

# LEZIONI LINCEE DI DATA SCIENCE E SCIENZE INFORMATICHE

La nuova Scienza dei dati e le sue sfide

Carlo Batini

Università di Milano-Bicocca

# Il prezzo dei biglietti aerei

## Problema 0 - Fissato il giorno del viaggio, trovare il biglietto meno costoso

The screenshot shows a flight search interface with the following details:

- From:** Milano
- To:** Dar es Salaam DAR
- Date:** gio 17 gen

Below the search bar, there are two main sections:

- Scegli viaggio a Dar es Salaam** (Select trip to Dar es Salaam) and **Riepilogo del viaggio** (Travel summary).
- Suggerimenti sui voli** (Flight suggestions) with four options:
  - Date**: Guarda i prezzi dei voli in date simili
  - Grafico dei prezzi**: Esplora le tendenze dei prezzi dei viaggi con destinazione Dar es Salaam
  - Aeroporti**: Confronta i prezzi per gli aeroporti vicino a Dar es Salaam
  - Suggerimenti**: Vola in premium economy al costo di 987 €

Below these suggestions, there is a section for **Voli migliori** (Best flights) with the following data:

Flight Details	Duration	Stops	Price
11:00 - 08:05 <sup>1</sup> Turkish Airlines	19 h 5 min MXP-DAR	2 scalo <span style="color:red;">▲</span> IST, LUN	348 €
18:55 - 03:05 <sup>2</sup> Turkish Airlines	30 h 10 min MXP-DAR	1 scalo <span style="color:red;">▲</span> 19 h 55 min IST	348 €
22:15 - 15:30 <sup>1</sup> Qatar Airways	15 h 15 min MXP-DAR	1 scalo 2 h 55 min DOH	572 €

**Problema 1** - Fissato il giorno del viaggio,  
scoprire **quale è il giorno**  
in cui il biglietto costa meno

?

## Problema 2 - Prevedere quando e dove ci saranno le eclissi di sole e di luna l'anno prossimo



**Problema 3** – Se oggi voglio fare un po' di corsa, quale sarà il livello di inquinamento che trovo? Verso dove conviene andare per respirare un'aria accettabile?



## Problema 4 – Tradurre una frase dall’italiano in inglese, arabo, cinese, spagnolo,...

Italiano ▾   Arabo ▾  

nel mezzo del  
cammin di nostra vita

في منتصف رحلة حياتنا  
fi mntsf rihlat hayatuna

[Apri in Google Traduttore](#) [Feedback](#)

Italiano ▾   Cinese (semplificato) ▾  

nel mezzo del  
cammin di nostra vita

在我们生命的旅程中  
Zài wǒmen shēngmìng de lǚchéng  
zhōng

[Apri in Google Traduttore](#) [Feedback](#)

# Sono problemi risolti? E da quanto tempo?

Problema 1 – **PREDIRE** Il giorno in cui acquistare un biglietto  
→ Risolto pochi anni fa

Problema 2 – **PREDIRE** quando ci sarà una eclissi  
→ Risolto dai babilonesi **oltre 2.000 anni fa** →

Problema 3 – **PREDIRE** i livelli di inquinamento  
→ Risolto pochi anni fa

Problema 4 – **TRADURRE** un testo dall’italiano in inglese, ecc.  
→ Risolto pochi anni fa

# Problema 2 – Predire le Eclissi



**L'osservazione delle eclissi** all'epoca dei Babilonesi portò a scoprire il **ciclo di Saros**, che dice secondo quale scansione temporale si succedono le eclissi del sole e della luna.

Il confronto tra le previsioni fatte dai babilonesi e quelle ottenute con le attuali tecnologie mostra una precisione stupefacente per l'epoca.

# Problema 4 - Tradurre un testo

## Le biografie inglesi di Palazzo Chigi

### Le biografie inglesi di Palazzo Chigi (biografie riprese dal sito ufficiale del governo)



[Silvio Berlusconi](#)



[Gianfranco Fini](#)



[Gianni Letta](#)



[Paolo Bonaiuti](#)



[Giuseppe Pisano](#)



[Franco Frattini](#)



[Rocco Buttiglione](#)



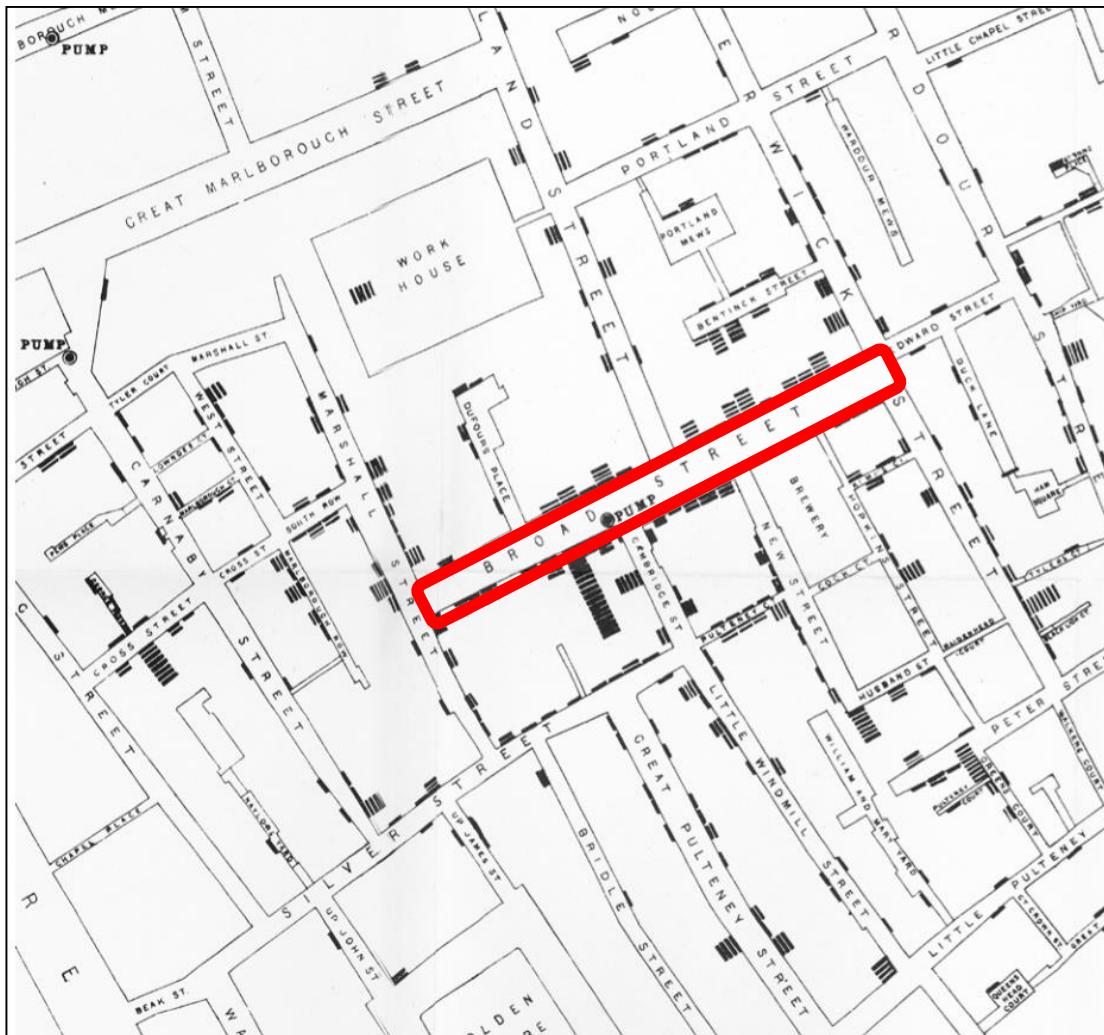
[Lucio Stanca](#)

### Lucio Stanca

Been born to Lucera (Foggia) 20 October 1941. Conjugated and it has two daughters. In 1965 one has graduated in Economy near the University Mouthfuls of Milan.

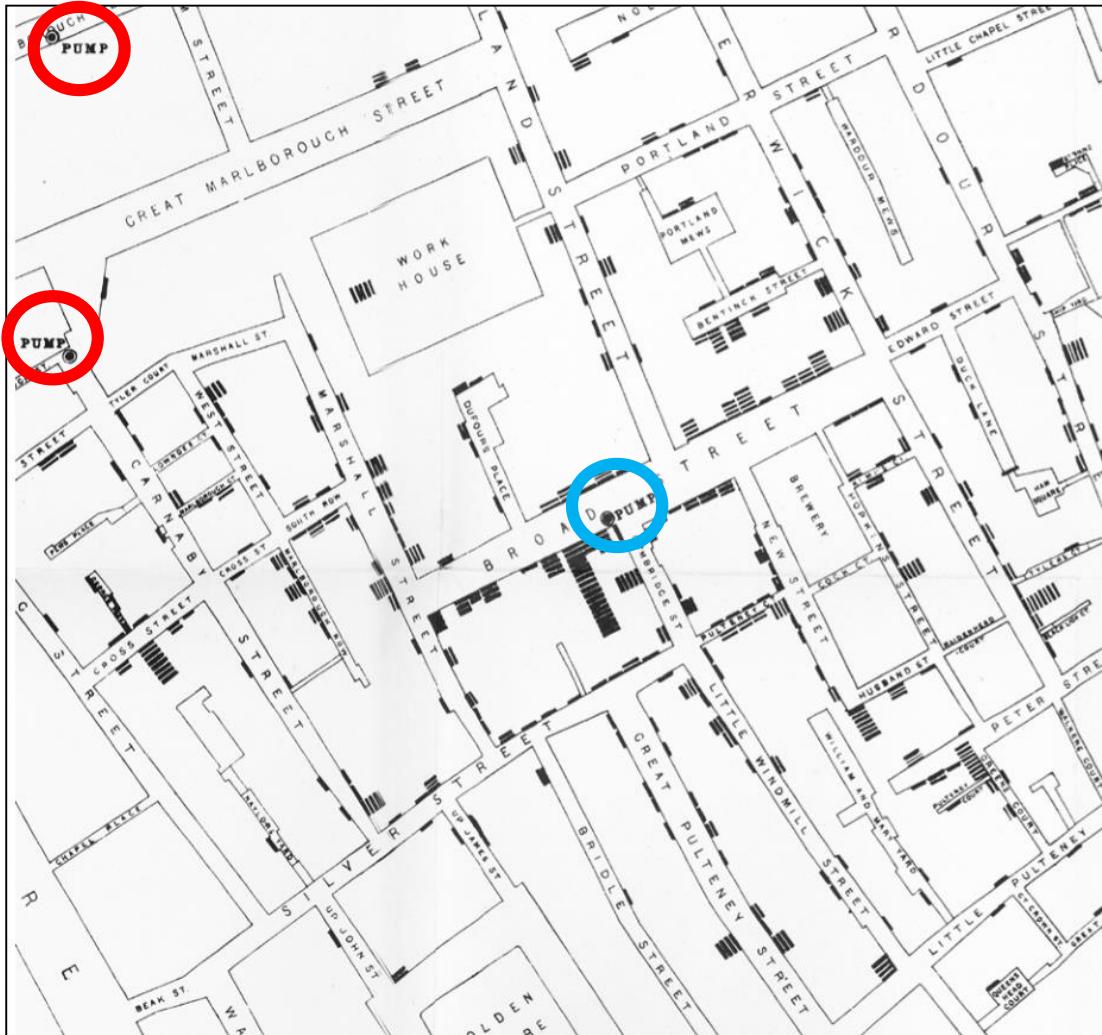
Perché gli altri problemi sono stati risolti  
solo pochi anni fa?

**Tutto è cominciato nel 1854... - La famosa mappa disegnata da Snow dell'area di Broad Street nell'anno 1854**



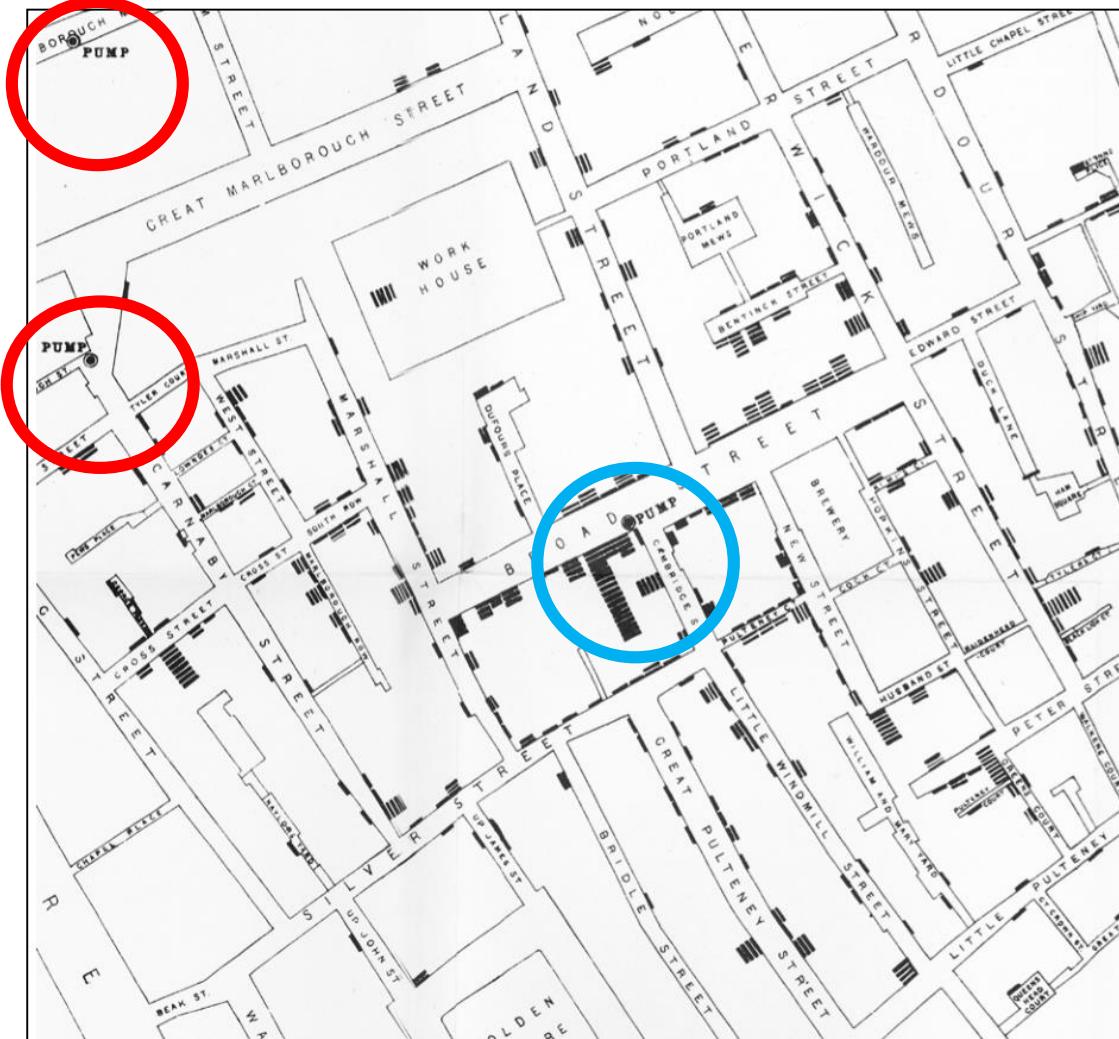
# Tutto è cominciato nel 1854...

