


Two sides of the same coin

The use of Big Data in social research
through theory & practice

Ságvári Bence, MTA TK


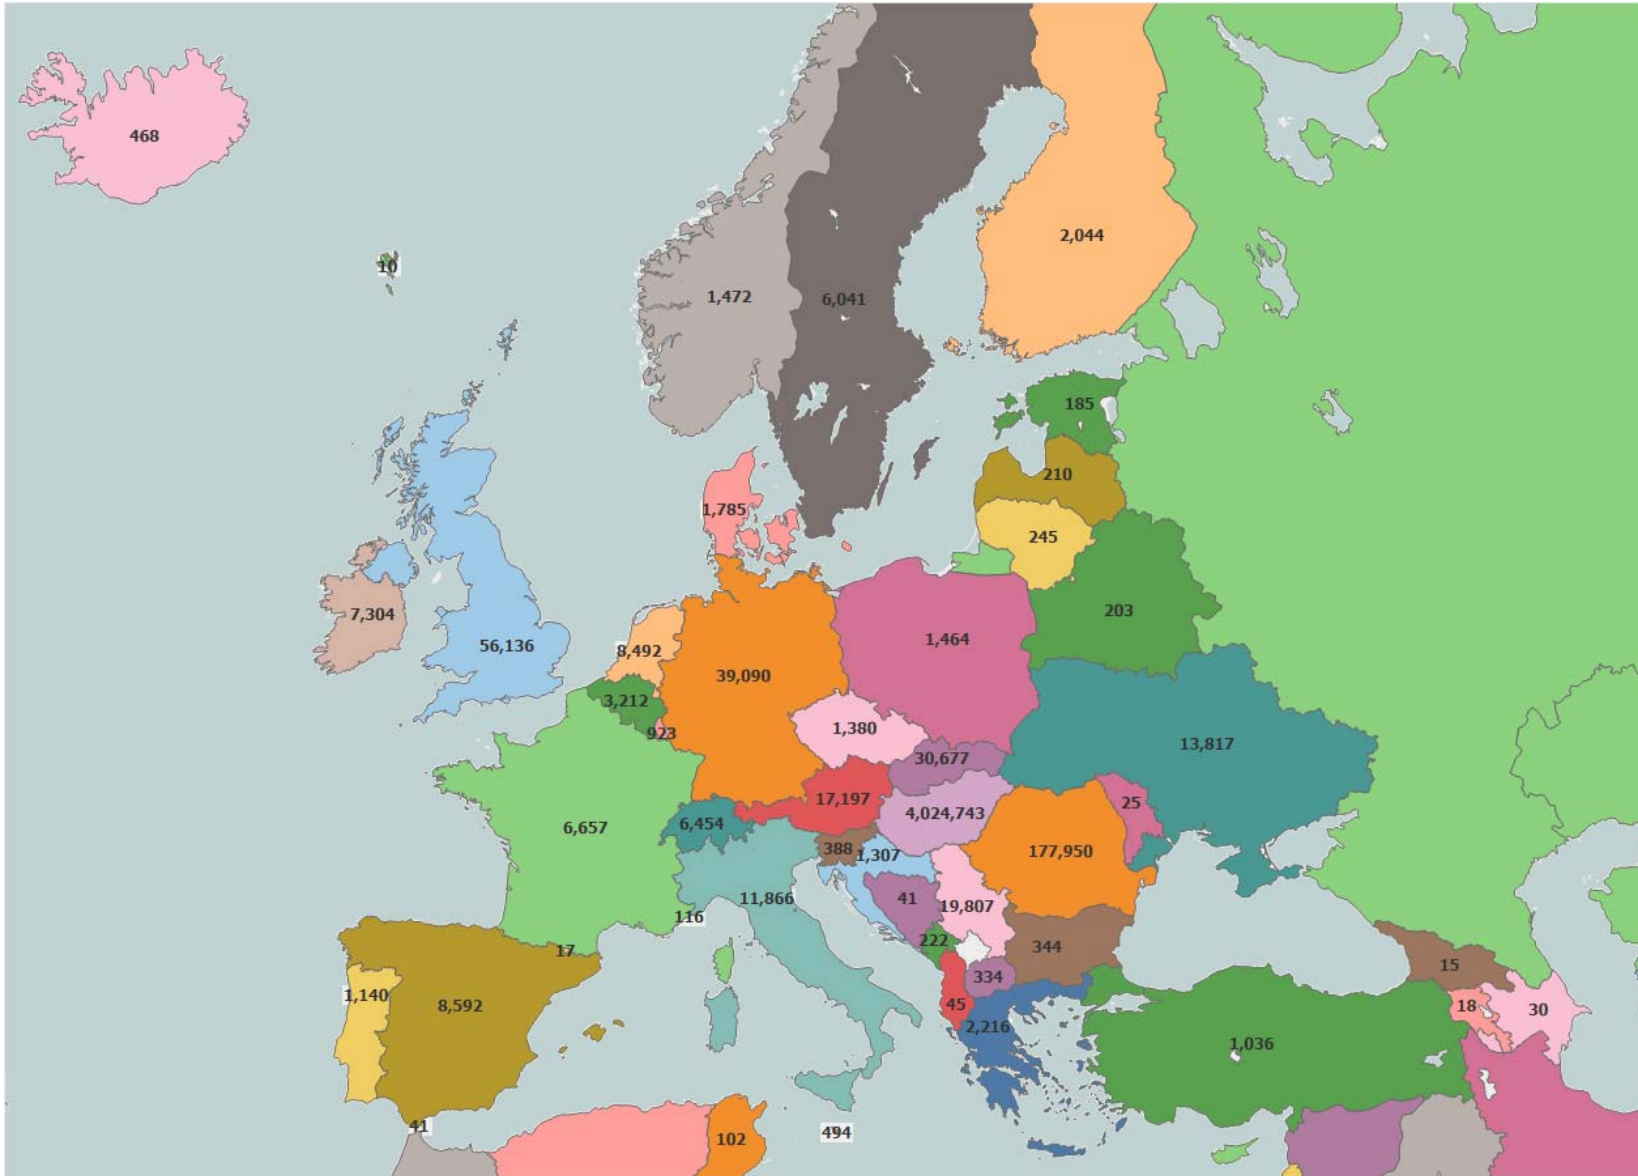


Ten common characteristics of big data

Matthew J. Salganik (2017) *Bit by Bit: Social Research in the Digital Age*. Princeton University Press

1. BIG

“Large datasets are a means to an end; they are not an end in themselves.”



2. ALWAYS-ON

“Always-on big data enables the study of unexpected events and real-time measurement.”

3. NONREACTIVE


“Measurement in big data sources is much less likely to change behavior.”



4. INCOMPLETE

“No matter how big your big data, it probably doesn't have the information you want.”

Massive share of missing information on age

Users with valid age by gender





5. INACCESSIBLE

“Data held by companies and governments are difficult for researchers to access.”

Az Üzleti titok megismerője **teljes körű felelősséggel tartozik Üzleti titokkal kapcsolatos kötelezettségei bármilyen megsértésért, ezekkel kapcsolatos kárért**, ha a titoksértés vagy kár az Üzleti titok megismerőjének felróható, vagy egyébként ő okozta, beleértve az alkalmazottai, Üzleti Partnerei és Jogosított megismerői általi károkozást, vagy titoksértést is. Az Üzleti titok megismerője a tudományos kutatásban részt vevő alkalmazottak és partnerek felelősségét szerződésben rögzíti.



A tudományos kutatás eredményeit a Partner közölheti olyan módon, hogy a tudományos és ismeretterjesztő publikációkba üzleti titok nem kerülhet. **A publikációk közlésének menetét a Felek a kizárólagos felhasználási szerződésben fektetik le.**

A jelen Megállapodás hatálya alatt az Üzleti titok jogosultja írásbeli kérésére az Üzleti titok megismerője a fizikailag birtokában lévő Üzleti **titkokat köteles az Üzleti titok jogosultjának visszaszolgáltatni vagy megsemmisíteni** (az Üzleti titok jogosultja utasítása szerint), annyiban amennyiben az ésszerűen végrehajtható.

