


Teljesítménymodellezés

Rendszermodellezés 2019.

**Budapest University of Technology and Economics
Fault Tolerant Systems Research Group**



Egy ismerős példa...

Budapesti Műszaki és Gazdaságtudományi Egyetem



Hallgatói BME_W2K8H_02(168)

Nyelv:    

Azonosító:

Jelszó:

Bejelentkezés >



Build: 430 (2014.11.11.) P20150304

Támogatott böngészők:

Microsoft Internet Explorer 9.0+ ; Mozilla Firefox ; Google Chrome

Friss hírek

[KTH hallgatói hírlevél 2014/15/1 félévzárásról 1. –
vizsgajelentkezés, vizsgaidőszak](#)

(2014.11.27.
8:56:21)

Kedves Hallgató!

2014. december 1-jén 18 órakor indul a vizsgajelentkezés. Milyen egyéb határidőkre kell figyelnie a félév végén? Melyek az ebben az időszakban aktuális Neptun kérvények? Mit

Letölthető dokumentumok

 Tantárgyfelvétel: eddig a legsimábban.pdf
(2015.02.07. 14:28:14)

 Tantárgyfelvétel: nem és nem.pdf
(2014.08.28. 21:19:50)

 Vizsgajelentkezés: szokványosan.pdf
(2014.05.06. 21:14:04)

Egy ismerős példa...

Kiszolgálóhiba történt az alkalmazásban: „/hallgato”.

Futásidejű hiba

Leírás: Alkalmazáshiba történt a kiszolgálón. Az alkalmazás jelenlegi egyéni hibakezelési beállításai (biztonsági okok miatt) nem engedik meg az adatainak távoli megjelenítését. A böngészőben azonban megtekinthetők.

Részletek: Ha távoli gépeken is meg szeretné jeleníteni a hibaüzenet részletes adatait, hozzon létre a konfigurációs fájlban elhelyezett „web.config” címke „mode” attribútumát állítsa „Off” értékre.

```
<!-- Web.Config konfigurációs fájl -->
```

```
<configuration>
  <system.web>
    <customErrors mode="Off"/>
  </system.web>
</configuration>
```


Megjegyzések:

```
<!-- Web.Config
<configuration>
  <system.web>
    <customErr
  </system.web>
</configuration>
```


Motiváció:
Már tervezési időben
készüljünk a terhelésre!



(... ezt tudják mások is...)




A Neptun vázlatos felépítése



Terhelésmodellezés

- Emlékeztető: nemfunkcionális követelmények
 - Teljesítmény, átbocsátóképeség, stb.
 - Hogyan ellenőrizzük őket a rendszer megépítése nélkül?
- **Terhelésmodellezés:**
 - Az eddigi modellek kiegészítése időzítéssel, erőforrásokkal, kapacitáskorlátokkal
 - Célja:
 - A rendszer teljesítményének értékelése a tervezési fázisban
 - Kritikus részek azonosítása
 - Skálázás, méretezés



Alapfogalmak

Terhelési diagram

Erőforrásmodellezés

TARTALOM

Alapfogalmak

Terhelési diagram


Erőforrásmodellezés

ALAPFOGALMAK

Érkezési ráta, átbocsátás


Alapmodell

- Folyamatmodell végrehajtása sok kérésre
 - Vizsgálat tárgya: időfüggő viselkedés
- Működés leírása:
 - Időfüggvényekkel
 - Átlagos értékekkel



Alapmodell


- Folyamatmodell végrehajtása sok kérésre
 - Vizsgálat tárgya: időfüggő viselkedés
- Működés leírása:
 - Időfüggvényekkel
 - Átlagos értékekkel



Emlékeztető: végrehajtási állapotok

- Folyamat/tevékenység végrehajtásának állapota:

State Machine



- Bejött(t): „*Enabled*” állapotban lévő tokenek
- Bentvan(t): „*Running*” állapotban lévő tokenek
- Kiment(t): „*Completed*” állapotban lévő tokenek


Definíció: ráta, átbocsátás

Érkezési ráta: egységnyi idő alatt **érkező** kérések

$$\lambda = \frac{Bejött(t)}{t} \quad [\lambda] = \frac{db}{s}$$

Átbocsátás: egységnyi idő alatt **feldolgozott** kérések

$$X = \frac{Kiment(t)}{t} \quad [X] = \frac{db}{s}$$




Megj: $\frac{db}{s}$ helyett $\frac{1}{s}$ is
elfogadható konzekvens
használat mellett...

