


„Big Data” elemzési módszerek

Kocsis Imre, ikocsis@mit.bme.hu

1. ea, 2017.09.04.



A félévről

- <https://inf.mit.bme.hu/edu/courses/bigdata>
- Előadók, közreműködők
 - Dr. Pataricza András
 - **Kocsis Imre (op. felelős)**
 - Klenik Attila
 - HF (várhatóan): Gönczy László, Hullám Gábor, ...
- ikocsis@mit.bme.hu, IB418, (+36 1 463) 2006
- 1 ZH (*terv*: 12. okt. hét), min. 40%
- Házi feladat
 - Kiadás: ~7-8. hét
 - Érdemjegyhez elfogadása szükséges
 - 2-3 fős csapatok
 - Bemutatáson minden csapattagnak jelen kell lennie
- Érdemjegy: $0.4 * ZH + 0.6 * HF$


MI AZ A “BIG DATA”?

Definíció [1]


- Adatkészletek, melyek mérete nagyobb, mint amit
 - regisztrálni,
 - tárolni,
 - kezelni és
 - elemezni tudunk
- a „tipikus” (szoftver) eszközökkel.
 - SQL Server, Matlab, SPSS, SAS, R, gnuplot...

Tárolási kapacitás a világon [1]

Overall
Exabytes





Detail
%; exabytes



NOTE: Numbers may not sum due to rounding.

SOURCE: Hilbert and López, "The world's technological capacity to store, communicate, and compute information," *Science*, 2011

Számítási kapacitás a világon [1]




NOTE: Numbers may not sum due to rounding.

SOURCE: Hilbert and López, "The world's technological capacity to store, communicate, and compute information," *Science*, 2011

Nagyvállalatok által tárolt adatok [1]

Companies in all sectors have at least 100 terabytes of stored data in the United States; many have more than 1 petabyte



Milyen adatok ezek?

- Időben/populáción ismétlődő megfigyelések
 - IoT/CPS/mobil eszközök
 - Elosztott szenzorhálózatok (pl. „smart metering”)
 - Járművek fedélzeti szenzorai
 - ...
 - Telekommunikációs hálózatok
 - 5G!
 - Kis(?)kereskedelmi üzletmenet
 - Tudományos kísérletek (LHC, neurológia, genomika, ...)
 - Számítógépes infrastruktúrák, “web logok”
 - ...
- Gráfok, hálózatok
 - Közösségi szolgáltatások
- Természetes szöveg
 - Wikipedia
- A “Big Data” határ változik; pár száz GB ... pár száz TB


~ Akármilyen adatban lehet (elég) (üzleti) érték, ha elég olcsón tudjuk tárolni + feldolgozni

a.k.a. “jó lesz az még valamire”

1GB tárolókapacitás ára (HDD)

Backblaze Average Cost per Drive Size

By Quarter: Q1 2009 - Q2 2017




- A trend a lényeg
- Cloud provider
- Nem SSD

Source: <https://www.backblaze.com/blog/hard-drive-cost-per-gigabyte/>




1GB tárolókapacitás ára (HDD)



<http://www.mkomo.com/cost-per-gigabyte-update>



https://www-03.ibm.com/ibm/history/exhibits/vintage/vintage_4506VV4023.html

Tárolókapacitás ára általánosságban



<http://www.jcmit.net/mem2015.htm>

És persze igazak ezek is: CPU, hálózat




<http://www.nature.com/news/the-chips-are-down-for-moore-s-law-1.19338>

<http://ix.br/pttforum/9/slides/ixbr9-ethernet.pdf>

Mire megyünk a sok adattal?


- Üzletmenet
 - Működési metrikák, előrejelzés, adatbányászat
- Szenzor-adatok
- „IT for IT”
 - loganalízis, diagnosztika, hibaelőrejelzés, kapacitásmenedzsment, ...
- Közösségi média elemzése
 - Pl. PeerIndex
- Csalásfelderítés (fraud detection), nemzetbiztonság
 - N.B. ritka események; az algoritmika részben újszerű
 - “terrorista nem vásárol életbiztosítást” (+ nincs megtakarítása + péntek délután nem vesz ki pénzt ATM-ből) – lásd Freakonomics
- IBM Big Data Success Stories [8]
- ...

