Forgalomszabályozás az Interneten (1)

Sonkoly Balázs
sonkoly@tmit.bme.hu

2015.11.10.

Áttekintés

- TCP áttekintése
  - egy működő protokoll
  - torlódásszabályozás
- Értsük meg, mit csináltunk
  - matematikai modellek (utólag)
  - probléma megfogalmazása
- Lehetséges eszközök
  - folytonos idejű visszacsatolt rendszer
  - szabályozástechnika

Forgalomszabályozás

- Sok területen jön elő a hálózatok világában (is)
- például a transzport rétegben
- egyik legfontosabb protokoll: TCP (Transmission Control Protocol)
- Probléma:
  - a küldő határozza meg az adási sebességet a vevő felé
  - sok küldő használja a közös hálózati erőforrásokat (linkek, routerek, switch-ek, bufferek, …)
  - ki milyen sebességgel adjon, hogy “optimálisan” használjuk a hálózatot?
  - ne árasszuk el / terheljül túl a vevőket
  - ne árasszuk el / terheljül túl a hálózati csomópontokat

TCP

- Transzport protokoll (szállítási réteg)
- TCP “szolgáltatás” tulajdonságai
  - hoszt-hoszt (end-to-end) átvitel
  - full-duplex
  - megbízható, sorrendhelyes, duplikáció mentes átvitel
  - megbízhatatlan IP (datagram) hálózat felett
  - multiplexelés az alkalmazási réteg számára (portok)
  - kapcsolat alapú
  - **forgalomszabályozás**
    - flow control
    - congestion control

TCP átvitel elemei

- TCP retransmit
  - megbízható átvitel kell IP hálózat felett
  - garantálni kell az elveszett csomagok újraküldését
  - nyugtázási mechanizmus kell (ACK)
- TCP flow control
  - vevő oldal védelme
  - ne árasszuk el a vevő oldali buffereket
- TCP congestion control
  - ne terheljük túl a közös hálózati erőforrásokat (switch-ek, routerek, bufferek, linkek …)
  - használjuk hatékonyan / optimálisan a hálózati erőforrásokat
  - kerüljük el a *"torlódási összeomlást"* (*"congestion collapse"*)
  - V. Jacobson, 1988

TCP retransmit: megbízhatóság

- Probléma
  - csomagvesztés → eldob és újraküld
  - csomaghiba → eldob és újraküld
  - duplikátum → eldob
  - sorrendcsere → helyreállítás sorszám alapján
- Csomagvesztés érzékelése az adó oldalon
  - **timeout**
    - ha RTO (Retransmission TimeOut) lejár → újraküldés
    - komoly torlódást jelez
  - **dup ACK**
    - 3 duplikált nyugta (dup ACK) vétele → újraküldés (*fast retransmit*)
    - kevésbé komoly torlódás (a vesztés után érkeztek csomagok)

Csúszóablakos szabályozás

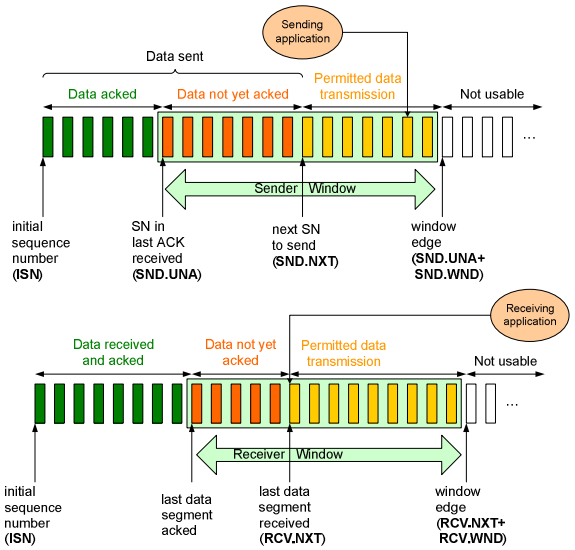

- Mechanizmus: *sliding window*
- TCP legtöbb szolgáltatása ennek segítségével megvalósítható
- Koncepció:
  - szabályozás az adó oldalon (**smart sender**)
  - egyszerű vevő, csak nyugtákat küld (**dump receiver**)

TCP congestion control alapok (1)

- Alapelvek
  - best-effort hálózatot feltételezünk (IP)
  - minden forrás maga határozza meg / számítja a hálóztai kapacitást
  - implicit visszacsatolás alapján
  - self-clocking
- Cél
  - elérhető kapacitás automatikus meghatározása

TCP congestion control alapok (2)

