλιότερο unacked segment***


Υπάρχει ***μονάχα ένας timer*** για το **κάθε TCP flow** στο host

- expiration interval: `TimeOutInterval`

Timer expired: Timeout event:

- Ξαναστέλνει το segment ***not-yet-acked-with-the-smallest-sequence-number***
- Ξανα-αρχινά το timer

Ack received:

- Εάν acknowledges παλιότερα unacked segments
  - Ενημέρωσε τους buffers/παραμέτρους για το τι ειναι γνωστό να έχει γίνει acked
  - Αρχισε το timer εάν υπάρχουν outstanding segments

TCP sender (simplified)

```
NextSeqNum = InitialSeqNum
SendBase = InitialSeqNum

loop (forever) {
   switch(event)

   event: data received from application above
        create TCP segment with sequence number NextSeqNum
        if (timer currently not running)
             start timer
        pass  segment to IP
        NextSeqNum = NextSeqNum + length(data)

   event: timer timeout
        retransmit not-yet-acknowledged segment with
             smallest sequence number
        start timer

   event: ACK received, with ACK field value of y
        if (y > SendBase) {
             SendBase = y
             if (there are currently not-yet-acknowledged segments)
                  start timer
             }

} /* end of loop forever */
```

Comment:

- SendBase-1: *last cumulatively* ack'ed byte

Example:

- SendBase-1 = 71;

y= 73, so the rcvr wants 73+ ;

