





SZÁLLÍTÁSI (TRANSPORT, HOST-TO-HOST) PROTOKOLLOK

UDP és TCP

Dr. Simon Vilmos
adjunktus

BME Hálózati Rendszerek és Szolgáltatások Tanszék
svilmos@hit.bme.hu

2013.Április 16.



A TCP/IP architektúra és az ISO/OSI rétegmodell

ISO/OSI

Alkalmazás
Megjelenítési
Viszony
Szállítási
Hálózati
Adatkapcsolati
Fizikai

TCP/IP

Alkalmazás
Szállítási / Host-to-host (TCP/UDP/...)
Internet (IP)
Hálózati interface/ Hálózati hozzáférési

TCP/IP+IEEE 802

Alkalmazás
TCP/UDP/...
IP
LLC
MAC
PCS & PMA
PMD

IP: Internet Protocol

TCP: Transmission Control Protocol

UDP: User Datagram Protocol


LLC: Logical Link Control

MAC: Medium Access Control

PCS: Physical Coding Sublayer

PMA: Physical Medium Attachment


PMD: Physical Medium Dependent



A hálózati és a szállítási réteg

- *hálózati réteg*: végpontok („host”-ok) közötti logikai kapcsolatok
- *szállítási réteg*: alkalmazások (process) közötti logikai kapcsolatok
 - a hálózati réteg szolgáltatásainak igénybevételére alapozva **megbízható** átvitel a **transzport entitások** között (transport entity)
 - Feladatai:
 - forgalom szabályozás
 - multiplexelés
 - hibadetektálás, javítás (pl. Automatic Repeat reQuest – ARQ)
 - sorrendhelyes átvitel
 - csomagképzés (szegmensek) és csomagok visszaállítása a felsőbb rétegek számára
 - byte alapú átvitel

A szállítási réteg



Logikai kapcsolatok a
végpontokban futó
alkalmazások között

A szállítási protokollok a
végpontokban futnak, a
csomópontokban nem

Az alkalmazások
adategységeit szállítási
protokoll-adategységekbe
tördeljük, a kapottakból
pedig összerakjuk


- **UDP – User Datagram Protocol**
- **TCP – Transmission Control Protocol**

- Az UDP és TCP közös képességei:
 - Portok kezelése
 - Multiplexelési képesség

- Alapvető különbség az UDP és a TCP között:
 - o UDP összeköttetésmentes (connectionless),
 - o TCP összeköttetés-alapú (connection-oriented)transzport-szolgáltatást nyújt

Az UDP és TCP közös képességei (1)


- Portok kezelése:
 - Az IP-rétegben a csomagok végpontnak, „host”-nak vannak címezve
 - A végpontokon belül: több alkalmazás, folyamat
 - Megkülönböztetésük: portok használatával
 - **Foglalt** (reserved, „well-known”) és **rendelkezésre álló** (available) portszámok
 - Foglalt portok: ide mindig lehet küldeni datagrammokat
 - 0...1023 közötti portszámok
 - pl. 80: HTTP, 21: FTP, 69: TFTP (ezek főként TCP-re)
 - Az UDP-en belül megállapításra kerülnek az alkalmazandó portszámok
- Multiplexelés /demultiplexelés
 - A portmechanizmus segítségével



Az UDP és TCP közös képességei (2)

Multiplexelés és demultiplexelés


Példa:




Multiplexelés-demultiplexelés




= socket



= process





Socket: magyarázat


- Socket: interfész, „ajtó” az alkalmazás és a hálózat között
- A socket-et az alábbiak jellemzik:
 - transzportprotokoll (UDP v. TCP)
 - saját IP cím
 - saját portszám

} helyi socket cím


 - *(opcionális) távoli host IP címe*
 - *(opcionális) távoli alkalmazás portszáma*


} távoli socket cím

} socket pár
- Leegyszerűsítve: socket = IP cím + portszám
- Az operációs rendszer a bejövő IP csomagokat a fentiek alapján továbbítja az alkalmazásnak, kiszedve ezeket a megfelelő PDU-kból



Socket: illusztráció






Socket típusok

- Datagramm socket
 - Összeköttetésmentes socket, UDP használja


- Stream socket
 - Összeköttetés-alapú socket, TCP használja

- Raw (IP) sockets
 - Routerekben és hálózati eszközökben
 - Pl. ICMP, IGMP, OSPF

