



3. Elosztott rendszerek

Dr. Bilicki Vilmos

Szegedi Tudományegyetem
Informatikai Tanszékcsoport
Szoftverfejlesztés Tanszék

Tartalom

- ▶ Bevezető
- ▶ Felmerülő problémák
- ▶ Alkalmazás architektúrák
- ▶ Elosztott rendszer architektúrák
- ▶ SOA koncepció
- ▶ Virtualizációs szintek
- ▶ Összefoglaló





Valós nagy rendszerrel kapcsolatos tapasztalatok (Inktomi)

Összeomlások/Merevlemez hibák	Óránként
Adatbázis frissítések	Naponta
Szoftver frissítések	Hetente/Havonta
OS frissítések	Kétszer
Energetikai hibák	néhány
Hálózat hibák	11
Az egész infrastruktúra fizikai átköltöztetése	2

Motiváció – nem funkcionális követelmények

- ▶ Rendelkezésre állás: azon idő amely alatt a komponens képes kielégíteni a funkcionális követelményekben meghatározott funkciókat azon időhöz viszonyítva amikor ezt nem tudja megtenni.
- ▶ Kapacitás/Skálázhatóság: A komponens a terhelés növekedésével is képes ellátni a funkcionális követelményekben megfogalmazott feladatokat.
- ▶ Párhuzamosság: A komponens a több egymással párhuzamos terhelés hatására is képes ellátni a funkcionális követelményekben megfogalmazott feladatokat.
- ▶ Fejleszthetőség: A komponens új funkcionális követelményeket is el tud látni viszonylag szerény fejlesztési ráfordítással.
- ▶ Együttműködési képesség: A komponens képes környezetével és a szükséges komponensekkel aránytalan plusz terhelés okozása nélkül is együttműködni.
- ▶ Késleltetés: A komponens az adott funkcionális követelményben szereplő szolgáltatását adott terhelés mellett adott időtartamon belül kiszolgálja.
- ▶ Karbantarthatóság: A komponensnek támogatnia kell az adott szervezetben definiált karbantartási feladatokat (pl.: backup)
- ▶ Menedzselhetőség: A komponensnek támogatnia kell a megfelelő konfigurálhatósági szintet.
- ▶ Monitorozhatóság: A komponensnek monitorozhatónak kell lennie.
- ▶ Visszaállíthatóság: Hibás adat esetén a komponensnek támogatnia kell a megfelelő állapot visszaállítását.
- ▶ Biztonság: A komponensnek a helyi biztonsági előírásoknak megfelelően kell működnie.
- ▶ Konzisztencia: A komponens az adatot konzisztens állapotban tartja.



Rendelkezésre állás

► Az alábbi paraméterektől függ

■ Megbízhatóság:

- Annak az esélye, hogy egy rendszer adott ideig hibamentesen működik (λ meghibásodási ráta)

$$R(t) = e^{-\lambda t}$$

■ Karbantarthatóság:

- Annek az esélye, hogy egy meghibásodás után egy adott időtartam alatt visszaáll a működőképes állapot (μ megjavítási ráta)

$$M(t) = 1 - e^{-\mu t}$$

- A rendelkezésre állás a rendszer működőképes ideje és a teljes idő hányadosa

$$A = \frac{\text{Up-Time}}{\text{Up-Time} + \text{Down-Time}}$$





Fogalmak


- ▶ MTTF Mean Time To Fail:

$$MTTF = \frac{B1 + B2 + B3}{3}$$


- ▶ MTBF Mean Time Between Failure: $MTBF = \frac{(A1 + B1) + (A2 + B2) + (A3 + B3)}{3}$

- ▶ MTTR Mean Time To Repair:

$$MTTR = \frac{A1 + A2 + A3}{3}$$



Fürdőkád görbe



Megoldás: redundancia

- ▶ Aktív redundancia
 - Elem/komponens duplikálás
 - Rendszer duplikálás
- ▶ Passzív redundancia
 - Hot Standby
 - Warm Standby
 - Cold Standby

▶ Soros rendszer:

$$R_s = p_1 \cdot p_2 \cdot \dots \cdot p_n$$

▶ Párhuzamos rendszer:

$$R_s = 1 - q_1 \cdot q_2 \cdot \dots \cdot q_m$$

$$q_1 = 1 - p_1$$

$$q_2 = 1 - p_2$$



Példa

- ▶ Amazon EC2:
 - 99.95% átlagos rendelkezésre állás egy év alatt
 - Évi 4,38 óra leállás
- ▶ Google Apps:
 - 99.9% havi alapon
 - Évi 8,76 óra leállás, havi 0,73 óra leállás
- ▶ Servaloft:
 - Hálózat: 99,9%, 4 órás helyreállítási idő
 - Gép: 4 órás helyreállítási idő
- ▶ Rackspace:
 - Hálózat: 100% (karbantartáson kívül)
 - Infrastruktúra: 100% havonta (karban tartáson kívül)
 - Gép: 1 órán belül csere