- Self-clocking
  - *packet conservation*: ne küldjünk új csomagot a hálózatba, amíg egy másik el nem hagyja azt (egyensúlyi állapotban)
  - küldő a nyugták érkezési üteme szerint küldi ki az új csomagokat
  - vevő nem tud gyorsabban nyugtát generálni, mint ahogy az adatcsomag keresztül jut a hálózaton
  - az adás automatikusan igazodik a sávszélesség és késleltetés változásaihoz

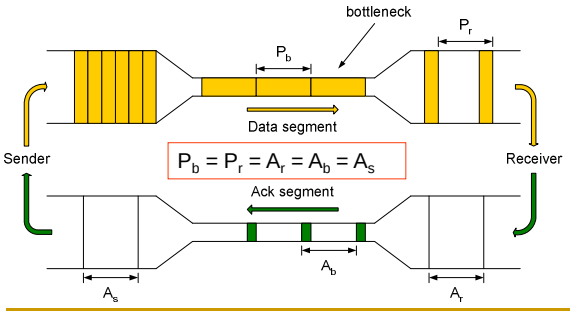

- függőleges dim: sávszélesség (BW)
- vízszintes dim: idő (T)
- BW x T = Bits (terület)
- "interarrival time" marad!
- TCP sending rate
  - bejövő ACK-ok határozzák meg
  - amit a bottleneck határoz meg!

TCP congestion control mechanizmusai

- Csúszóablakos szabályozás
  - flow control és congestion control is ez alapján
  - TCP adó nem tudja, hol a bottleneck: vevőnél vagy a hálózatban
  - congestion window (**cwnd**)
    - dinamikusan frissített változó
    - ami meghatározza az adási sebességet
- Négy fő működési fázis
  - (különböző algoritmusok a cwnd szabályozására)
  - Slow start
  - Congestion Avoidance
  - Fast retransmit
  - Fast recovery

Congestion avoidance – RFC 1122

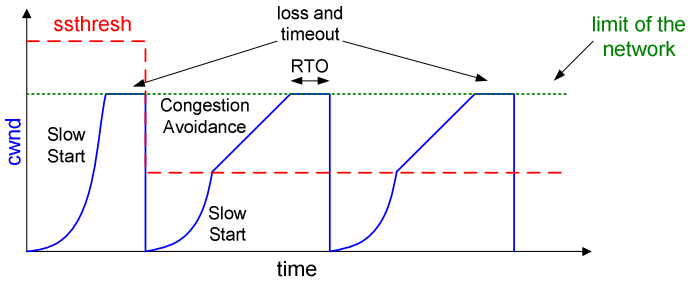

- Célok (RFC 1122)
  - tartsuk a cwnd-t az optimum környékén amennyire csak lehet
  - Slow start
    - indulásnál növeljük gyorsan a cwnd-t, amivel gyorsan elérhetünk egy maximálisan biztonságos adási sebességet
    - max. biztonságos: fele annak az értéknek, ami csomagvesztést okozott (konzervatív!)
  - Congestion avoidance
    - növeljük lassan a cwnd-t, hogy elkerüljük a csomagvesztést, amíg csak lehet

Fast retransmit – TCP Tahoe

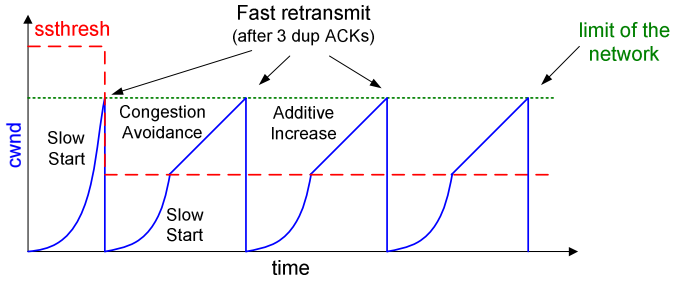

- TCP Tahoe
  - slow start + congestion avoidance
  - + fast retransmit (3 dup ACK után)
- TCP Tahoe problémái
  - fast retransmit után tudjuk, hogy torlódás történt
  - DE slow start-ra visszalépni túl konzervatív
  - tudjuk, hogy későbbi csomagok megérkeztek
  - nagyon érzékeny a csomagvesztésre (1%-os csomgvesztési arány: 50-75% throughput visszaesés!)
- Megoldás: két különböző típusú torlódás
  - RTO lejár → komoly torlódás
  - 3 dup ACK → nincs komoly torlódás (legalább 3 csomag megérkezett)