y > SendBase, so that new data is acked

TCP: retransmission scenarios

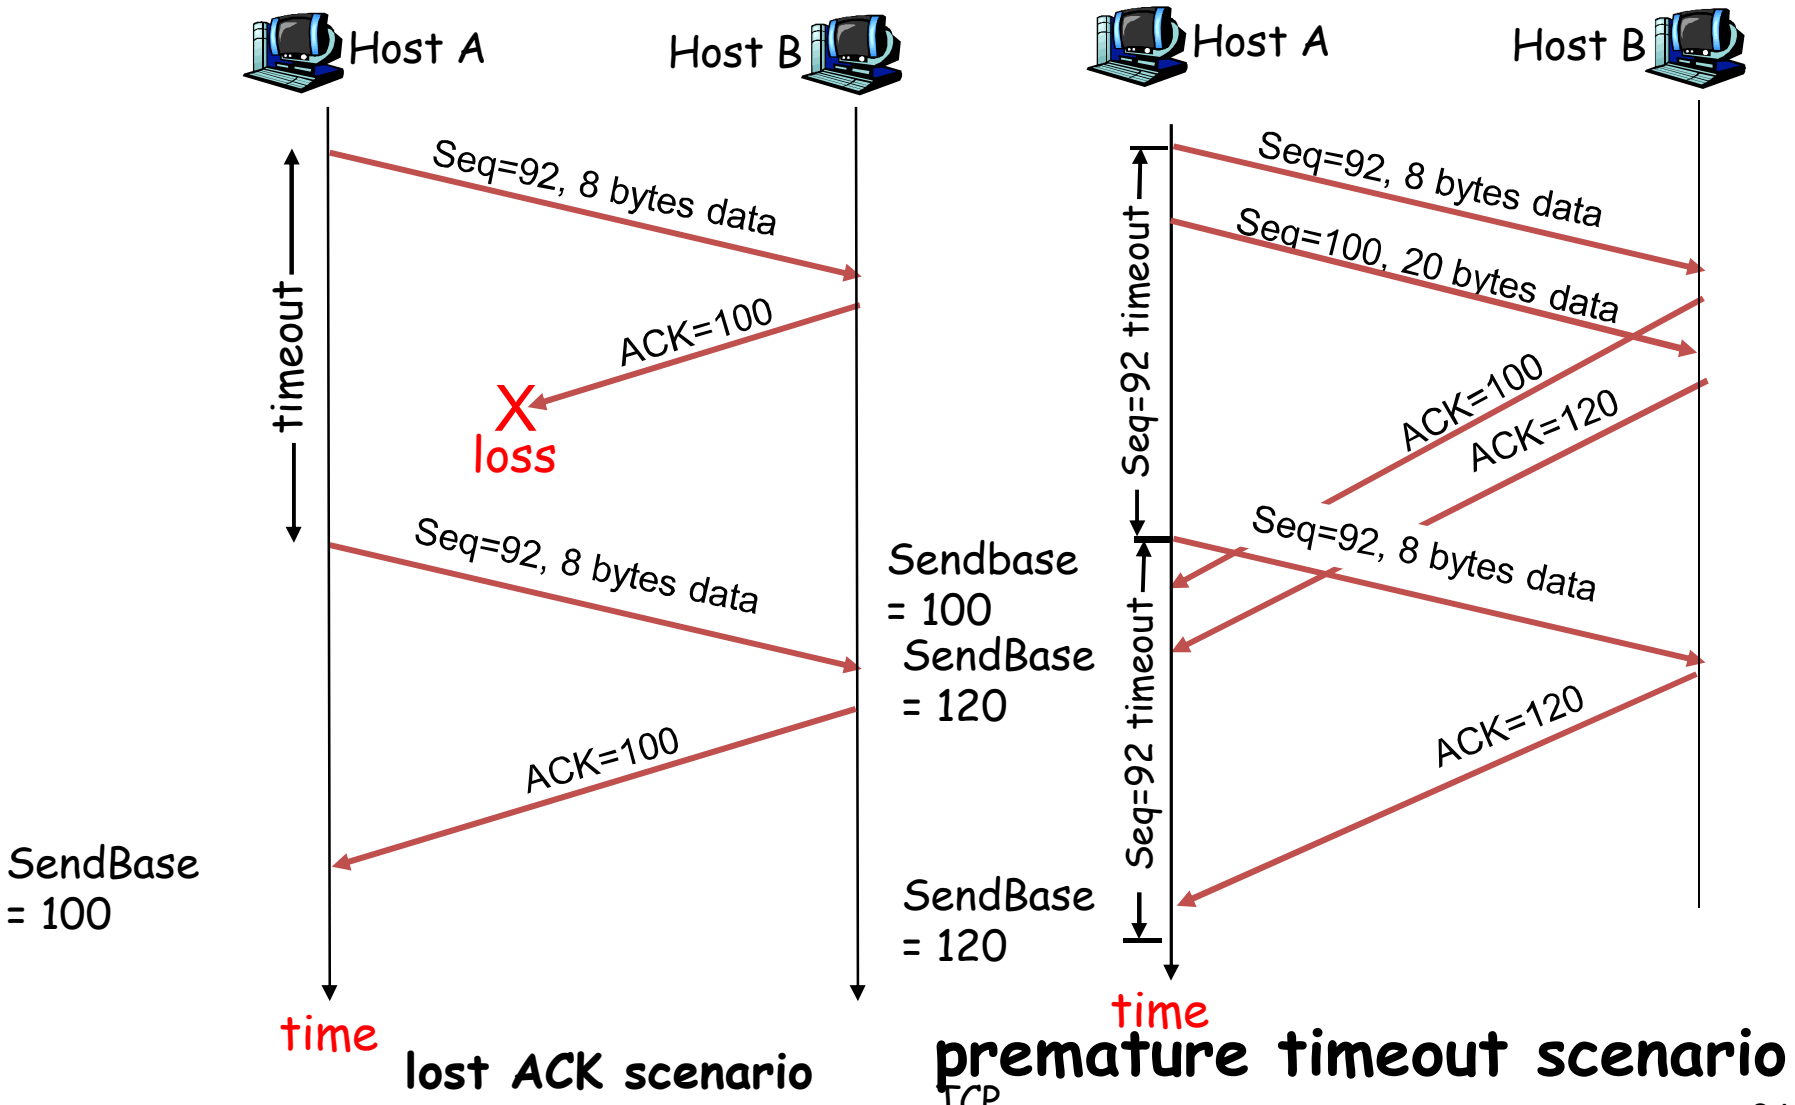

TCP retransmission scenarios (more)

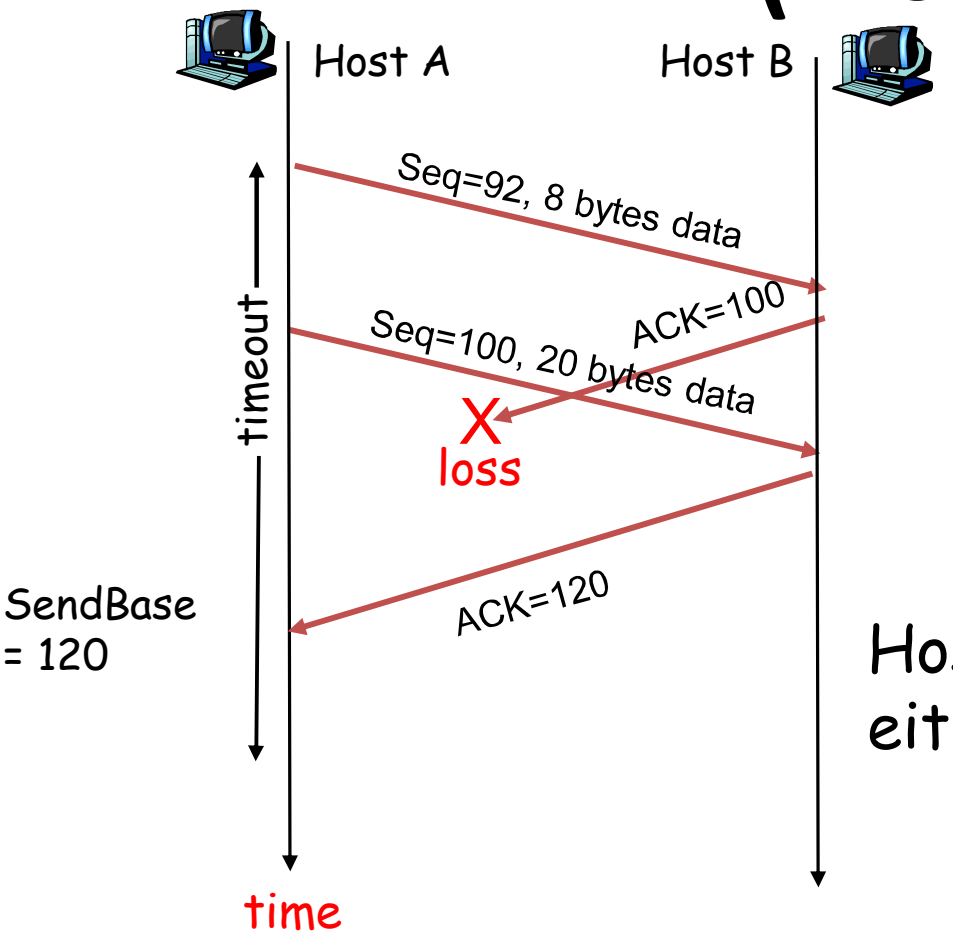

Host A does not resend either of the two segments

Cumulative ACK scenario

TCP ACK generation [RFC 1122, RFC 2581]

Event at Receiver	TCP Receiver action
Arrival of **in-order segment with expected seq #. All data up to expected seq # already ACKed**	***Delayed ACK***. Wait up to 500ms for next segment. If no next segment, send ACK
Arrival of in-order segment with expected seq #. **One other segment has ACK pending**	***Immediately*** send ***single cumulative ACK,*** ACKing both in-order segments
Arrival of **out-of-order segment higher-than-expect seq. # .** *Gap detected*	***Immediately*** send ***duplicate ACK***, indicating seq. # of next expected byte
Arrival of segment that partially or completely fills gap	***Immediately*** send **ACK**, provided that segment startsat lower end of gap

Να θυμάστε

- TCP acks είναι **cumulative !**

☞ Ενα segment που **έχει ληφθεί σωστά *αλλά σε λάθος σειρά* δεν** γίνεται ACKed από τον παραλήπτη

- TCP sender διατηρεί μονάχα την πληροφορία:
  - segment # με τον μικρότερο αριθμό **που έχει στείλει αλλά δεν έχει γίνει ACKed ακόμη** (***sendBase***), καθώς και
  - sequence # του **επόμενου byte** που θα πρέπει να σταλεί (***NextSeqNum***)

Παρατήρηση σχετικά με τα Timeout Διαστήματα

- Τα timer expiration συμβαίνουν συνήθως εξαιτίας της συμφόρησης του δικτύου
- Πολλά πακέτα που φτάνουν σε ζεύξεις στο μονοπάτι μεταξύ του sender & receiver χάνονται ή έχουν μεγάλες καθυστερήσεις στις ουρές των δρομολογητών λόγω συμφόρησης

Εάν οι senders συνεχίσουν να ξαναστέλνουν τα πακέτα “σταθερά”, η συμφόρηση μπορεί να χειροτερεύσει

- Με την **<u>εκθετική αύξηση</u>** με κάθε retransmission του sender, ο TCP sender προσπαθεί “ευγενικά” **να περιμένει *όλο και μεγαλύτερο διάστημα***

✓ Οι περισσότερες TCP υλοποιήσεις το υποστηρίζουν

Διπλασιάζοντας το Timeout Διάστημα

☞ Κάθε φορά που το TCP ***retransmits*** διπλασιάζει το επόμενο timeout διάστημα αντί να θέτει την τιμή απο τον υπολογισμό των lastEstimatedRTT & DevRTT

- έχομε δηλαδή ***εκθετική αύξηση του timer*** μετά από κάθε retransmission

Οταν ένα από τα παρακάτω γεγονόταν συμβούν:

- ***Νεα δεδομένα προωθούνται*** απο την εφαρμογή για τον σχηματισμό segment
- ***Παραλαβή*** ενός ACK

