Szállítási réteg (L4)

Gyakorlat

Budapest University of Technology and Economics

Department of
Telecommunications and Media Informatics

A gyakorlat célja

- A TCP-t nagyon sok környezetben használják
- A főbb mechanizmusok ismerete fontos
  - A programozónak
  - A hálózati szakembernek
    - Wired
    - Wireless
  - Lassan az ipari környezetbe is beszivárog

Portok

- Kapcsolat fogalma
  - 5-tuple
- Kapcsolat kiépítése
  - UDP - nincs
  - TCP
    - 3 way handshake
    - Miért van rá szükség?

Demultiplexing Traffic

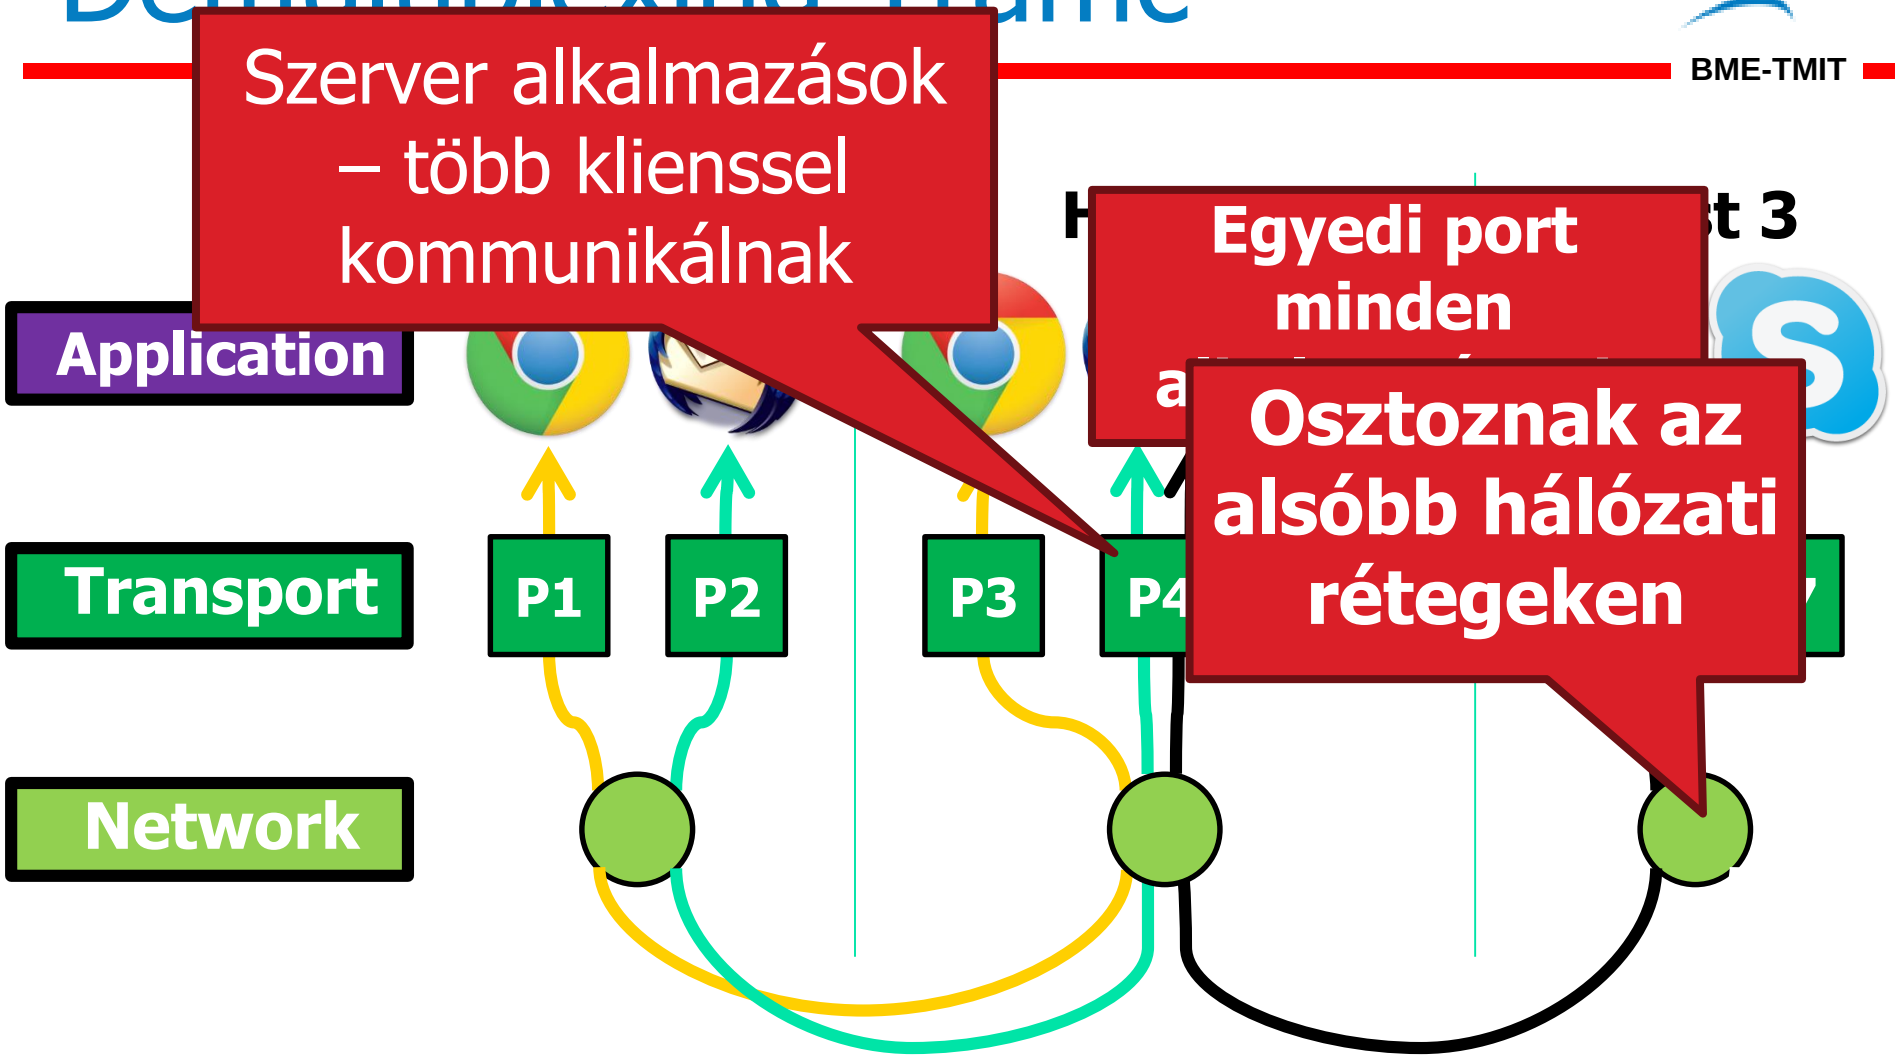

Endpoints identified by *<src_ip, src_port, dest_ip, dest_port>*

Portok egy gépen

- Netstat parancs

```
TCP    127.0.0.1:1906         localhost:1907     ESTABLISHED
TCP    192.168.1.147:53699    13.77.87.52:https      ESTABLISHED
TCP    192.168.1.147:53703    91.190.216.57:12350    ESTABLISHED
TCP    192.168.1.147:53737    64.4.23.152:40008      ESTABLISHED
TCP    192.168.1.147:53759    108.177.96.188:5228    ESTABLISHED
TCP    192.168.1.147:53772    40.77.226.192:https    ESTABLISHED
TCP    192.168.1.147:54512    a104-96-129-73:https   CLOSE_WAIT
TCP    192.168.1.147:54513    a104-96-129-73:https   CLOSE_WAIT
TCP    192.168.1.147:54514    a104-96-129-73:https   CLOSE_WAIT
```

UDP

- Adatküldés: szegmensek
- Hibakezelés
  - ICMP: port nem elérhető
  - Loss: nincs visszajelzés
- Sávszélesség, késleltetés

The Evolution of TCP

- TCP Tahoe
  - Kezdeti verzió
- A TCP 1974-ben volt kitalálva!
  - Manapság rengeteg változata van a TCP-nek
- Kezdeti, elterjedt: TCP Reno
  - Tahoe, plus…
  - Fast retransmit
  - Fast recovery

