


Számítógépes hálózatok – 8. előadás

TCP adatforgalom

Hogyan adjunk, ha ki akarjuk használni a sávszélességet?

- Figyelembe kell venni a késleltetést is (TFTP példa)
- Akkor küldhetünk folyamatosan, ha az első csomagunk nyugtájának megérkezéséig folyamatosan adhatunk
 - A csomagfordulási idő, **RTT** – Round Trip Time korlátoz
- $\text{Sávszélesség} * \text{RTT}$ elküldött bit legyen a window
 - Az első nyugta megérkezésekor ekkor $\text{sávszélesség} * \text{késleltetés}$ úton levő bit
- Pl. 100 Mb/sec vonal, 0,01 sec RTT: 1Mbit = 125 KByte
- Pl. 100 Mb/sec vonal, 2 sec RTT: 200Mbit = 25 MByte !

Sliding window



- A nyugtázott+window sorszámig folyamatosan küldhető adat
 - Rendszerint nem tölti ki az egész window-t
- A nyugtázott+window sorszámnál nagyobb sorszámú oktet nem küldhető
- A window folyamatosan csúszik jobbra az ábrán
- A window-t a fogadó csökkentheti/növelheti
- A window mérettel a fogadó szabályozhatja a küldés ütemét
 - Flow control: az alkalmazás igényeihez igazodhat
 - Pl. a window lehet az alkalmazás által vételre felkínált buffer mérete
 - Congestion control: torlódás és csomagvesztés elkerülésére
- Egy nyugta mindig addig az SN-ig nyugtáz mindent, nem csak az utolsó csomagot
- A window nyílik, ha a jobb széle jobbra mozdul
- A window becsukódik:
 - ha a hirdetett window 0,
 - az adó kimerítette a küldhető adatmennyiséget,
 - a vevő mindent nyugtázott
- A window zsugorodik (shrinks), ha a jobb széle balra mozdul
 - Lehetséges, de ellenjavalt
 - Vannak protokollok, ahol ez lehetetlen
- Újraküldés

- Ha három ugyanolyan ACK-t kapok, onnan kezdve újraküldök
- Ha timeout (RTO) lejár, és nem kapok ACK-t

TCP nyugták




Figure 2: Csomag sorrend felcserélődés és TCP nyugták

Window scale opció

- **RFC1323**
- 3 byte-os opció a TCP fejrészben:

```
+-----+-----+-----+
| kind=3 | len=3 |shift count|
+-----+-----+-----+
```

- 2-nek a *shift count* -adik hatványa lesz a window paraméter mértékegysége
- 0 azt jelenti, hogy a window byte-okban számolandó (nincs scale)
- 3 azt jelenti, hogy 8 byte-os darabokban
- Maximum 14 a megengedett = $2^{30} = 1G$
- A SYN flag-gel együtt küldhető a three-way handshake során
- Akkor él, ha a SYN/ACK-ban is megismétli a partner
- Lehet különböző a két irányban

Delayed ACK

- A TCP réteg nem feltétlenül küld nyugtát, ha tud
 - Legalább 40 byte-ot kell küldeni!
- Egy timer lejártát megvárja, hátha addig lesz:
 - elküldendő adat, amivel „mellékesen” nyugtáz: piggyback nyugta
 - újabb bejövő adat, amit nyugtázhat.

ACK generálás

Esemény	Akció
A nyugtázotthoz, és vett sorszámmal képest folyamatosan jön egy szegmens	Késleltetés. Ne küldj ACK-t, még 200 ms-ig.
A vett sorszámmal képest folyamatosan jön egy szegmens, van már nyugtázni való (timer ketyeg)	Azonnal küldj ACK-t, csúsztasd a window-t.
A vett sorszámmal összevetve kimaradást jelző sorszámmal jön csomag	Azonnal küldj ACK-t az előző csomagot nyugtázva (duplicate ack).
Egy lyukból eddig hiányzó, a lyuk aljához illeszkedő csomag érkezik	Azonnal küldj ACK-t.

TCP Retransmission timeout (RTO): a nyugtázatlan csomag újraküldésének időzítése

- Ha túl rövid, felesleges újraküldés történik
- Ha túl hosszú, nagy csuklást okoz egy csomag elvesztése
- **RTT** – Round Trip Time
 - TCP szegmens újraküldésénél ez határozza meg a timeout-ot
 - Egy szegmens elküldése és a hozzá tartozó ACK megérkezése közti idő
 - Időben változik, sok mindentől függ
 - Átlagot érdemes venni
- Exponential Backoff: ha újraküldünk, az RTO-t duplázzuk, egy határig (jellemző érték: 9 perc)

Hogyan függ az RTO az RTT-től ?

