

DISA: Data Intensive Systems and Applications

Prezentace laboratoře pro den otevřených dveří na FI MU

RNDr. Vladimír Míč

Fakulta informatiky Masarykovy univerzity, Brno

24. října 2019

Big data \approx big problem

Rok	2005	2010	2015	2020	2025
Množství digitálních dat	100	2 000	17 000	50 000	175 000

Tabulka: Digitální data, celosvětově, v milionech terabajtů (TB)¹

- 175 miliard TB
 - Blu-ray disky²: sloupec výšky 222 krát obvod Země
 - Stahování 100 Mb/s³: 450 milionů let, tj. pětina stáří Země a 4 500 krát doba existence Homo sapiens sapiens
 - Na FI MUNI jen 52,3 milionů let!⁴

¹ „IDC data age study 2025“ sponzor: Seagate, listopad 2018

² „DVD s kapacitou 25 GB“

³ slušná rychlosť internetu v soukromém bytě v Brně 2018

⁴ Rychlosť stahování na FI MU, 14.12.2018 v 0:38: 860 Mb/s

Vlastnosti dnešních dat

Čo bolo (to bolo)	Sílící trendy
Malé množství datových typů (texty, jména, čísla, adresy ...)	Boom datových typů (obrázky, videa, pohybová data, zvuky, otisky prstů, časové řady, 3D grafy, modely, ...)
Strukturovaná data	Vytrácející se, dynamická či složitá struktura, ... (video)
Jasně vztahy a souvislosti dat	Vágní, složité, dynamické vztahy, „big data se ovlivňují navzájem“ (internet, sociální sítě)

- Xindong Wu: *On Big Wisdom* (ICDM 2018 Singapur)
 - „HAO“: integrace lidské (H), umělé (A) a firemní (O) inteligence s analýzou big data

Nutnost nových postupů

- Nové nároky na zpracování dat
 - Detekce krádeží ve videu z bezpečnostní kamery
 - Doporučení relevantních položek (*reklama, vyhledávání*)
 - Identifikace lidí (*otisky prstů, duhovka, (tváře?)*)
 - Dynamické (kontextové) hledání souvislostí v datech (*setkaly se osoby A a B?*)
- Jak je řešit? **Podobnost!**



- **Laboratoř DISA:** podobnostní vyhledávání v multimédiích ve velkých datech
 - Základní úloha: „*dotaz příkladem*“
Cílem je nalézt nejpodobnější objekty k vybranému