Skálázás kocka

► Dimenziói

- Klónozás
- Dekompozíció (szolgáltatás, funkcionalitás)
- Adat partícionálás



Skálázhatóság

► Adat tárolás/Feldolgozás

■ Vertikális (Scale up)

- Fizikai korlátai vannak (processzorok száma, JVM szeméthyűjtő, ...)
- Közös memória mint kommunikációs médium



■ Horizontális (Scale out)

- Elosztott rendszer (Leslie Lamport: „Elosztott rendszer az ahol egy addig teljesen ismeretlen számítógép hibája teszi használhatatlanná a gépünket”)
- Elvileg korlátlan (elosztottságból fakadóan nem lehet ACID)
- Távoli hozzáférés problematikája (érték szerint vs. referencia szerint)





Virtualizációs rétegek






IaaS - Infrastruktúra mint Szolgáltatás

► Valós vagy virtualizált HW

- Processzor
- Memória
- I/O
- Hálózat

► Függ a fizikai eszközöktől

► Példák:





Virtualizáció

- ▶ Absztrakt fizikai komponensek logikai objektumok segítségével
- ▶ A fizikai és logikai objektumok dinamikus kötése
- ▶ Példa:
 - Hálózat: VLAN, VPN, P2P
 - Tárhely: SAN
 - Számítógép: Virtuális Gép





Fizikai vs. Virtuális gép

- ▶ Fizikai HW:
 - Processzor, memória, chipset, I/O busz
 - A fizikai erőforrások gyakran üresjáratban vannak
- ▶ Szoftver:
 - Szorosan kapcsolódik a HW-hez
 - Egy aktív OS kép
 - Az OS vezérli a HW-t
- ▶ Hardver szintű absztrakció:
 - Virtuális HW: processzor, memória, chipset, I/O eszközök, ...
 - Magában foglalja az OS és alkalmazás állapotot
- ▶ Virtualizációs SW:
 - Elválasztja a HW-t és az OS-t
 - A vendég OS-ek felé multiplexálja a HW-t
 - Erős szeparáció
 - Kezeli a fizikai erőforrásokat




Típusai

- ▶ Type 2: Hosztolt architektúra:
 - Befogadó Oprendszer felett van futtatva
 - Kicsi kontextus váltó meghajtó
- ▶ Type 1: Csupasz fém architektúra
 - A Hypervisort közvetlenül a HW-re telepítik
- ▶ Paravirtualizáció
 - Az operációs rendszer tud a Hyervisorról






Magas rendelkezésre állás






Konszolidált mentés







Probléma:



PaaS - Gartner




PaaS Felmerülő problémák

- ▶ Leslie Lamport egy igen frappáns definíciót adott az elosztott rendszerekre:
- ▶ *“A distributed system is one in which the failure of a computer you didn't even know existed can render your own computer unusable”* azaz *„Elosztott rendszer az, ahol egy olyan számítógép hibája teszi használhatatlanná a saját gépünket, amiről azt sem tudtuk, hogy létezik.”*
- ▶ Egy szabatosabb definíció Wolfgang Emmerichtől: *„Elosztott rendszernek nevezzük az autonóm, egymással hálózaton együttműködő számítógépeket, amelyek közös együttműködésén alapuló szolgáltatását a felhasználó úgy érzékeli, mintha azt egy integrált eszköz szolgáltatta volna.”*



CAP Tétel

- Prof. Eric Brewer sejtése 2000
- Elosztott rendszer tervezési döntési pontok
- Nem lehet egyszerre mindhármát kielégíteni:
 - **Konzisztencia**
 - **Rendlkezésre állás**
 - **Partíció tűrés**



CAP Tétel

► Konzisztencia:

- Adott időpillanatban minden csomópont ugyanazon adatot látja

► Rendelkezésre állás:

- A kieső csomópontok nem akadályozzák a működőket a működésben


► Partíció tűrés:

- A rendszer partíciók esetén istovább működik

► Egy elosztott rendszer ezek közül csak **tettőt** tud teljesíteni **mindhármát nem**



CAP Tétel






CAP Tétel

► Példa

Hotel Foglалás: Lefoglaljuk ugyanazt kétszer?



Bob


Dong



CAP Tétel

► Példa

Hotel foglalás: Lefoglaljuk ugyanazt kétszer?