## Le pompe delle diverse compagnie rosse e blu

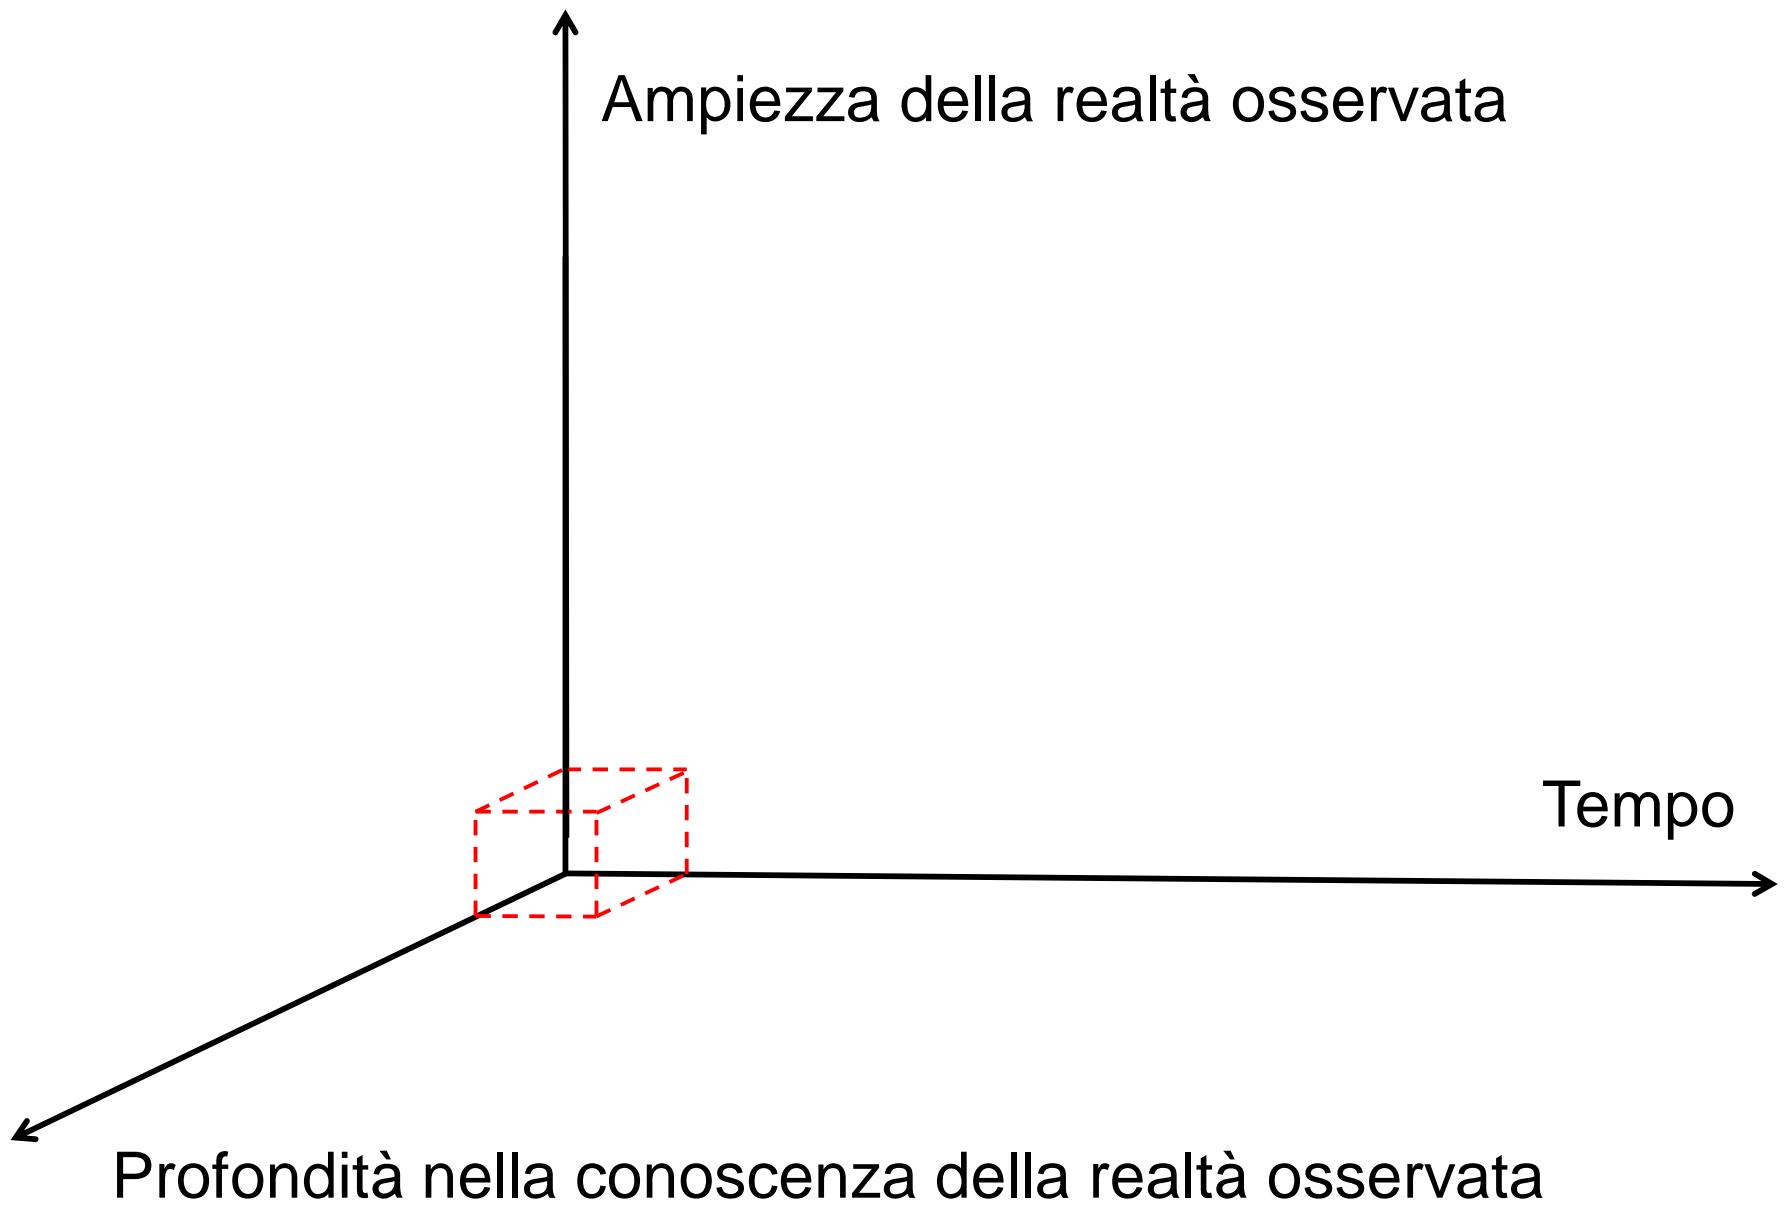


# Tutto è cominciato nel 1854...

## Correlazione tra pompe e decessi



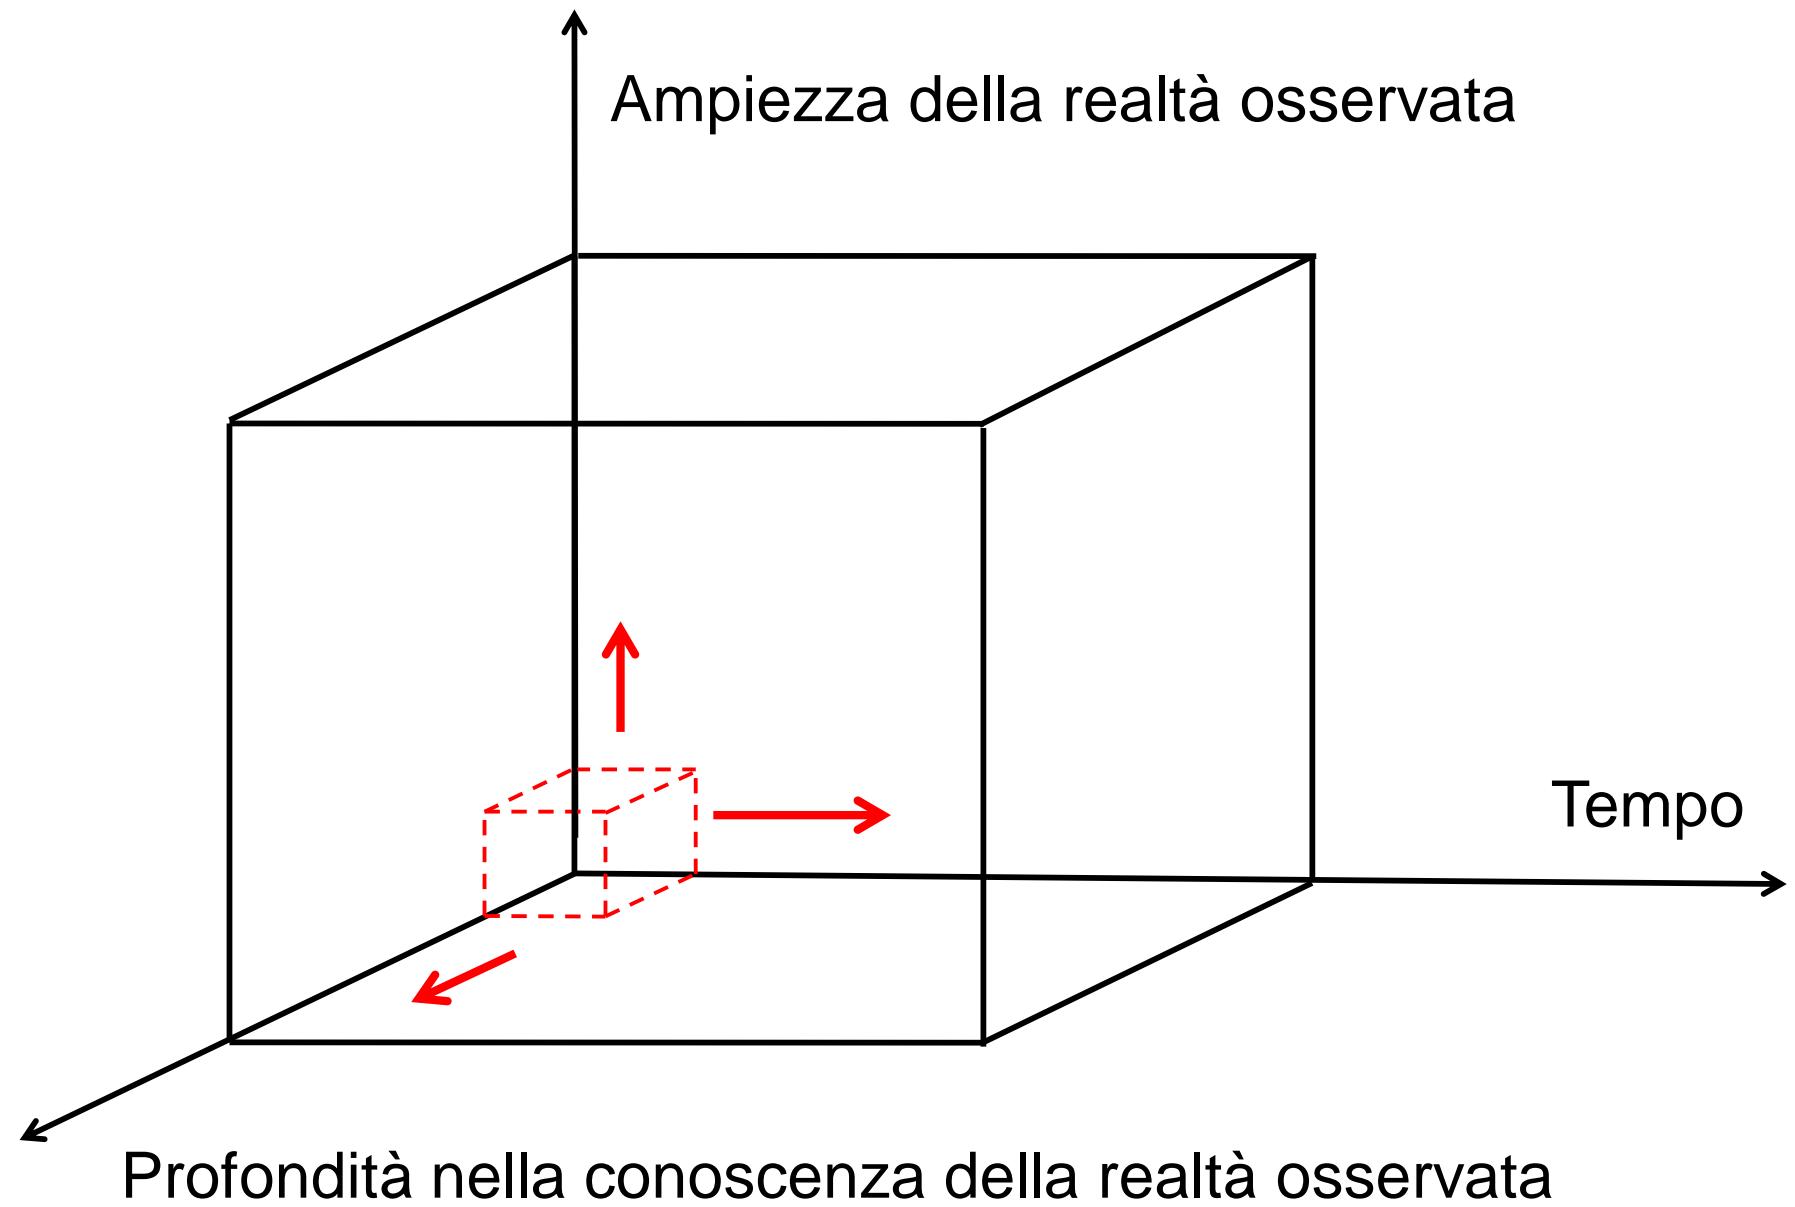
# Dai piccoli dati .....



# Il diluvio dei dati

- Ogni anno e mezzo raddoppia la quantità di dati scambiati sul Web
- Nel 2025 ci saranno 1.000 sensori dell'Internet delle cose per ogni essere umano

..... ai grandi dati



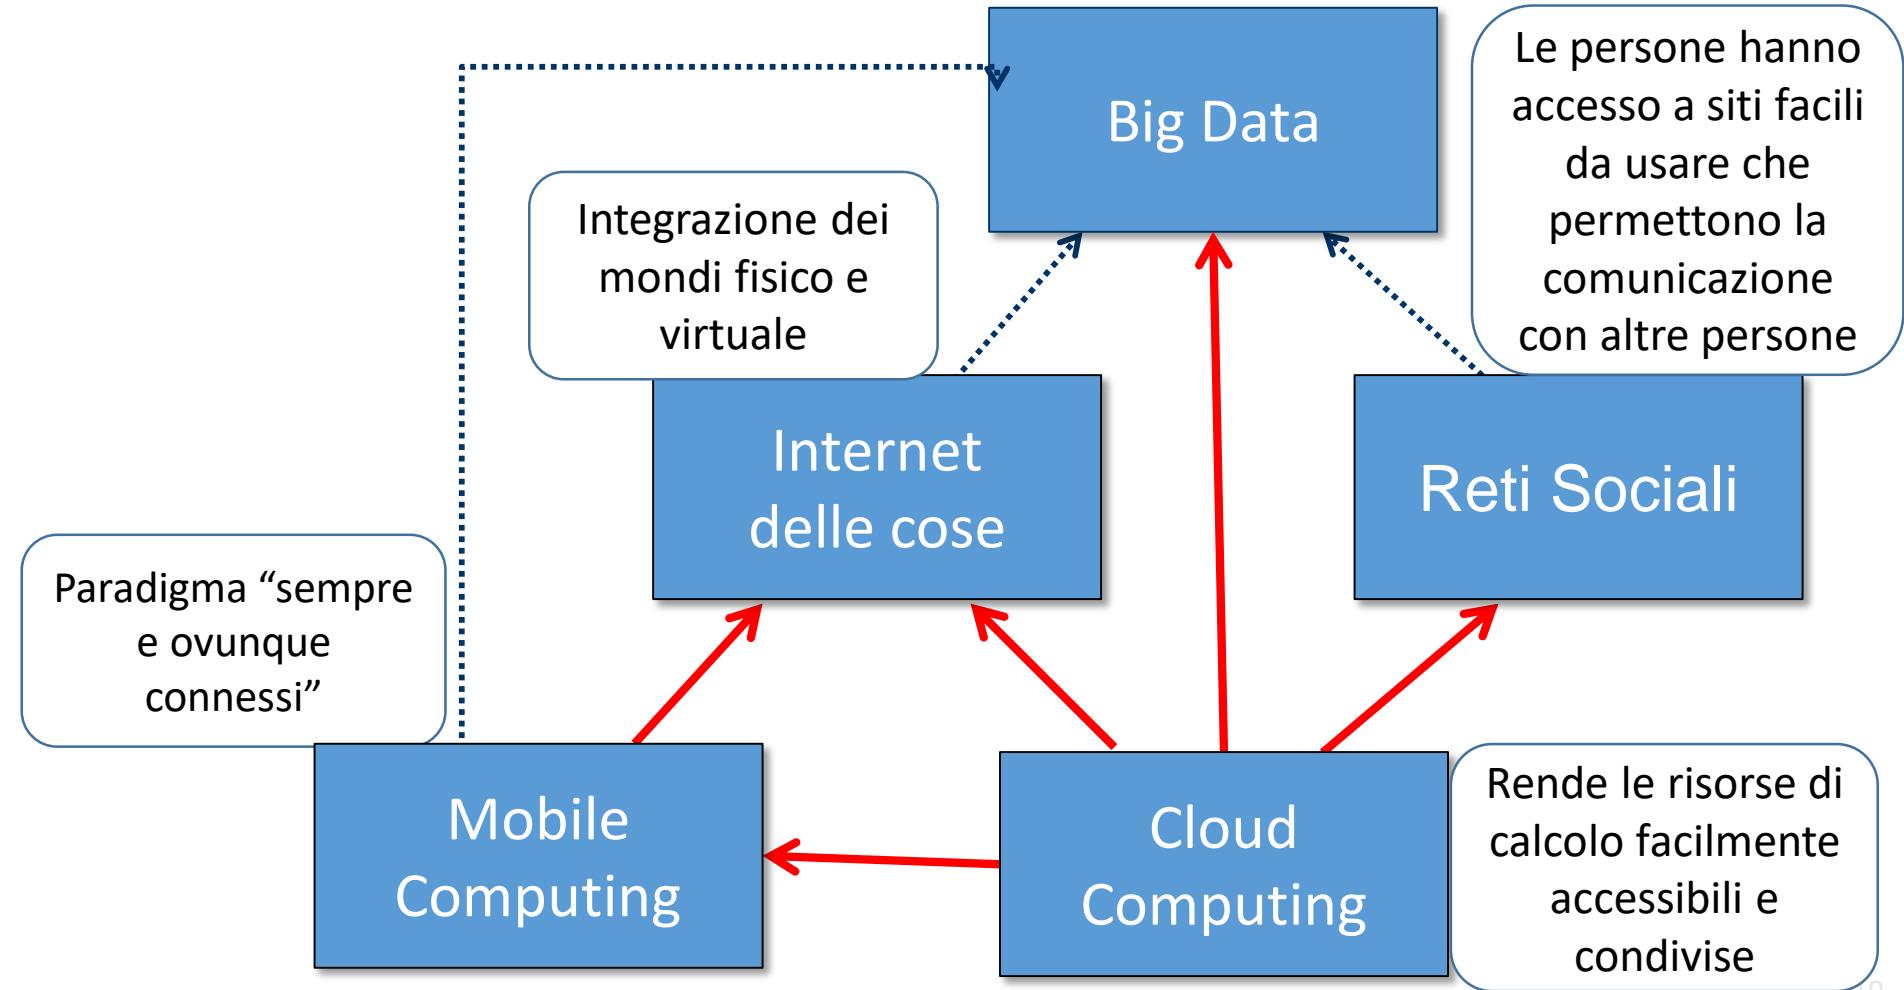
# Il genoma umano



Cosa sta rendendo possibile  
questo «diluvio di dati»?