Vagy csak vizualizáljuk, “hátha kijön valami...”



https://anaconda.org/jbednar/nyc_taxi/notebook


Vagy csak vizualizáljuk, “hátha kijön valami...”




<https://anaconda.org/jbednar/census/notebook>

Ilyeneket fogunk és fogtok csinálni.

Egy saját példa: VDI kapacitástervezés



Egy saját példa: VDI kapacitástervezés



Alternatív definíció: Big Data jellemzők [2]

- **,Volume'**: igen nagy mennyiségű adat
- **,Variety'**: nagyszámú forrás és/vagy nemstrukturált/részben strukturált adatok
- **,Velocity'**: a ,Return on Data' (ROD) a lassú feldolgozással csökken
 - Főleg ,streaming' problémáknál
 - Ellentéte: ,at rest' Big Data problémák
- **,Veracity'**: nagymennyiségű zaj
 - Pl. Twitter ,spam'

Amiben a Big Data adatelemzés más


- Nem mintavételezünk (nem/kevésbé kell)
- De az adat nem/kevésbé fogyasztásra kész
- Nem feltétlenül tudjuk előre, hogy mit csinálunk
 - Leíró statisztika
 - Adatfelderítés módszerei
 - Vizualizáció
 - (Nyelvfeldolgozás)
 - Statisztikusokat felháborító Machine Learning (ML)
- Más szoftver eszközök
- De ettől még az adatelemzés, adatbányászat és gépi tanulás “konceptcionális” rétege nagyban hasonlít

De miért nem RDBMS (+SQL)?

Miért nem RDBMS? Például...

- „Big Data” problémáknál sokszor létezik természetes (részleges) rendezési szempont
 - Természetes: a nemtriviális analízisek ebben a sorrendben működnek
 - Pl. idő (idősor-analízis)
- Relációs modell: sorok sorrendje?
- Következmény: véletlenszerű hozzáférés diszkről
- Az „optimális” hozzáférési mintához képest lassú
- **Ingyen ebéd továbbra sincs.**

A normalizált séma *igen* lassú lehet... [3]



Indexekről, ACID tulajdonságokról, klaszter-állapotszinkronitásról még nem is beszéltünk.

Nagyvállalati adattárházak?

- Jellemzően igen komoly ETL
- „Válaszidő”-követelmények
 - Régi adatok aggregálása/törlése/archiválása
- Strukturálatlan adatok nem jellemzőek
- Drágák...
- Nem lehet későbbi analízisre „leborítani” az adatokat

Analízis eszközök?

- Példa: R (base)
 - De lehetne SPSS, SAS, h.d. Excel is
- Kulcsrakész függvények mediántól a neurális hálókig
- De: csak memóriában tárolt adattípusok, nem hatékony memóriakezelés
- Ez változóban; SQL/R/Python/... “rárakódik” a Big Data eszközökre

ELOSZTOTT SZÁMÍTÁSTECHNIKA ALKALMAZÁSA


Big Data probléma

- „At rest Big Data”
 - Nincs update
 - „Mindent” elemzünk
- Elosztott tárolás
- „Computation to data”



„Not true, but a very, very good lie!”
(T. Pratchett, Nightwatch)

Lazán csatolt, magas lokalitású párhuzamosítás



Elosztott számítástechnika

- Big Data: a ma alkalmazott stratégia COTS elosztott rendszerek alkalmazása
 - Kivételek vannak; lásd IBM Netezza
- 8 db nyolcmagos gép jóval olcsóbb, mint egy 64 magos
- Modern hálózati technológiák:
 - Memóriánál lassabb
 - Helyi diszk áteresztőképességénél/válaszidejénél nem feltétlenül!
- *A tárolás és a feldolgozás is elosztott*
 - Lehetőleg egy helyen legyen azért