Multiplexelés-demultiplexelés, összeköttetésmentes eset (UDP)



Multiplexelés-demultiplexelés, összeköttetés-alapú eset (TCP)




TCP kliens-szerver socket kezelés

- Szerver létrehoz „**hallgató**” **módban** lévő socketeket
 - várja a kliensek kapcsolatfelvételét
 - ilyenkor távoli cím: 0.0.0.0, távoli port: 0
- Kapcsolatfelvétel után: **dedikált socket** minden kapcsolathoz
 - Socket-socket közötti virtuális áramkörkapcsolás: TCP kapcsolat, duplex byte folyam
- Szerver különböző TCP socketeket hozhat létre ugyanazzal a helyi IP címmel és port számmal
 - mivel a távoli host IP címével, portjával **más socket párt alkot**
 - szerver gyerek processz összerendelése a kliens processzával
- UDP-ben **nincs dedikált socket**
 - Nincs külön gyerek processz minden távoli processzhez, egy processz kommunikál velük

És ahol nincs transzport réteg implementálva?

- Egyes hálózati elemekben nincs implementálva a transzport réteg
 - Router hálózati rétegben
 - Switch adatkapcsolati rétegben
- De tűzfalak, NAT-ok és proxy szerverek figyelik az aktív socket párokat és fenntartanak socket interfészeket
- Továbbá: ütemezéshez (WFQ), QoS támogatáshoz routerekben a csomagfolyamokat a socket párokkal lehet azonosítani




Megoldás: Egyszerű (raw) socket


- **Közvetlenül** az alkalmazásnak továbbítja a csomagot a **fejléccel**
 - Nincs TCP/IP feldolgozás, alkalmazás látja el fejléccel/veszi le a fejléct
 - Pl. routerekben ICMP-hez
- Windows XP-ben 2001-ben jelent meg: biztonsági aggályok (Unixban régóta)
 - Félelem **TCP reset támadástól**: „lelövi” a TCP kapcsolatot
 - +: gyanús kapcsolatok megszakítása
 - -: harmadik fél beékelődve megszakítja a kapcsolatot
 - +/- ? Peer-to-peer forgalom szűrése (Comcast-NNSquad eset)

UDP (User Datagram Protocol)

- Nincs kapcsolatfelépítés, kézfogás
- Semmi garancia:
 - a csomagok sorrendjére
 - adatintegritására
 - elvesztésének detekciójára
- A megbízható átvitel garantálását az alkalmazási rétegre bízza
- *Unreliable* Datagram Protocol 😊
- Multiplexálást és opcionálisan adatintegritás ellenőrzést nyújt




UDP – User Datagram Protocol (2)



- **Source port** opcionális
- **Length**: oktettben, max (65 535-8-20)
- **Checksum**: opcionális (nincs: 0, IPv6-nál már nem opcionális)
- Az UDP checksum az egyetlen lehetőség annak ellenőrzésére, hogy a datagram helyesen érkezett-e meg
 - adatra és fejlécre!
 - az IP-csomag ellenőrzése csak a fejrészt fogja át

UDP – User Datagram Protocol (3)


- A checksum számítási elve
 - 1-es komplement 16 bites szavakra
- Tartalmazza az IP-címeket is
 - annak ellenőrzésére, hogy a datagramm elérte a helyes címzettet, nemcsak a helyes portot
- „Pseudo-header” hozzáadásával (IPv4-re):



UDP – User Datagram Protocol


Összefoglalás: funkcionalitás és a költsége

- Portkezelés
 - a különböző alkalmazások/folyamatok megkülönböztethetők
- Több alkalmazás egyidejű kezelése
 - port-hozzárendeléssel és multiplexeléssel/demultiplexeléssel
- Hibajelzés az UDP datagram tartalmára és az IP csomag további részeire
- A fentiek költsége:
minimum 8 oktettnyi overhead



UDP alkalmazása

- Broadcast, multicast (TCP nem képes rá)
- Média: streaming, valós idejű játékok, VoIP, IPTV
- Gyors és rövid lekérdezések:
 - DNS
 - DHCP
 - RIP
- Tipikusan a hálózati forgalom pár százaléka
 - De növekszik a részaránya és nincs torlódás szabályozás: aggályok!
 - Datagram Congestion Control Protocol (DCCP)




TCP –Transmission Control Protocol

Fő jellemzői

- **Célkitűzés:** megbízható szállítási szolgáltatás nyújtása az IP nem megbízható datagram-szolgáltatásán