# Le “cinque grandi tecnologie”

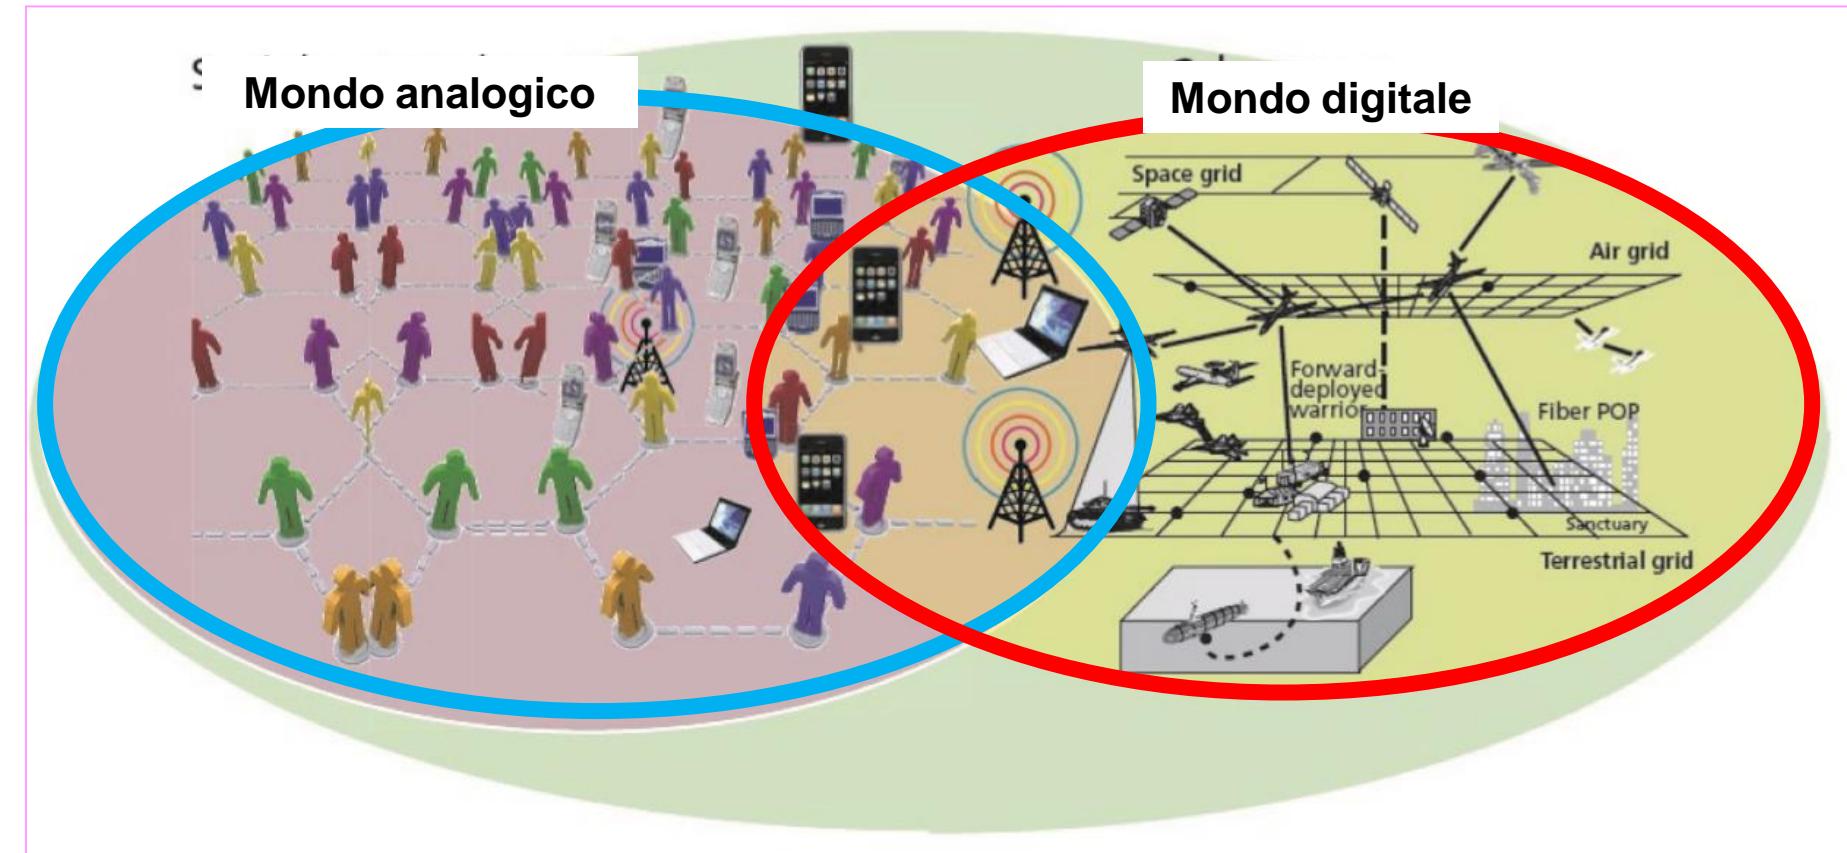
abilita  
alimenta



# **L'ecosistema** dei dati

## **L'infosfera** di Floridi

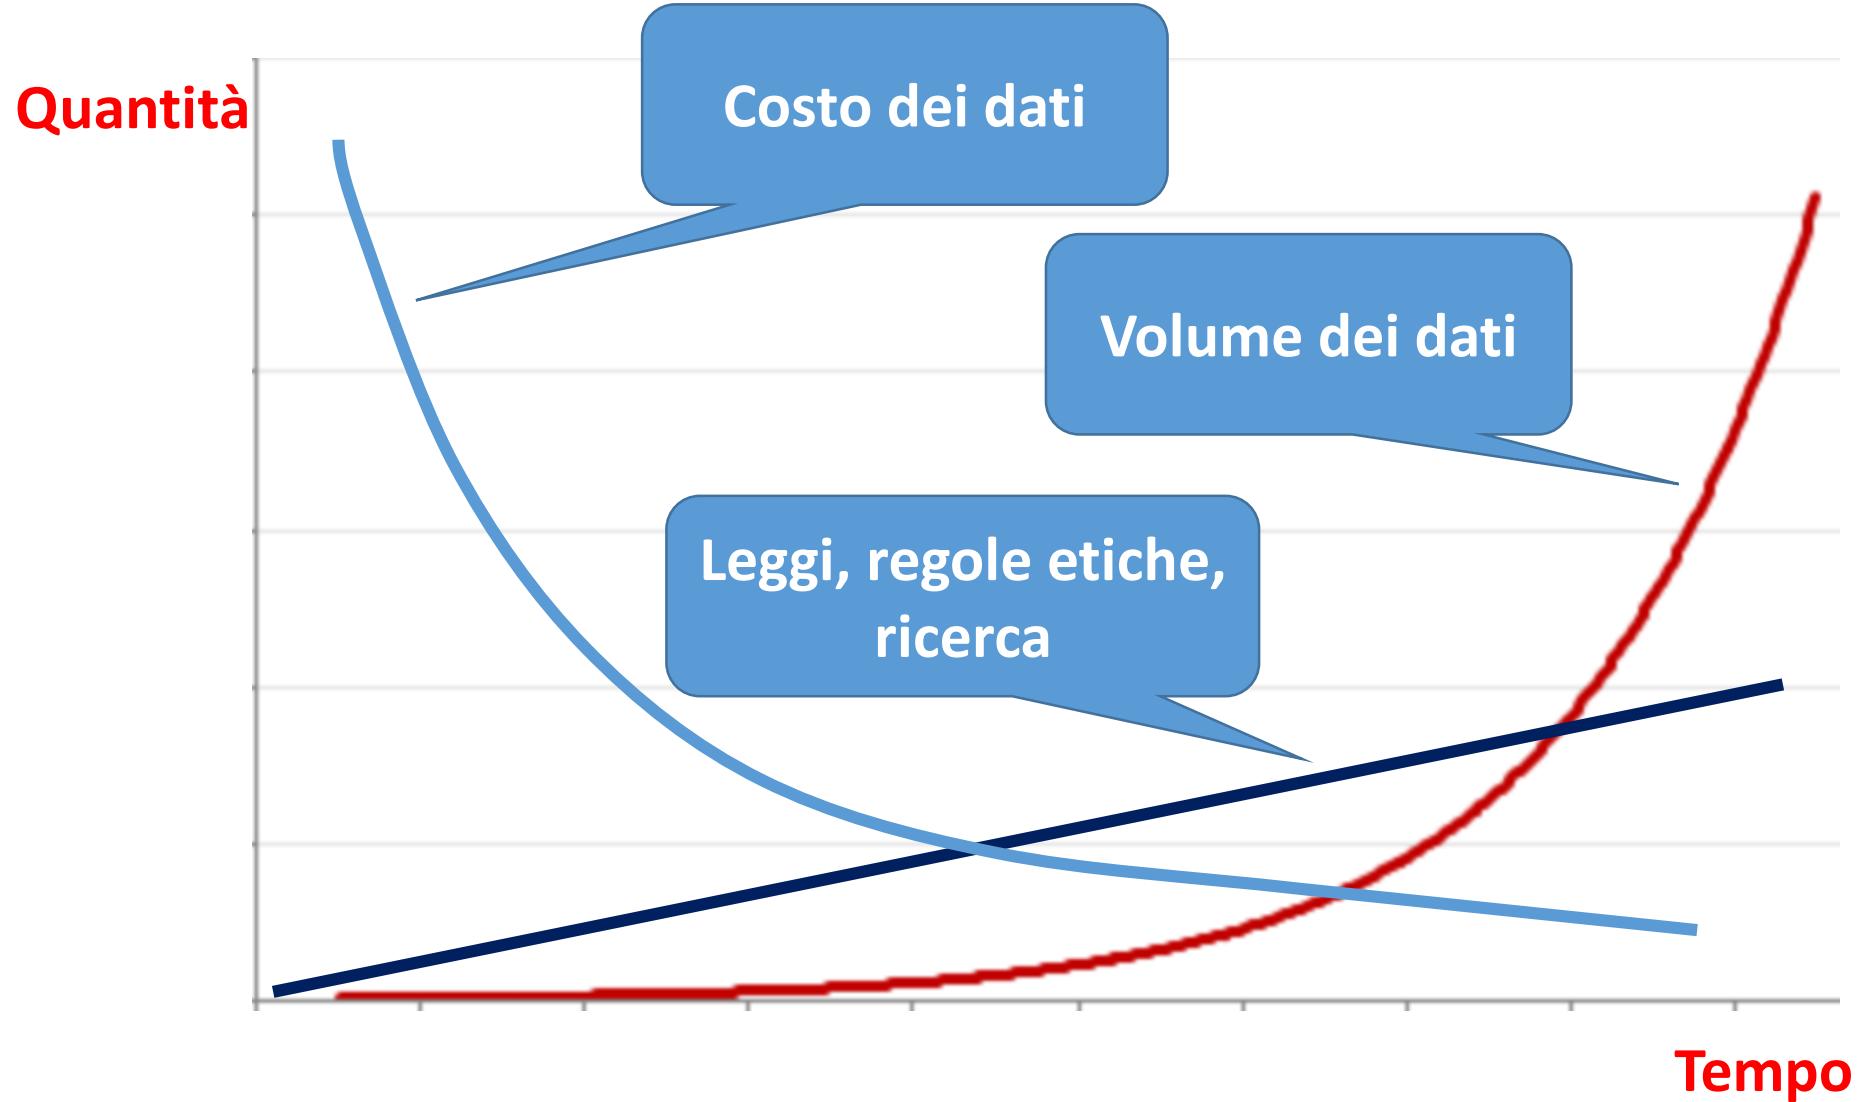
## **L'altro mondo** di Baricco



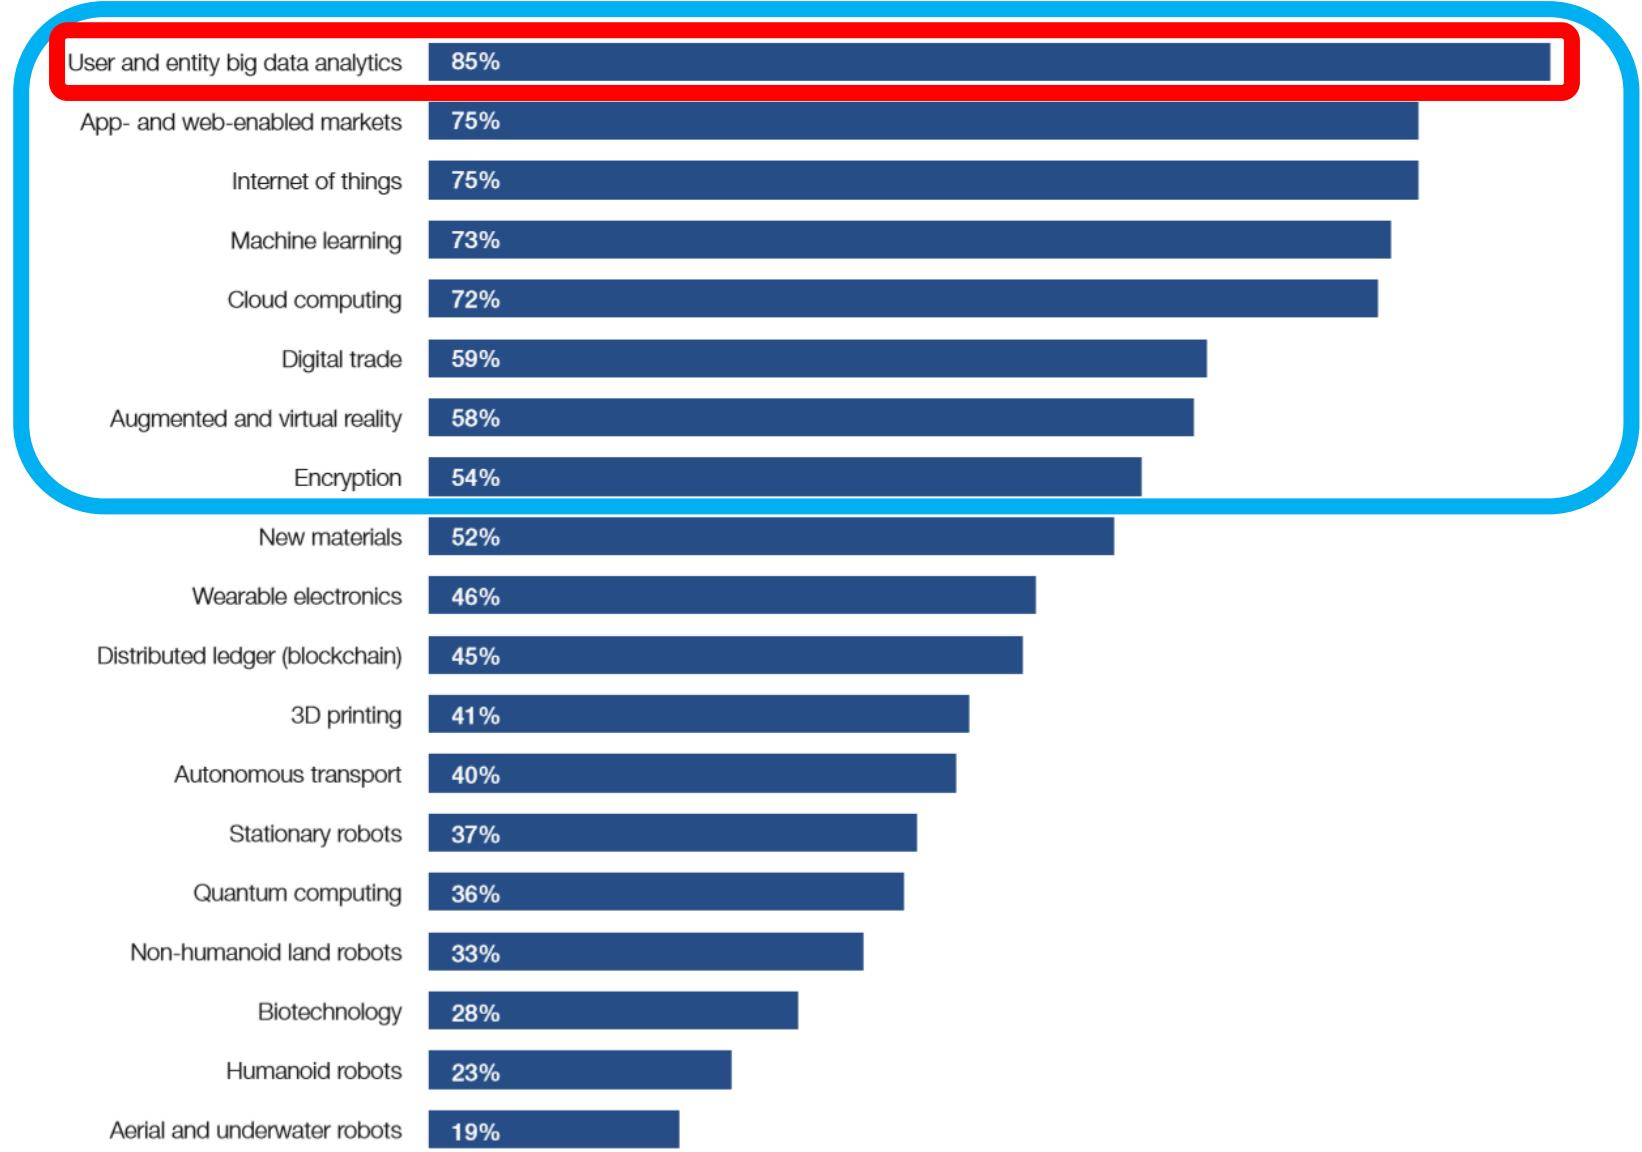
# Ready Player One, di Steven Spielberg



# Crescita *esponenziale* dei dati, decrescita dei costi e crescita *lineare* della ricerca



# Percentuale di aziende che assumerà per tecnologia entro il 2022



Source: Future of Jobs Survey 2018, World Economic Forum.

# I due pilastri su cui si fonda la Scienza dei dati



# Come vanno usati i dati? Il ciclo di vita del dato digitale

1. **Scelta** delle fonti e acquisizione
2. **Preparazione** (o **Valorizzazione**) dei dati
3. **Analisi** dei dati
4. **Visualizzazione** dei risultati

# Lo strumento Breezometer per prevedere i livelli di inquinamento



Dati satellitari

Fondi di dati ambientali

Flussi di trasporto

Sensori nei Comuni

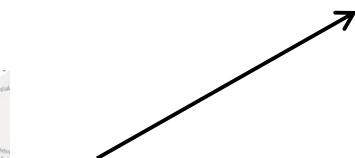
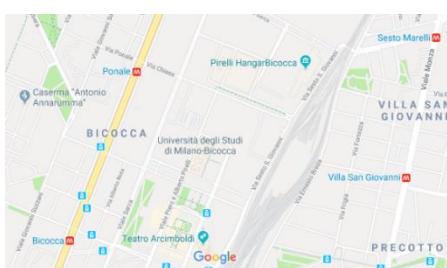
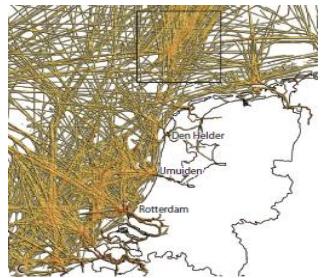
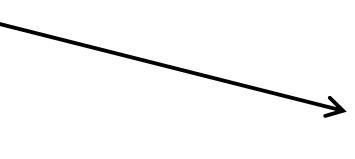
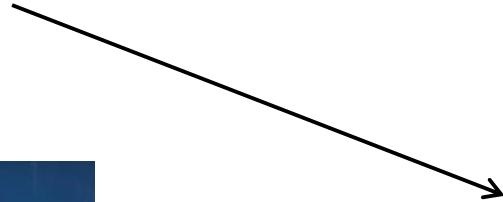
Google Maps

→ **Previsione** →



# Scelta delle fonti

# 1. Scelta delle fonti per prevedere l'inquinamento in Breezometer



Dati satellitari

Fondi di dati ambientali

Flussi di trasporto

Sensori nei Comuni

Google Maps

# Valorizzazione

**2. Valorizzazione** dei dati: Quale di queste due immagini è di migliore **qualità**?



# Tradeoff tra qualità



Fedeltà



Leggibilità

# La qualità dei dati nel Web

Queste sono due immagini di Marte.  
Secondo te quale è di migliore qualità?