TCP Reno: Fast Retransmit

- **Problem: in Tahoe, if segment is lost, there is a long wait until the RTO**
- **Reno: retransmit after 3 duplicate ACKs**

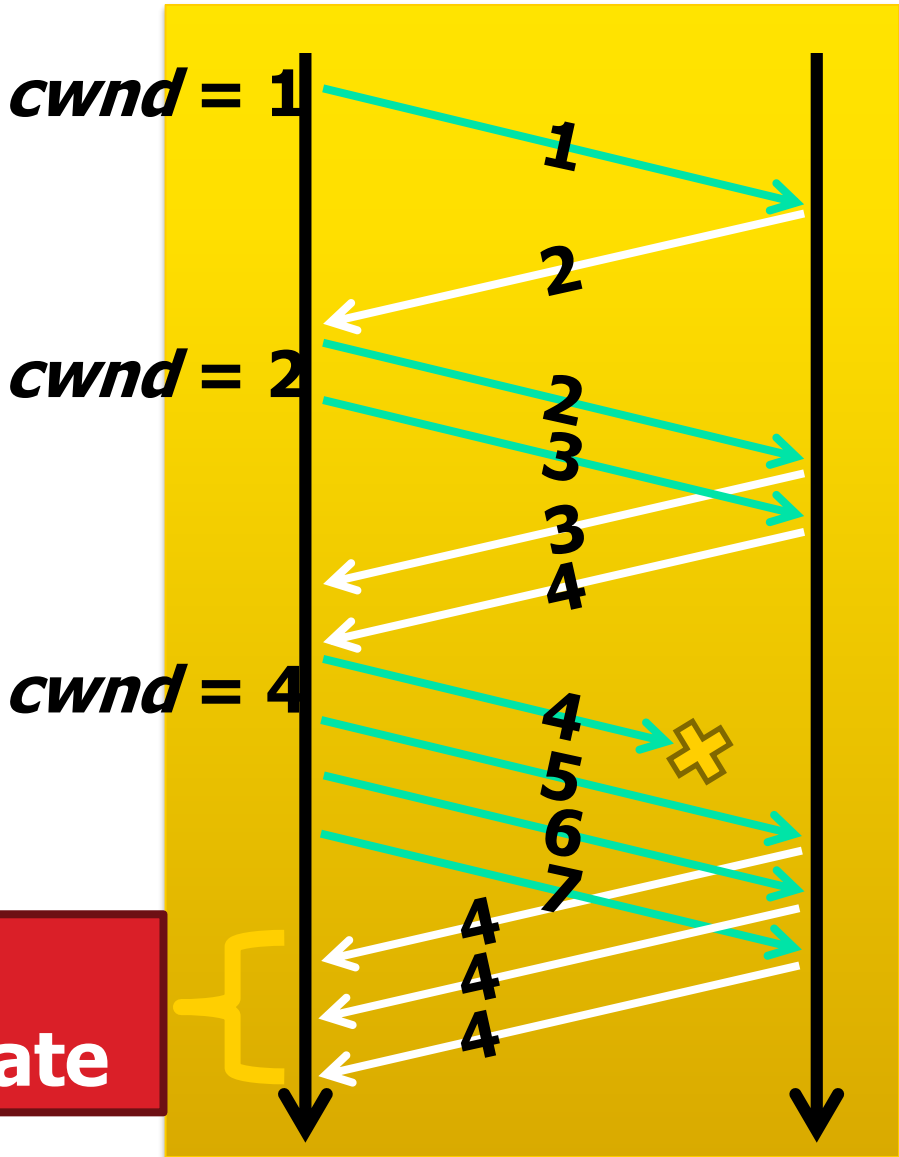

TCP Reno: Fast Recovery

- After a fast-retransmit set *cwnd* to *ssthresh/2*
  - i.e. don't reset *cwnd* to 1
  - Avoid unnecessary return to slow start
  - Prevents expensive timeouts
- But when RTO expires still do *cwnd* = 1
  - Return to slow start, same as Tahoe
  - Indicates packets aren't being delivered at all
  - i.e. congestion must be really bad

Fast Retransmit és Fast Recovery

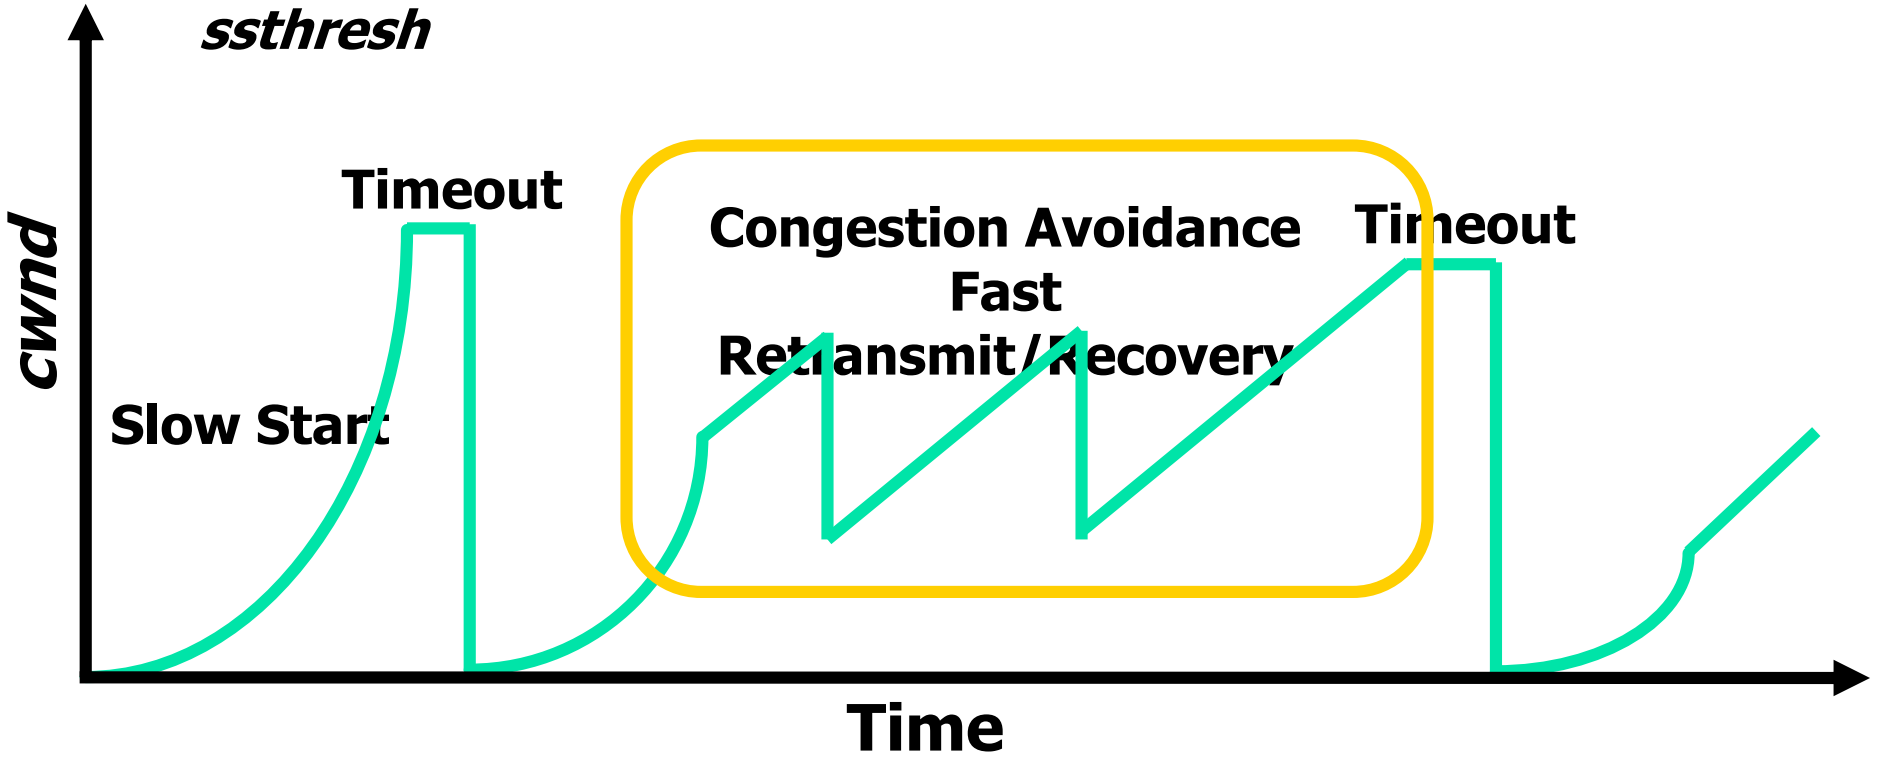

- A *cwnd* oszcillál az optimális ablak körül
- TCP mindig erőlteti a csomageldobást

Csomagvesztés – jó vagy rossz?