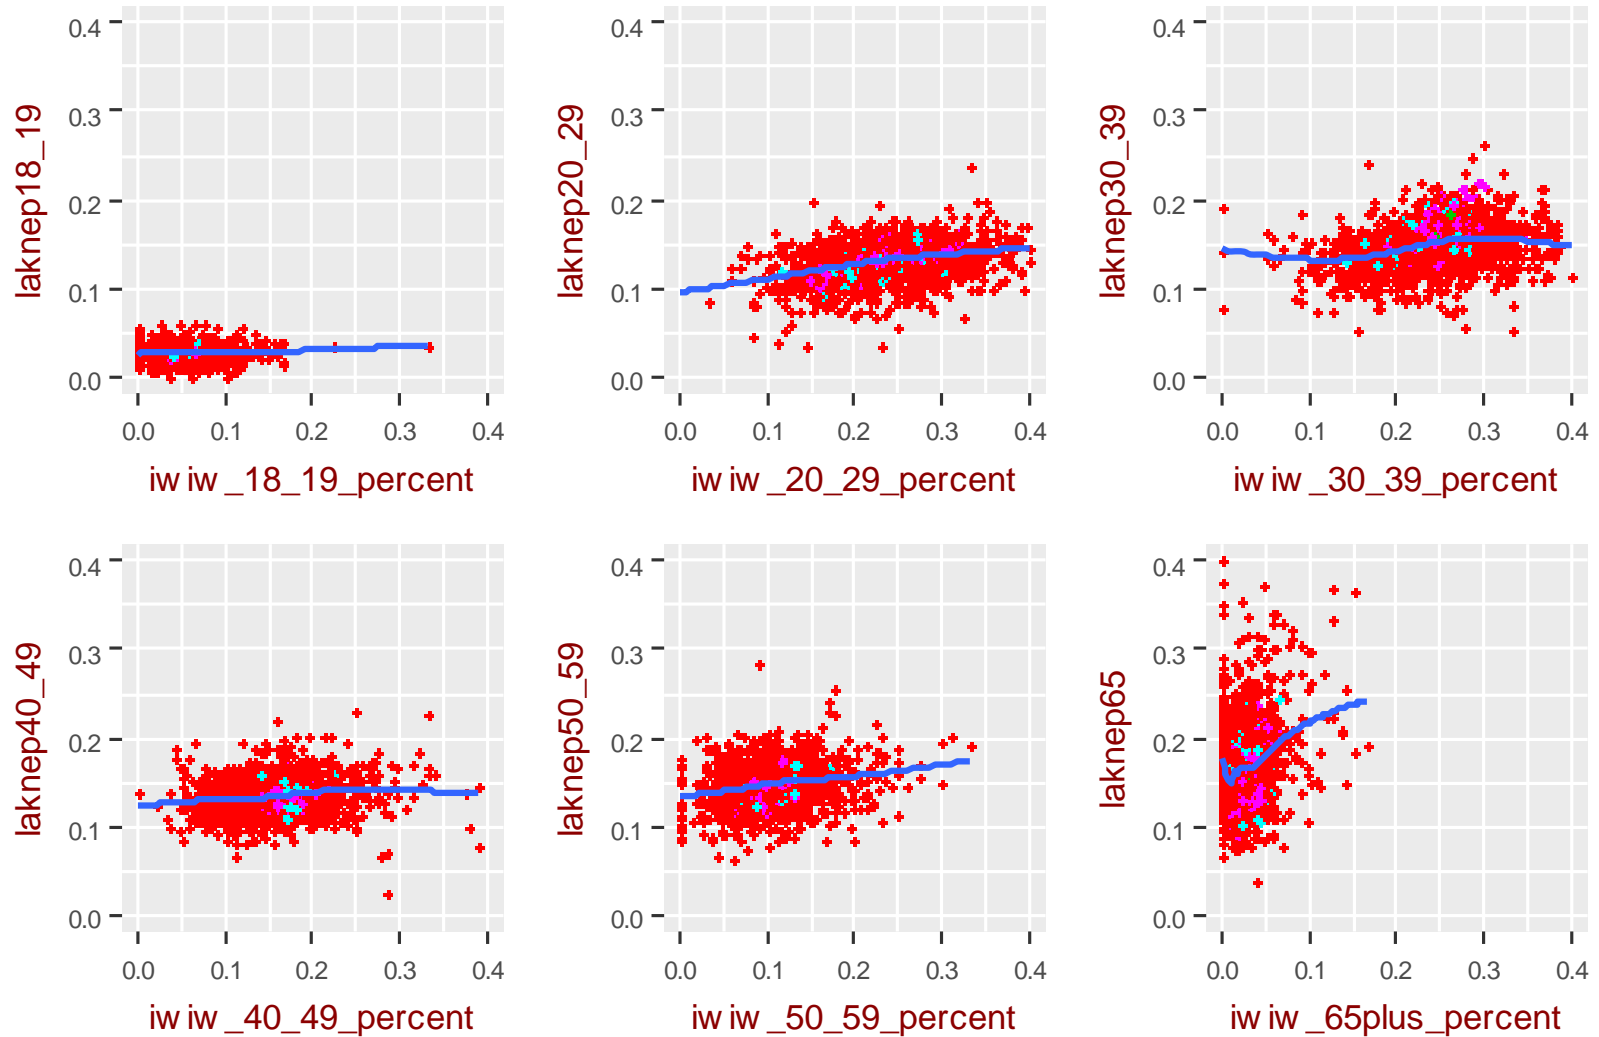
6. NONREPRESENTATIVE

“Non-representative data are bad for out-of-sample generalizations, but can be quite useful for within-sample comparisons.”

Real vs. iWiW population in Hungarian settlements



Age distribution of real vs. iWiW population in Hungarian settlements



7. DRIFTING

“Population drift, usage drift, and system drift make it hard to use big data sources to study long-term trends.”