Ο timer παίρνει τιμή βάσει των lastEstimatedRTT και DevRTT

✓ Οι περισσότερες TCP υλοποιήσεις το υποστηρίζουν

Fast Retransmit

☹ Time-out period often relatively long:

– long delay before resending lost packet

- Detect lost segments via ***duplicate ACKs***
  - ✓ Sender often sends many segments back-to-back
  - – If segment is lost, there will likely be many duplicate ACKs

☞ If sender receives 3 ACKs for the same data, it supposes that segment after ACKed data was lost:

fast retransmit: **resend segment *before* timer expires**

Fast retransmit algorithm:

```
event: ACK received, with ACK field value of y
            if (y > SendBase) {
                SendBase = y
                if (there are currently not-yet-acknowledged segments)
                    start timer
              }
            else {
                increment count of dup ACKs received for y
                if (count of dup ACKs received for y = 3) {
                    resend segment with sequence number y
                }
```

a duplicate ACK for already ACKed segment

fast retransmit

Chapter 3 outline

- 3.1 Transport-layer services
- 3.2 Multiplexing and demultiplexing
- 3.3 Connectionless transport: UDP
- 3.4 Principles of reliable data transfer
- 3.5 Connection-oriented transport: TCP
  - segment structure
  - reliable data transfer
  - flow control
  - connection management
- 3.6 Principles of congestion control
- 3.7 TCP congestion control

TCP Flow control (1/3)

- **Receiver advertises spare room** (**`ReceiveWindow`** in segments)
- Sender limits unACKed data to **`Receive Window`**
  - guarantees receive buffer doesn't overflow

@ Receiver

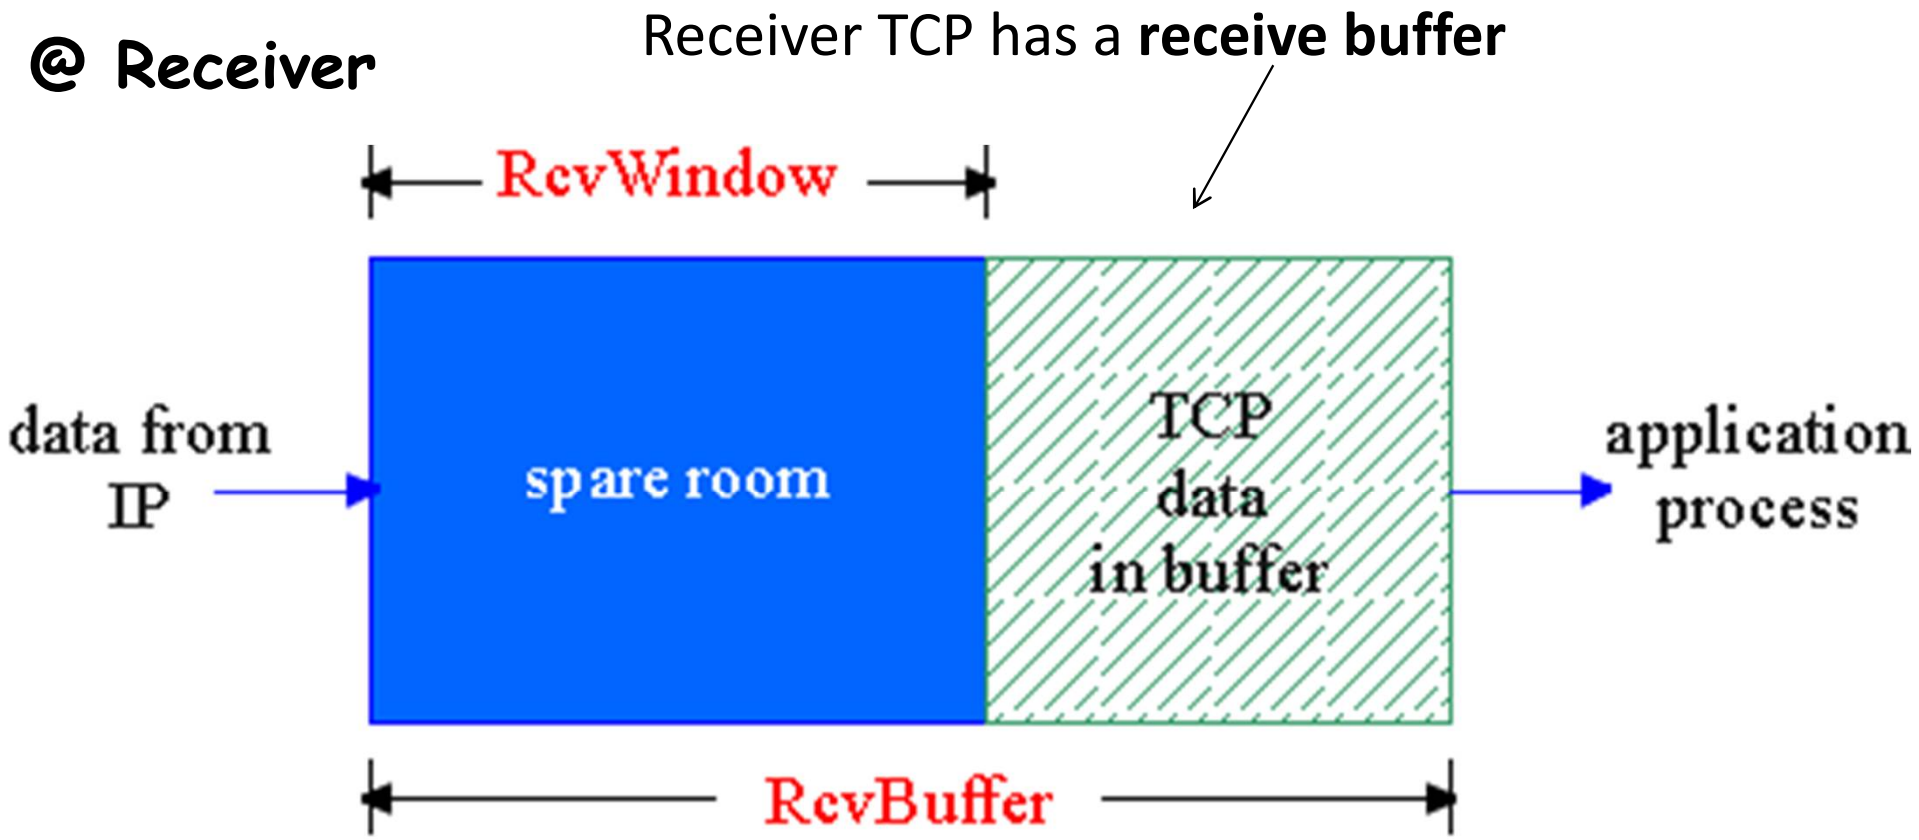

TCP Flow Control (2/3)