- Példa: DSL 10Mbit/s vonal, 2 lehetőség
  - a) x% loss vs
  - b) FEC – hibajavító kód, fix 20% adat
- TCP transport, letöltések: melyik jobb?
- a) 10Mbps – x% loss (pl. BER=10^{-6})
  - $\Rightarrow$1 csomag 1500 byte, 12000bit, minden 83.3 csomag elvész
- b) 8Mbps
  - – a hibajavító kód 20% veszteség mindig

Many TCP Variants…

- Tahoe: the original
  - Slow start with AIMD
  - Dynamic RTO based on RTT estimate
- Reno: fast retransmit and fast recovery
- NewReno: improved fast retransmit
  - Each duplicate ACK triggers a retransmission
  - Problem: >3 out-of-order packets causes pathological retransmissions
- Vegas: delay-based congestion avoidance
- And many, many, many more…

TCP in the Real World

- Manapság?
  - Nagy bandwidth-delay a jellemző, a TCP nem annyira szereti
  - Compound TCP (Windows)
    - Reno alapú
    - Két congestion window: delay és loss alapú
    - Ezért a *compound* vezérlés
  - TCP CUBIC (Linux)
    - BIC (Binary Increase Congestion Control)
    - Az ablakot egy cubic function vezérli

Amit tudni kell a TCP-ről

- Programozónak
- Hálózati operátornak

- Miért teszünk különbséget?
  - Programozóként nem érdekel a hálózat
  - Operátorként nem érdekel az alkalmazás

Programozóként…

1. Forgalom a kapcsolat kiépítésekor
   - A three-way handshake, blokkolás
2. Az adat blokkokban érkezik
   - Hacsak push/urgent biteket nem használunk (ritka)
3. TCP throughput függ az applikációtól is
   - Néha ez jó

TCP ablak

- Bandwidth delay product
- 8k – korlátos sávszélesség
  - Telítődés
- 64K
  - jobb
  - Window scale option

TCP opciók - példa

No.	Time	Source	Destination	Protocol	Length	Info
4	0.168986	192.168.0.11	239.255.255.250	SSDP	175	M-SEARCH * HTTP/1.1
5	0.221892	fe80::d0f9:8c1:d62f:eb63	ff02::1:3	LLMNR	86	Standard query 0x7e01 A isatap
6	0.000117	192.168.0.11	224.0.0.252	LLMNR	66	Standard query 0x7e01 A isatap

```
▷ Frame 12: 66 bytes on wire (528 bits), 66 bytes captured (528 bits) on interface 0
▷ Ethernet II, Src: Wistron_2d:ab:ba (00:1f:16:2d:ab:ba), Dst: 3Com_03:04:05 (00:01:02:03:04:05)
▷ Internet Protocol Version 4, Src: 192.168.0.11, Dst: 192.168.0.168
◢ Transmission Control Protocol, Src Port: 29385, Dst Port: 22, Seq: 0, Len: 0
    Source Port: 29385
    Destination Port: 22
    [Stream index: 0]
    [TCP Segment Len: 0]
    Sequence number: 0    (relative sequence number)
    [Next sequence number: 0    (relative sequence number)]
    Acknowledgment number: 0
    1000 .... = Header Length: 32 bytes (8)
  ▷ Flags: 0x002 (SYN)
    Window size value: 8192
    [Calculated window size: 8192]
    Checksum: 0x822a [unverified]
    [Checksum Status: Unverified]
    Urgent pointer: 0
  ◢ Options: (12 bytes), Maximum segment size, No-Operation (NOP), Window scale, No-Operation (NOP), No-Operation (NOP), SACK permitted
      ▷ TCP Option - Maximum segment size: 1460 bytes
      ▷ TCP Option - No-Operation (NOP)
      ▷ TCP Option - Window scale: 2 (multiply by 4)
      ▷ TCP Option - No-Operation (NOP)
      ▷ TCP Option - No-Operation (NOP)
      ▷ TCP Option - SACK permitted
  ◢ [Timestamps]
      [Time since first frame in this TCP stream: 0.000000000 seconds]
      [Time since previous frame in this TCP stream: 0.000000000 seconds]
```

Programozóként… (folyt)

4. A hálózat korlátozhatja a sávszélességet
   - Akkor gond ha nincs elég hálózati kapacitás
5. Socket opciók
   - Algoritmusok/paraméterek állítása
6. Portok újrahasználása
   - Fin bit – zárás után még nem fejeződik be a kapcsolat

Operátorként…

1. A forgalom jellege
   - Börsztös, vezérlés
2. Bottleneck detektálása
   - A forgalom nem nő ~80% fölé (aggregált)
3. Congestion control algoritmusok a routerben
   - Előre kezelik a szűk keresztmetszetet
   - Fairness elérése
4. Lossy csatornák - rádió
   - A csomagvesztést félreértelmezi