Fast recovery – TCP Reno

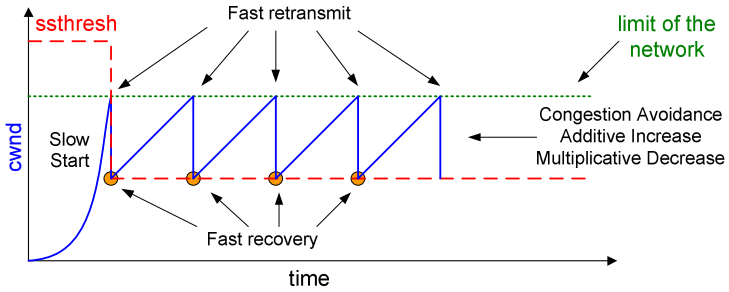

- TCP Reno
  - első implementáció: 4.3 BSD Reno, Net/2, ~1990
  - Slow start
  - Congestion avoidance: ***AIMD*** (Additive Increase Multiplicative Decrease)
  - Fast retransmit
  - Fast recovery
- Problémák
  - következő előadás…

TCP Reno – summary

- When **cwnd** is below **ssthresh**, sender in slow-start phase, window grows exponentially
- When **cwnd** is above **ssthresh**, sender is in congestion-avoidance phase, window grows linearly
- When a triple duplicate ACK occurs, **ssthresh** set to **cwnd/2** and **cwnd** set to **ssthresh** (fast retransmit, fast recovery then congestion avoidance)
- When timeout occurs, **ssthresh** set to **cwnd/2** and **cwnd** is set to 1 segment (slow-start)

Torlódás elkerülés a routerekben

- RED: Random Early Detection
  - active queue management (AQM) mechanizmus
  - cél: torlódás megelőzése a routerekben
  - random csomagdobás (burst-ös helyett) mielőtt megtelik a várakozási sor
  - dropping rate ~ flow rate
  - elkerülhető a globális szinkronizálódás

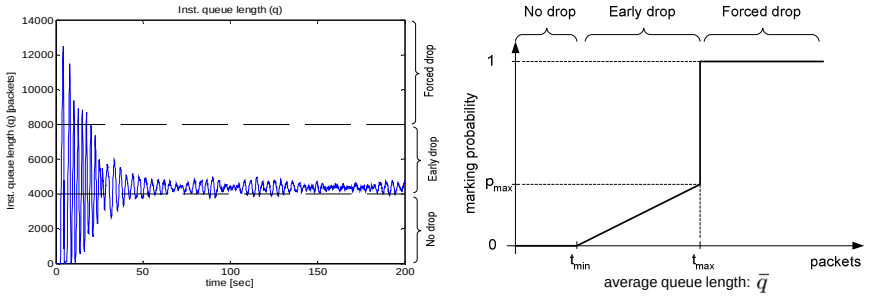

Áttekintés

- TCP áttekintése
  - egy működő protokoll
  - torlódásszabályozás
- Értsük meg, mit csináltunk
  - matematikai modellek (utólag)
  - probléma megfogalmazása
- Lehetséges eszközök
  - folytonos idejű visszacsatolt rendszer
  - szabályozástechnika

Congestion control – általánosan

- Célok
  - operátorok oldaláról
    - hálózati elemek *túlterhelésének elkerülése*
    - DE használjuk *hatékonyan* az erőforrásokat
    - "**knee-point**" belövése (load-throughput görbén)
    - *stabil* hálózati működés
  - felhasználók oldaláról
    - *hatékonyság*
    - *fairness!*
- hatékonyság ↔ fairness

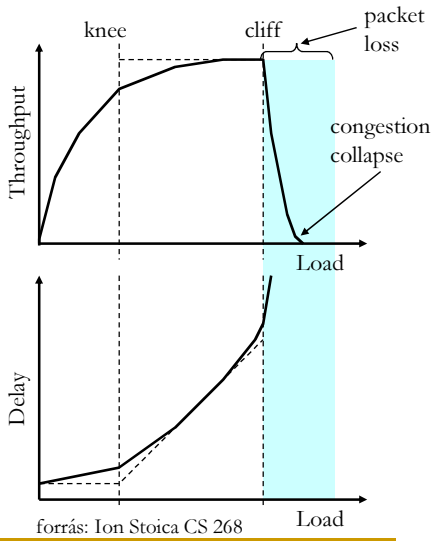

forrás: Ion Stoica CS 268

Congestion control – módszerek

- Ha a hálózat is segít
  - explicit congestion control
  - explicit visszajelzés a routerektől (pl. egy bit beállítása torlódás esetén – ECN, de kifinomultabb módszerek is vannak – XCP, RCP)
  - fő probléma: módosítani kell a routereket
- Ha a hálózat nem segít
  - NINCS explicit visszajelzés
  - következtetni kell *implicit torlódási mérőszámokból*
    - csomagvesztés → ***loss-based*** mechanizmusok (pl. TCP Reno)
    - késleltetés → ***delay-based*** mechanizmusok (pl. TCP Vegas, FAST)
      - round-trip time (RTT): csomag kiküldése – ACK vétele
    - kombinált ***loss- and delay-based*** mechanizmusok (pl. Compound TCP)
    - bandwidth ***measurement*** (pl. TCP Westwood)
      - aktív / passzív mérések