Miért fontos?

- ▶ Az adatbázis a jövőben **elosztottak** lesznek (Big Data Trend, etc.)
- ▶ CAP tétel megadja a döntési pontokat
- ▶ Meg kell értenünk a lehetőségeket és a veszélyeket



A CAP tétel újragodolása

- Ezek közül kettő teljesül:
 - Consistency
 - Availability
 - Partition tolerance
- Válasszunk kettőt
- A fentiek alapján ezek lehetségesek:
 - CP
 - AP
 - CA



***Bármilyen
probléma?***


Relációs adatbázis skálázás

- ▶ A relációs adatbázisok az **ACID** (Atomicity, Consistency, Isolation, Durability) képességeket szeretnék teljesíteni
- ▶ A fentiek alapján egy igazán elosztott relációs adatbázisnak mindhárom paramétert teljesíteni kelene, Ez lehetetlen.



Egy népszerű hiba:

- ▶ Mi lenne a CA?
- ▶ Lehet egy elosztott rendszer konzisztens és rendelkezésre álló hibás hálózat esetén?



Néhány vélemény


- ▶ Coda Hale, Yammer mérnök:
 - “Of the CAP theorem’s Consistency, Availability, and Partition Tolerance, **Partition Tolerance is mandatory in distributed systems**. You cannot not choose it.”



<http://codahale.com/you-cant-sacrifice-partition-tolerance/>

A few witnesses

- ▶ Werner Vogels, Amazon CTO
 - “An important observation is that in larger distributed-scale systems, network partitions are a given; therefore, **consistency and availability cannot be achieved at the same time.**”





A few witnesses


- ▶ Daneil Abadi, Co-founder of Hadapt
 - So in reality, there are only two types of systems ... I.e., if there is a partition, **does the system give up availability or consistency?**



Konzisztencia vagy rendelkezésre

állás

- Nem bináris döntés
- AP csökkenti a konzisztencia követelményt, de nem szünteti azt meg
- CP csökkenti a rendelkezésre állás követelményt, de nem szünteti azt meg
- A CP és az AP is lehet köztes megoldás



AP: Legjobb szándék szerinti konzisztencia

▶ Példa:

- Web Gyorstár
- DNS

▶ Jellemzők:

- Optimista
- Expiration/Time-to-live
- Konfliktus feloldás



CP: Legjobb szándék szerinti rendelkezésre állás

▶ Példa:

- Többségi protokollok
- Elosztott zárolások (Google Chubby Lock service)

▶ Jellemzők:

- Pesszimista zárolás
- A kisebbségi partíció nem működik



A konzisztencia típusai

- ▶ Erős konzisztencia
 - Az írás után **bármely ezt követő** hozzáférés ugyanazt az eredményt adja vissza
- ▶ Gyenge konzisztencia
 - **Nem garantált** az, hogy az írást követő olvasások ugyanazt az értéket kapják
- ▶ **Végső soron konzisztens**
 - A gyenge konzisztencia egy típusa
 - Garantált, hogy **amennyiben nincs több írás akkor előbb utóbb** minden hozzáférés az utolsó eredményt fogja kapni



Végső soron konzisztens variációk

► Kauzális konzisztencia

- A kauzális viszonyban lévő folyamatok konzisztens adatot fognak látni

► Olvasd a saját írásod konzisztencia

- A folyamat a saját írsát mindig visszakapja

► Viszony konzisztencia

- Amíg a viszony tart addig a rendszer garantálja az olvasd a saját írásodta konzisztenciát




Végső soron konzisztens variációk

- ▶ Monoton olvasás konzisztencia
 - Amennyiben egy folyamat már egy értéket látott attól régebbit nem láthat
- ▶ Monoton írás konzisztencia
 - A rendszer az írásokat folyamat szinten sorosítja
- ▶ A gyakorlatban
 - Több típus is kombinálható
 - Monoton olvasás és olvasd az írásod javasolt



Facebook

- ▶ Bob egy érdekes történetet oszt meg Alizzal
- ▶ Jelzi ezt Aliznak
- ▶ Alíz belép de:
 - **Semmit sem talál!**



Végsősoron konzisztens

- ▶ Bob szól, hogy egy kicsit később nézze meg
- ▶ Alíz vár és újra megnézi
 - Most már látja a Bob által megosztott történetet



Végsősoron konzisztens

- ▶ Megoldás: azért van így mert a Facebook a **végsősoron konzisztens modellt** használja
- ▶ Mirt nem az erős konzisztenciát?
 - Több mint 1 millárd felhasználó
 - Nem triviális ezt erős konzisztenciával kezelni
 - A végsősoron konzisztens megoldás **csökkenti a terhelést és növeli a rendelkezésre állást**



Dinamikus választás C és A között

- ▶ Egy repülő társaság foglaló rendszer
 - Amikor sok az üres szék akkor a konzisztencia kevésbé fontos, fontosabb a rendelkezésre állás
 - Amikor a gép majdnem tele van akkor a konzisztencia fontosabb mint a rendelkezésre állás



Mi van akkor ha nincs partíció?