- **Jellemzői:**
 - ***Virtuális összeköttetések:*** összeköttetés épül fel és marad fenn a kommunikáció tartamára
 - ***Stream-típusú szolgáltatás:*** byte- (oktett-) streamek sorrendhelyes átvitele
 - ***Strukturálatlan stream:*** nincsenek határolók a streamen belül
 - ***Pufferelt átvitel:*** a streamből a datagramm megtöltéséhez szükséges mennyiséget várja össze
 - ***Duplex kapcsolatok:*** két független stream
 - ***Vezérlő információk küldése:*** az ellenkező irányban folyó streambe ágyazva (piggybacking)



TCP – Transmission Control Protocol

Miről lesz szó?


- **Adategység:** szegmens; szegmensstruktúra
- **Megbízható átvitel** sorszámozás és pozitív nyugtázás segítségével
- Összeköttetés-alapú kommunikáció: **kapcsolatfelépítés és -lebontás**
- **Forgalomszabályozás** (flow control) ablakmechanizmus segítségével
- **Torlódásvezérlés** (congestion control)




TCP kialakulása

- 1974: "*A Protocol for Packet Network Interconnection.*" Vint Cerf és Bob Kahn
- Itt vezetik be a *Transmission Control Program*-ot, ez válik szét később TCP-re és IP-re
- Eleinte Internet Protocol Suite, majd TCP/IP elnevezés

A PDU – Protocol Data Unit (a TCP-ben: „segment”) struktúrája




- **Sequence no.:** a szegmensben levő adat első byte-jának pozíciója a küldő byte stream-jében
- **Ack no.:** annak a byte-nak a sorszáma, amelyet a forrás legközelebb vár




TCP – Transmission Control Protocol

Szegmensformátum (folyt.)




- **HLEN**: fejléc mérete, minimum 20 byte, max 60 byte
- **Code bits** (flags): URG, PSH, ACK, RST, SYN, FIN bitek a kapcsolat kezeléséhez használt jelzőbitek
- **Window**: a küldő ismertté teszi a **vételi pufferének méretét**
- **Checksum**: mint az UDP-ben (pseudorandom)
- **Urgent pointer**: ha URG=1, a szegmens „urgent” részt tartalmaz, ilyenkor a végére mutat (pl. jelszóküldés)




Hívásfelépítés a TCP-ben

„3-way handshake” eljárás (3 utas kézfogás)





Elején véletlenszerű sorszám: a TCP sorszám predikciós támadás elkerülése




Híváslebontás a TCP-ben


„Modified 3-way handshake” eljárás





Sorszámok és nyugtaszámok használata a TCP-ben








Várakozás nyugtázásra

- Várakozás ACK-ra: **time-out**
- Mekkora válasszuk a time-out-ot?
- Probléma a túl kicsivel és a túl nagygal
- Megoldás:
a teljes terjedési időhöz
(RTT - round-trip time) igazítani, **adaptív**vá tenni
- Szabályok arra, hogy mit tegyünk, ha nem jön ACK a time-out alatt

Újraküldési esetek a TCP-nél: elveszett nyugta és korai timeout



Újraküldési esetek a TCP-nél: összevont nyugta




Gond összevont nyugtával

- Pl. 1000 bájt kerül elküldésre 10 szegmensben
 - Ha elveszik az első szegmens, a fogadó nem tudja visszajelezni, hogy 100-999 megjött, de 0-99 nem
 - Újra elküldi a teljes 1000 bájt
- Megoldás: **szelektív nyugtázás**
 - SACK-ban meg tudja mondani, hogy 100-999 megjött sikeresen
 - Opcionális fejrészmezőben
 - Népszerű, minden TCP implementációban


Gond sorrend keveredéssel

- Sorrendkeveredés miatt elveszett csomagnak hiszi a küldő
->újraküldés->forrás visszafogás
- Megoldás: **D-SACK (duplikált nyugta)**
 - Fogadó szól, hogy az újraküldött csomag duplikátum
->visszagyorsul a forrás





Fast retransmit (1)