Congestion control → "szabtech"

- End-to-end congestion control az Interneten
  - (hatalmas) visszacsatolt rendszer
  - (szabályozástechnika!)
  - elosztott (distributed)
  - nem elhanyagolható késleltetések (delayed)
  - adók:
    - adási sebesség beállítása
    - a mért torlódási jelek alapján

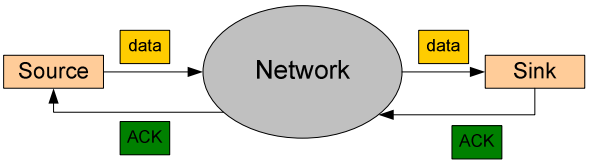

Modellek és eszözök

- Csomagszint
  - sztochasztikus modellek
  - queueing theory
  - kevés jól használható eredmény visszacsatolás esetén
- Folyamszint
  - adott időskálán érvényes
  - determinisztikus folyadékmodellek
  - eszközök
    - optimization-theory
    - **control-theory**
    - game-theory
- Vizsgáljuk meg a meglévő protokollokat!

TCP & AQM

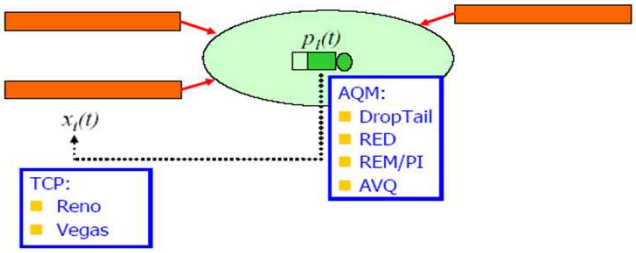

- Transzport protokollok
  - küldési ráta ($x_i(t)$)
  - rendszer bemeneti paramétere
- Active Queue Management (AQM)
  - torlódási mérőszám ($p_l(t)$) (pl. loss rate, delay,...)
  - visszacsatolt jel

TCP & AQM

TCP – AQM modell:

$$x(t+1) = F(p(t), x(t))$$
$$p(t+1) = G(p(t), x(t))$$

- **Egyensúlyi állapot**
  - throughput, loss, delay,...
  - fairness
  - utility
- Duality theory (optimization)
  - sending rates → primal variables
  - cong. measure → dual variables
  - flow / cong. control → optimization

- **Dinamikus viselkedés**
  - lokális stabilitás
  - globális stabilitás
- Control theory
  - feedback system
  - distributed
  - delayed

TCP & AQM

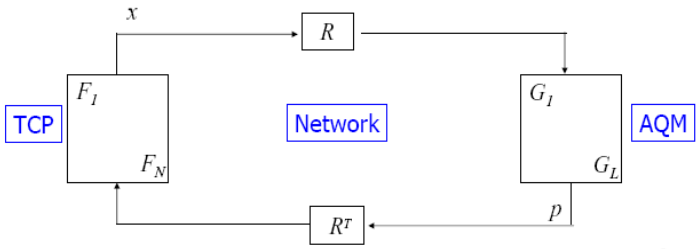

$R_{li} = 1$ if source i uses link l ← IP routing

$[R_f(s)]_{li}$ forward delays
$[R_b(s)]_{li}$ backward delays

$x(t+1) = F(R^T p(t), x(t))$ ← Reno, Vegas

$p(t+1) = G(p(t), Rx(t))$ ← DT, RED, ...

Áttekintés

- TCP áttekintése
  - egy működő protokoll
  - torlódásszabályozás
- Értsük meg, mit csináltunk
  - matematikai modellek (utólag)
  - probléma megfogalmazása
- Lehetséges eszközök
  - folytonos idejű visszacsatolt rendszer
  - szabályozástechnika

Egy gyakorlati példa

- HighSpeed TCP / RED hálózatok vizsgálata
- (szabályozástechnika) control-theory módszereivel

HighSpeed TCP (1)

- TCP Reno egyszerű javítása nagysebességű környezethez
- RFC 3649: HighSpeed TCP for Large Congestion Windows (Sally Floyd, 2003)
- csomagvesztés alapú protokoll
- módosított AIMD mechanizmus
  - cwnd növelésének és csökkentésének mértéke az aktuális cwnd értéktől függ
  - “skálázódás”
  - nagy torlódás esetén → TCP Reno szerű működés
  - különben → agresszívabb kontroll

HighSpeed TCP (2)