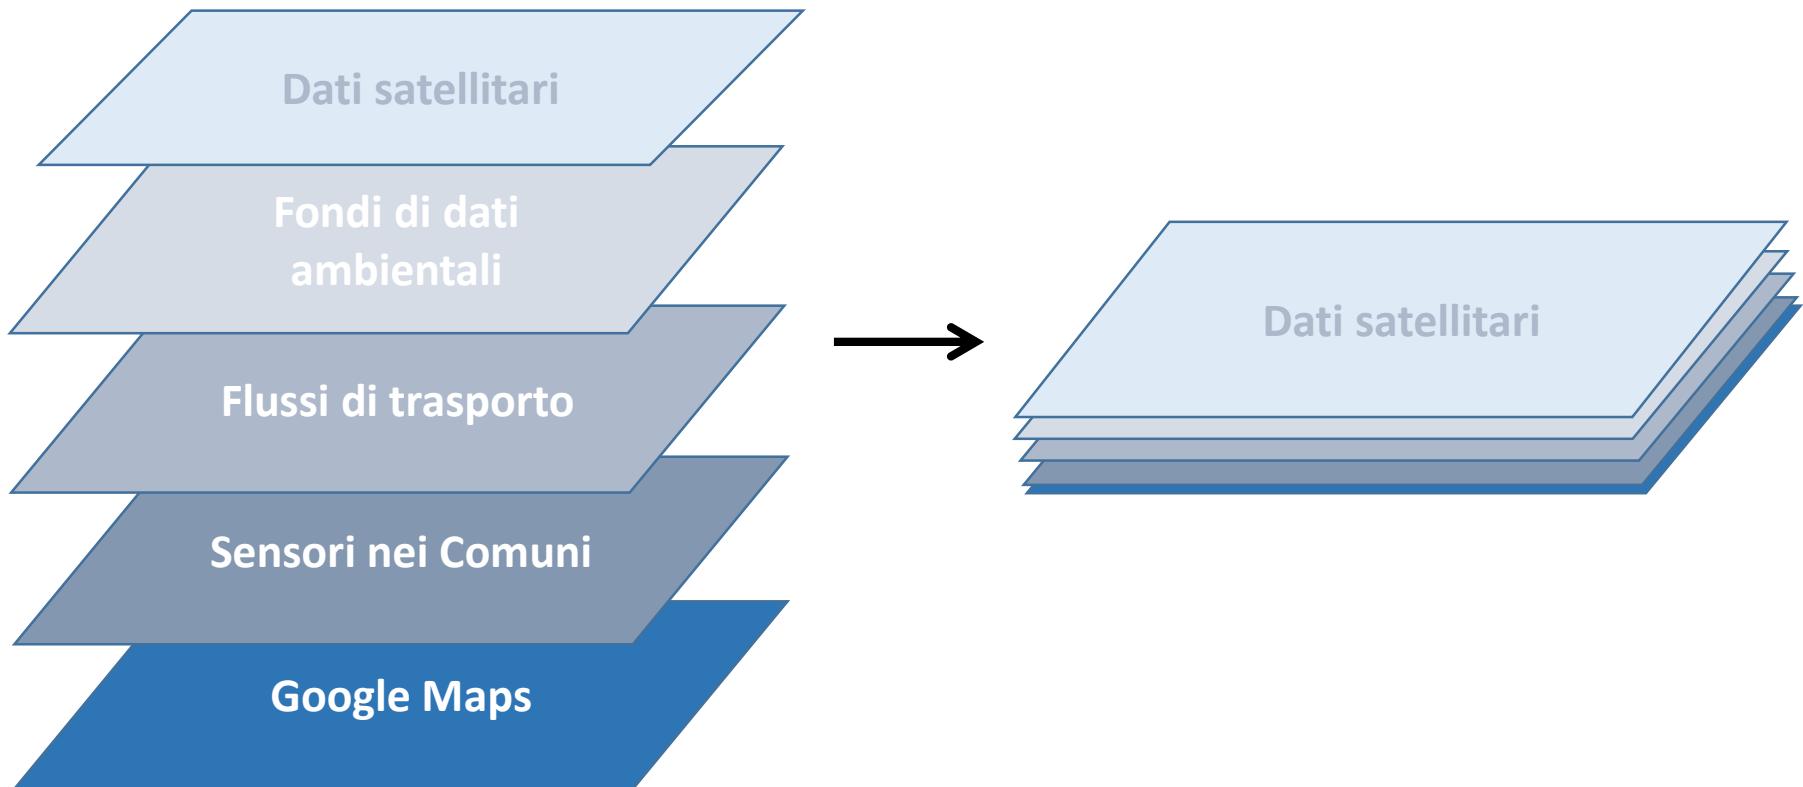


[www.hoax-slayer.com](http://www.hoax-slayer.com)



[astrobiology.nasa.gov](http://astrobiology.nasa.gov)

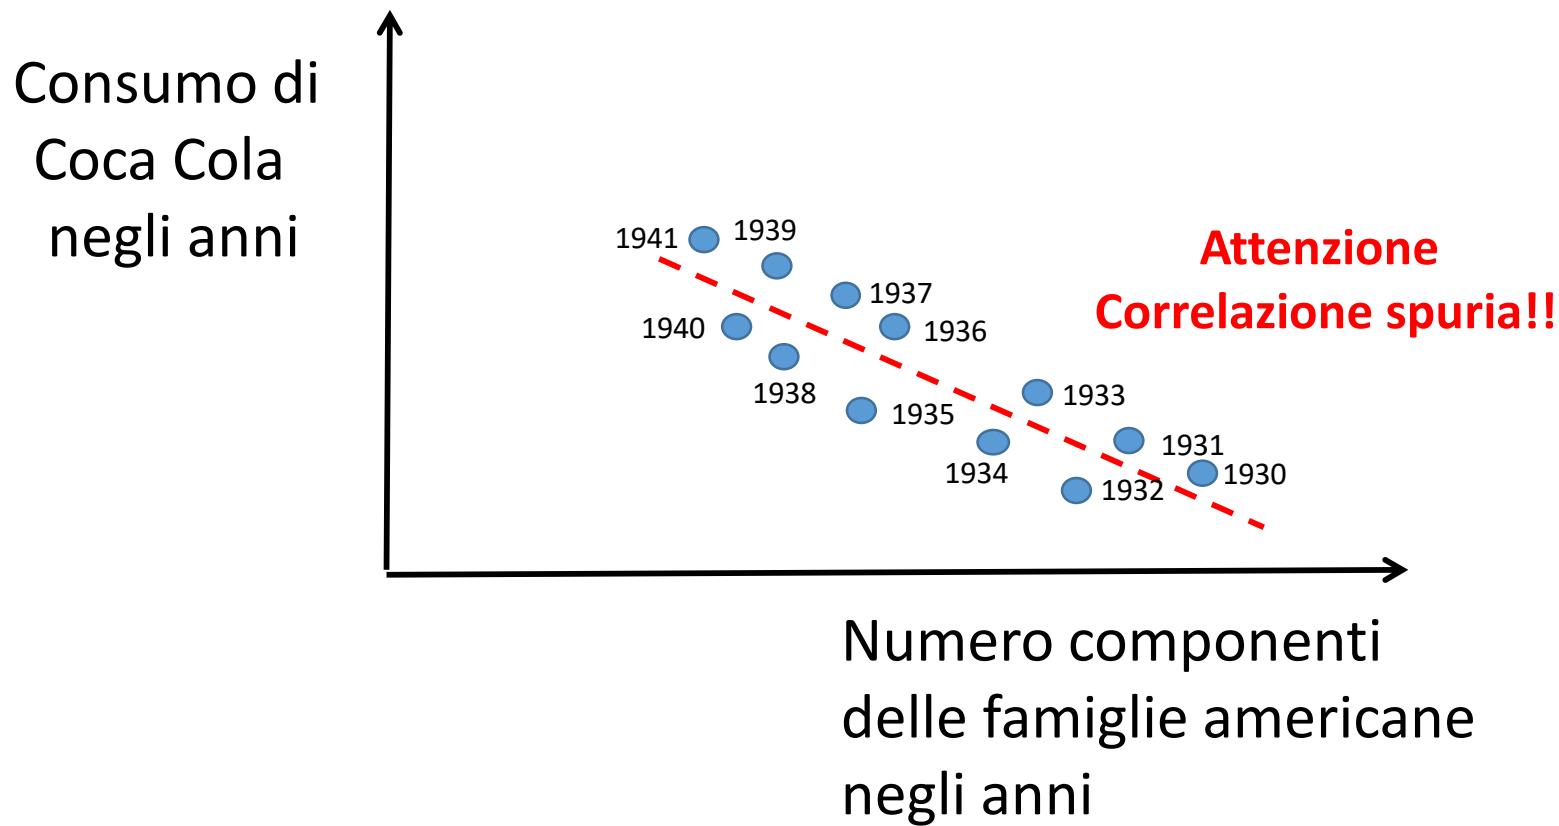
# Integrazione delle fonti in Breezometer



# Analisi

### 3. Analisi - Correlazione

Consumo di Coca Cola e numero di componenti delle famiglie americane



### 3. Analisi per prevedere il giorno del biglietto

#### Il modello predittivo di Oren Etzioni

Campione  
di 12.000  
biglietti

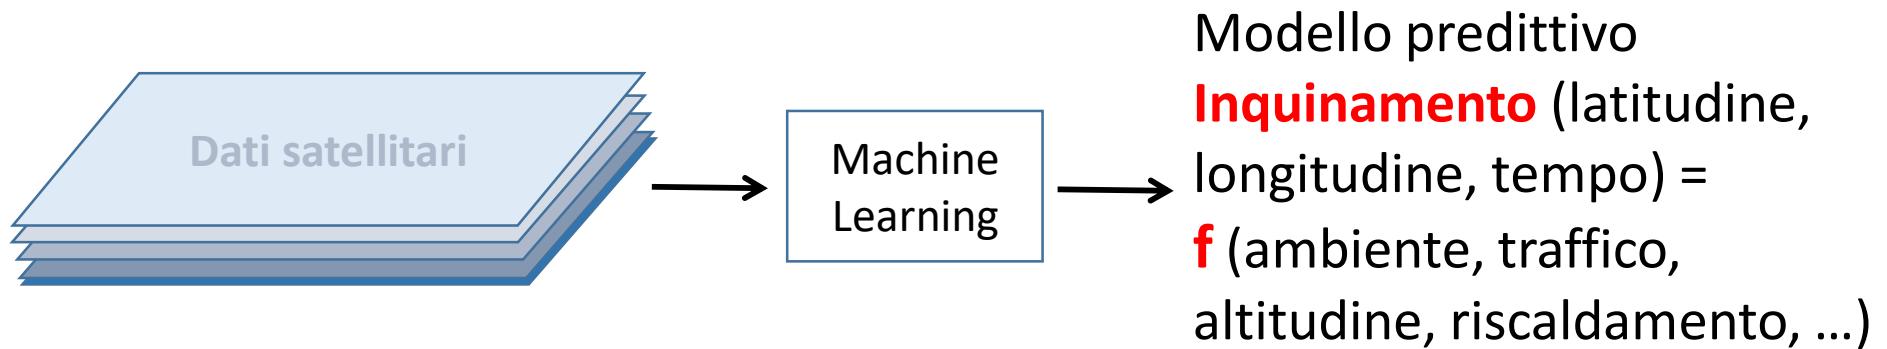


$200 \cdot 10^9$

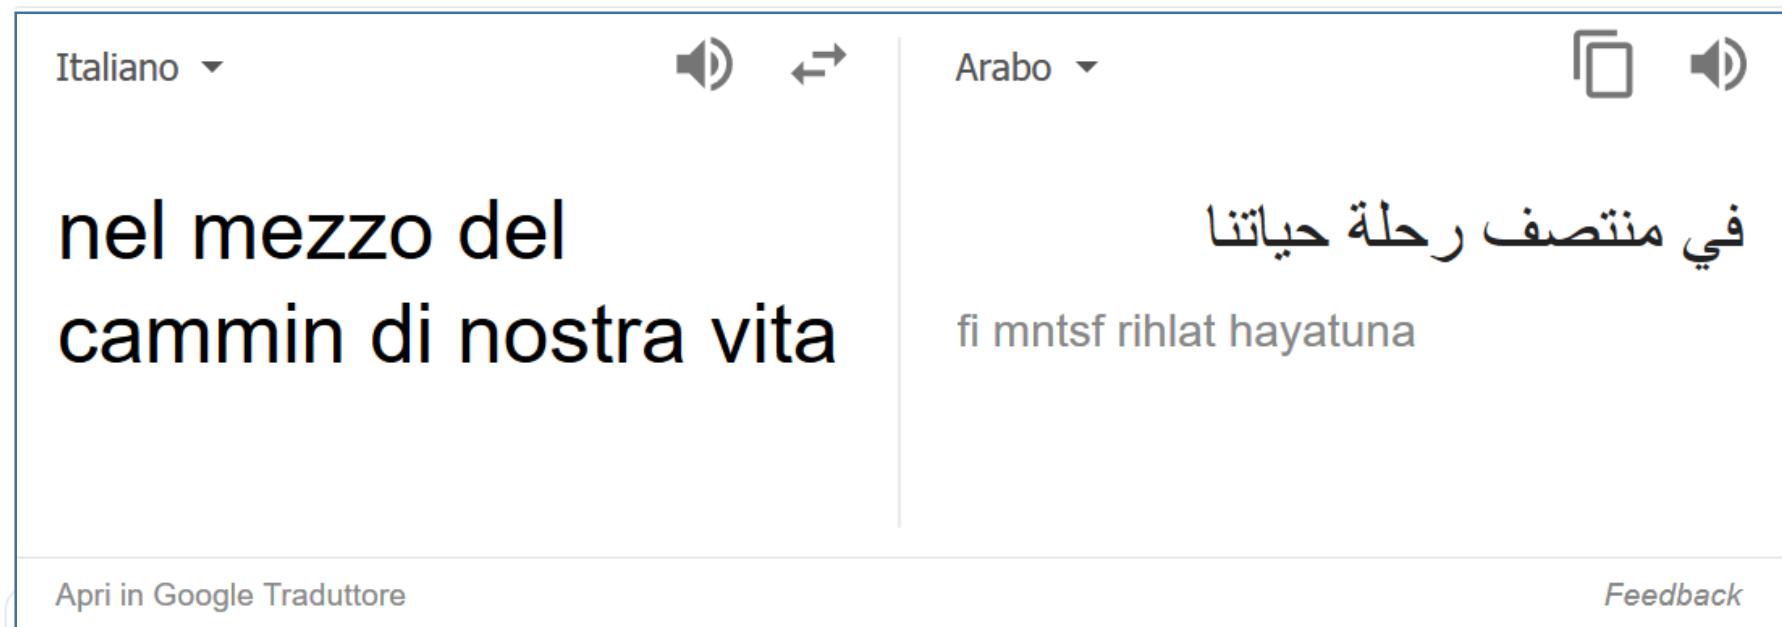
50 \$ risparmio medio per biglietto  
Compagnia venduta per  $110 \cdot 10^6$  \$

### 3. Analisi dei dati in Breezometer

## Tecniche di **Machine Learning**



### 3. Analisi per traduzione - Il traduttore di Google



The screenshot shows the Google Translate interface. The source text "nel mezzo del cammin di nostra vita" is in the Italian input field. The target text "في منتصف رحلة حياتنا" is in the Arabic output field, with the phonetic transcription "fi mntsrf rihlat hayatuna" below it. The interface includes language selection dropdowns for Italian and Arabic, and audio playback icons. Buttons for "Apri in Google Traduttore" and "Feedback" are at the bottom.

Italiano ▾

Arabo ▾

nel mezzo del cammin di nostra vita

في منتصف رحلة حياتنا

fi mntsrf rihlat hayatuna

Apri in Google Traduttore

Feedback



The screenshot shows the Google Translate interface. The source text "nel mezzo del cammin di nostra vita" is in the Italian input field. The target text "在我们生命的旅途中" is in the Chinese output field, with the phonetic transcription "Zài wǒmen shēngmìng de lǚchéng zhōng" below it. The interface includes language selection dropdowns for Italian and Chinese, and audio playback icons. Buttons for "Apri in Google Traduttore" and "Feedback" are at the bottom.