Alapvető kérdések

- Elosztott platformon párhuzamosítás szükséges
- Hatékony feldolgozáshoz továbbra is referenciális lokalitás kell
- Bár a feldolgozás „közel vihető az adathoz”, az adatterítés logikája befolyásolja a teljesítményt
 - Pl. csak egy csomópont dolgozik

Node 1

timestamp	sensor	reading
19990101000000	1	
19990101000015	1	
19990101000030	1	
⋮	⋮	⋮
20081231235930	1	
20081231235945	1	
19990101000000	2	
19990101000015	2	
19990101000030	2	
⋮	⋮	⋮
20081231235930	2	
20081231235945	2	
19990101000000	3	
⋮	⋮	⋮
20081231235945	100	

Node 1

timestamp	sensor	reading
19990101000000	1	
19990101000000	2	
19990101000000	3	
⋮	⋮	⋮
19990101000000	1000	
19990101000015	1	
19990101000015	2	
19990101000015	3	
19990101000015	4	
⋮	⋮	⋮
19990101000015	1000	
19990101000030	1	
19990101000030	2	
⋮	⋮	⋮
19991231235945	100	

Node 2


timestamp	sensor	reading
19990101000000	101	
19990101000015	101	
19990101000030	101	
⋮	⋮	⋮
20081231235930	101	
20081231235945	101	
19990101000000	102	
19990101000015	102	
19990101000030	102	
⋮	⋮	⋮
20081231235930	102	
20081231235945	102	
19990101000000	103	
⋮	⋮	⋮
20081231235945	200	

Node 2


timestamp	sensor	reading
20000101000000	1	
20000101000000	2	
20000101000000	3	
⋮	⋮	⋮
20000101000000	1000	
20000101000015	1	
20000101000015	2	
20000101000015	3	
20000101000015	4	
⋮	⋮	⋮
20000101000015	1000	
20000101000030	1	
20000101000030	2	
⋮	⋮	⋮
20001231235945	1000	

A klasszikus minta: MapReduce

„Reduce”




„Map”



Distributed
File System

MapReduce – funkcionális nézet [6]



MapReduce: szavak számolása szövegben [7]

```
map(String input_key, String input_value):  
    // input_key: document name  
    // input_value: document contents  
    for each word w in input_value:  
        EmitIntermediate(w, "1");
```

```
reduce(String output_key, Iterator intermediate_values):  
    // output_key: a word  
    // output_values: a list of counts  
    int result = 0;  
    for each v in intermediate_values:  
        result += ParseInt(v);  
    Emit(AsString(result));
```

Rendszerszervezési alapelvek

- Egyszerű elosztott tárolás
 - Nem hogy ~~ACID~~, de állomány-frissítés
 - Sáv szélesség n-szerzése!
- Optimális esetben: tárolóelem egyben számol is
- ~Ua a (párhuzamos) kód mindenhol
- Lokalitás fontos: hálózati kommunikáció “drága”
- ! nem minden probléma “embarrassingly parallel”

MapReduce, mint párhuzamosítási minta

- Számos probléma jól megfogalmazható MapReduce szemléletben
 - Mátrix-mátrix és mátrix-vektor szorzás
 - Relációalgebra
 - Korreláció
 - Google PageRank (az eredeti)
 - ...
- (Mélyebb) algoritmikát lásd: Rajaraman, Ullman et al.: **Mining of Massive Datasets** [6]
 - www.mmds.org – ingyenesen letölthető
 - ~ azonos nevű Stanford CS kurzus alapján


Big Data == Hadoop?

- Google MapReduce, GFS, BigTable cikkek...
- ... Apache Hadoop
- Nyílt forráskódú, Java alapú keretrendszer
- Hadoop Distributed File System (HDFS)
- Eredetileg: MapReduce programozási paradigma
- Ráépülő/kiegészítő/kapcsolódó projektek
- “Pay for support” disztribúciók – Cloudera, Hortonworks, MapR, ...