Receiver TCP has a receive buffer:

flow control

sender won't overflow receiver's buffer by **transmitting too much, too fast**

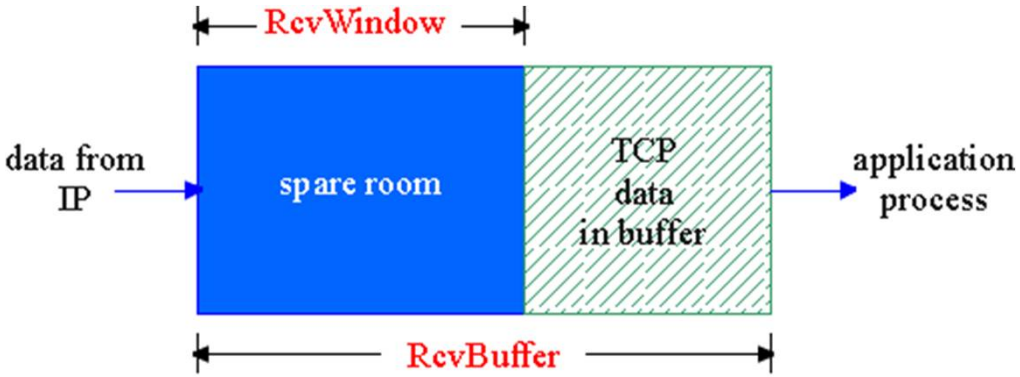

- speed-matching service: ***matching* the *send rate* to the receiving application's drain rate**

☞ application process may be slow at reading from buffer

TCP Flow control (3/3)

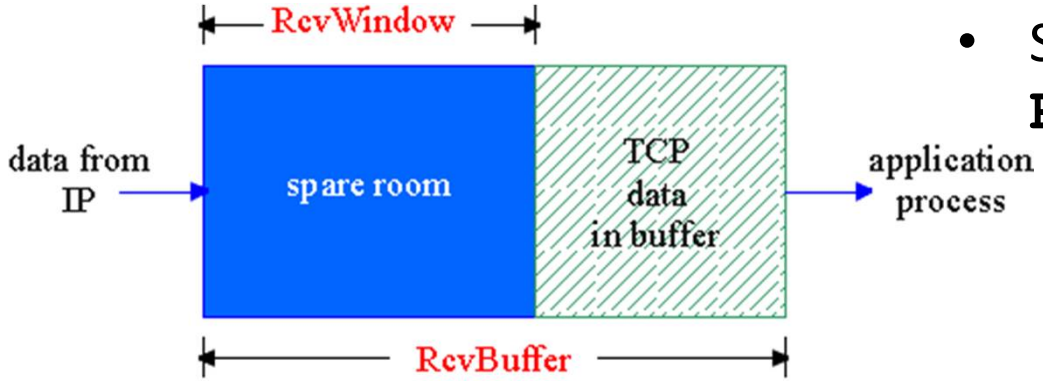

- Receiver advertises spare room by including value of **`Receive Window`** in segments
- Sender limits unACKed data to **`Receive Window`**
  - guarantees receive buffer doesn't overflow

(Suppose TCP receiver discards out-of-order segments)

- spare room in buffer

`= RcvWindow`

`= RcvBuffer-[LastByteRcvd - LastByteRead]`

Buffer @ Receiver becomes full

- The sender will be notified with the RcvWindow value (=0) in the ACK messages
- The receiver will keep processing the received segments and forward them to the application …

  Eventually there will be space at its buffer …

How the sender will be informed when there is empty space at the receiver buffer?

- TCP requires the sender to keep sending messages of 1Byte when the receiver's ***RcvWindow=0***
- These segments will be ACKed and eventually they will contain nonzero RcvWindow value!

Βασικά για τον Ελεγχο Συμφόρησης

Συμφόρηση:

- informally: "***too* many sources** sending ***too* much data *too* fast** for ***network*** to handle"

☞ **Διαφορετικό** από τον **έλεγχο ροής (flow control) !!!**

Εκδηλώνεται με:

- **lost packets** (***buffer overflow*** at routers)
- **long delays** (***queuing*** in router buffers)

 a top-10 problem!

Causes/costs of congestion: scenario 1

- 2 senders, 2 receivers
- 1 router με buffer απείρου μεγέθους
- no retransmission

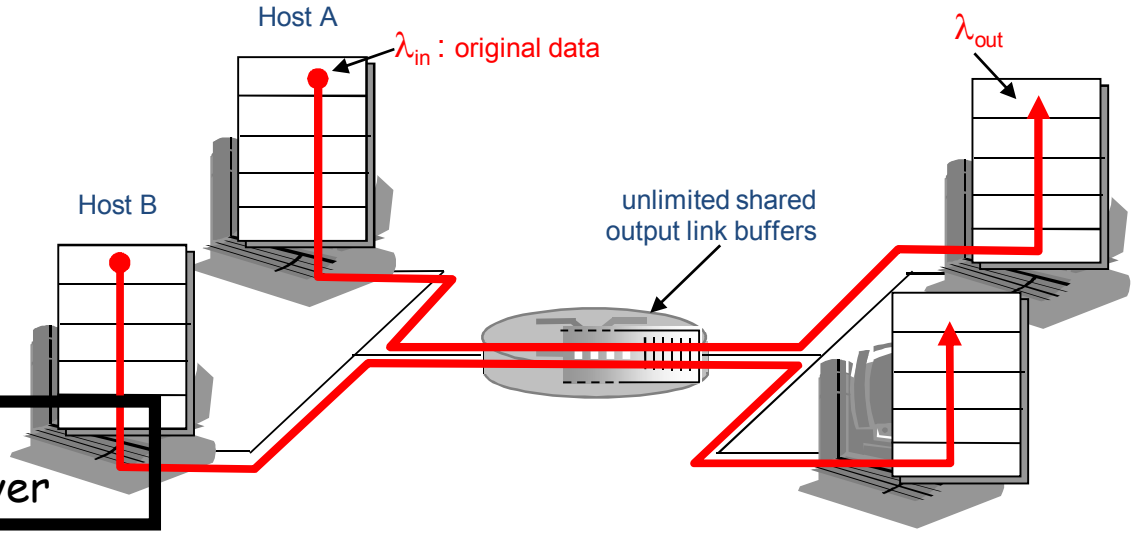

Per-connection throughput:
Number of bytes/second @ receiver

Αλλά αυτό είναι πρόβλημα!