Italiano ▾

Arabo ▾

nel mezzo del cammin di nostra vita

在我们生命的旅途中

Zài wǒmen shēngmìng de lǚchéng zhōng

Apri in Google Traduttore

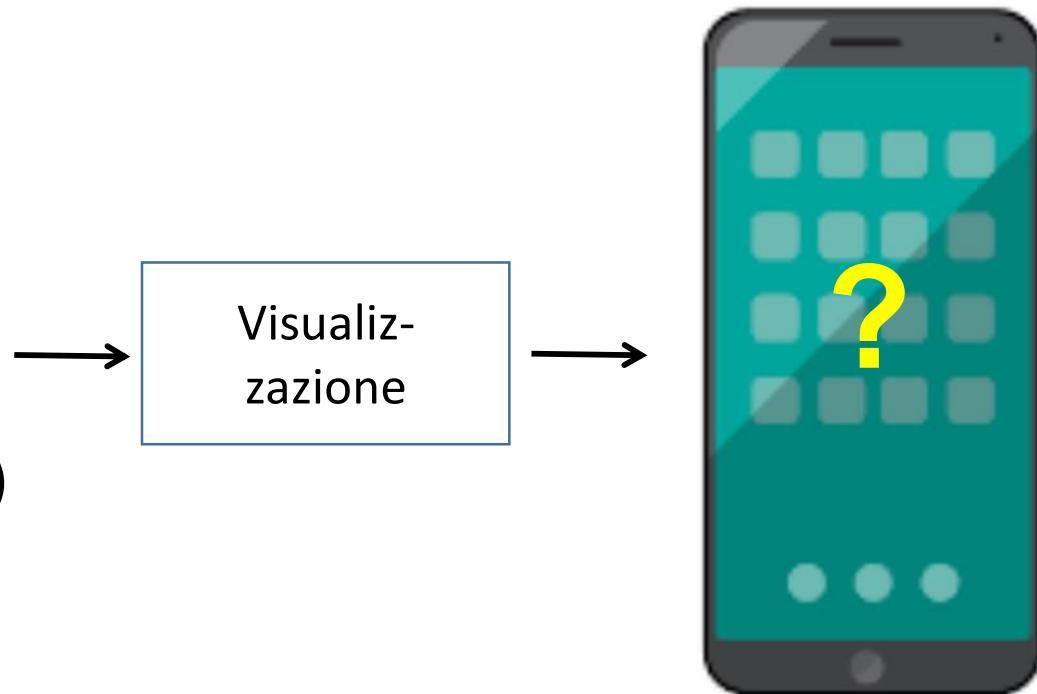
Feedback

# Visualizzazione

## 4. Visualizzazione dei dati in Breezometer

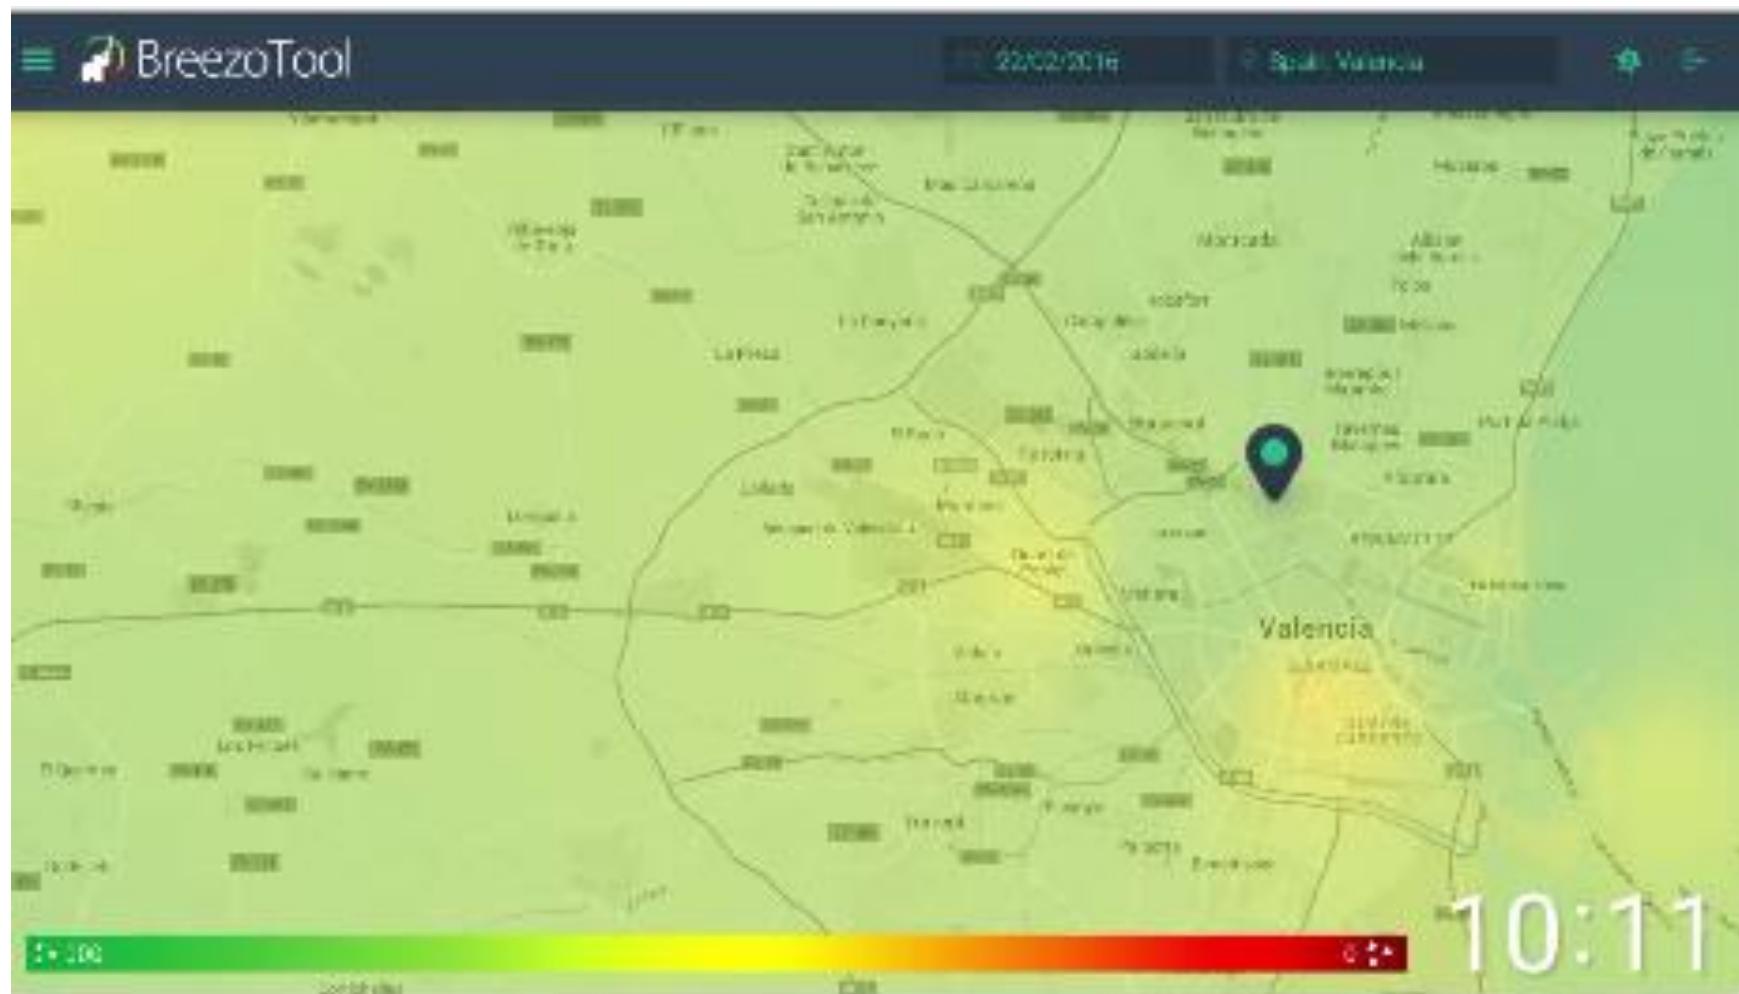
Modello predittivo

**Inquinamento** (latitudine,  
longitudine, tempo) =  
**f** (ambiente, traffico,  
altitudine, riscaldamento, ...)

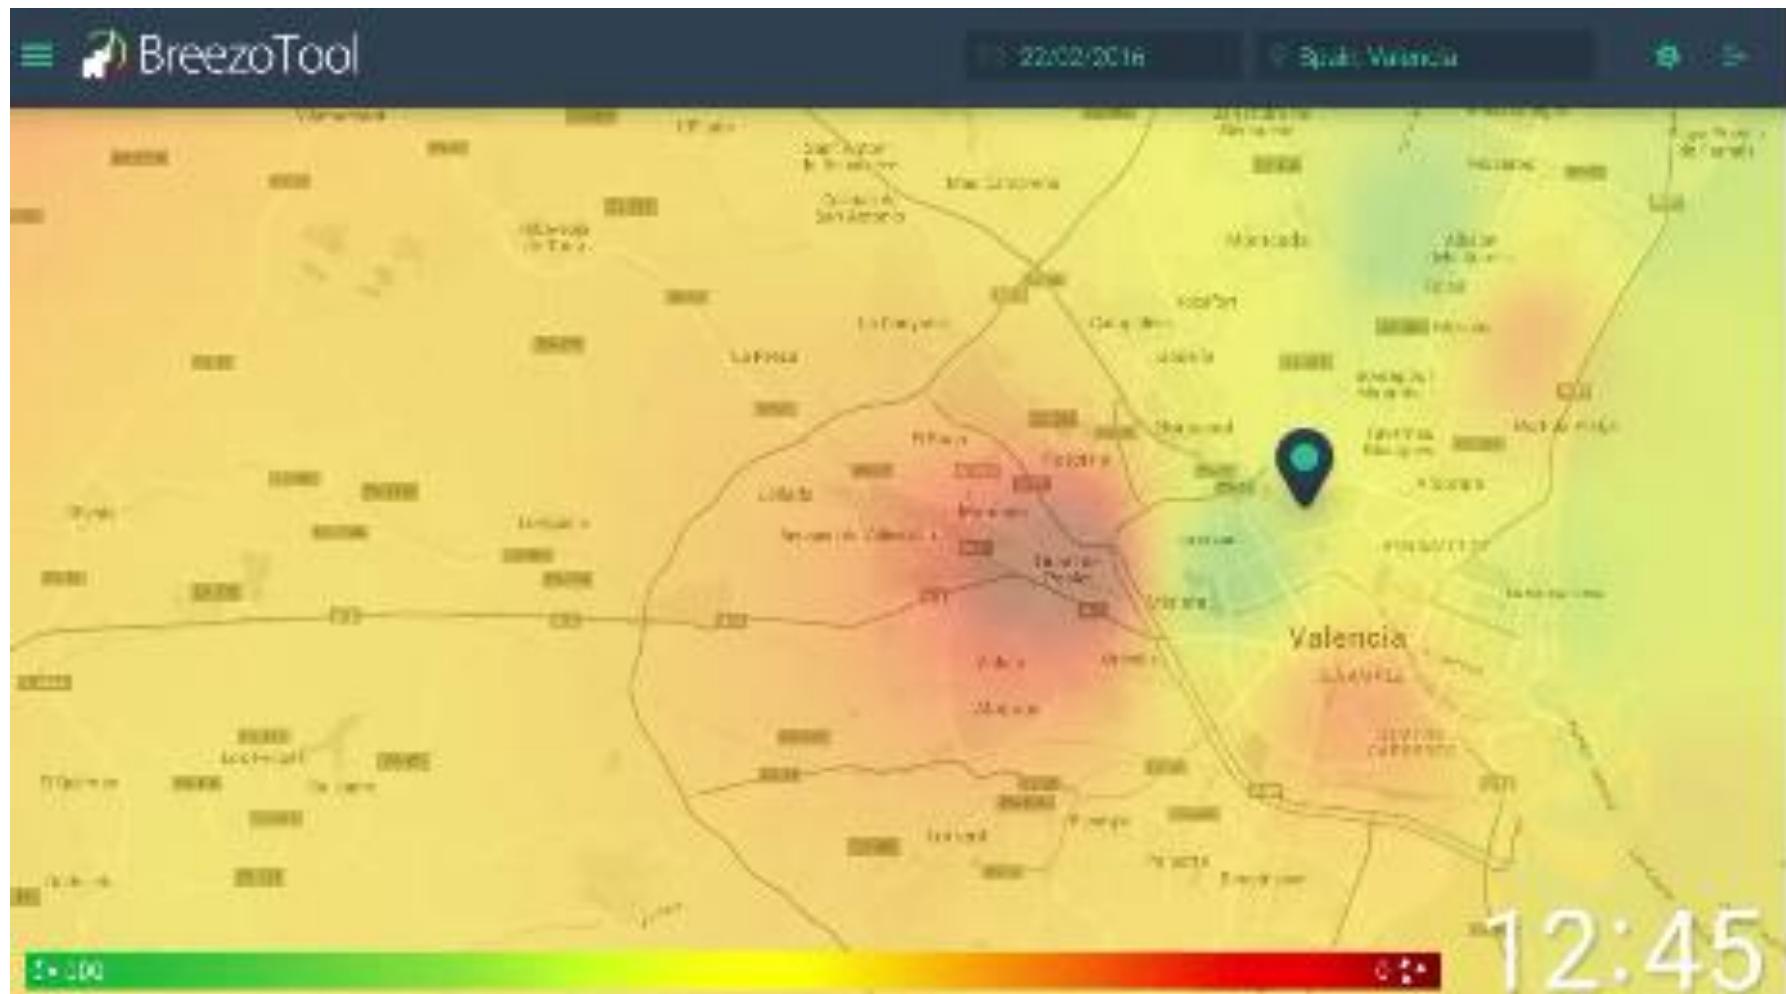


# Heat Maps relative a varie ore del giorno

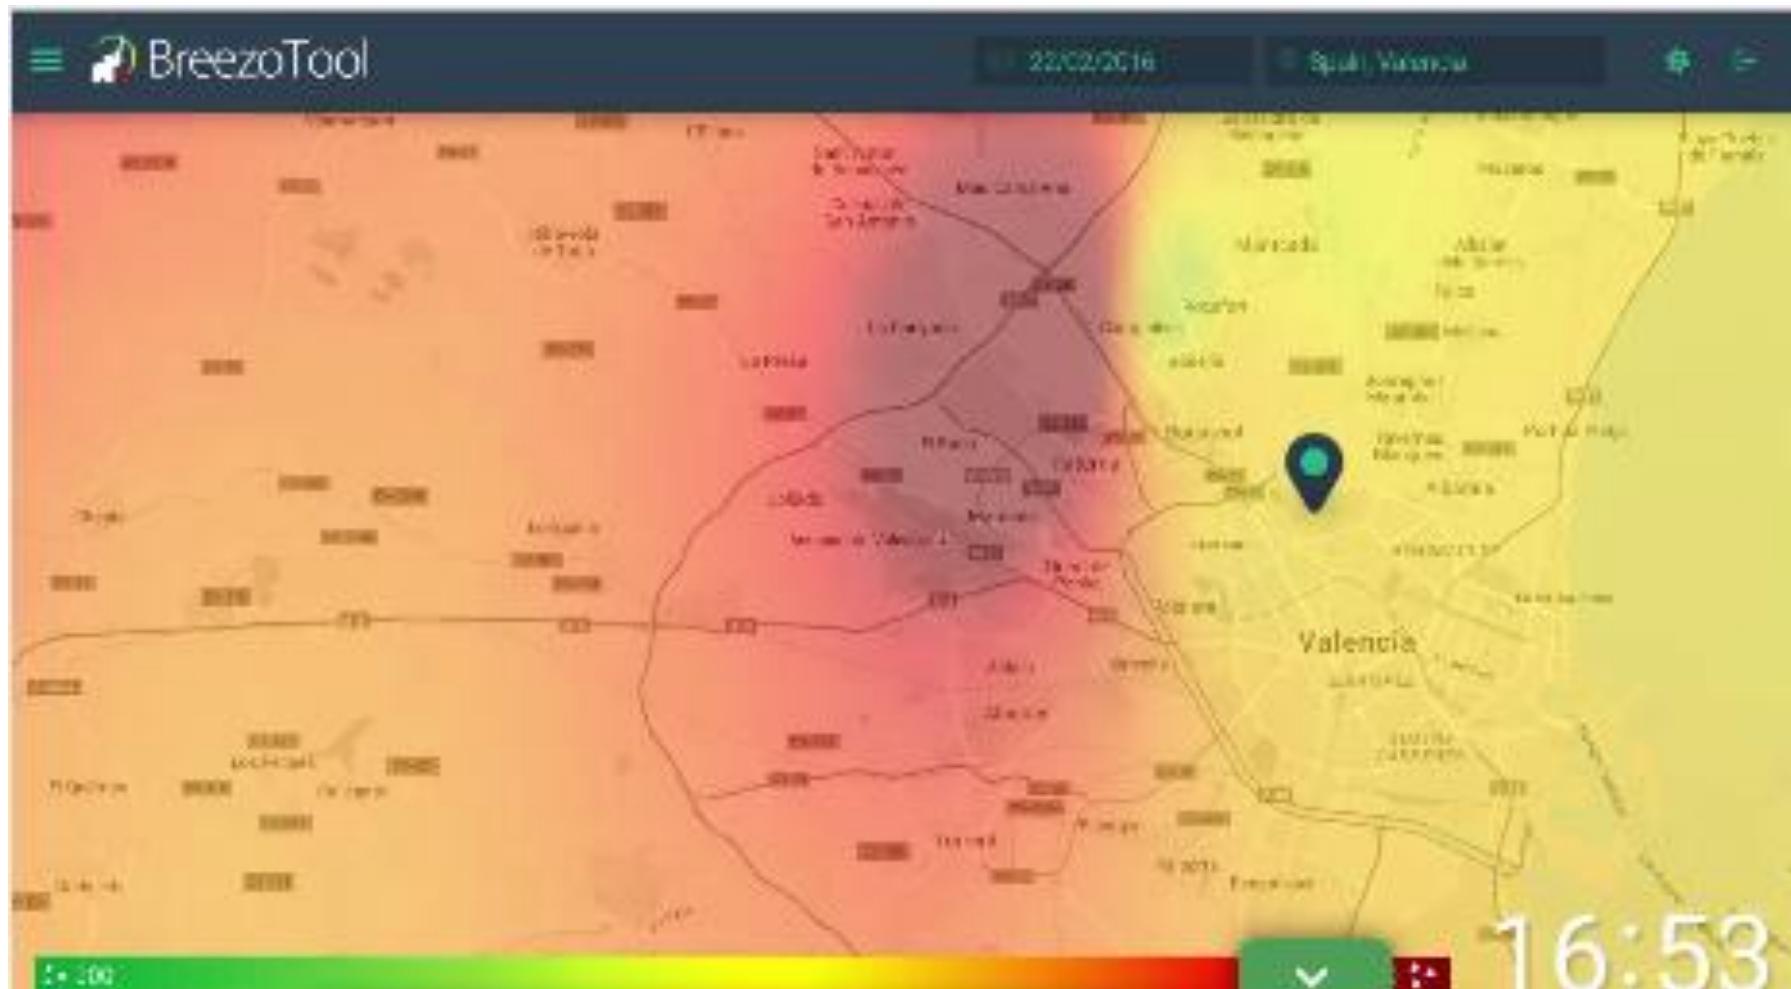
## Ore 10:11



# Ore 12.45

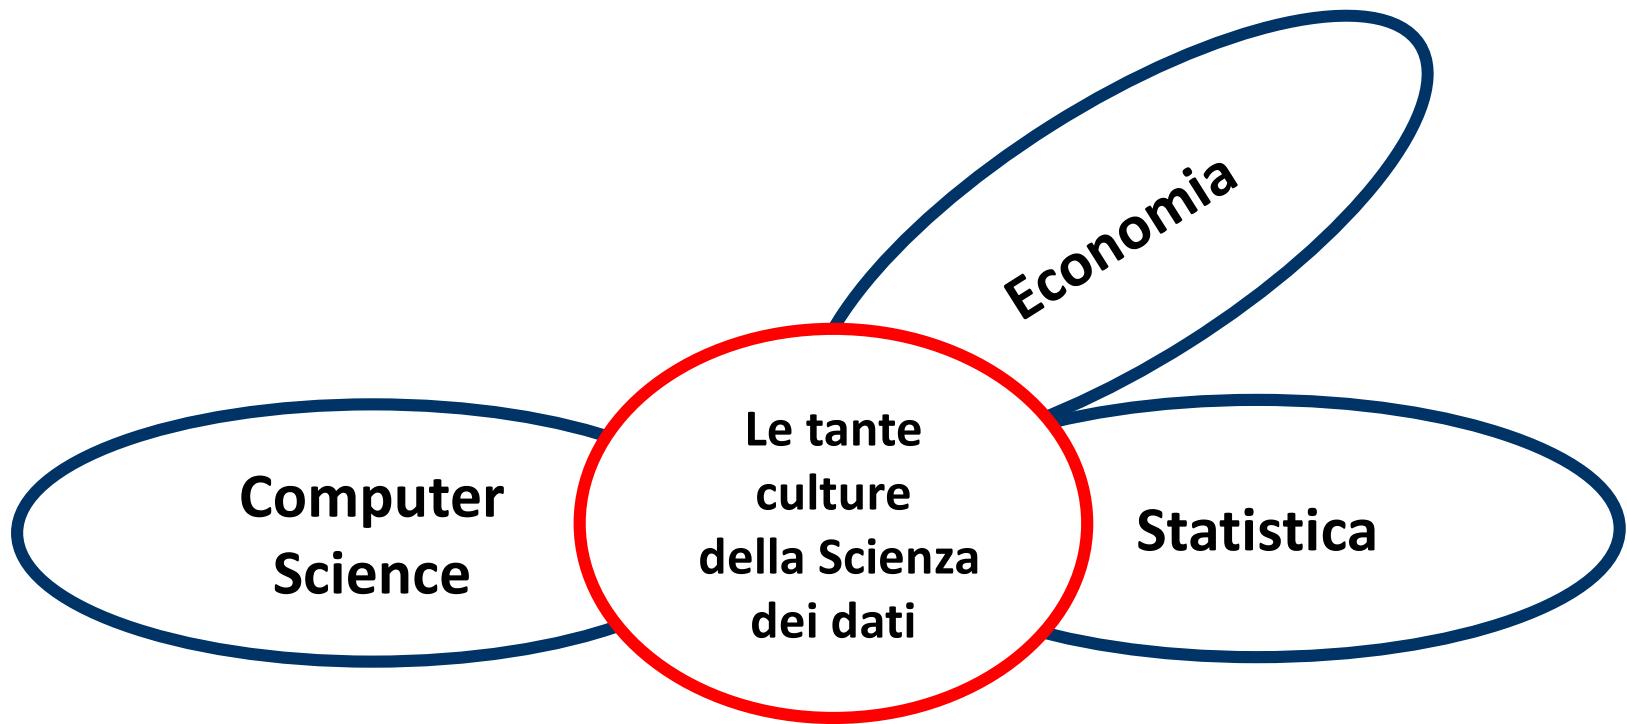


# Ore 16.53



# La Scienza dei Dati: una nuova Scienza sulle spalle dei giganti

# Una nuova Scienza



# Beni, dati, servizi



Dati  
?



La psicoanalisi è un mito  
tenuto vivo dall'industria dei divani.  
- Aforismario -      Woody Allen      - Aforismario -

Jeans

Seduta di supporto  
psicologico

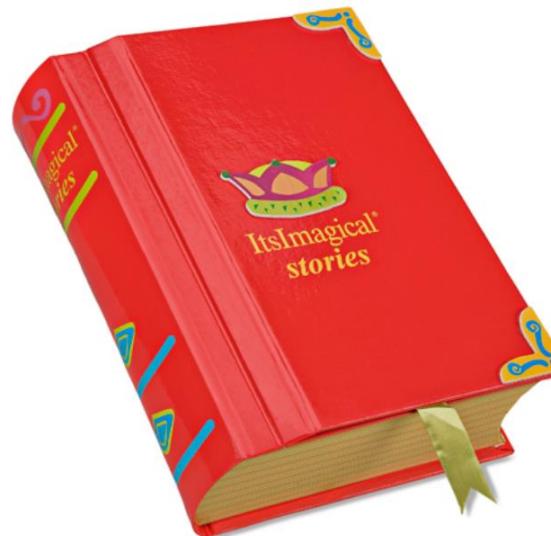
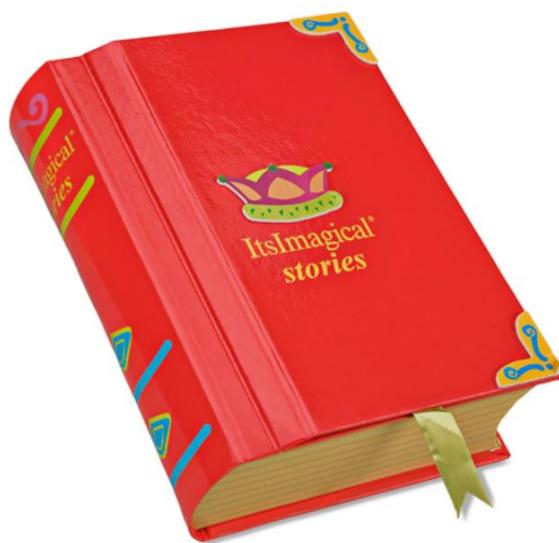
# I dati non sono materiali come i beni

```
Source:  query [8.074e+07 x 5]
Database: spark connection master=local[8] app=sparklyr local=TRUE

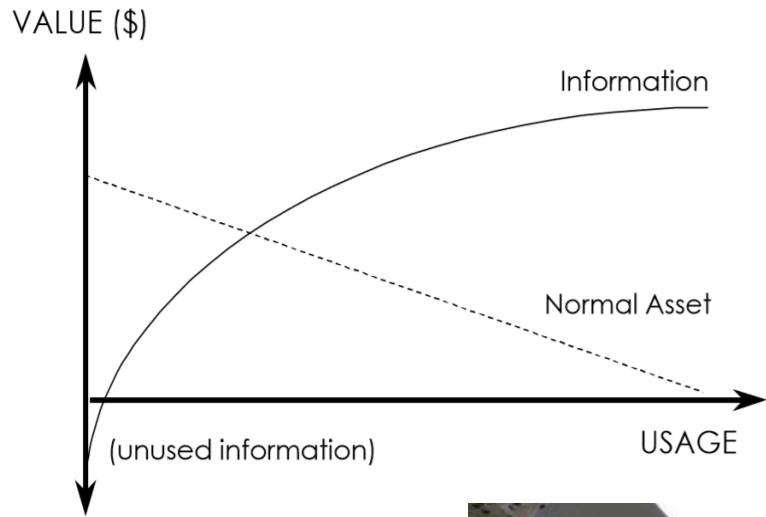
  user_id    item_id rating timestamp      category
  <chr>      <chr>  <dbl>      <int>      <chr>
1 A1EE2E3N7PW666 B000GFDAUG      5 1202256000 Amazon Instant Video
2 AGZ8SM1BGK3CK B000GFDAUG      5 1198195200 Amazon Instant Video
3 A2VHZ21245KBT7 B000GIOPK2      4 1215388800 Amazon Instant Video
4 ACX8YW2D5EGP6 B000GIOPK2      4 1185840000 Amazon Instant Video