- $Becsült-RTT = a * Becsült-RTT + (1-a) * Mért-RTT$, ahol $0 < a < 1$
- $RTO = b * Becsült-RTT$, ahol $b > 1$
- Tipikus értékek: $a = 0.9$, $b = 2$
- Ravaszágok
 - a nem konstans: ha hirtelen nő a $Mért-RTT$, legyen kisebb: gyorsabban vegyük figyelembe a romlást
 - Karn algoritmus:
 - Ha ismételtünk egy csomagot, az arra jövő ack-ból ne számoljunk RTT-t
 - Nem tudhatjuk, hogy az ismételt csomagra jött, vagy az eredetire
 - Ha ismételtünk egy csomagot, az RTO-t ne módosítsuk (most dupláztuk exponential backoff miatt!), míg ismétlés nélkül nem csikarunk ki ack-t

Interaktív adatforgalom

- Kis csomagok
- Lehetőleg azonnali echo
- TOS: minimize delay
- Nagy a csomagokon az overhead: sokszor 1 byte-on 40, ráadásul a nyugta!

Nagle algoritmus

- Probléma: a lassú vonal végén ülő felhasználó gépelésével mindig újabb csomagokat generál
 - Ha torlódnak a csomagok, ezzel tetézi a bajt
- **RFC896**
- Nem küldünk újabb csomagot, bufferelünk, míg van nyugtázatlan kintlevő csomag
- Timeout után mindenképpen ürítünk
- Önszabályozó: ha gyors a hálózat, nincs is hatása
- Egyes alkalmazásoknál hátrányt jelent
 - X terminálok
 - Több karakteres vezérlőszekvenciák (pl. PF gomb)
 - Ki lehet kapcsolni (klasszikus mondás: `TCP_NODELAY`)

Torlódás kezelése

- Számítani kell rá, hogy sok eszközön megy át a csomag, amiket túlterhelhetünk, csomagokat dobhatnak el
- Ha bambán újraküldünk: növeljük a bajt, a túlterheltséget
- Congestion control: mit csinálunk, ha torlódás lett
- Congestion avoidance: mit csinálunk, hogy elkerüljük a torlódást
- Összefoglaló: **RFC2581** TCP Congestion Control
 - Az egyik szerző R.W. Stevens
 - Újabb változat **RFC5681**
- Nem csak a technológia tanulságos, hanem a szemléletmód is: a congestion avoidance a szolidaritásra szép példa (ahogy a DNS a szubsidiaritásra)

Slow start

- Nem csak a fogadó, a küldő is flow controlt alkalmaz
- Congestion window: a hálózat kímélése érdekében bevezetett ablak
 - A küldő becslése, a TCP masina belső változója: *cwnd*
 - A receive window és a congestion window jobb szélének minimuma határozza meg, hogy küldhetek-e csomagot
- Kezdetben a Congestion window (klasszikusan) 1 MSS méretű
 - Lehet 10 MSS, sőt van javaslat még nagyobbra
- Minden ack-zott szegmens 1 MSS-sel növeli a *cwnd*-t
 - Ideális esetben a *cwnd* nem korlátoz
 - A vevő képességét, illetve a hálózati kapacitást teljesen kihasználva tömjük a hálózatot
- Slow start alatt az átvitel exponenciálisan nő
- A slow start alkalmazásával elkerüljük, hogy azonnal bajt okozunk
- Ha torlódást észlelünk, a congestion avoidance algoritmus jut szóhoz





Figure 3: TCP slow start

Congestion avoidance

- Congestion avoidance-nál a *cwnd*-t 1 szegmensnyivel növeljük minden RTT alkalmával
 - lineáris növekedés
- Additive increase, multiplicative decrease (AIMD)
- Bevezetünk egy új változót: slow start threshold, *ssthresh*
 - Kezdetben a receiver window
- Slow startot alkalmazunk, ha $cwnd < ssthresh$, congestion avoidance-t különben
- Ha congestion-t észlelünk (RTO, vagy tripla ack), akkor
 1. Újraküldjük a szegmenst (fast retransmit)
 2. A nyugtázatlan_byte-ok/2-re, de legfeljebb 2 MSS-re csökkentjük *ssthresh*-t (multiplicative decrease)
 3. Ha RTO történt, akkor slow start-tal indítunk: $cwnd = 1$
 4. Ha tripla ack, akkor $cwnd = ssthresh + 3 * MSS$



Fast retransmit és fast recovery

- Ha a küldő tripla ACK-kat kap ugyanarra az sequence numberre, akkor congestion-ra következtet
- Nem várja ki az RTO-t, hanem újra küld: ez a fast retransmit
- Ez után nem kezd előlről a Slow Start szerint, hanem a congestion avoidance algoritmust alkalmazza ($cwnd=sssthresh+3MSS$): ez a fast recovery




Figure 5: TCP forgalom kisimitas (Forras: Tanenbaum konyv)