RED – Random Early Drop

- Buffer menedzsment routerben
  - Egyedi dobás jobb mint a timeout

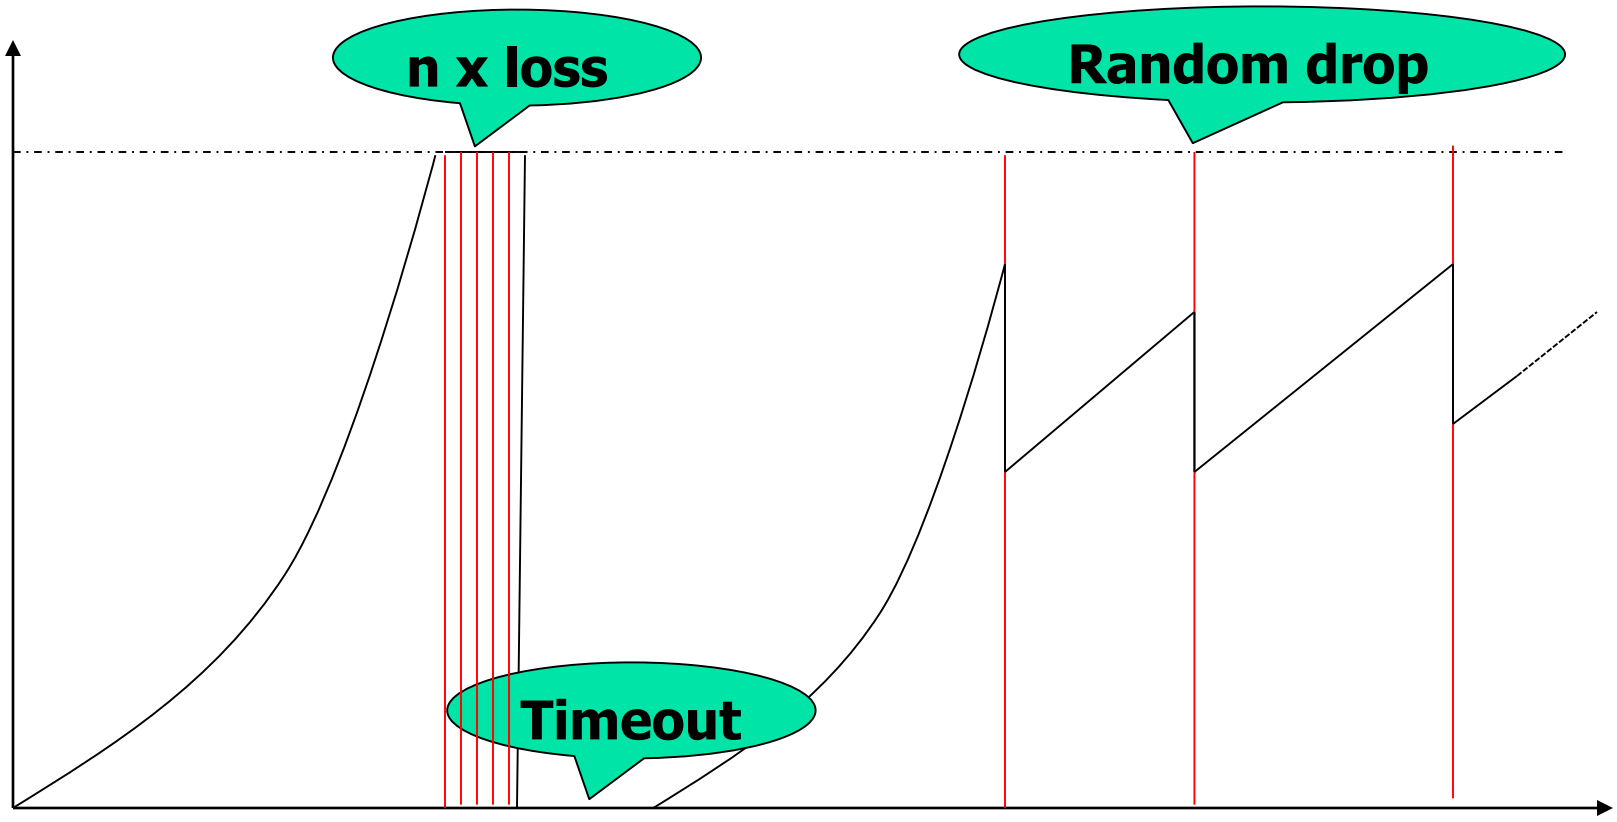

TCP - Wireless

- Hibás működés:
  - Wireless – rádiós dobás
    - Nem szűk keresztmetszet!
    - TCP félreértelmezi, csökkenti a cwnd-t
  - Megoldás
    - L2 újraküldések
    - WTCP – proxy
    - SACK – selective acknowledgements

No.	Algo.	Sender	Traffic	# conn.	Receiver	Kbytes/sec	# ovfl.
413	None	Linux 2.1	one.1024	1	Linux 2.0	1097.7 (gw)	0

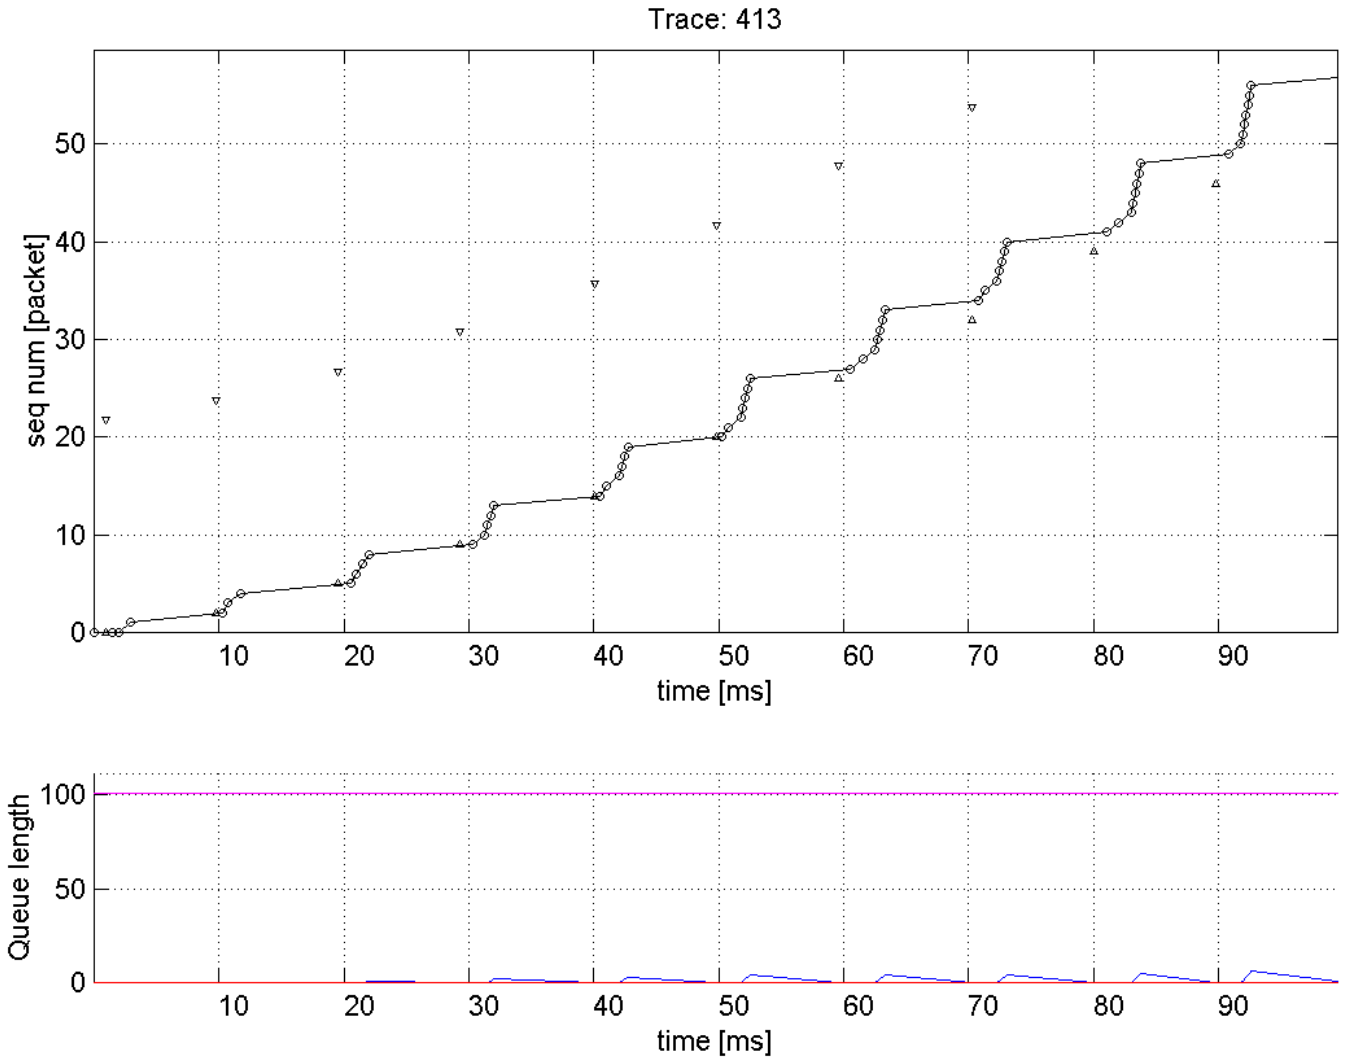

Megjegyzések

- A fogadó csak egy ACK-t küld egy csomagcsoportra
- Minden ACK érkezése a küldőnél egy csomagbörszt küldését eredményezi
- A küldő a *cwnd*-t minden egyes ACK érkezésekor eggyel növeli
- A sorok hossza növekszik a börsztök érkezésekor, a börsztök méretei pedig növekednek az idővel
- ACK érkezések 10 ms-ként