5 A9RNM09MUSMTJ B000GIOPK2      2 1281052800 Amazon Instant Video
6 A3STFVPM8NHJ7B B000GIOPK2      5 1203897600 Amazon Instant Video
7 A2582KMXLK2P06 B000GIOPK2      5 1205884800 Amazon Instant Video
8 A1TZCLCW9QGGBH B000GIOPK2      4 1209427200 Amazon Instant Video
9 A2E2I6B878CRMA B000GIOPK2      5 1378684800 Amazon Instant Video
10 AD5MZA8S0VMPJ B000GIOPK2      5 1218240000 Amazon Instant Video
# ... with 8.074e+07 more rows
```



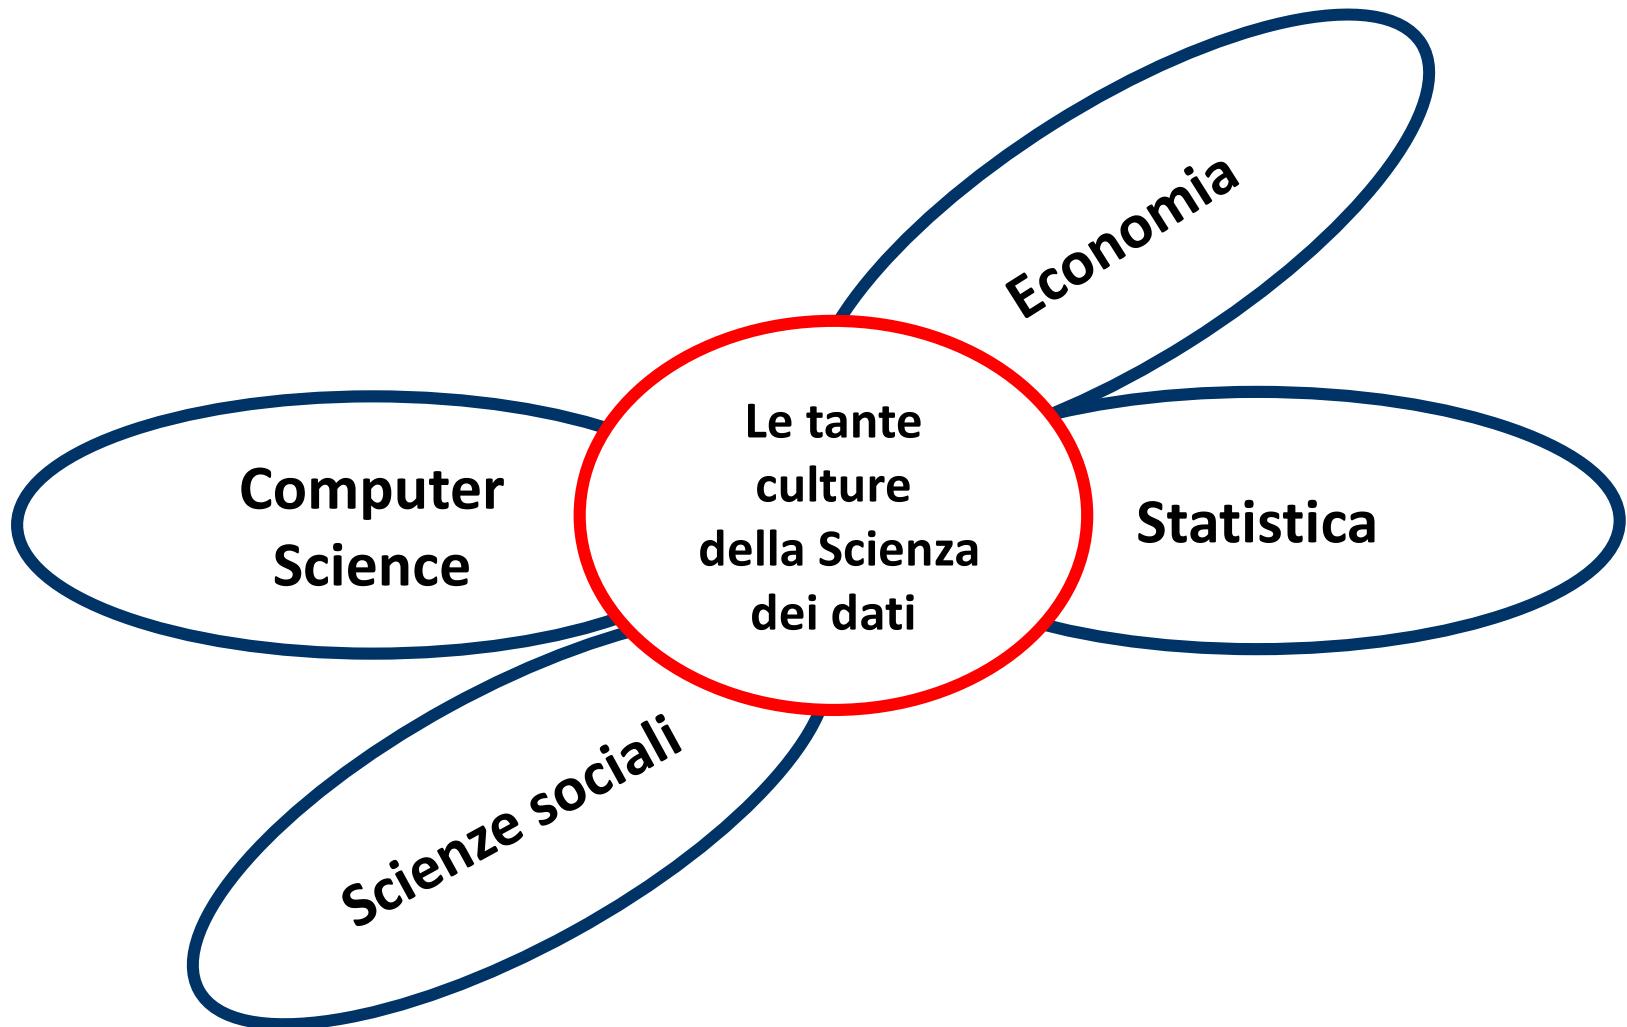
# Un libro, due libri



# I dati non svaniscono come i servizi



# Una nuova Scienza



# Valore sociale dei dati: Ospedali e qualità della cura in Uganda

## The Economist 2011

**The Economist**

World politics Business & finance Economics Science & technology Culture Blogs Debate & discuss Multimedia Print edition

All audio  
All video  
The Economist audio edition

### The Open Government Partnership

## The parting of the red tape

Is it just another global talking-shop—or a fresh approach to shaking out government secrecy?

Oct 8th 2011 | NEW YORK AND TALLINN | from the print edition

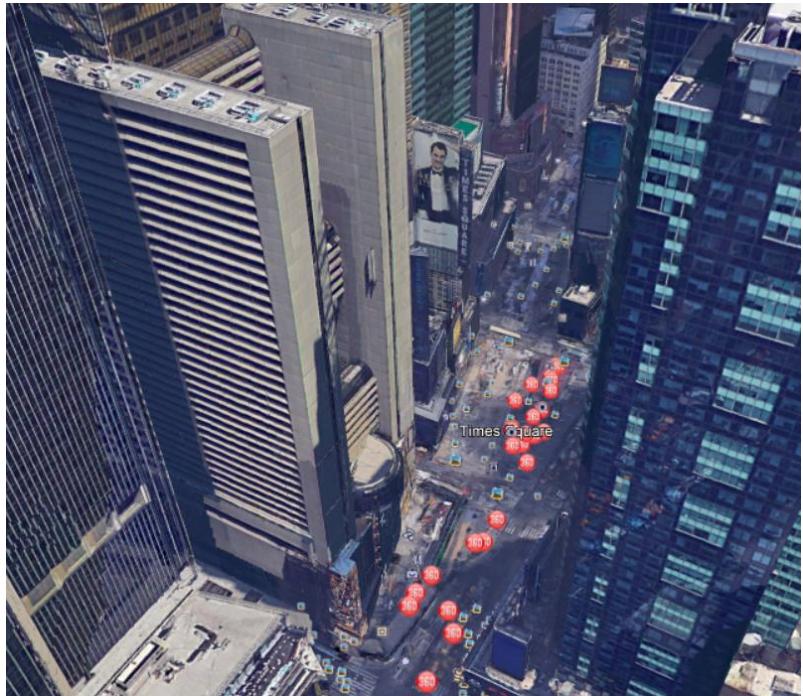
Like 151 0

UGANDA is not best known as a testbed for new ideas in governance. But research there by Jakob Svensson at the University of Stockholm and colleagues suggested that giving people health-care performance data and helping them organise to submit complaints cut the death rate in under-fives by a third.

Publishing data on school budgets reduced the misuse of funds and increased enrolment.