- A **time-out idő** gyakran **túl hosszú**:
 - nagy késleltetés mielőtt az elveszett csomagot az adó újra tudná küldeni.
- De hogy értesülhetne az elveszett csomagról előbb, mintsem hogy letelt volna a timeout?
 - Az elveszett szegmensekre utalhatnak a duplikált ACK-ok
 - Ha a vevő hézagot vesz észre a vett szegmensek sorozatában (elveszett csomag) akkor újból lenyugtázza a megelőző helyesen vett szegmenst.
 - Több egymást követő duplikált ACK érkezhethet.
- **Fast retransmit szabály**: ha az **adó 3 egymást követő ACK-t kap** ugyanarra a szegmensre, feltételezi, hogy az azt követő szegmens elveszett és
 - **újraküldi azt még mielőtt lejárna a timeout.**




Fast retransmit (2)






Flow control: a „sliding window” módszer elve




- Csúszóablakos („sliding window”) mechanizmus
 - az ablak mérete megadja a „kintlevő”, nyugtázatlan csomagok max. számát. (Pl.: $w=8$)
- A TCP-ben: az ablak-mechanizmus oktetteken működik

TCP Flow control: hogy működik?




- Spare room:
= **RcvWindow**
= **RcvBuffer - [LastByteRcvd - LastByteRead]**

- A vevő közli a szabad helyének a méretét (**RcvWindow**) a küldött szegmensben
- Az Adó legfeljebb **RcvWindow** mennyiségű nyugtázatlan adatot küld




MSS (Maximum Segment Size)

- A legnagyobb adatméret bájiban, amit a TCP hajlandó küldeni egy szegmensben
- Össze kell egyeztetni az adatkapcsolati réteg MTU-jával
 - elkerülendő a tördelést
- TCP kapcsolatfelépítésnél kell egyeztetni, **MSS opció a fejlécben**
- TCP adó használhat Path MTU discovery-t is: dinamikus MSS változtatás




Csúszóablakos problémák


- I. Ha a vevő **nullás csúszóablak** méretet hirdet: adó leáll a küldéssel
 - Ha **elveszik a vevő csomagja az új csúszóablak méretről**: adó vár hiába
 - Megoldás: adó egy **timert** indít, lejártá után felkéri a vevőt, hogy küldjön ACK-ot az új ablakméretről
- II. **Buta ablak jelenség**
 - Ha a vevő oldalon kicsi (akár 1 byte) szabadul fel, lehet 1 byte az ablak
 - A küldő 1 byte-ot küld, a vevő megint 1 byte-tal nyit
 - Erőforráspocsékolás: kisebb az adat mint a fejléc!
 - Megoldás:
 - A vevő nem nyitja az ablakot, csak akkor, **ha MSS nagyságrendűt nyithat**
 - A küldő nem küld, hacsak nem
 - MSS-nyit küldhet
 - Mindent küldhet, amit az alkalmazás kért



A TCP „óra”




- A torlódásvezérlésről általában:
 - Azok a módszerek, amelyekkel linkek, csomópontok időszakos túlterheltségét megkíséreljük megszüntetni.
- Két fő módszer:
 - „Hálózat által segített” (**network assisted**) torlódásvezérlés
 - A hálózati elemek szolgáltatnak információt a túlterhelésről az adónak
 - Végpontok közötti (**end-to-end**) torlódásvezérlés
 - nincs visszacsatolás a hálózatból, a végpont következtet arra, hogy torlódás léphetett fel
- A TCP az utóbbit csinálja!




Torlódásvezérlés a TCP-ben

- Módszer:
 - **növeljük az adatsebességet**, ha úgy érzékeljük, van elég átbecsátókéesség
 - amíg **torlódásra utaló jeleket** nem tapasztalunk, ha igen, csökkentsük.
- Hogyan:
 - congestion window, **CongWin**
 - növeljük a CongWin-t minden RTT alatt MSS-sel, amíg vesztést nem érzékelünk
 - csökkentsük a CongWin-t felére minden vesztéskor
 - = **Additive increase – multiplicative decrease (AIMD)** módszer
- Hogyan érzékeljük a torlódást (vesztést)?
 - timeout letelt, nem jött nyugta
 - többszörös nyugta érkezett ugyanarra a szegmensre




Az adatsebesség alakulása AIMD esetén




- Az AIMD kiegészítései:
- „Slow Start”
 - az összeköttetés kezdetén a sebesség gyors (exponenciális) növelése az első veszteségig, utána AIMD
 - Gyors növelés: minden ACK után kétszerezünk
- Eltérő viselkedés timeout és többszörös (3-szoros) nyugták esetén