RED: Random Early Detection

- A TCP congestion control eljárások egészségesebbé tették az internetet
 - A TCP kapcsolatok „reagálnak” a torlódásokra
 - Megszűnt a 80-as években előforduló „congestion collapse”
- A hálózat belsejében is lépéseket kell tenni:
 - Active queue management a routerekben
- **RFC2309**: Internet Performance Recommendations
- Első megoldás
 - A router queue-kat kezel egyes interfészeihez
 - Ha a queue-ba már nem fér egy csomag, eldobja
 - Hátrányok:
 - Egyes kapcsolatok monopolizálhatják az erőforrásokat
 - Ha beáll egy telítettség, nehéz kivergődni belőle
 - Újabb lökések tovább rontják a helyzetet
- Arra kell törekedni, hogy tartósan kicsik legyenek a Q-k
 - Úgyis lesznek lökések, amiket el kell viselni
 - Interaktív kapcsolatoknál a hosszú Q-k kibíráhatatlanok a nagy késleltetés miatt
- RED működés:
 - Minden csomagot bizonyos valószínűséggel eldobunk
 - A valószínűség annál nagyobb minél nagyobb volt az elmúlt időszakban a Q hossza
 - Egy-egy eldobott csomag nem okoz nagy gondot, de zsinórban eldobott sok csomag igen
 - Le tudunk lassítani minden adatfolyamot, flow-t
 - Folytonosan mérjük az átlagos Q hosszt
 - A régebbi időket exponenciálisan kisebb súllyal vesszük figyelembe
 - A hossz mértékegysége csomag, de byte is lehet
 - Változók: minimum (m) és maximum (M) küszöb, $0 < maxp < 1$
 - Ha a Q mért hossza m -nél kisebb, nem dobunk el csomagot, ha M -nél nagyobb minden csomagot eldobunk
 - Ha a kettő közt van akkor a mért hosszal arányos 0 és $maxp$ közti valószínűséggel dobjuk el a csomagot
- WRED - Weighted RED: vannak „egyenlőbb” csomagok: valamilyen szempont szerint bizonyos csomagokat kevésbé valószínűen dobunk el
 - IP címek
 - Protokoll
 - TOS
 - ...

Persist timer

- Ha a fogadó bufferei elfogytak, bezárja a window-t
- Ha újra tud fogadni, nyitja: ACK megismételt acknowledgement numberrel, de nem 0 window-val
- Mi van, ha ez az ACK elvész?
 - A fogadó nem tudhatja, hogy van-e még a küldőnek mondandója
 - A küldő próbálkozik: küld egy 1 byte-os csomagot (hite szerint window-n kívül!) (window jobb széle után)
 - Ezt ismétli persist timer-enként
 - A persist timer exponenciálisan nő (Exponential Backoff)
 - Tipikusan 1,5 sec-ről indul, 1 percnél nem lesz nagyobb

Silly window szindróma

- Ha a vevő oldalon kicsi (akár 1 byte) szabadul fel, lehet 1 byte a window

- A küldő 1 byte-ot küld, a vevő megint 1 byte-tal nyit é.í.t.
- Erőforráspocsékolás
- Elkerülésére
 - A vevő nem nyitja a window-t, csak akkor, ha MSS nagyságrendűt nyithat
 - A küldő nem küld, hacsak
 - MSS-nyit küldhet
 - Mindent küldhet, amit az alkalmazás kért
 - Feltéve, hogy Nagle ezt nem tiltja (nem vár ACK-t, és Nagle nincs kikapcsolva)

Keep-alive timer

- TCP kapcsolatok eredendően nem bomlanak forgalom hiányában sem
 - Akár hónapokig „élve” maradnak
 - Közben a middlebox-okat újraindíthatták, átkonfigurálhatták, akár kicserélhették
- Az eredeti szándék szerint az alkalmazások használhatnak „AYT” (Are You There) mechanizmust
- Mégis divatba jött a keep-alive mechanizmus
- **RFC1122** leírja, bár ellenjavallva
 1. Feleslegesen lebonthat később még használható kapcsolatokat
 2. Feleslegesen hálózati erőforrásokat használ
 3. Kidobott pénz, ha forgalom után fizetünk
- **RFC1122** megengedi, hogy opcionálisan használni lehessen
- Keep-alive time: jellemzően 2 óra, általában rendszerparaméter
- Ha egy kapcsolat keep-alive ideig néma, akkor a mechanizmust alkalmazó oldal
 - Küld egy próba csomagot
 - Jellemzően 0 adattal, a küldött utolsó sorszámú SN-nel
 - Ez window-n kívül lesz! (window bal széle előtt)
- A másik oldal erre ACK-t küld

Wireshark és TCP

- A wireshark nagyon alkalmas arra, hogy sok TCP-vel kapcsolatos dolgot megértsünk, felfedezzünk
- Follow tcp-stream → tcp streamgraph → Stevens




Figure 6: TCP slow start - Stevens graph

Szerző: Pásztor Miklós, Máray Tamás