Definíció: egyensúlyi állapot


- **Egyensúlyi állapot:** $Bentvan(t)$ közel állandó
 - Átlagos értékek csak ilyenkor használhatók!
 - Ilyenkor:

$$\lambda = X$$


$$\lambda = X$$



$$\lambda > X$$



$$\lambda < X$$



Definíció: egyensúlyi állapot

- **Egyensúlyi állapot:** *Bentvan(t)* közel állandó
 - Átlagos értékek csak ilyenkor használhatók!
 - Ilyenkor:

$$\lambda = X$$

Egyensúlyi állapotban:
Percenként ugyanannyian
lépnek be, mint ki



Korlátozott kapacitás – DDoS

- Idáig N akár végtelen is lehetett
- Mi van, ha véges?

Denial of Service Attack


Thursday, August 6, 2009 | By Biz Stone (@biz) 08/06/2009 - 15:00

Tweet

On this otherwise happy Thursday morning, Twitter is the target of a [denial of service attack](#). Attacks such as this are malicious efforts orchestrated to disrupt and make unavailable services such as online banks, credit card payment gateways, and in this case, Twitter for intended customers or users. We are defending against this attack now and will continue to update our [status blog](#) as we continue to defend and later investigate.

Distributed Denial of Service (DDoS)


- Tömeges kéresgenerálás
→ rendszer lefoglalása
- A leterhelt rendszert könnyebb támadni
- Teljes szolgáltatások leállíthatóak




TERHELÉSI DIAGRAM

Az érkezési ráta és az átbocsátás kapcsolata,
átbocsátóképeség


Terhelési diagram




Terhelési diagram




Terhelési diagram




Átbocsátókéesség




Kihasználtság




Közelítő terhelési függvény



Valós terhelési diagram



Valós terhelési diagram



Definíciók

Átbocsátókéesség: a maximális átbocsátás.

○ Jele: $X^{\max}$


Kihasználtság (Utilization): a jelenlegi átbocsátás és a maximális átbocsátás **aránya**.

○ $U = \frac{X}{X^{\max}}$

Vergődés: a rendszer átbocsátása visszaesik a telített működés során.

A modellben elhanyagolt hatások

- Taszkváltások számításigénye
 - Takarítás az előző után
 - Előkészítés a következőhöz
- Erőforrásváltás számításigénye
- Többszörös telítés
 - Egyszerre több erőforrás (pl. szerver) is telített
 - Pl. ha az M7-esen baleset van, bedugul a 70-es út is



Elriasztott kérések esete


- Az igények csak a fanatikus klienseknél függetlenek a sor hosszától....



A terhelésingadozás hatása

■ Átlagos értékek vs. Valós terhelés

Telített rendszerben a válaszidő **2-3 nagyságrenddel** nagyobb is lehet!



A terhelésingadozás hatása

- Átlagos értékek vs. Valós terhelés

Nem érdemes 40-60%-nál nagyobb kihasználtságra tervezni!

Telít
vén a
renddel

[%]

Average: 75%

Time [s] →

Neptun tárgyfelvétel



Max. egyidejű
felhasználó

Max. egyidejű felhasználó
optimális működés mellett

Az elmúlt időkben előfordult, hogy a Neptun rendszer használata során a következő problémák merültek fel:

Dátum	Jelleg	Max. felhasználó	Op. felhasználó
2010.11.29 18:00	vizsga	7303	4623
2010.12.22 06:00	tárgy (EO)	831	831
2011.01.10 18:00	tárgy	12062	4837
2011.01.12 18:00	tárgy (EP)	1765	1765
2011.01.31 16:00	tárgy	1519	1519
2011.05.02 18:00	vizsga	2761	2761
2011.06.07 18:00	tárgy	6095	6095
2011.11.28 18:00	vizsga	4897	4897
2012.01.16 18:00	tárgy	8120	5328
2012.01.30 16:00	tárgy	1703	1703
2012.05.02 18:00	vizsga	2603	2603

Neptun tárgyfelvétel



$\approx$ Érkezési ráta (λ)

$\approx$ Átbocsátóképeség ($X^{\max}$)

Az elmúlt időkben előfordultak olyan esetek, amikor a Neptun rendszer túlterhelt volt.