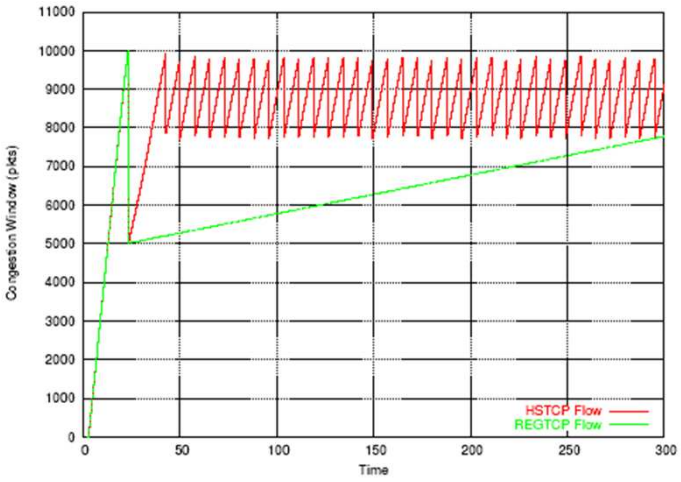

Control-theoretic model

- Modeling network with single bottleneck link
- Plant: HSTCP sources, queue
- Controller: Active Queue Management (e.g., RED)
- Feedback control system

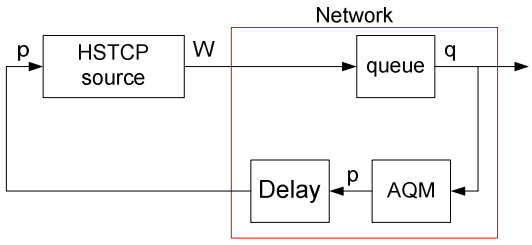

- *W*: congestion window
- *q*: inst. queue length
- *p*: dropping/marking probability

Fluid-flow model of HSTCP/RED networks

- Notations

$W \doteq$ expected TCP window size (packets),
$q \doteq$ expected queue length (packets),
$x \doteq$ expected queue length estimation (packets),
$R \doteq$ round-trip time (RTT) $= \frac{q}{C} + T_p$ (secs),
$C \doteq$ link capacity (packets/sec),
$T_p \doteq$ fix round-trip propagation delay (secs),
$N \doteq$ load factor (number of TCP sessions),
$p \doteq$ probability of packet mark/drop.

Fluid-flow model of HSTCP/RED networks

- Dynamics can be described by differential equations
- expected (average) transient behavior is captured
- **dynamics of HSTCP source:**

$$\dot{W}(t) = \frac{a(W(t))}{R(t)} - b(W(t))\,W(t)\frac{W(t-R(t))}{R(t-R(t))}\,p(t-R(t))$$

- first term: Additive Increase
  - *W* is increased by *a(W(t))* for one RTT
  - "positive" ACKs arrived at a rate proportional to
    1-p(t) ≈ 1 → not lost packets
- second term: Multiplicative Decrease
  - *W* is decreased by *bW(t)*
  - at a rate proportional to
    - *p(t)* → lost packets (loss ratio)
    - *x(t-R) = w(t-R)/R(t-R)* → sending rate at one RTT earlier

Fluid-flow model of HSTCP/RED networks

- **dynamics of bottleneck queue** → differential equation

$$\dot{q}(t) = N(t)\frac{W(t)}{R(t)} - 1_{q(t)}C$$

- first term
  - sending rate of N identical HSTCP sources
  - aggregate arriving traffic
- second term
  - serving rate
  - according to the link capacity (if the buffer is not empty)
- **queue estimation** (exponentially weighted moving average)

$$\dot{x}(t) = -Kx(t) + Kq(t)$$

- low-pass filter
- with a cut-off frequency of *K*, where $K = -C\ln(1-\alpha)$
- α is the forgetting factor

Fluid-flow model of HSTCP/RED networks

- Dynamics of
  - congestion window (HSTCP source)
  - bottleneck queue
  - queue estimation (at RED)
- coupled differential equations
- complex dependence between the variables
- delay in some arguments
- moreover: variable delay in some arguments
- model is analytically not tractable
- numerical approximations can be applied to solve the equations

Simulink framework

- MATLAB/Simulink is a suitable framework
- system models can easily be implemented
- numerical approximation based solvers can be applied
- here: Domand-Prince algorithm (“ode45”)

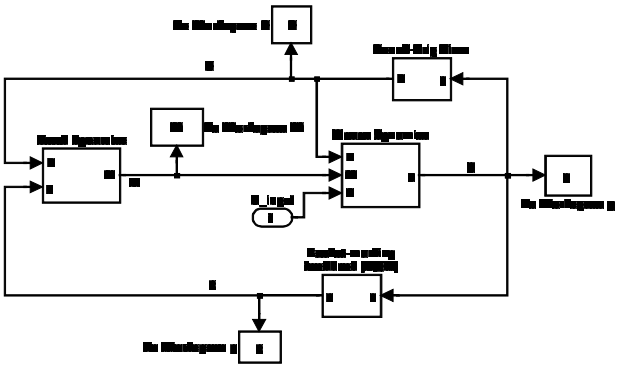

- Plant: HSTCP source + bottleneck queue
- Controller: RED module
- *W*: cwnd (state variable)
- *q*: inst. queue length (state variable, output)
- *p*: dropping/ marking probability (feedback signal, input)
- *R*: round-trip time
- *N_input*: No. of sources