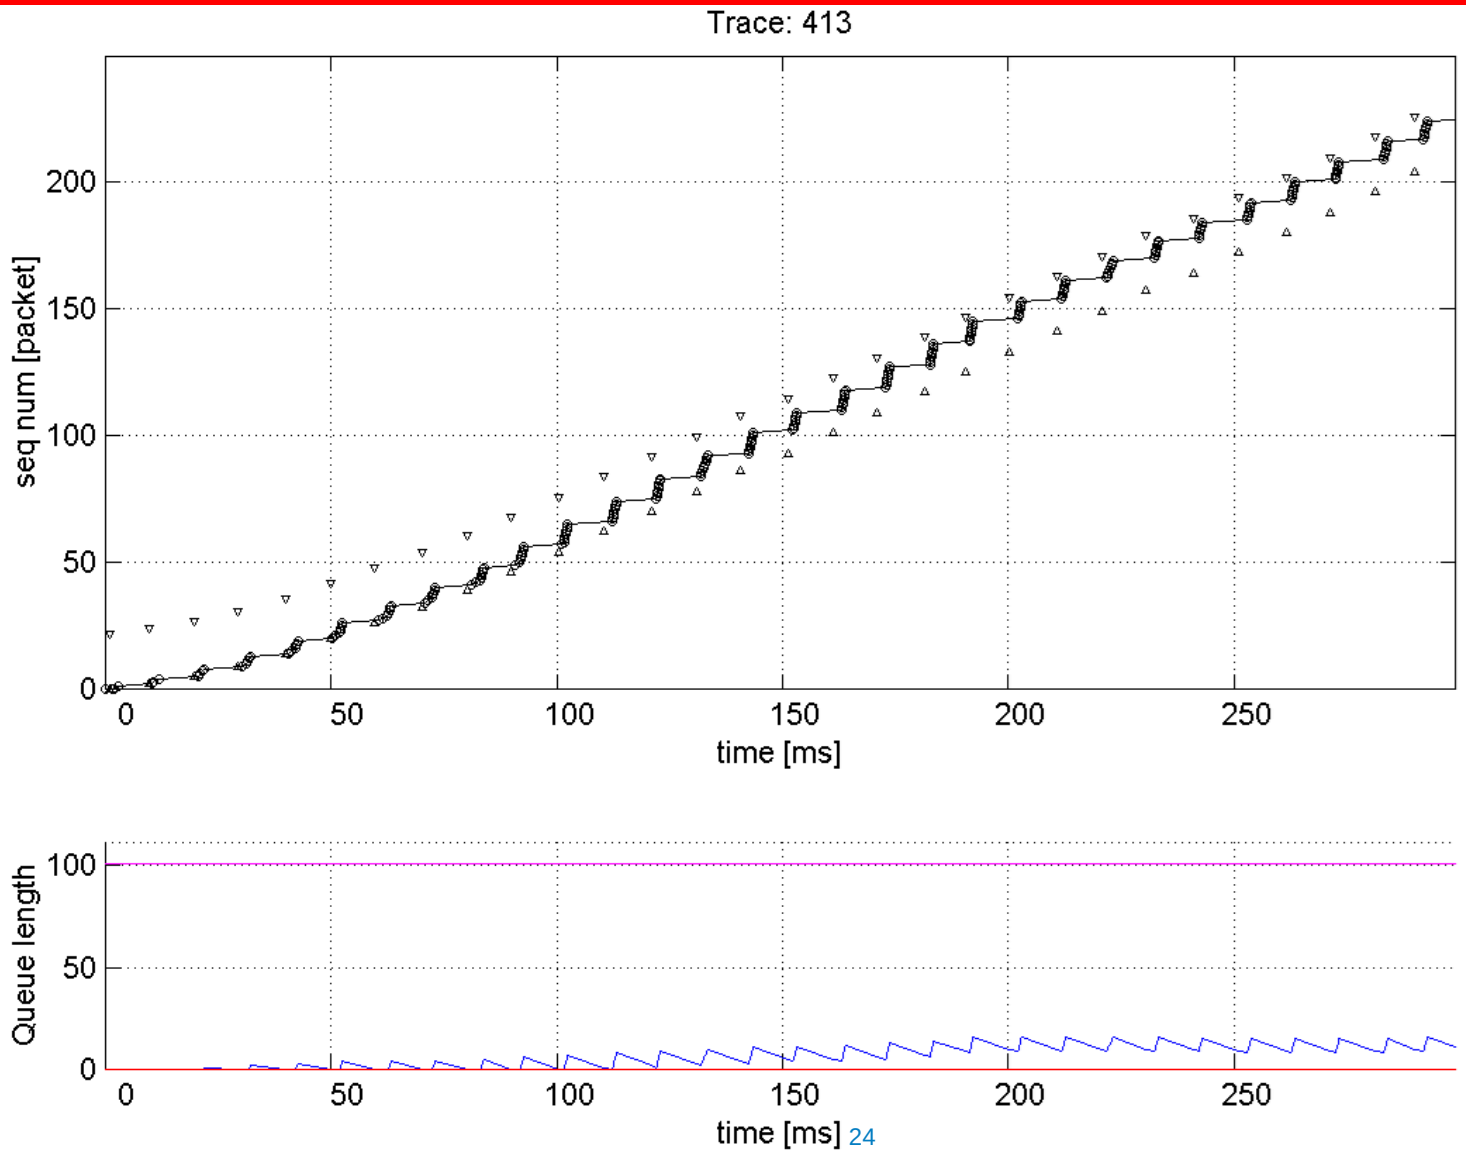
Trace: 413
seq num [packet]
time [ms]
Queue length
time [ms]
0
50
100
150
200
250

Megjegyzések

- Kb 200ms után, a küldő eléri a fogadó meghirdetett ablakméretének felső határát
- A sorhosszúság kb. 15 körül stabilizálódik
- A sorok hossza a börsztök érkezésekor növekszik – ezeket a fogadó egy-egy csomagcsoportot nyugtázó ACK-ra küldött
- A sorok hossza fokozatosan csökken függően a 10 Mbps-os Ethernet kapacitásától

Börsztös forgalom

- Ablak – gyors felfutás
  - Hatása: többszörös loss
  - Timeout
- Sok timeout – lassú kapcsolat
  - Főleg a kapcsolat elején nagy gond
  - Inkább fast retransmit kellene

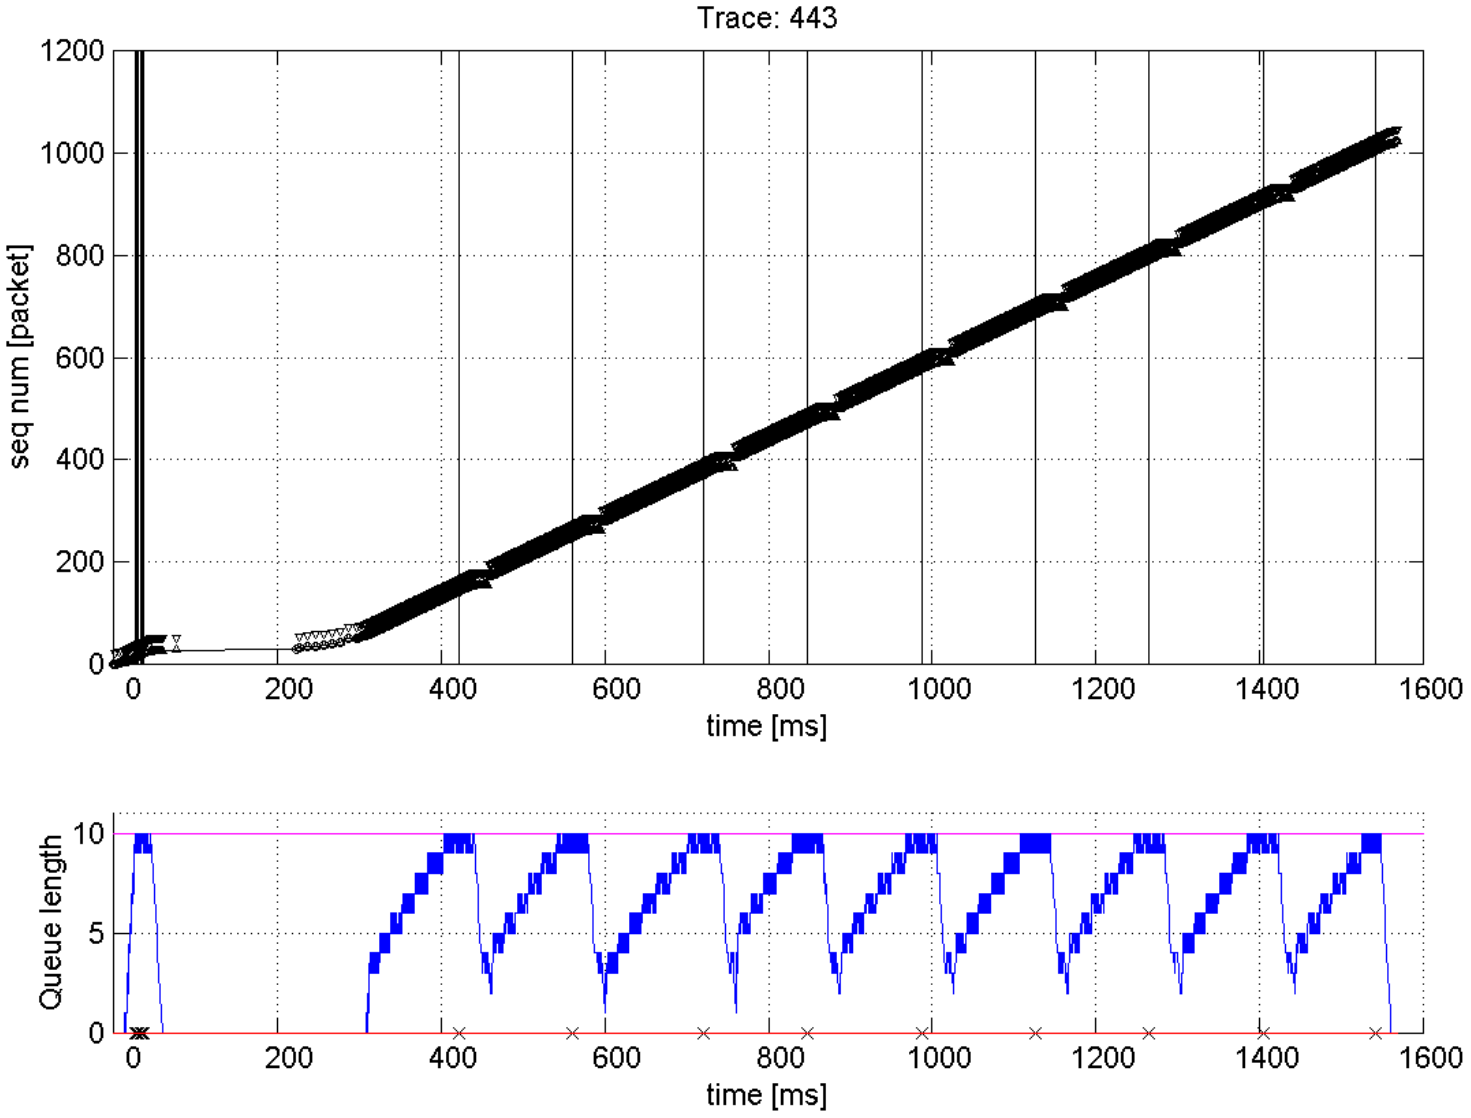
Trace: 443
seq num [packet]
time [ms]
Queue length
time [ms]