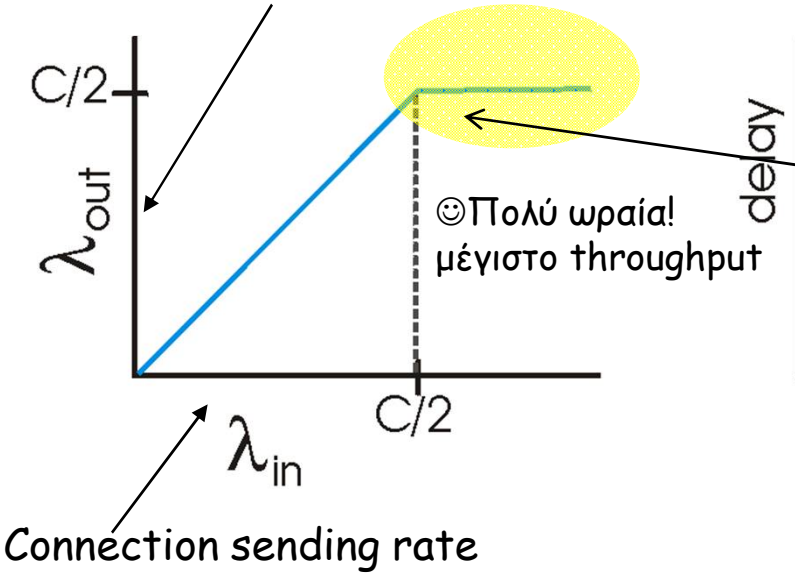

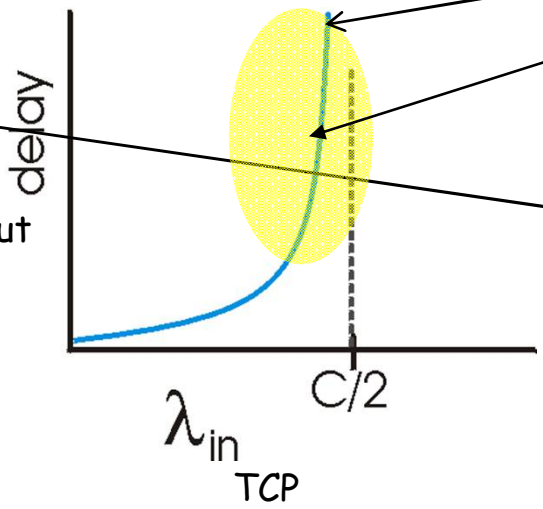

- **large queuing delays** when congested!!!!
- maximum achievable throughput!!!

Causes/costs of congestion: scenario 2

- 1 router, με περιορισμένου μεγέθους buffer
- sender retransmission of lost packet

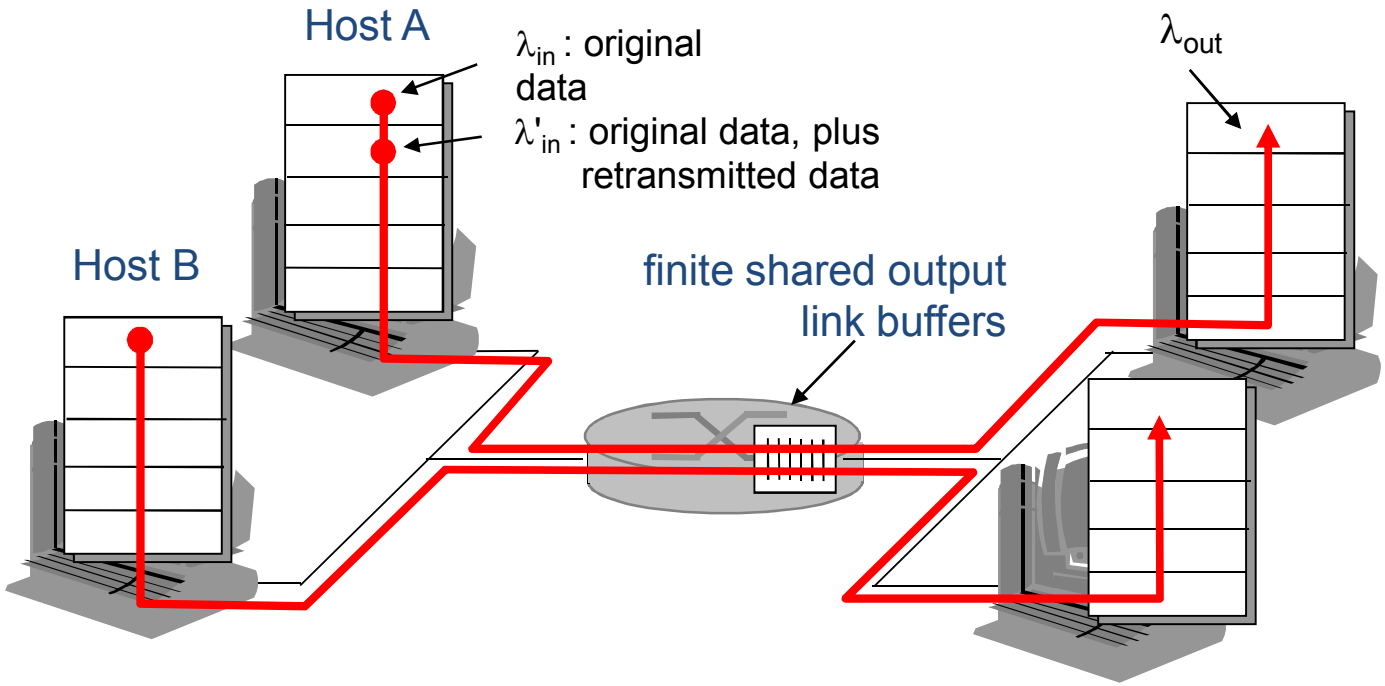

Causes/costs of congestion: scenario 2

Μαντεύει αν ο buffer ειναι γεμάτος ή οχι

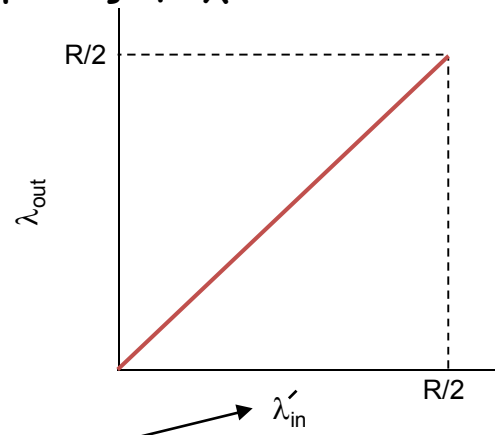

Original data + retransmissions

a.

Retrx οταν ξέρει ότι το πακέτο θα χαθεί

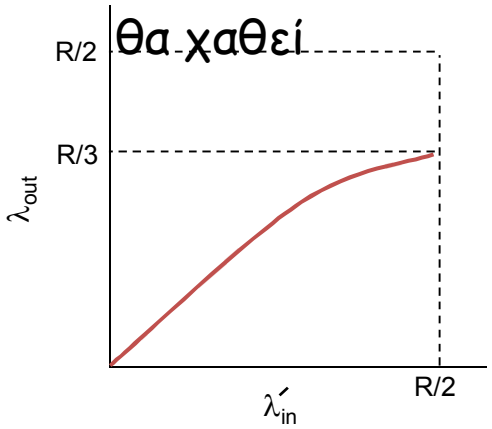

b.