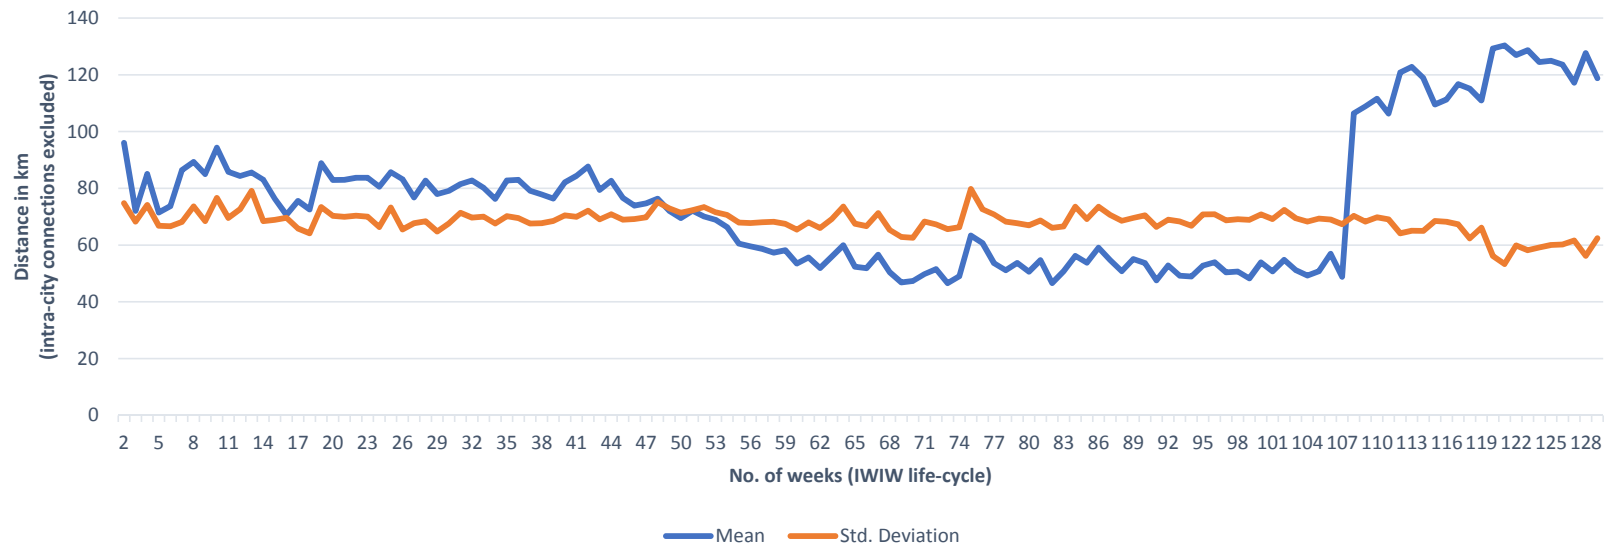

8. ALGORITHMICALLY COUNFOUNDED

"Behavior in big data systems is not natural; it is driven by the engineering goals of the system."

9. DIRTY

“Big data sources can be loaded with junk and spam.”

Average distance of invitor-invited connections across adopter categories
(intra-city connections excluded)



10. SENSITIVE

“Some of the information that companies and governments have is sensitive.”

Thank you...

sagvari.bence@tk.mta.hu