Dátum	Jelleg	Max. felhasználó	Op. felhasználó
2010.11.29 18:00	vizsga	7303	4623
2010.12.22 06:00	tárgy (EO)	831	831
2011.01.10 18:00	tárgy	12062	4837
2011.01.12 18:00	tárgy (EP)	1765	1765
2011.01.31 16:00	tárgy	1519	1519
2011.05.02 18:00	vizsga	2761	2761
2011.06.07 18:00	tárgy	6095	6095
2011.11.28 18:00	vizsga	4897	4897
2012.01.16 18:00	tárgy	8120	5328
2012.01.30 16:00	tárgy	1703	1703
2012.05.02 18:00	vizsga	2603	2603

Mikor volt telített (túlterhelt) a Neptun?

Neptun tárgyfelvétel



≈ Érkezési ráta (λ)

≈ Átlagos várakozási idő ($X^{\max}$)

Az elmúlt időkből előfordultak a következők:

Dátum	Jelleg	
2010.11.29 18:00	vizsga	
2010.12.22 06:00	tárgy /	
2011.01.10 18:00		
2011.01.12 18:00		
2011.01.31 18:00		
2011.02.02 18:00		2761
2011.02.04 18:00		6095
2011.11.10 18:00		4897
2012.01.10 18:00		5328
2012.01.30 18:00		1703
2012.05.02 18:00		2603

A túlterhelt rendszer teljesítménye drasztikusan leeshet, akár össze is omolhat!

Mikor lett túlterhelt (túlterhelt) a Neptun?

Neptun tárgyfelvétel



$\approx$ Érkezési ráta (λ)

$\approx$ Átbocsátóképesség ($X^{\max}$)

Az elmúlt időkben előfordultak a következők:

Dátum	Jelleg	Max. felhasználó	Op. felhasználó
2010.11.29 18:00	vizsga	7303	4623
2010.12.22 06:00	tárgy (EO)	831	831
2011.01.10 18:00	tárgy	12062	4837
2011.01.12 18:00	tárgy (EP)	1765	1765
2011.01.31 16:00	tárgy	1519	1519
2011.05.02 18:00	vizsga	2761	2761
2011.06.07 18:00	tárgy	6095	6095
2011.11.28 18:00	vizsga	4897	4897
2012.01.16 18:00	tárgy	8120	5328
2012.01.30 16:00	tárgy	17	
2012.05.02 18:00	vizsga	26	

Jól konfigurált
szerverek, megfelelő
terhelésméretezés!

Neptun tárgyfelvétel

NEPTUN

Ugyanez az alapja
a DDoS elleni
védekezésnek is

áta (λ)

$\approx \text{Áth}$


ség ($X^{\max}$)

**A létszámkorlátos megoldás
célja egyensúlyi állapotban
tartani a rendszert**

Jól konfigurált
szerverek, megfelelő
terhelésméretezés!

Dátum	Állapot	Álló
2010.11.29 18:00	vizsga	
2010.12.22 06:00	tárgy /	
2011.01.10 18:00		
2011.01.12 18:00		
2011.01.31 18:00		
2011.05.02 18:00		2761
2011.06.02 18:00		6095
2011.11.28 18:00		4897
2012.01.16 18:00		5328
2012.01.30 16:00	17	
2012.05.02 18:00	26	

Példa adatvizualizáció



Alapfogalmak

Terhelési diagram

Erőforrásmodellezés

ERŐFORRÁSMODELLEZÉS

Miből származik az átbocsátás korlátja?