- ▶ Döntenünk kell a **Konzisztencia** és a **Késleltetés** között:
- ▶ **a hiba lehetősége**
 - Magas rendelkezésre állás -> replikát adat -> konzisztencia probléma
- ▶ Alap ötlet:
 - A rendelkezésre állás és a késleltetés ugyanaz: :
nem áll rendelkezésre -> extrém nagy késleltetés




CAP -> PACELC

- ▶ Egy jóval gyakorlat közelebb megközelítésmód:
 - Amennyiben van **partíció (P)**, akkor döntenünk kell a **rendelkezésre állás és a konzisztencia között (A and C)**; egyébként **(E)**, amikor minden rendben van akkor **késleltetés (L) vagy konzisztencia(C)?**




Abadi, Daniel J. "Consistency tradeoffs in modern distributed database system design." Computer-IEEE Computer Magazine 45.2 (2012): 37.

PACELC



**Partícionál
t**



Normál

Példák

- ▶ **PA/EL rendszer:** Adjuk fel a C-t a rendelkezésre állásért és a konzisztenciáért
 - Dynamo, Cassandra, Riak
- ▶ **PC/EC rendszer:** Nem adjuk fel a konzisztenciát így a rendelkezésre állással és a késleltetéssel fizetünk
 - BigTable, Hbase, VoltDB/H-Store
- ▶ **PA/EC rendszer:** Partíció esetén adjuk fel a konzisztenciát, egyébként adjuk fel a válaszidőt
 - MongoDB
- ▶ **PC/EL rendszer:** Konzisztencia ha partíció van, de adjuk fel a konzisztenciát ha normál üzem van
 - Yahoo! PNUTS

Elosztott rendszer architektúrák

- ▶ CS – Kliens szerver
- ▶ P2P
- ▶ N rétegű architektúra
- ▶ Szorosan csatolt rendszer
- ▶ Lazán csatolt rendszer (EDA)
 - Esemény
 - ESP
 - CEP
- ▶ SBA (Space Base Architecture) (PU alapú)
 - Klaszter
 - Felhő
 - Rács
 - Elosztott Objektum



Kliens - Szerver

- ▶ Szerepkörök alapján határozza meg a rendszerben résztvevő entitások helyzetét.
- ▶ A szerver oldal birtokolja az erőforrásokat,
- ▶ Kliens oldal használja azokat.
- ▶ Ezen elvek mentén működnek napjaink legnépszerűbb protokolljai (HTTP, SMTP, DNS, stb.).
- ▶ A megközelítés előnyei
 - könnyebb karbantarthatóság, és a központosítás miatt elvileg könnyebb biztonságos rendszert készíteni.
- ▶ Hátránya
 - a skálázhatóság és a robusztusság kérdése, mivel ez csak a szerver oldalon múlik.



P2P

- ▶ A kliens szerver architektúra ellentétje a P2P architektúra, ahol egyenrangú vagy nem egyenrangú, de az erőforrások megosztásában egyaránt részt vevő entitások alkotják a rendszert.
- ▶ Skype vagy a legtöbb fájlcsere-protokoll ezen az elven működik.
- ▶ A kliens-szerver megoldással szemben a hátránya a komplexitásában és elosztottságában rejlik, viszont cserébe extrém skálázhatóságot nyújt.
- ▶ Típusai:
 - Elosztott kivonat tábla (pl.: Kademina)
 - Kicsi világ (pl.: Gnutella)
- ▶ Szolgáltatás primitívek:
 - Store
 - Load
 - Search



N-rétegű architektúra

- ▶ *Megjelenítés*: a társ rendszer felé nyújt interfészt (gyakran ez a felhasználói interfész), és az ehhez kapcsolódó eseményeket kezeli le. Ennek a leggyakoribb megvalósítása a weboldal és az előállító logika.
- ▶ *Üzleti logika*: ezen réteg feladata az üzleti folyamatok futtatása, hosszú életű tranzakciók kezelése. Itt kerül sor az adatok szélesebb hatókört, több adattípust átölelő szabályainak kikényszerítése is.
- ▶ *Perzisztencia*: az adatok tartós tárolásával foglalkozik. Itt történik meg a szűkebb hatókörrel rendelkező adatszabályok kikényszerítése és gyakran az objektum és relációs adatmodellek közötti leképezés is.