Megjegyzések

- A slow start börsztös csomagvesztéssel és az adás szüneteltetésével ér véget
- Periódikus vesztések láthatók, melyeket a küldő gyorsan javít – a vesztések nem okoznak jelentős teljesítménycsökkenést
- A sorhosszban periódikus minta van 300 ms után: lineáris növekedés, egy vesztés, egy esés. Ez mutatja a congestion avoidance mechanizmus működését a küldő oldalon: a vesztés észrevételekor csökkenti a congestion window értékét, majd ismét lineárisan (additívan) növeli

Az első 80 ms

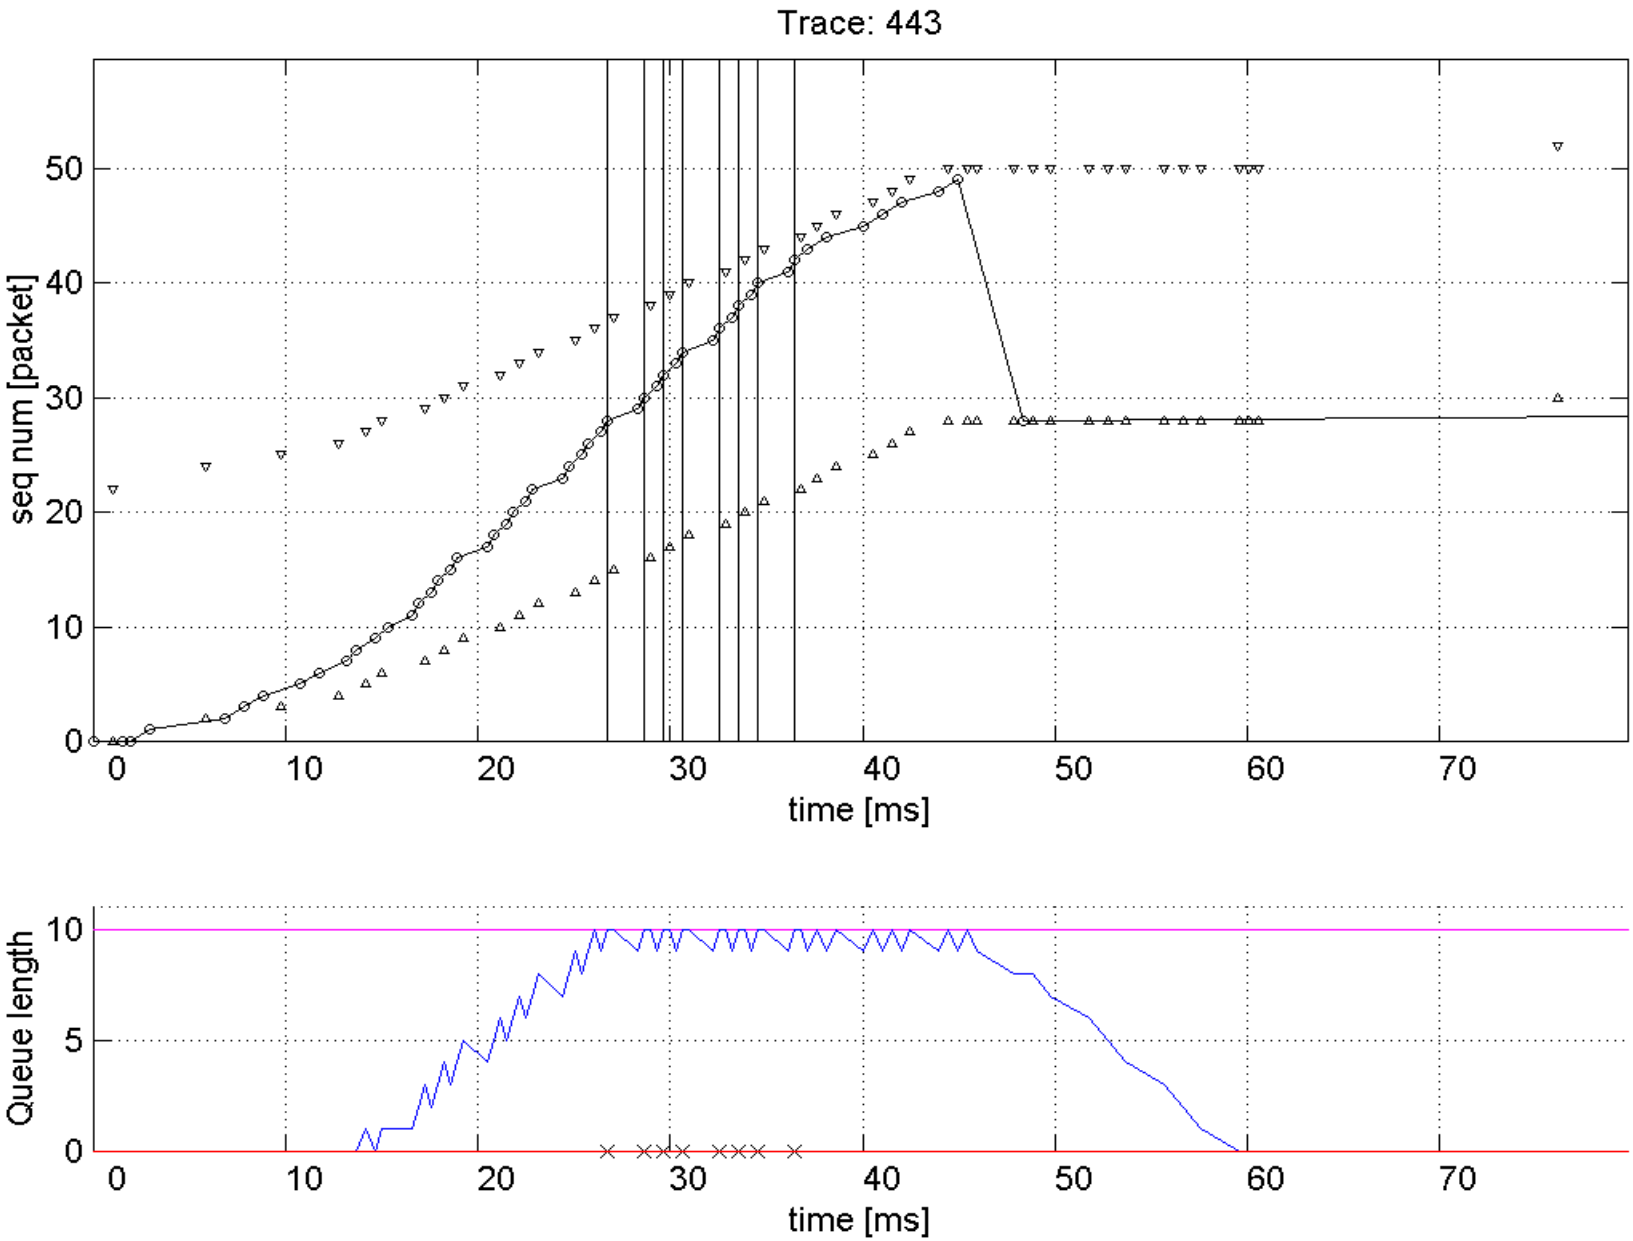

Magyarázatok

26-36ms	A fogadó felé a sorok túlcsordulnak, a csomagok eldobásra kerülnek
37-45ms	A fogadó felé menő csomagok továbbításra kerülnek, a fogadó fogadja ezeket a csomagokat, de nem nyugtázza őket, mert néhány korábbi csomag is hiányzik