Πρώιμα timeouts

Κάθε πακέτο στέλνεται (κατά μέσο όρο) 2 φορές

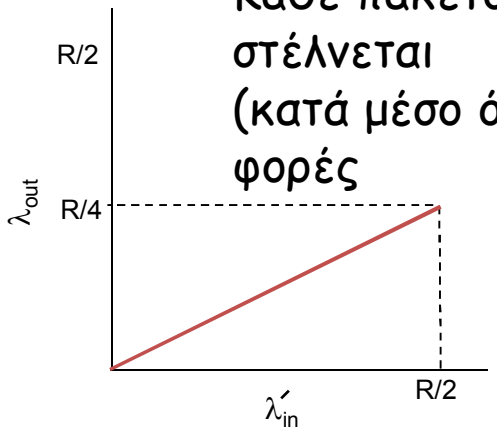

c.

☞ "costs" of congestion:

☹ more work (retransmissions) for given "goodput"

☹ unneeded retransmissions: link carries multiple copies of packet

Causes/costs of congestion: scenario 3

- 4 senders
- multihop paths
- timeout/retransmit

Q: what happens as λ_{in} and λ'_{in} increase ?

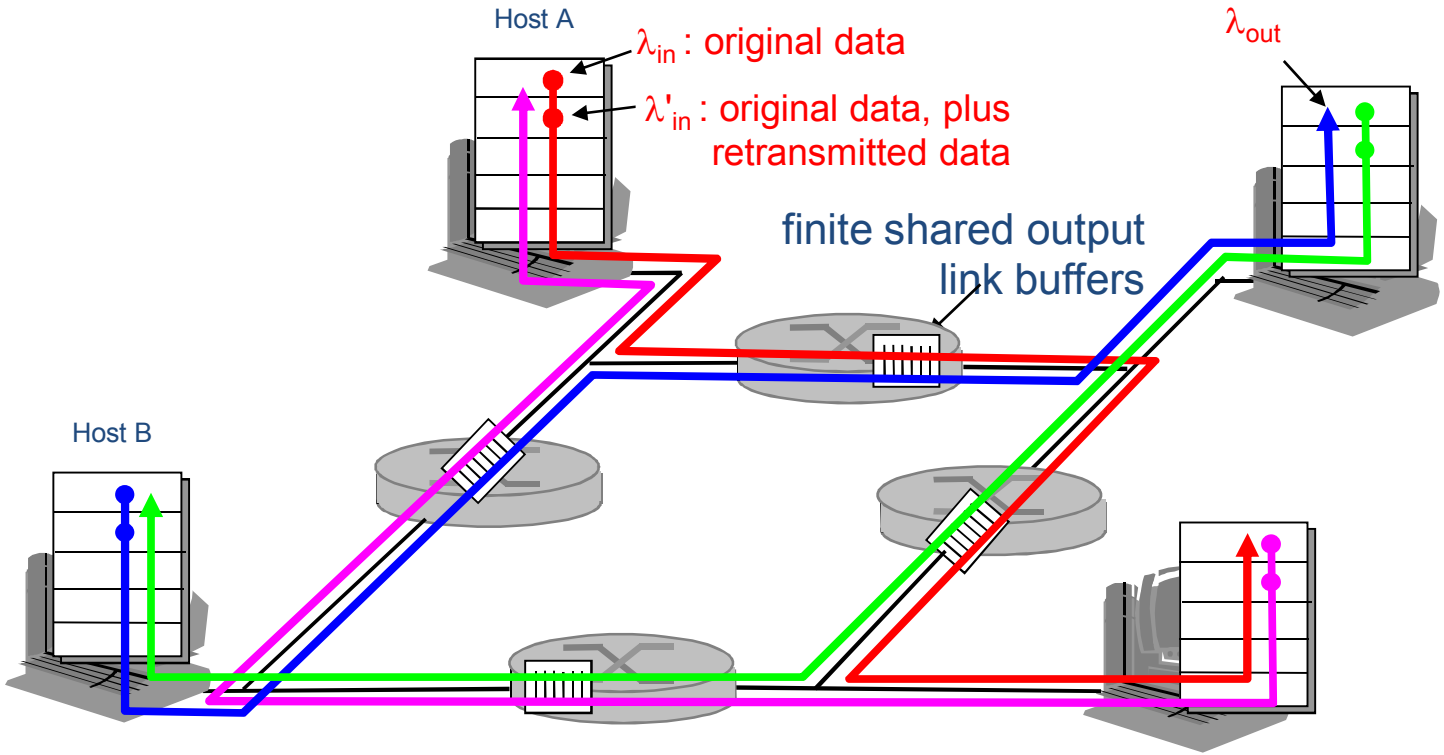

Causes/costs of congestion: scenario 3

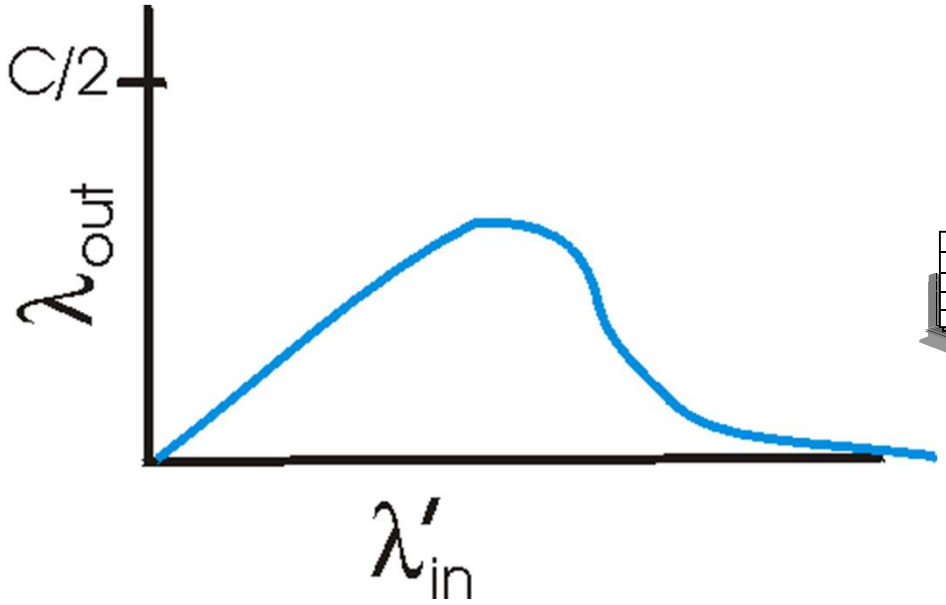

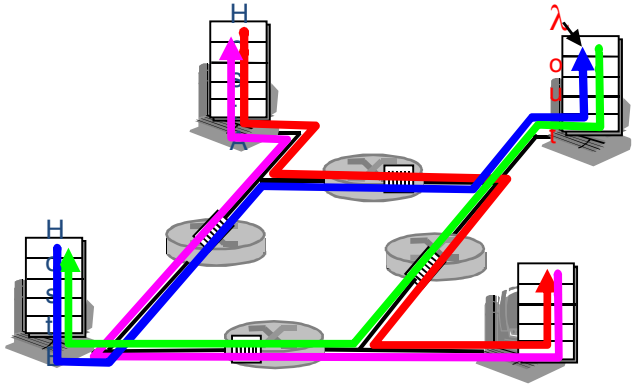

Another “cost” of congestion:

☹ when packet dropped, any “transmission capacity used for that packet at each of the upstream routers to forward that packet to the point at which it is dropped was wasted!