Szorosan csatolt rendszerek

- ▶ A szorosan csatolt rendszerekben a komponensek (vagy ha ilyenek nincsenek, akkor az osztályok, objektumok) szinkron módon kommunikálnak egymással, szorosán követve a klasszikus függvényhívás szemantikáját.
- ▶ Ebbe a kategóriába tartoznak a távoli eljárásokon alapuló rendszerek is.
- ▶ A megközelítés előnye az, hogy a rendszer a klasszikus, egy processzen belül is megtalálható interkációs paradigmákra épít, egyszerűvé téve ezzel a megvalósítást.
- ▶ Ezzel a megoldással viszont nehéz robosztus, skálázható rendszereket létrehozni.



Lazán csatolt rendszerek

- ▶ *Egyszerű események feldolgozása*: ez esetben egy atomi esemény beérkezése indít el egy feldolgozási folyamatot. Egy példa erre a különböző felhasználói interakciókat támogató keretrendszerek eseménykezelése (pl. SWING JSF, stb.)
- ▶ *Eseményfolyamok feldolgozása (Event Stream Processing – ESP)*: ezesetben eseményfolyamokat szűrnek egyszerű feltételek alapján, és az érdekes eseményekre feliratkozott vevőknek küldik ki a szűrt eseményeket. Példa lehet erre, amikor a naplózásnál csak adott szintet elérő eseményeket továbbítunk.
- ▶ *Komplex esemény feldolgozás (Complex Event Processing - CEP)*: ez esetben a valós idejű eseményfolyamon értékelünk ki olyan szabályokat, melyek figyelembe vehetik az események sorrendiségét, bekövetkeztét, számosságát és számos egyéb tulajdonságát. Erre a későbbiekben majd látunk példát a Drools-szal kapcsolatban.




SBA rendszerek

- ▶ *Klaszter alapú (Cluster):* a feldolgozásra koncentrálnak, az adattárolásra különböző tervezési minták vannak, a tipikusan olvasás jellegű alkalmazásoknál igen jó skálázódást tud elérni a CAP kompromisszumai nélkül. Le tudja kezelni az írási ütközést is. Példák erre a különböző alkalmazásszerverek által nyújtott klaszterezési lehetőségek (pl. JBoss Cluster)
- ▶ *Felhő alapú (Cloud):* a CAP paradigma mentén a skálázható adattárolást is biztosítja, tipikusan a konzisztencia rovására. Példa erre a Google App Engine.
- ▶ *Rács alapú (Grid):* főleg a feldolgozásra koncentrálnak, nincs igazán írási ütközés, így a feldolgozás tetszőlegesen párhuzamosítható. Ezt leginkább munkafolyamatok (**Job**) formájában szokták megtenni.
- ▶ *Elosztott objektum alapú (Distributed Objects):* az elosztott objektumok gyakran a fenti architektúrák alapjait képezik. Ekkor egy-egy objektum vagy replikánsa (**replikált objektum** – replicated object) megjelenik azokon a helyeken, ahol használják, és a háttérben egy keretrendszer (köztes réteg) gondoskodik arról, hogy konzisztens maradjon, vagy pedig egy helyen van tárolva (**élő objektum** – live object), és azokon a helyszíneken, ahol szükséges megfelelő proxy objektumok képviselik az objektumot. A megosztott objektumok gyakran **objektumterekben (object spaces)** vannak szervezve, melyet valamilyen köztes réteg tart karban, virtualizál (pl. Java Spaces).






SOA koncepció






SOA háromszög

Szolgáltatás Orientált Architektúra





WS világ




Mikroszolgáltatások

- ▶ Írjunk nagy alkalmazásokat: írjunk kicsiket (egy nagy alkalmazás kicsikből álljon)
- ▶ Egy architektúrláti típus:
 - Egy alkalmazás több önnáló könnyűsúlyú processz
 - Egymással HTTP-n kommunikál
 - Automatizált telepítés
 - Központosított menedzsment





Mikroszolgáltatások



Összefoglaló

- ▶ Bevezető
- ▶ Felmerülő problémák
- ▶ Alkalmazás architektúrák
- ▶ Elosztott rendszer architektúrák
- ▶ SOA koncepció
- ▶ Virtualizációs szintek
- ▶ Összefoglaló



A következő előadás tartalma

- ▶ Kontextus
- ▶ Biztonsági kontextus
- ▶ Tranzakciós kontextus
- ▶ Perzisztencia kontextus