44-47ms	A fogadó duplikált ACK-t küld
48ms	A küldő újraküldi az első nemnyugtázott csomagot (fast retransmit).
49-61ms	A fogadó továbbra is duplikált ACK-kat küld
76ms	A fogadó nyugtázza az újraküldött csomagokat

200 ms környéke

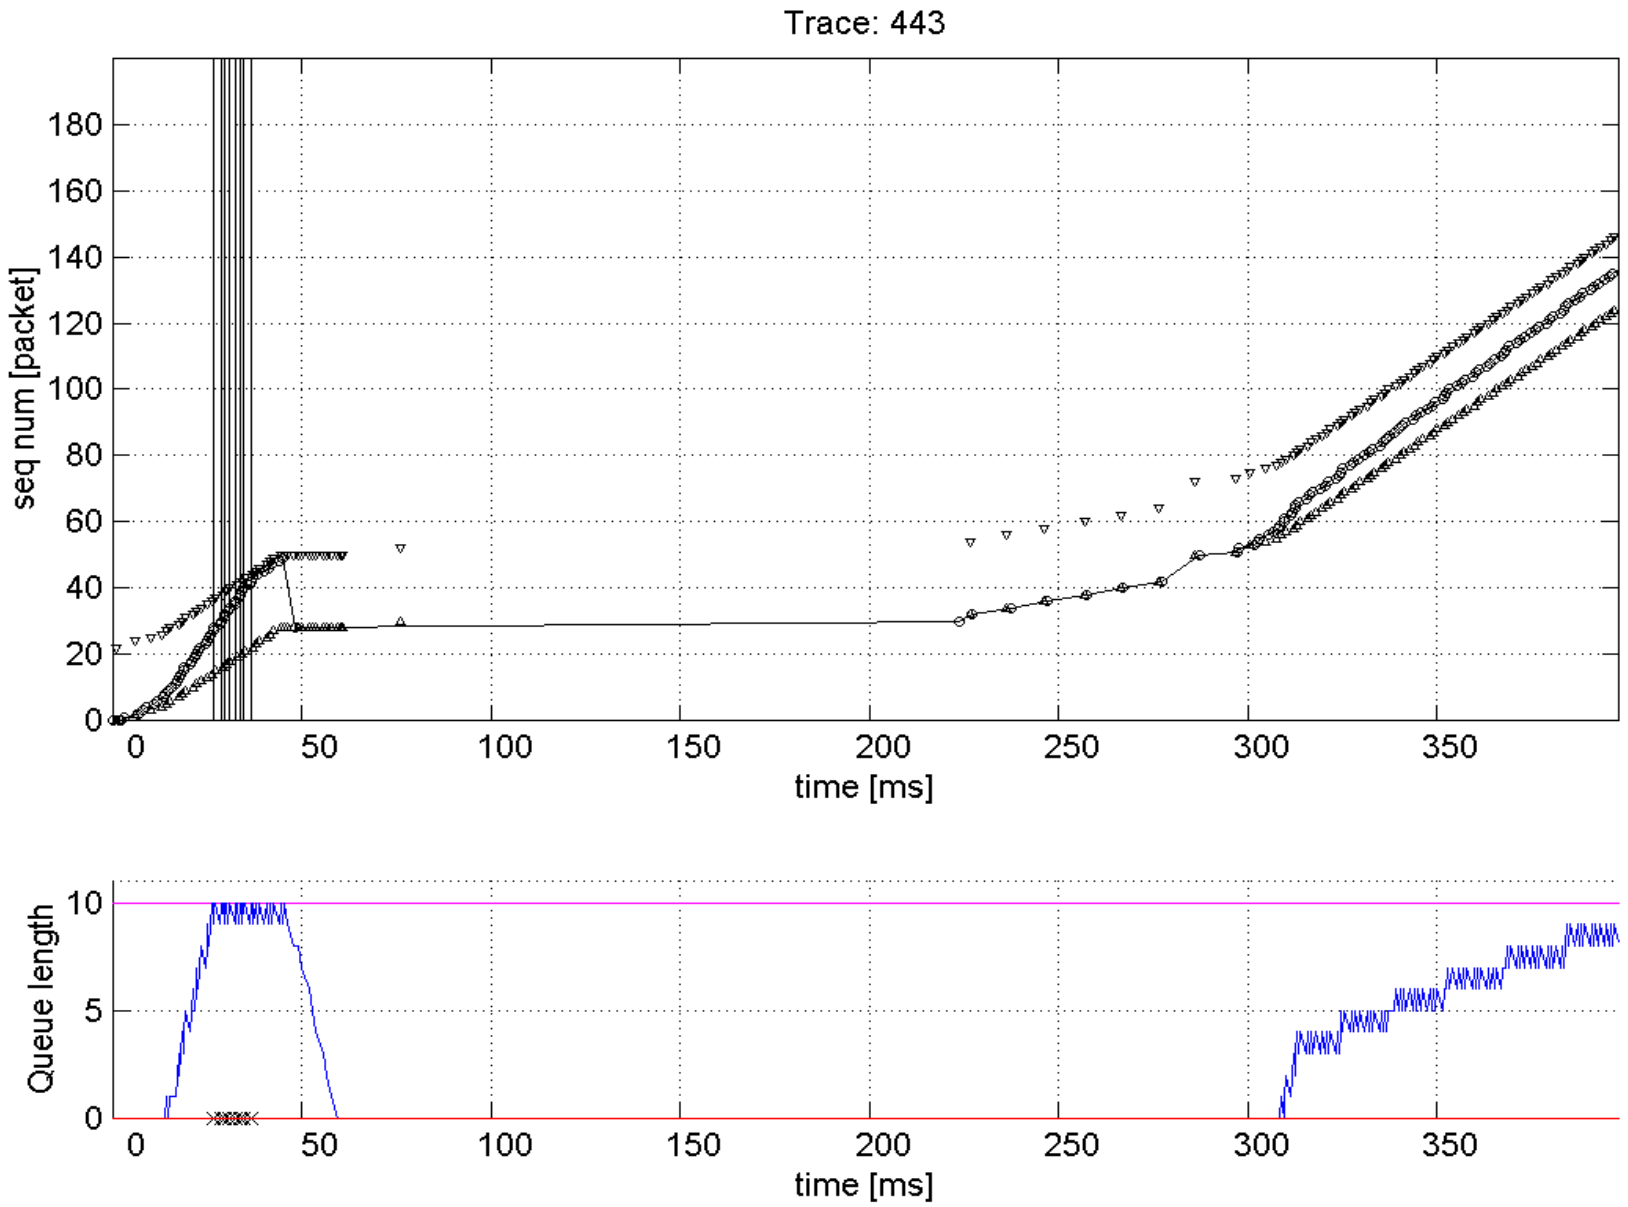

Magyarázatok

225ms	A küldő időzítője lejár és küld egy következő nemnyugtázott csomagot. Az időztés kb 200 ms
225-275ms	A küldő továbbít egy csomagot rögtön, amint a fogadó nyugtázta az előzőt. A küldő nem növeli a congestion window méretét, amíg újraküldést végez
275ms	A küldő minden elküldött adatára kap nyugtát (Az ACK számok ugrása). Slow start kezdődik.
330ms-	A gyors (exponenciális) növekedése a nemnyugtázott csomagoknak megáll és congestion avoidance szakasz következik – ez látszik a sorhossz lineáris növekedéséből