Law of Betteridge
applies



Az építőkészlet – egy nézet




Forrás: <http://slides.com/racku/deck-4-3-2#/4/13>

BIG DATA ÉS A FELHŐ

Költségoptimalizálás?

- Ára van...
 - A ki nem szolgált igényeknek
 - És a felesleges kapacitásnak
- A felhő „egységára” (*unit price*) lehet magasabb a saját befektetésnél, de...
- ... ugyanez igaz az autóbérlésre és a hotelszobákra
- **Hibrid felhők:** privát: alapterhelés, publikus: változó
 - Komolyabb optimalizációs probléma és még mindig terhelést kell becsülni...

Szolgáltatói oldalon...




Miért éri meg a szolgáltatónak? [9]

- (Centrális határeloszlás-tétel nélkül)
- X_i azonos várhatóértékű (μ) és varianciájú (σ^2), független val. változók
- Variációs koefficiens (*coefficient of variation*): $\frac{\sigma}{\mu}$
- Összeg várhatóértéke: várh. összege
- Összeg varianciája: varianciák összege

$$CV(X_{sum}) = \frac{\sqrt{n\sigma^2}}{n\mu} = \frac{1}{\sqrt{n}} \frac{\sigma}{\mu} = \frac{1}{\sqrt{n}} CV(X_i)$$

A „statisztikai multiplexálás” hatása

- Az átlaghoz képest vett szórás csökken
- $\frac{1}{\sqrt{n}}$: gyorsan; kisebb privát cloud-ok!
- A valóságban persze nem független minden terhelés



Ábra forrása: http://en.wikipedia.org/wiki/Central_limit_theorem

Párhuzamosítható terhelések

- Egyre több „zavarbaejtően” párhuzamos (*embarrassingly parallel*), „scale-out” alkalmazáskategóriánk van
- NYT TimesMachine [10]: public domain archív
 - Konverzió web-barát formátumra [11]: Hadoop, pár száz VM, 36 óra
- **A használat alapú számlázás miatt ~ugyanannyiba kerül, mint egy VM-mel**
- Praktikusan: „ingyen idő”

Vagy ha nem akarunk Hadoop-ot építeni...

Secure | <https://aws.amazon.com/ec2/pricing/on-demand/>

Menu  English ▾ My Account ▾ [Sign In to the Console](#)

PRODUCTS & SERVICES

- Amazon EC2 >
- Product Details >
- Getting Started >
- Instances >
- Developer Resources >
- FAQs >
- Amazon EC2 Run Command >
- Pricing >

Memory Optimized - Current Generation

x1.16xlarge	64	174.5	976	1 x 1920 SSD	\$6.669 per Hour
x1.32xlarge	128	349	1952	2 x 1920 SSD	\$13.338 per Hour
r3.large	2	6.5		1 x 32 SSD	\$0.166 per Hour
r3.xlarge	4				
r3.2xlarge	8	26	61	1 x 160 SSD	\$0.665 per Hour
r3.4xlarge	16	52	122	1 x 320 SSD	\$1.33 per Hour

GiB. Kell egyáltalán Hadoop?

Javasolt olvasmány: <http://www.kdnuggets.com/2015/11/big-ram-big-data-size-datasets.html>

Vagy ha nem akarunk Hadoop-ot építeni (2)...

Microsoft Azure

ÉRTÉKESÍTÉS 06-1-437

Miért érdemes az Azure-t választani? Megoldások Termék Dokumentáció Díjszabás Képzés Piacter Partnerek Blog Seg

 HDInsight

Spark- és Hadoop-felhőszolgáltatás a vállalat számára

Az Azure HDInsight az egyetlen olyan teljes körűen felügyelt Apache Hadoop-felhőajánlat, amely optimalizált, nyílt forráskódú analitikus fűtöket biztosít a Spark, a Hive, a MapReduce, a HBase, a Storm, a Kafka és a Microsoft R Server számára. 99.9%-os SLA-val támogatva. Ezek a big data technológiák és ISV-alkalmazások könnyűszerrel

Docs Catalog Log In Sign Up

IBM Bluemix Catalog

All Categories

Infrastructure

- Compute
- Storage
- Network
- Security
- Containers
- VMware

Search Filter

Essential data services; limitless possibilities.