Γενικοί τρόποι αντιμετώπισης συμφόρησης

Two broad approaches towards congestion control:

☞ Network-assisted congestion control:

- routers provide feedback to end systems
  - single bit indicating congestion (SNA, DECbit, TCP/IP ECN, ATM)
  - explicit rate sender should send at

end-to-end: τα 2 hosts που συμμετέχουν **παρακολουθούν** και **ρυθμίζουν** το ρυθμό κίνησης τους

☞ End-to-end congestion control:

- no explicit feedback from network
- congestion inferred from end-system observed loss, delay
- approach taken by TCP

IP does not provide explicit feedback to the end systems

TCP

Chapter 3 outline

- 3.1 Transport-layer services
- 3.2 Multiplexing and demultiplexing
- 3.3 Connectionless transport: UDP
- 3.4 Principles of reliable data transfer
- 3.5 Connection-oriented transport: TCP
  - segment structure
  - reliable data transfer
  - flow control
  - connection management
- 3.6 Principles of congestion control
- 3.7 TCP congestion control

TCP congestion control:έλεγχος στο sending rate

📣Ο αποστολέας:

- ***Μειώνει*** το ***sending rate*** με το να ελαττώνει το *congestion window* όταν ένα ***loss event*** εμφανίζεται
- Και αυξάνει το ***sending rate***, όταν η συμφόρηση μειώνεται

timeout ή ***3 όμοια ACKs***

But howmuch should a sender reduce its congestion window ?

LastByteSent- LastByteAcked ≤ min {*Congestion Window, Receive Window*}

συμφόρηση

flow control

Observation: Large Congestion Windows → Large Number of non-ACKed packets trx → Large Sending Rate

3 κεντρικά σημεία του TCP congestion control

1. **Additive increase, multiplicative decrease**:

   Increase transmission rate (window size), probing for usable bandwidth, until loss occurs

   - ***additive increase:*** increase **Congestion Window** by ***1 MSS*** **every RTT until loss detected**
   - ***multiplicative decrease***: cut **Congestion Window** in ***half*** after loss

1. **Slow start**
2. **Reaction to timeout events**

time

TCP congestion control: additive increase, multiplicative decrease (AIMD)

Λέγεται και congestion avoidance

- *Approach:* increase transmission rate (window size), probing for usable bandwidth until loss occurs
  - *additive increase:* increase **Congestion Window** by 1 MSS every RTT until loss detected
  - *multiplicative decrease*: cut **Congestion Window** in half after loss

Με την γραμμική αύξηση "διστακτικά" ελέγχει κατα πόσο η συμφόρηση έχει ελαττωθεί

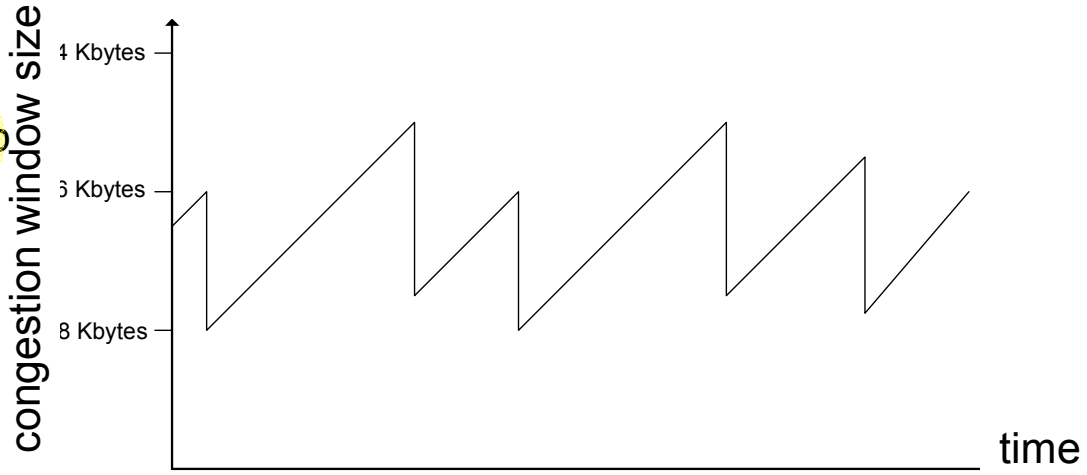

Saw tooth behavior: probing for bandwidth

Προσθετική αύξηση της AIMD

Πώς ακριβώς λειτουργεί η προσθετική αύξηση:

Κάθε φορά που ο TCP sender στέλνει με ***επιτυχία πακέτα*** (δηλαδή όλα τα πακέτα που στέλνονται κατά τη διάρκεια του τελευταίου RTT έχουν επιβεβαιωθεί με πακέτα ACK) με συνολικό μέγεθος ίσο με το **CongWin**,

προσθέτει το ισοδύναμο του **ενός πακέτου** στο CongWin

☞ Προσέξετε ότι στην πράξη το TCP αυξάνει ελαφρώς το μέγεθος του CongWin ***με την άφιξη κάθε ACK***.
Συγκεκριμένα, το **CongWin αυξάνεται με το κάθε ACK κατά**

MSS * MSS/CongWin

Congestion Avoidance

- Η φάση της γραμμικής αύξησης του TCP congestion control protocol λέγεται και φάση αποφυγής συμφόρησης

AIMD: παρατηρήσεις

? Γιατί έχομε γραμμική αύξηση και όχι εκθετική αύξηση?

- Ο sender είναι πρόθυμος να μειώσει το μέγεθος του παραθύρου συμφόρησης με αρκετά μεγαλύτερο ρυθμό απ' ότι είναι πρόθυμος να το αυξήσει
- Έχει αποδειχτεί ότι η μέθοδο AIMD αποτελεί απαραίτητη συνθήκη έτσι ώστε οι μηχανισμοί ελέγχου συμφόρησης να είναι σταθεροί.
- Ένας διαισθητικός λόγος για την επιθετική μείωση και τη συντηρητική αύξηση του μεγέθους του παραθύρου είναι ότι οι ***συνέπειες ενός παραθύρου με μεγάλο μέγεθος είναι πολύ χειρότερες*** από τις αντίστοιχες ενός παραθύρου με μικρό μέγεθος.
- πχ, όταν το μέγεθος του παραθύρου είναι πολύ μεγάλο, τα πακέτα που απορρίπτονται ***θα αναμεταδοθούν προκαλώντας ακόμα χειρότερη συμφόρηση.***

Επομένως η έξοδος από αυτή την κατάσταση έχει ιδιαίτερη σημασία.