Példa: ZH javítás

- Egy hallgató dolgozatának kijavítása **15 perc**
- **Egy** javító **óránként** hány dolgozattal végez?

$$X_{(1)}^{max} = \frac{1 \text{ ZH}}{15 \text{ perc}} = 4 \frac{\text{ZH}}{h}$$

- És **nyolc** javító?


$$X_{(8)}^{max} = 8 \times X_{(1)}^{max} = 8 \times \frac{1 \text{ ZH}}{15 \text{ perc}} = 32 \frac{\text{ZH}}{h}$$

Kizárólagos erőforrás törvénye

- Ha a kérések közül egyszerre **legfeljebb egy** futhat
 - Pl. egyetlen szerver futtatja őket, azonos változót írnak
 - A többi kérés **sorban áll**
- Ekkor T az **átlagos végrehajtási idő** mellett:

$$X_{(1)}^{max} = \frac{1}{T}$$

Egyensúlyi állapotban!



Kizárólagos erőforrás törvénye


- Ha a kérések közül egyszerre **legfeljebb egy** futhat
 - Pl. egyetlen szerver futtatja őket, azonos változót írnak
 - A többi kérés **sorban áll**
- Ekkor T az **átlagos végrehajtási** idő mellett:

$$X_{(1)}^{max} = \frac{1}{T}$$

„Hány végrehajtás fér bele egy egységnyi időbe?”


$$T_{ZH} = 15 \text{ perc}$$

$$X^{max} = 4 \frac{1}{h}$$



Mérhető idők

- **Sorbanállási idő:** várakozás erőforrásra
- **Végrehajtási idő:** kérés feldolgozása
- **Válaszidő:** Sorbanállási + Végrehajtási



Kizárólagos erőforrás kihasználtsága

- Kihasználtság:

„Az átbocsátás és az átbocsátóképeség aránya”

$$X_{(1)}^{max} = \frac{1}{T} \Rightarrow X_{(1)}^{max} \times T = 1$$

Kizárólagos erőforrás kihasználtsága

- Kihasználtság:

„Az átbocsátás és az átbocsátókéesség aránya”

$$X_{(1)}^{max} = \frac{1}{T} \Rightarrow X_{(1)}^{max} \times T = 1 = U^{max}$$

- A kihasználtság képlete tehát:

$$U = X \times T$$

- Intuitíven:

„Az egységnyi idő alatt beérkező X taszk végrehajtása T végrehajtási idővel az egységnyi idő hányadrészét teszi ki?”

Kizárólagos erőforrás kihasználtsága

- Kihasználtság:

„Az átbocsátás és az átbocsátókéesség aránya”

$$X_{(1)}^{max} = \frac{1}{T} \Rightarrow X_{(1)}^{max} \times T = 1 = U^{max}$$

- A kihasználtság képlete tehát:


$$U = X \times T$$

- Intuitíven:

$$X = 3 \frac{1}{h}$$

$$T_{ZH} = 15 \text{ perc}$$

$$U = 75\%$$



Kitekintés: skálázás

- **Vertikális skálázás** (Scale-up):
 - A feldolgozóegység **teljesítményét** növeljük
 - Pl. erősebb CPU, több RAM
 - Egyszerű és nagyszerű 😊
 - Technológiai korlátok ☹️
- **Horizontális skálázás** (Scale-out):
 - A feldolgozóegységek **számát** növeljük
 - Pl. több CPU mag, több szerver
 - Elvileg korlátlanul növelhető 😊
 - Plusz bonyolultság ☹️

Scale-out a hétköznapiakban




The image shows a bank teller counter with four tellers. A large digital display on the left shows four identical 'NO. 0000 TO 00' messages. Red dashed lines divide the counter into four sections, each with a teller and a calculator. A man in a suit is writing on a notepad in the foreground. A white machine with a blue logo is on the counter.