- Börsztös csomagvesztés történt
- Az első vesztést a küldő vette észre a duplikált ACK-ból, és gyors újraküldés következett
- A következő vesztéseket szintén a küldő vette észre az időzítők lejáratakor – emiatt slow start indult
- Ez a mechanizmus börsztös vesztéseknél gyakori

870 ms környéke

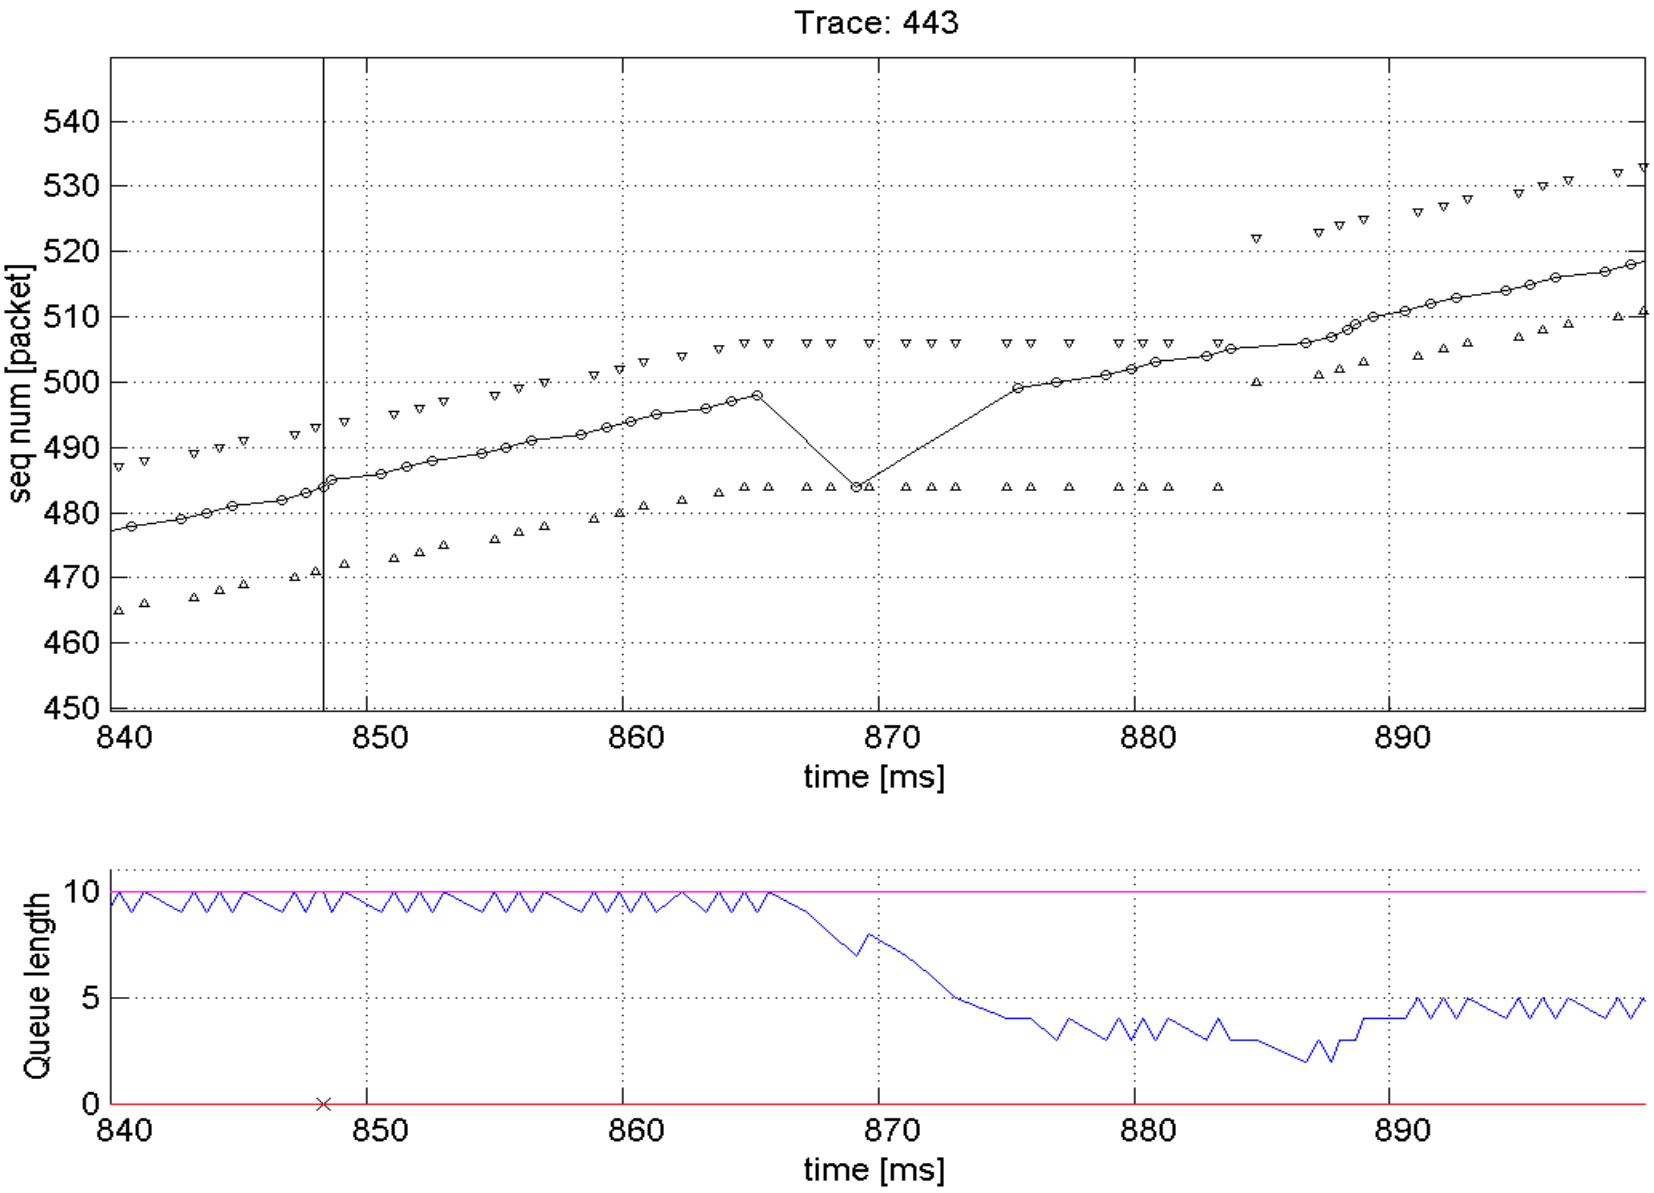

Magyarázatok

848ms	Egy csomag veszett el a közbenső sorok megtelése miatt
848-864ms	A fogadó a korábbi csomagokat nyugtázza
864-868ms	A fogadó a további csomagokat nem tudja nyugtázni, mert egy hiányzik. Emiatt a fogadó duplikált ACK-t küld
869ms	A küldő 3 duplikált ACK-t kap, majd gyors újraküldést hajt végre
875-884ms	A küldő folytatja a csomagok küldését, mivel nem érte el a fogadó advertised window méretét még.
885ms	Egy ugrás látható az ACK numberek között – a fogadó megkapta a hiányzó csomagot, és az azutániakkal együtt nyugtázta azt.
885ms-	A küldő folytatja a csomagok továbbítását (fast recovery történt: slow start nem következik most). A gyors újraküldés nem okozott nagy teljesítmenycsökkenést

Köszönöm a figyelmet

- Vége -

Budapest University of Technology and Economics

Department of
Telecommunications and Media Informatics