TCP Congestion Control: παρατηρήσεις

- sender limits transmission:

  `LastByteSent-LastByteAcked`

  `≤ CongWin`

`(ignoring flow control here)`

- Roughly:

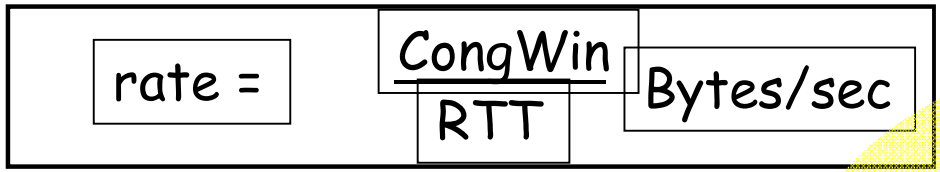

- **`Congestion Window`** is **dynamic**, function of perceived network congestion

How does sender perceive congestion?

- loss event = ***timeout*** *or* ***3 duplicate acks***
- TCP sender reduces rate (**`Congestion Window`**) after loss event

three mechanisms:

- AIMD
- slow start
- conservative after timeout events

Observation: Large Congestion Windows → Large Sending Rates
in the slides, sometimes we talk about increase/decrease of the rate and other times about increase/decrease of CongWindow

TCP

TCP Slow Start (1/3)

- **When connection begins:** `CongestionWindow` = 1 MSS

  congestion window is very small (hence the name “slow start”)
  - Example: MSS = 500 bytes & RTT = 200 msec
  - initial rate = 20 kbps

note: **Διαθέσιμο bandwidth μπορεί να είναι >> MSS/RTT**

☺ Οπότε **γρήγορα** θέλομε να το ***αυξήσομε*** ώστε να φτάσομε το bandwidth που μπορούμε να πετύχομε

❒ When connection begins:

increase rate exponentially fast *until first loss event*

✓Η αύξηση (CongestionWindow++) γίνεται **κάθε φορά που λαμβάνεται 1 ACK** …

why the rate increases exponentially fast?

Example of TCP Slow start (2/3)

1. TCP sends the first segment and waits for the ACK
2. If this segment is acked before a loss event,
   - the TCP sender increases the congestion window by 1 MSS, and
   - sends out two maximum-sized segments.
3. If these segments are acked before loss events,

- the sender increase the congestion window by 1 *MSS for <u>each of the ACK segments</u>*,
  (giving a congestion window of 4 *MSSS*), and
- sends out 4 maximum sized segments.

The value of CongWindow **effectively doubles** every RTT during the slow-start phase.

TCP Slow Start (3/3)

- When connection begins, increase rate exponentially **until first loss event:**

  double `CongWin` every RTT

  ☞ done by **incrementing `CongWin`** for **every ACK received**

Summary: initial rate is ***slow*** **but ramps up *exponentially fast***

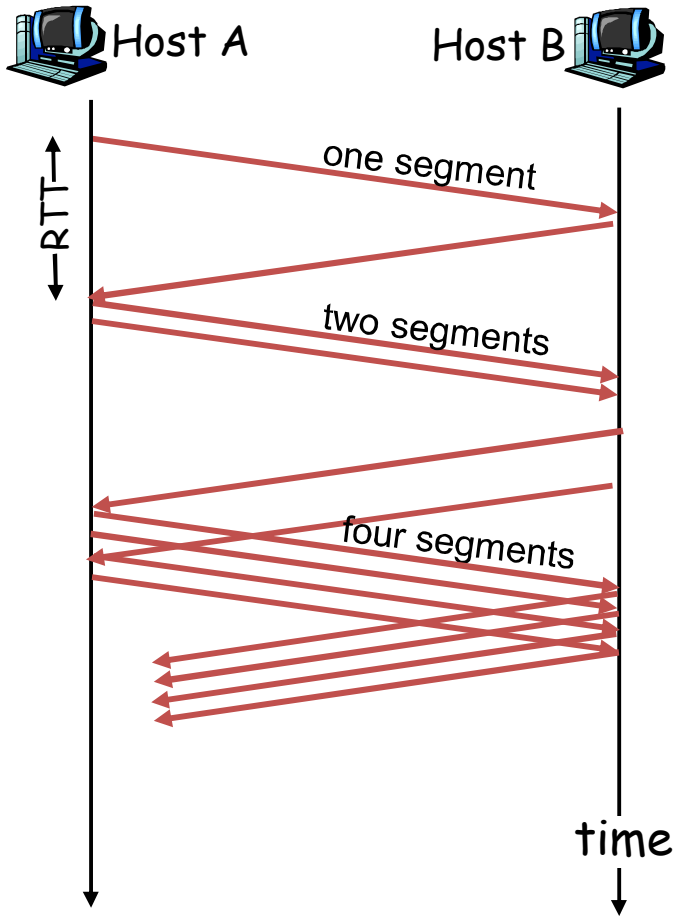

Refinement: inferring loss

☞ **Διαφοροποιείται η αντίδραση** εάν είναι ***timeout*** ή ***3 όμοια ACKs***

Philosophy:

3 dup ACKs (duplicate acknowledgements) indicate network capable of delivering ***some*** segments

☞ timeout indicates a ***more alarming*** congestion scenario

Αντίδραση σε γεγονότα συμφόρησης

☞ Διαφοροποιείται η αντίδραση εάν είναι **timeout** ή **3-όμοια-ACKs**

- Εάν είναι **3-όμοια-ACKs**:
  - **Congestion window *διαιρείται δια 2*** και **μετά αυξάνεται *γραμμικά***
- Εάν όμως συμβεί **timeout:**

  ☹ Ο sender μπαίνει ***σε slow-start φάση!!!***

  - **Congestion window = *1MSS***
  - μετά **αυξάνεται *εκθετικά*** **μέχρι να φτάσει το μισό της τιμής που είχει πριν το timeout**,

    και μετά από αυτό το σημείο

  - **αυξάνεται *γραμμικά*** (όπως θα γινόταν μετά από ένα 3-όμοια-ACKs γεγονός)

TCP Congestion Control

Determines the **window size** at which the ***slow start will end*** and the ***congestion avoidance will begin***

- When **CongWin <= *Threshold:***

  sender in ***slow-start* phase**, window grows ***exponentially***

- When ***CongWin > Threshold*:**

  sender is in ***congestion-avoidance* phase**, window grows ***linearly***

- When **triple duplicate ACK** occurs:
  - **Threshold=CongWin/2**
  - **CongWin=Threshold**
- When **timeout** occurs:
  - Threshold=CongWin/2
  - CongWin= 1 MSS

Τέλος Ενότητας