Implementation of HSTCP source

- Module **“Cwnd dyamics”** → describe the corresponding differential equation

$$\dot{W}(t) = \frac{a(W(t))}{R(t)} - b(W(t))W(t)\frac{W(t-R(t))}{R(t-R(t))}p(t-R(t))$$

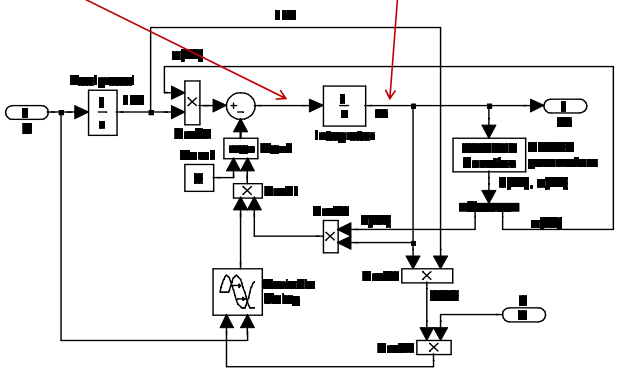

Implementation of network model

- Module **"queue dyamics"** → describe the corresponding differential equation

$$\dot{q}(t) = N(t)\frac{W(t)}{R(t)} - 1_{q(t)}C$$

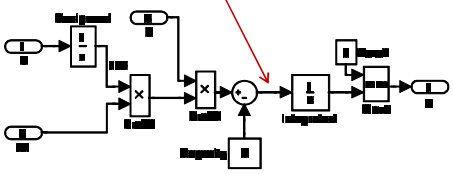

- **AQM module** → implementing RED packet marking profile
  - averaging filter (low-pass filter)
  - packet-marking profile
- **RTT module**: simple relation

$$R = T_p + \frac{q(t)}{C}$$

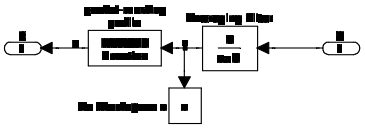

Validation of the model

- Flow-level model ↔ packet-level simulations
- MATLAB/Simulink ↔ Ns-2
  - with similar parameter sets
  - impact of Slow-Start is modeled by initial condition of congestion window at the flow-level
- single HSTCP flow
- more HSTCP flows, impact of different parameters
- oscillation or stability at the flow-level
- (expected values!)

Single HSTCP flow

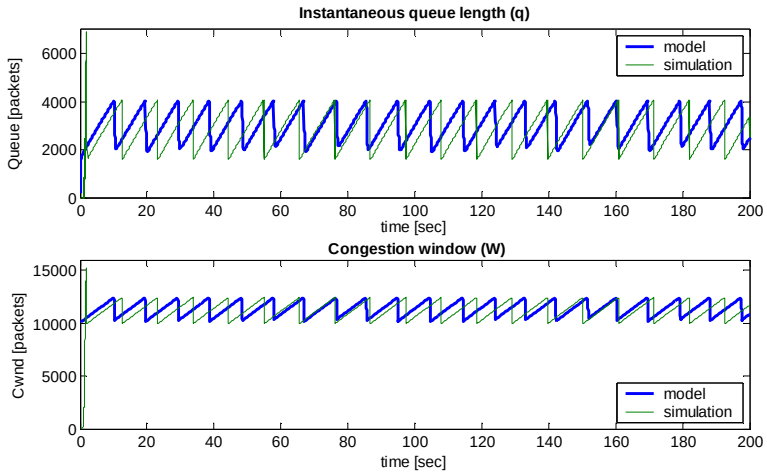

100 HSTCP flows

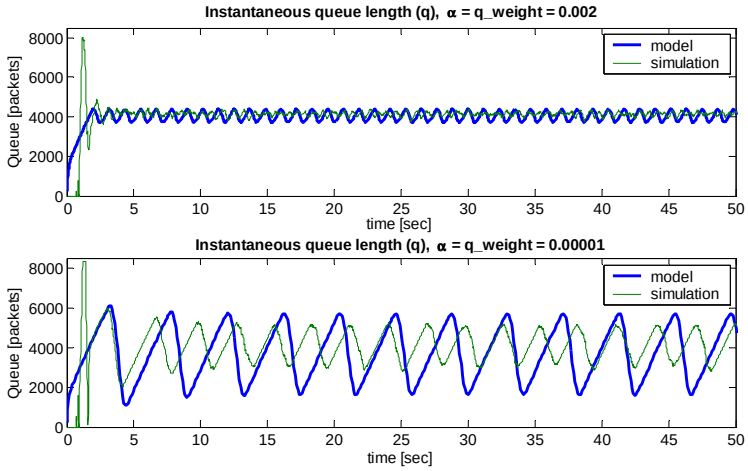

Kitekintés

MIRE IS HASZNÁLHATÓ A MODELL?