# Data divide nelle mappe

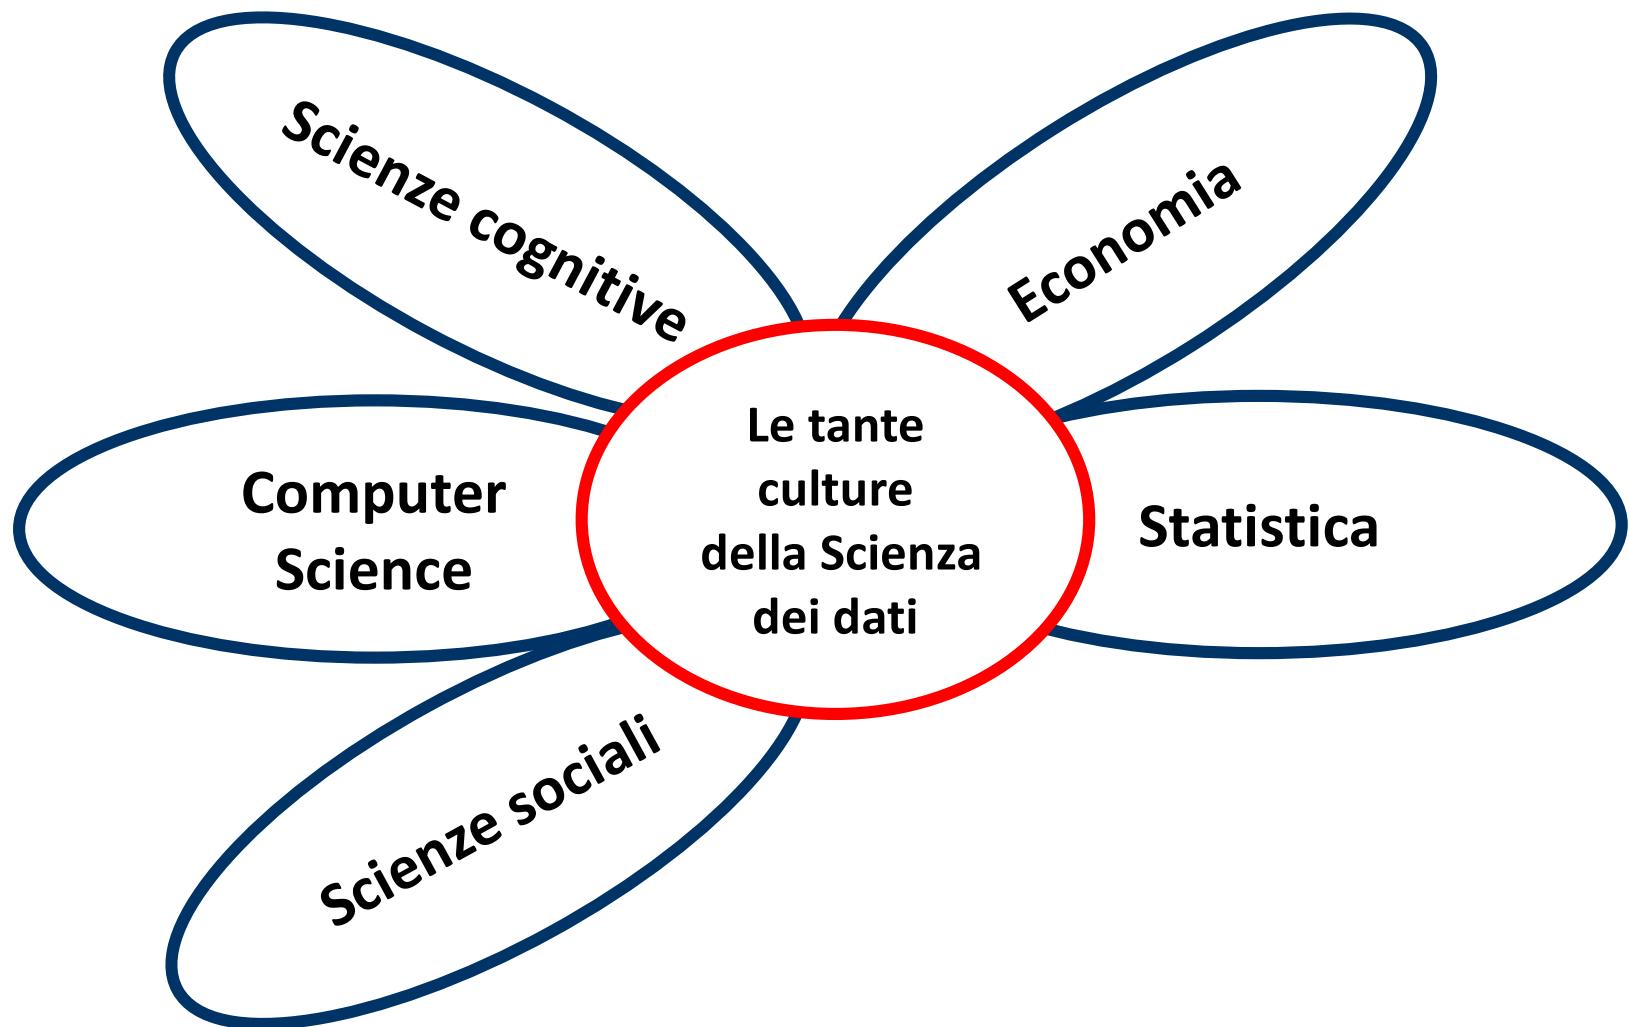


**Times Square, New York**



**Somaliland**

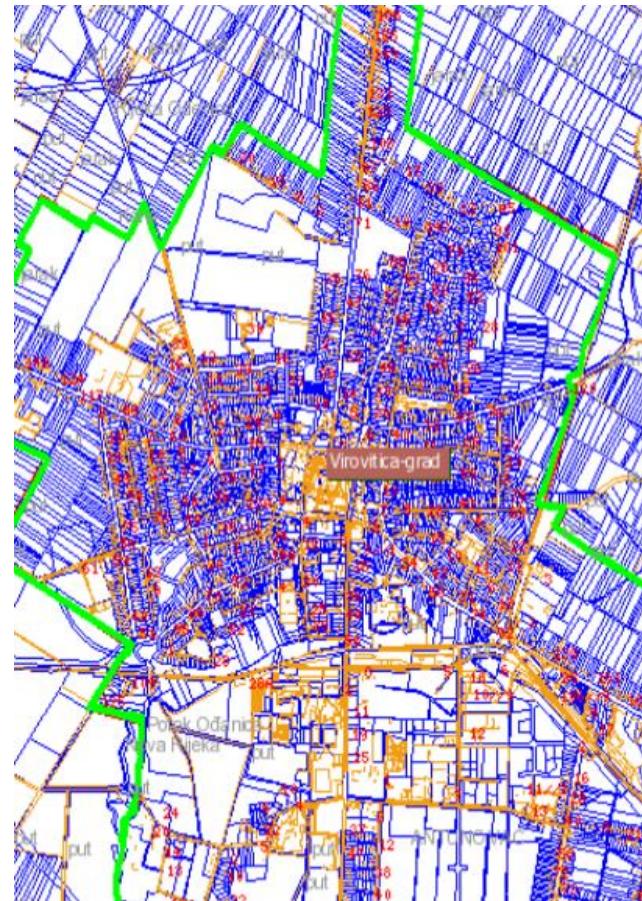
# Una nuova Scienza



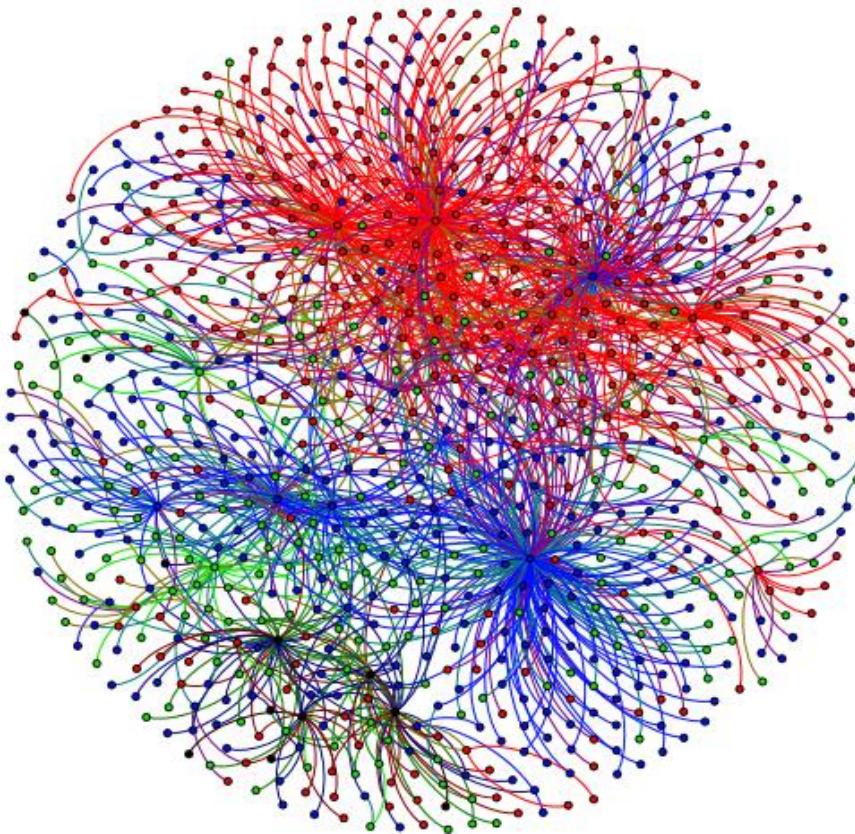
# Dati catastali in India



# Dati catastali in India

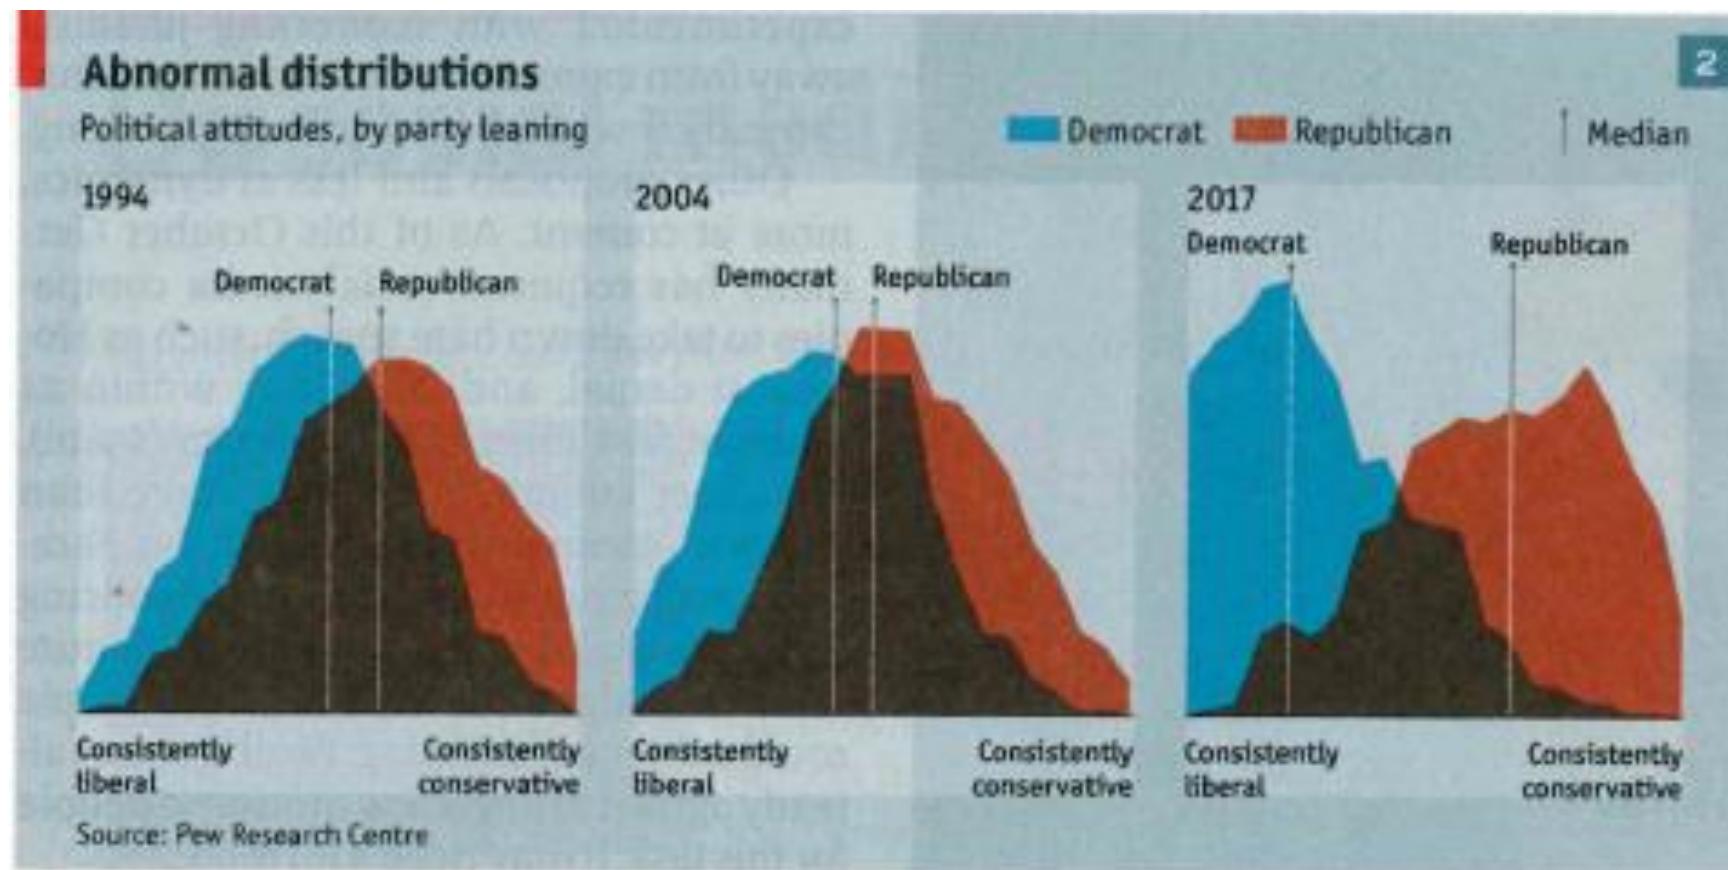


# La rabbia è molto più presente della gioia



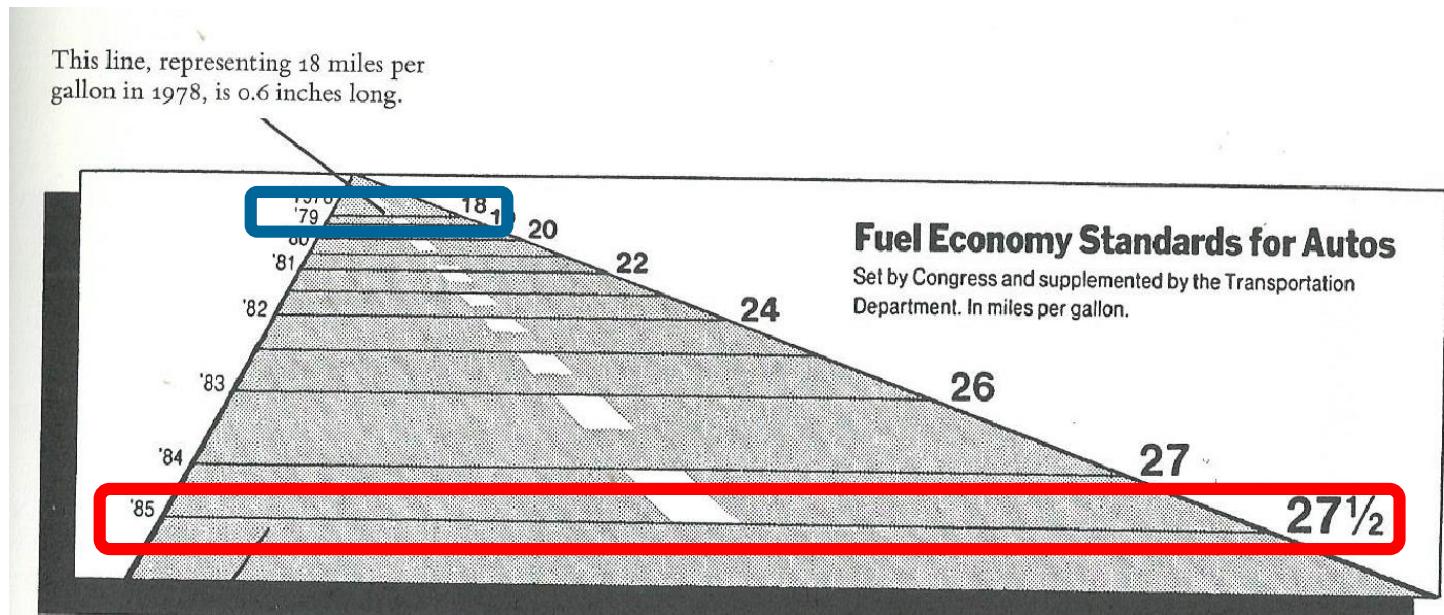
- **Rosso** sta per rabbia,
- **Verde** sta per gioia,
- **Blu** è la tristezza
- **Nero** rappresenta il disgusto.

# Polarizzazione delle opinioni politiche nella popolazione USA - Economist 4/11/2017



# Quante bugie nelle visualizzazioni

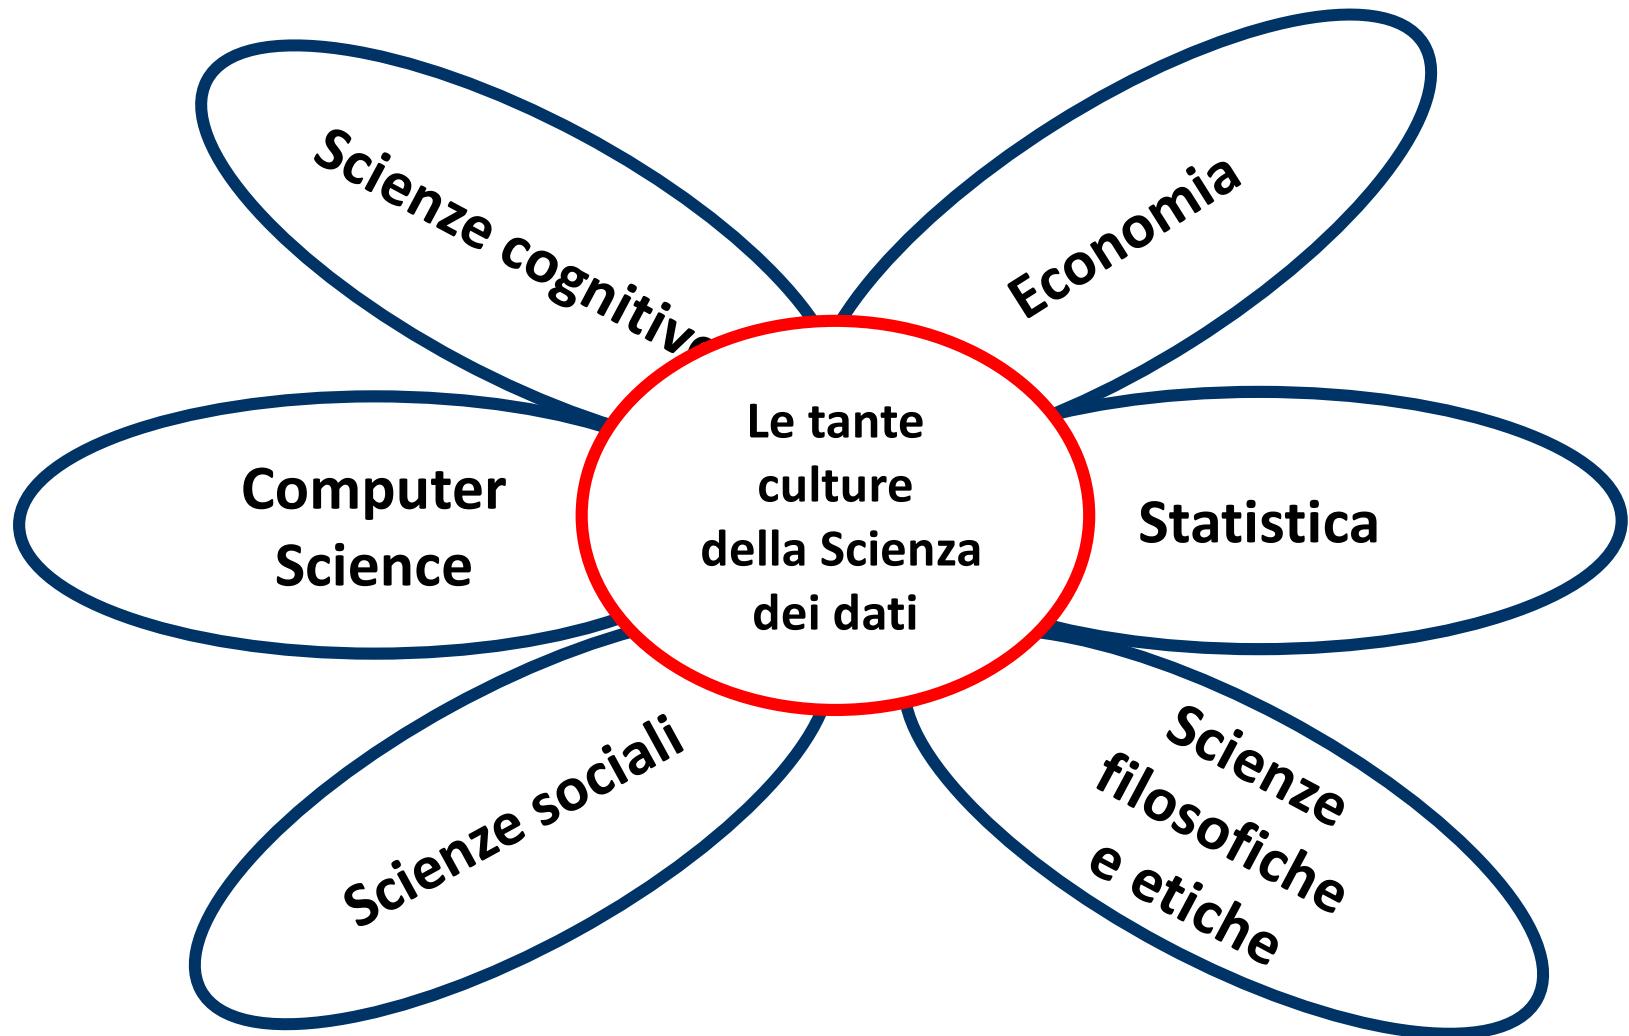
Year	Miles per gallon
1978	18
1979	19
1980	20
1981	22
1982	24
1983	26
1984	27
1985	27,5



This line, representing 27.5 miles per gallon in 1985, is 5.3 inches long.