46



Scale-out a Neptunban



K erőforráspéldány használata

- Ha az összes kérés közül egyszerre **legfeljebb K** futhat
 - Pl. K darab fürtözött szerver futtathatja őket
 - A többi folyamatpéldány **sorban áll**
- Ekkor:
 - Legyen T az **átlagos végrehajtási idő**

$$X_{(K)}^{max} = K \times X_{(1)}^{max} = \frac{K}{T}$$

K erőforráspéldány használata

- Ha az összes kérés közül egyszerre **legfeljebb K** futhat
 - Pl. K darab fűrtözött szerver futtathatja őket
 - A többi folyamat
- Ekkor:
 - Legyen T az átlag

Több erőforráspéldánnyal és párhuzamosítással a rendszer **skálázható**.

$$X_{(K)}^{max} = K \times X_{(1)}^{max} = \frac{K}{T}$$


Vízvezeték analógia

Egyetlen kizárólagos
erőforráspéldány



Átbocsátóképesség:
 $X_{(1)}^{max}$

K szabadon választható
erőforráspéldány



Átbocsátóképesség:
 $X_{(K)}^{max} = K \times X_{(1)}^{max}$

K erőforráspéldány kihasználtsága

- Az előző gondolatmenet analógiájára:

$$X_{(K)}^{max} = \frac{K}{T} \Rightarrow X_{(K)}^{max} \times T = \textcircled{K} ?$$

K erőforráspéldány kihasználtsága

- Az előző gondolatmenet analógiájára:

$$X_{(K)}^{max} = \frac{K}{T} \Rightarrow X_{(K)}^{max} \times T = K = K \times U^{max}$$

- A kihasználtság képlete ebben az esetben:

$$U = \left(\frac{X}{K} \right) \times T$$

- Intuitíven:

„K időegység hányadrészében dolgozna 1 példány?”

„Az **egy példányra eső átlagos átbocsátás** mellett mekkora egy erőforráspéldány kihasználtsága?”

K erőforráspéldány kihasználtsága

- Az előző gondolatmenet analógiájára:

$$X_{(K)}^{max} = \frac{K}{T} \Rightarrow X_{(K)}^{max} \times T = K = K \times U^{max}$$

- A kihasználtság képlete ebben az esetben:

$$U = \frac{X}{K} \times T$$

- Intuitíven:

$$X = 5 \frac{1}{h}$$

$$T_{ZH} = 15 \text{ perc}$$

$$U = 62,5\%$$



Összefoglalás

■ Egyensúlyi állapot:

- Átlagos értékekkel számolunk
- $\lambda = X$ (érkezési ráta = átbocsátás)

■ Átbocsátókéesség:

- Az elérhető maximális átbocsátás
- $X^{\max} = \frac{K}{T}$ (K erőforráspéldány esetén)

■ Kihasználtság:

- Az átbocsátás és az átbocsátókéesség aránya
- $U = \frac{X}{K} \times T$ (K erőforráspéldány esetén)

PÉLDA

Tudok-e venni akciós zoknit Black Friday alkalmával?
(avagy hogyan üthet vissza a skálázás...)

Henning Jacobs: Running Kubernetes in Production: A Million Ways to Crash Your Cluster - DevOpsCon Munich 2018


https://www.slideshare.net/try_except/running-kubernetes-in-production-a-million-ways-to-crash-your-cluster-devopscon-munich-2018

<https://github.com/zalando-incubator/kubernetes-on-aws/blob/dev/docs/postmortems/jan-2019-dns-outage.md>

Skálázás a gyakorlatban

LIFE OF A REQUEST (INGRESS)


A külvilág felől beérkező
kérelmek szétosztása





Hogyan jut el a kérés a kiszolgálóhoz?

ROUTES FROM API SERVER


A kérések szétosztásához
egy belső „címtár” kell



Kívülről látható hibák az oldalon




404-es hibák (rossz hálózati cím)




Elemi kiszolgálók (Pod) száma


Egyre több erőforrás
→ egyre több hiba



Alkalmazás hibák az utolsó 30 percben



Címlekérések száma az utolsó 30 percben



Tanulság

- A több erőforrás többletműveleteket igényel
 - Itt pl. hálózati címek kezelése (DNS)
- Címek kezelése egyszerű, kicsi erőforráson történt
- Az erőforrás telítődött
 - Rossz a megfigyelő állapotgép modellje
 - Helyesen: „Telítődő” != „Újrainduló” állapot
 - Felesleges újraindítások, felesleges belső címek
 - felesleges üzenetek/akciók
 - egy idő után a monitorozó is leállt
 - a teljesítménymodell önmagában ezt nem fogja leírni...