Stability analysis

- Non-linear model (diff. equations)
  - global asymptotic stability could be analyzed
  - starting from any (feasible) initial condition, the algorithms converge to the unique equilibrium state
  - BUT this model is analytically not tractable!
- Linearization
  - our non-linear model can be linearized about an operating point (now at the stable point)
  - dynamics → approximated by the first order derivatives
  - local behavior
  - local asymptotic stability can be analyzed
  - with reasonable region of attraction
- Stability condition
  - designing RED (parameters) for stable behavior
- Numerical evaluation

Linearized model

- Operating point (W_0, q_0, p_0) → *dW/dt = 0* and *dq/dt = 0* (equilibrium)
- some variables can be approximated by constant values (R_0, a_0, b_0)
- first-order dynamics based on first-order partial derivatives

$$\begin{aligned}\delta\dot{W}(t) &= -\frac{a_0 N}{R_0^2 C}\left(\delta W(t) + \delta W(t - R_0)\right) \\ &\quad -\frac{b_0 R_0 C^2}{N^2}\delta p(t - R_0) \\ \dot{\delta q}(t) &= \frac{N}{R_0}\delta W(t) - \frac{1}{R_0}\delta q(t)\end{aligned}$$

- where the variables denote perturbations

$$\delta W \doteq W - W_0,\ \delta q \doteq q - q_0 \text{ and } \delta p \doteq p - p_0$$

Linearized model

- this linear system (plant) can be transformed into the Laplace transform domain, transfer functions can be derived

$$\begin{aligned}P(s) &= -e^{-sR_0}\, P_{hstcp}(s)\, P_{queue}(s) = \\ &= -e^{-sR_0}\, \frac{\frac{b_0 R_0 C^2}{N^2}}{s + \frac{a_0 N}{R_0^2 C}\left(1 + e^{-sR_0}\right)}\, \frac{\frac{N}{R_0}}{s + \frac{1}{R_0}}\end{aligned}$$

- and can be further simplified

$$P_{hstcp}(s) = \frac{\frac{b_0 R_0 C^2}{N^2}}{s + \frac{2a_0 N}{R_0^2 C}} \quad ; \quad P_{queue}(s) = \frac{\frac{N}{R_0}}{s + \frac{1}{R_0}}$$

RED controller for the linear plant

- Linear phase of the packet-marking profile is considered
- (early drop)

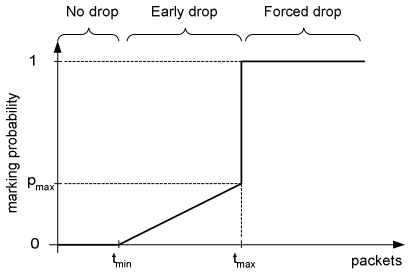

- *C(s)*: transfer function of RED controller
- *α*: forgetting factor
- *δ*: sample time (≈*1/C* in steady-state)
- *L*: slope of the curve of RED profile
- *K*: cut-off frequency of RED controller

$$C(s) = C_{red}(s) = \frac{L}{\frac{s}{K} + 1}$$

$$L = \frac{p_{max}}{t_{max} - t_{min}} \quad \text{and} \quad K = -\frac{\ln(1-\alpha)}{\delta} \approx -C\ln(1-\alpha),$$

RED controller for the linear plant

- Goal of the RED controller design
- to select RED parameters (*L*, *K*)
- to stabilize the feedback control system
- for a given range of *N* and R_0 → $N \geq N^-$ and $R_0 \leq R^+$

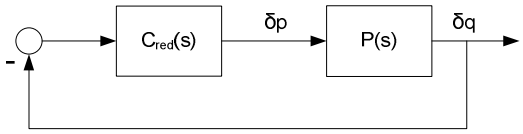

$$P(s) = \frac{\frac{b_0 C^2}{N} e^{-sR_0}}{\left(s + \frac{2a_0 N}{R_0^2 C}\right)\left(s + \frac{1}{R_0}\right)} \quad ; \quad C_{red}(s) = \frac{L_{hstcp}}{\frac{s}{K_{hstcp}} + 1}$$

Stability condition

- Stability condition based on Nyquist-criterion can be derived analytically

If L_{hstcp} and K_{hstcp} satisfy

$$\frac{L_{hstcp}\, b_0 \left(R^+ C\right)^3}{2a_0 \left(N^-\right)^2} \leq \sqrt{\frac{\omega_g^2}{K_{hstcp}^2} + 1}$$

where

$$\omega_g = 0.1 \min\left\{\frac{2a_0 N^-}{\left(R^+\right)^2 C}, \frac{1}{R^+}\right\}$$

then, the linear feedback control system is stable for all $N \geq N^-$ and $R_0 \leq R^+$.