TCP Slow Start

- Az elején: **CongWin** = 1 MSS
 - Példa: MSS = 500 byte & RTT = 200 msec
 - kezdeti sebesség = 20 kbps
- Mivel a rendelkezésre álló átb. képesség $\gg$ CongWin/RTT lehet,
 - célszerű gyorsan elérni, ezért
 - induláskor exponenciálisan növelni az első vesztésig






Csomagvesztés

- 3 duplikált ACK után:
 - **CongWin** felére csökken
 - Utána lineáris növekedés
 - torlódás elkerülés
- De timer lejártá esetén:
 - **CongWin** 1 MSS lesz;
 - Utána exponenciálisan nő,
 - Egy korlátig, majd onnan lineáris


Filozófia:

❑ timer lejártá rosszabb torlódási helyzetet jelez, mint a 3 duplikált ACK




Összefoglaló: TCP torlódás szabályozás

- Ha a **CongWin** egy korlát alatt van, adó **slow-start** fázisban, exponenciális ablak növelés
- Ha **CongWin** a korlát felett, az adó **torlódás elkerülési fázisban**, lineáris ablak növelés
- Ha **3 duplikált ACK**, a korlát **CongWin/2** lesz és a **CongWin** pedig a korlát
- Ha **timer lejárt**, a korlát **CongWin/2** lesz, míg a **CongWin** 1 MSS lesz




TCP sender congestion control *

State	Event	TCP Sender Action	Commentary
Slow Start (SS)	ACK receipt for previously unacked data	$\text{CongWin} = \text{CongWin} + \text{MSS}$, If ($\text{CongWin} > \text{Threshold}$) set state to "Congestion Avoidance"	Resulting in a doubling of CongWin every RTT
Congestion Avoidance (CA)	ACK receipt for previously unacked data	$\text{CongWin} = \text{CongWin} + \text{MSS} * (\text{MSS} / \text{CongWin})$	Additive increase, resulting in increase of CongWin by 1 MSS every RTT
SS or CA	Loss event detected by triple duplicate ACK	$\text{Threshold} = \text{CongWin} / 2$, $\text{CongWin} = \text{Threshold}$, Set state to "Congestion Avoidance"	Fast recovery, implementing multiplicative decrease. CongWin will not drop below 1 MSS.
SS or CA	Timeout	$\text{Threshold} = \text{CongWin} / 2$, $\text{CongWin} = 1 \text{ MSS}$, Set state to "Slow Start"	Enter slow start
SS or CA	Duplicate ACK	Increment duplicate ACK count for segment being acked	CongWin and Threshold not changed




TCP átbocsátóképessége

- TCP átlagos átbocsátó képessége az ablak méret és RTT függvényében?
 - Nem foglalkozunk slow-start-al
- W az ablakméret a csomagvesztés pillanatában
- Csomagvesztés előtt az átbocsátás W/RTT
- Vesztes után az ablak $W/2$ lesz, átbocsátás $W/2RTT$.
- Átlagos átbocsátás: $.75 W/RTT$




TCP és UDP: összefoglalás

- o Mindkettő host layer/transport layer protokoll
- o Mindkettő portokat kezel
 - o multiplexelés/demultiplexelés
 - o ezáltal interface nyújtása az alkalmazói folyamatok felé
- o Az UDP összeköttetés-mentes, best effort szolgáltatás
 - o nem garantál célba juttatást, csak hibajelzést nyújt
 - o gyorsan célba juttat
- o A TCP összeköttetés-alapú, megbízható transzport szolgáltatás
 - o sorrendhelyes, hibamentes szállítást nyújt
 - o ára: késleltetés



Néhány gyakori alkalmazás és az használt transportprotokollok

<i>Alkalmazás</i>	<i>Alkalmazási rétegbeli protokoll</i>	<i>Használt transport-protokoll</i>
<i>E-mail</i>	SMTP	TCP
<i>Távoli elérés</i>	Telnet	TCP
<i>Web-elérés</i>	HTTP	TCP
<i>File-átvitel</i>	FTP	TCP
<i>Routing</i>	RIP	UDP
<i>Hálózatmenedzsment</i>	SNMP	UDP, TCP
<i>VoIP, média-streaming</i>	Többnyire nem szabványos	UDP



Kérdések?

KÖSZÖNÖM A FIGYELMET!

Dr. Simon Vilmos
adjunktus

BME Hálózati Rendszerek és Szolgáltatások Tanszék
svilmos@hit.bme.hu