 **Apache Spark**

IBM Analytics for Apache Spark for

IBM


 **BigInsights for**

+ “kulcsrakész” DM és ML különböző formái

BIG DATA 2017-BEN (NÉHÁNY GONDOLAT EREJÉIG)

Hol a Big Data???

Hype Cycle for Emerging Technologies, 2017




Note: PaaS = platform as a service; UAVs = unmanned aerial vehicles

Source: Gartner (July 2017)

Válasz: már 2015-ben sem volt rajta.
Már nem “emerging”.

Ipari folyamatok



Inspiráció: <http://mattturck.com/bigdata2017/>

Zárszó: oktatási céljaink (2 kredit kiméretben)

- “Data science” alapfogalmai, felderítő elemzés
 - Vizualizáció!
- DM és ML fő céljai, szemelvények
 - Mélységben min. egy szakirány
- Fő Big Data platformok koncepcionális megértése
 - Némi algoritmika
 - Egyre magasabb szintű programozás (inkl. SQL visszatérése)
 - + DM/ML “könyvtárak” és szolgáltatások
- Hands-on készségek alapjai: házi feladat
 - A tárgy élvezetes része 😊

Tervezett tematika

Dátum	2017-es terv
szeptember 5	BD bevezetés
szeptember 12	Stat. alapfogalmak
szeptember 19	vizualizáció + EDA
szeptember 26	Interaktív és BD vizualizáció, datashader
október 3	Az adatelemzés alapfeladatai
október 10	Folyt; munkafolyamatok, cloud szolgáltatások
október 17	HDFS, MapReduce - alapelvek, tulajdonságok, algoritmika
október 24	Spark - alapelvek, tulajdonságok
október 31	Vendégelőadás (téma egyeztetés alatt)
november 7	BD ML szemelvények
november 14	Stream processing
november 21	ZH
november 28	Szűrés, mintavételezés, outlier-detektálás, ritka események
december 5	HF bemutatás

Források

- [1] Manyika, J., Chui, M., Brown, B., & Bughin, J. (2011). *Big data: The next frontier for innovation, competition, and productivity*. Retrieved from <http://www.citeulike.org/group/18242/article/9341321>
- [2] Zikopoulos, P., Deroos, D., Parasuraman, K., Deutsch, T., Corrigan, D., & Giles, J. (2013). *Harness the Power of Big Data*. McGraw-Hill. Retrieved from <http://medcontent.metapress.com/index/A65RM03P4874243N.pdf>
- [3] Jacobs, A. (2009). The pathologies of big data. *Communications of the ACM*, 52(8), 36. doi:10.1145/1536616.1536632
- [4] <http://www.ibm.com/developerworks/library/wa-introhdbs/>
- [5] Borkar, V., Carey, M. J., & Li, C. (2012). Inside “Big Data management.” In *Proceedings of the 15th International Conference on Extending Database Technology - EDBT '12* (pp. 3–14). New York, New York, USA: ACM Press. doi:10.1145/2247596.2247598
- [6] Rajaraman, A., & Ullman, J. D. (2011). *Mining of Massive Datasets*. Cambridge: Cambridge University Press. doi:10.1017/CBO9781139058452
- [7] <http://research.google.com/archive/mapreduce-osdi04-slides/index.html>
- [8] IBM Big Data Success Stories. <ftp://ftp.software.ibm.com/software/data/sw-library/big-data/ibm-big-data-success.pdf>
- [9] Weinman, Joe. *Cloudonomics: The business value of cloud computing*. John Wiley & Sons, 2012.
- [10] <http://timesmachine.nytimes.com/browser>
- [11] <http://open.blogs.nytimes.com/2008/05/21/the-new-york-times-archives-amazon-web-services-timesmachine/>