Stability region

- Based on the condition, a stability region can be derived for given network parameters
- simple example:
  - *K* is fixed
  - *L* can be plotted in 3D
  - stability: under the surface

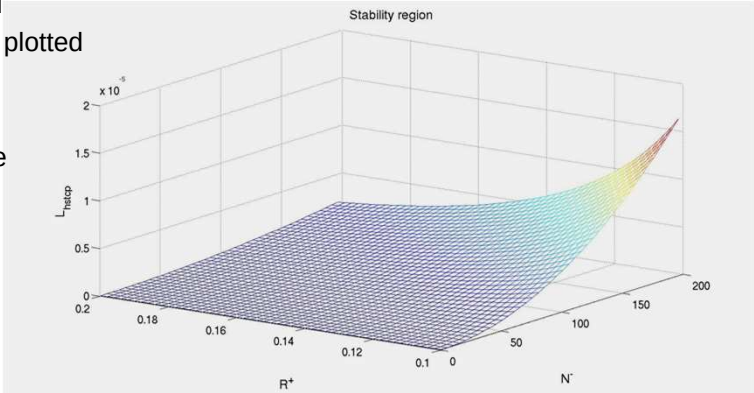

Numerical examples (1)

- Fixed parameters, only the flow number (*N*) is changed
- according to the stability condition → stability at around 160 flows

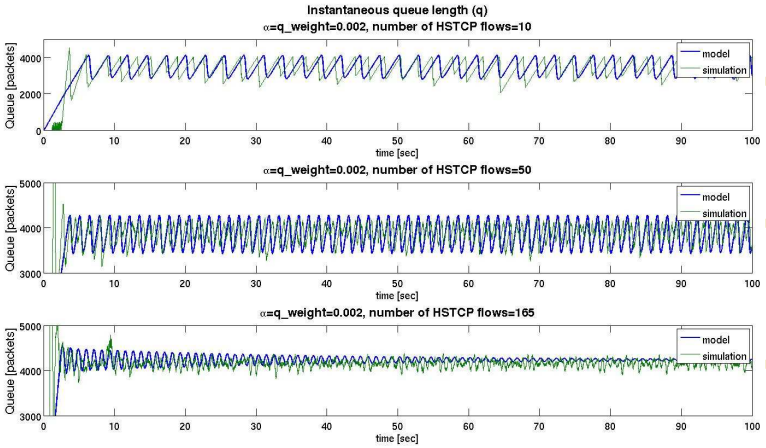

- N=10
- N=50
- N=165

Numerical examples (2)

- Stabilizing the behavior → tuning RED parameter p_{max}

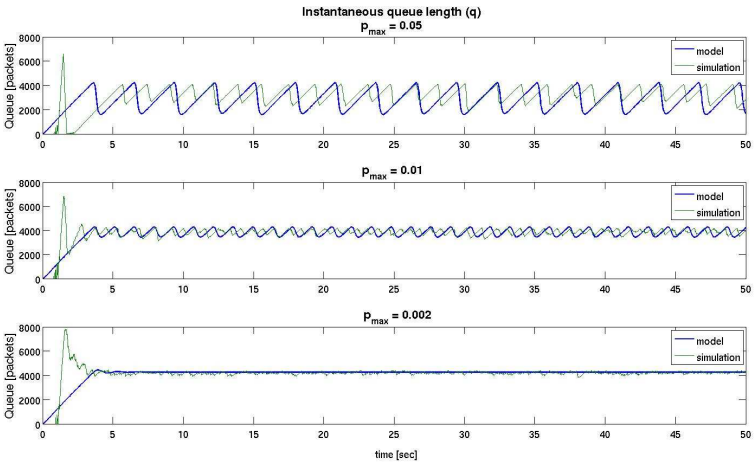

- p_{max} = 0.05
- p_{max} = 0.01
- p_{max} = 0.002

Összefoglalás

- TCP áttekintése
  - egy működő protokoll
  - torlódásszabályozás
- Értsük meg, mit csináltunk
  - matematikai modellek (utólag)
  - probléma megfogalmazása
- Lehetséges eszközök
  - folytonos idejű visszacsatolt rendszer
  - szabályozástechnika