**Livello di bugia = rapporto tra valori numerici nel mondo reale / rapporto tra valori numerici nella visualizzazione = 15**

# Una nuova Scienza



# Le ceremonie di insediamento di Obama e di Trump



# I fatti alternativi di Kellyanne Conway



❶ Kellyanne Conway denies Trump press secretary lied: 'He offered alternative facts'

# Dalla psicologia cognitiva non arrivano buone notizie

**Non è tanto  
rilevante ciò che  
la gente pensa,  
ma come pensa.  
Riconoscere la  
cattiva  
informazione  
richiede processi  
cognitive  
complessi**

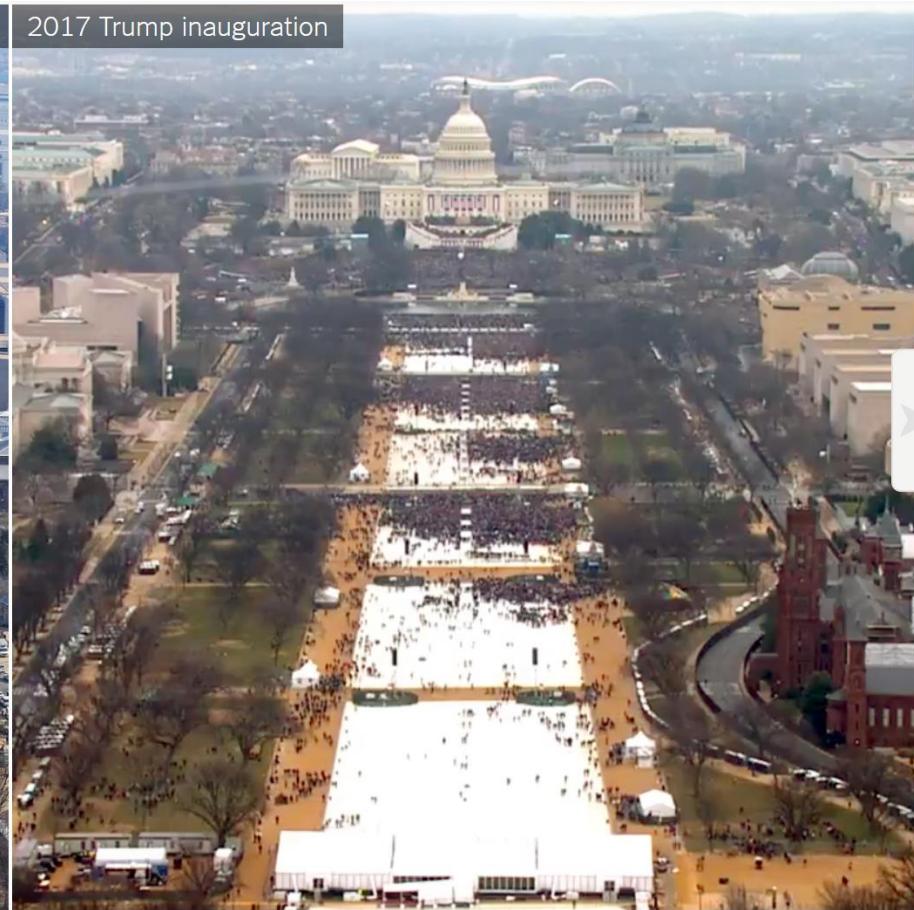
**Un semplice  
mito è più  
attrattivo  
cognitiva-  
mente di  
una  
complicata  
correzione**

**Per coloro che  
sono  
fortemente  
convinti delle  
proprie idee,  
gli argomenti  
fortemente  
contrari  
possono  
rafforzare le  
loro convinzioni**

# Come possiamo capire chi ha ragione? I fatti sono testardi



2009 Obama inauguration



2017 Trump inauguration

Ora della foto: 11.30

Ora della cerimonia: 12

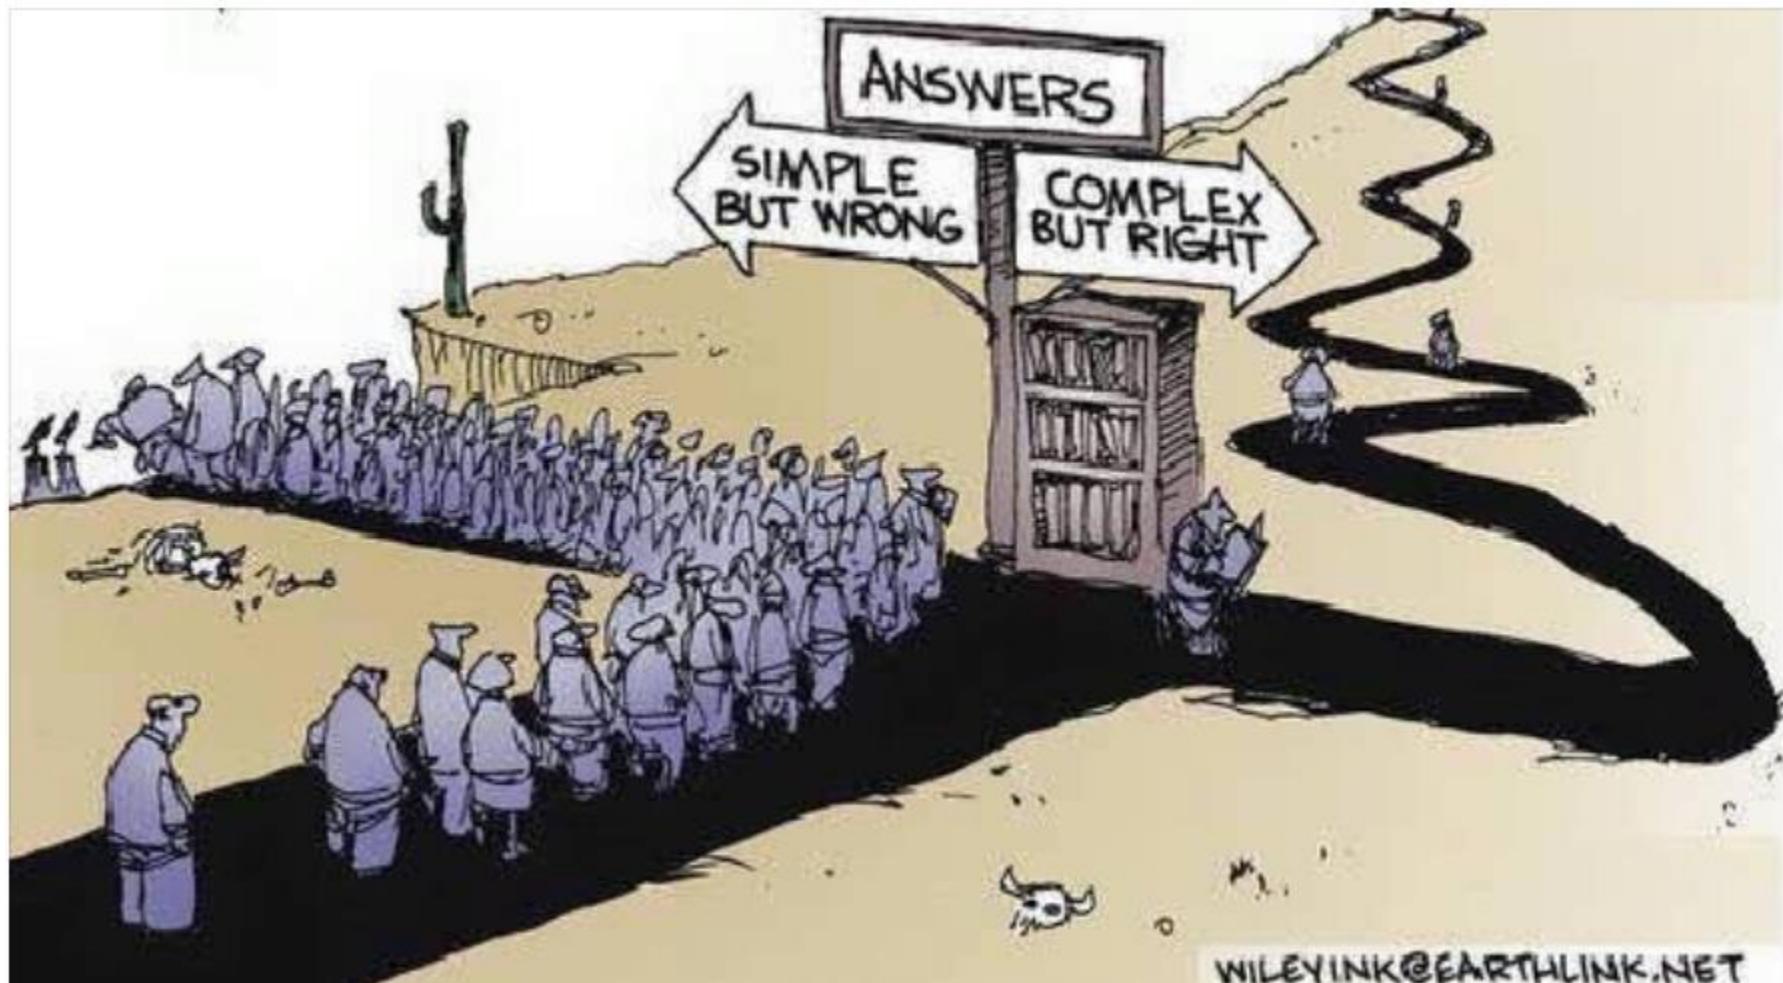
Numero biglietti metropolitana nell'ora  
precedente: 80.000

Ora della foto: 11.30

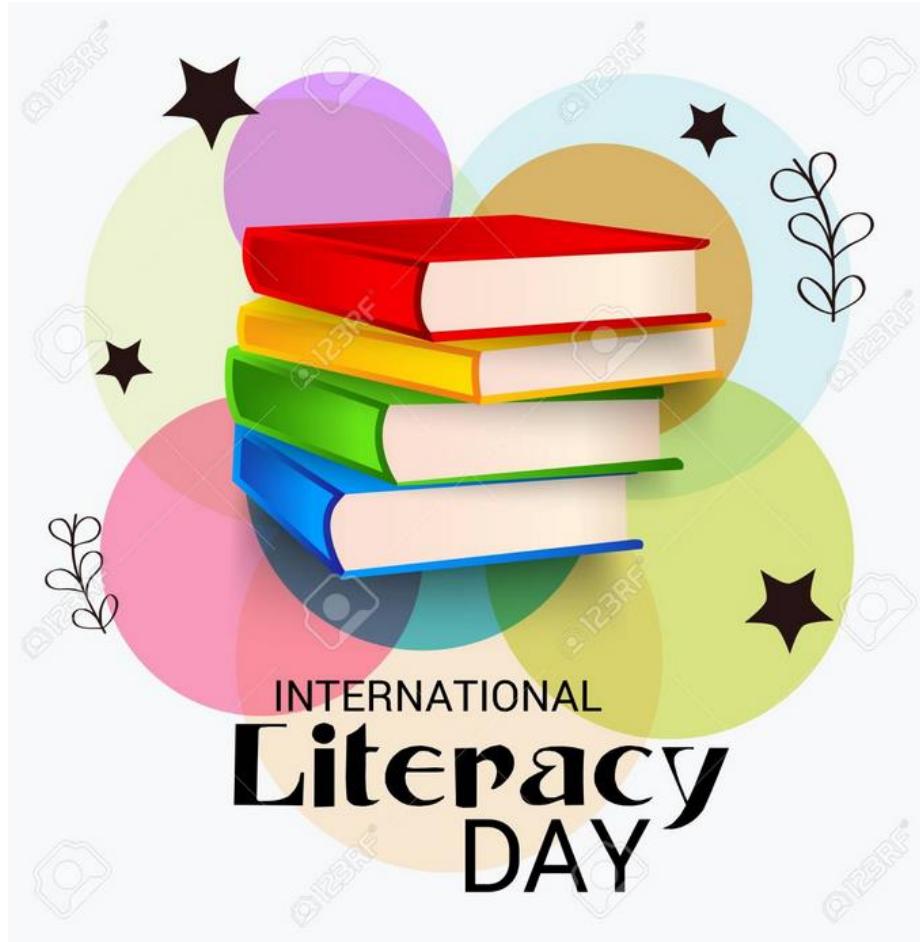
Ora della cerimonia: 12

Numero biglietti metropolitana nell'ora  
precedente: 20.000

# Non ci sono risposte semplici a domande complicate



# Literacy o alfabetizzazione



# Numeracy, o capacità di far di conto



# Una Definizione di Datacy: capacità di ...

- applicare tecniche e modelli statistici e informatici basati su **apprendimento** per costruire modelli decisionali, interpretativi e predittivi.
- **risolvere problemi** con il supporto dei dati e prendere decisioni complesse.
- comprendere l'impatto sulla **economia** e sulla **società** del fenomeno dei dati digitali.
- analizzare i **corpi giuridici** sviluppati dalle istituzioni pubbliche in tema di dati digitali
- affrontare i nuovi temi **etici** che nascono dall'uso dei dati digitali.

# L'INNOVAZIONE DIGITALE, LA CULTURA DEI DATI DIGITALI E LA SCIENZA DEI DATI

## 11 febbraio 2019 – 29 aprile 2019

### Descrizione del progetto

- Il corso intende presentare alcune tematiche di maggiore rilevanza per l'educazione nella innovazione digitale e in particolare nella nascente disciplina della Scienza dei dati nella scuola secondaria superiore. Le lezioni saranno tenute da esperti attivi in ambito universitario e nelle aziende.

### Contenuti del progetto

- Destinatari Docenti scuola secondaria II grado Durata 24 ore Per la validità del corso è necessaria la frequenza del 75% delle ore previste (minimo 15 ore) Sedi Istituto Lombardo di Cultura e Università di Milano-Bicocca

### Programma del corso

#### Obiettivi formativi

- Gli obiettivi del corso consistono nel fornire agli animatori digitali e ai docenti di scuola secondaria di II grado i riferimenti concettuali e gli strumenti di lavoro al fine di sviluppare attività formative sui temi della cultura digitale e della scienza dei dati in ambito scolastico. Ogni lezione prevedrà una presentazione generale del tema seguita da un'illustrazione in forma di demo di idee e strumenti per attività informative e formative che potranno essere impartite indipendentemente dai docenti.
- L'insieme dei seminari costituenti il progetto non potrà affrontare tutti i temi descritti in precedenza nell'ambito della Scienza dei dati, vista la loro ampiezza e articolazione. E' possibile approfondire alcuni temi in relazione a un possibile trasferimento in esperienze didattiche nella scuola secondaria. Essi riguardano, oltre a una introduzione generale su innovazione digitale e scienza dei dati, i linguaggi e gli strumenti per l'eLearning e per l'analisi dei dati digitali, le applicazioni in ambito scientifico e aziendale, il tema del data journalism, e approfondimenti sulla trasparenza nelle tecniche di apprendimento e sull'impatto di dati e algoritmi nella economia digitale.

# Iscrizioni

- Numero massimo di corsisti: 100 (fino a esaurimento posti)
- Scadenza iscrizioni: 5 febbraio 2019

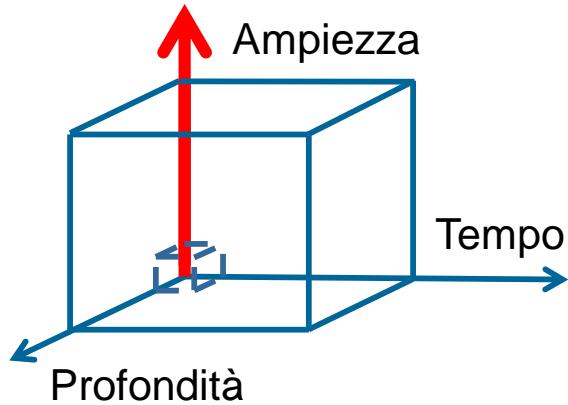
Per iscriversi al corso è necessario seguire entrambe le modalità di registrazione:

- 1) Compilare la scheda di iscrizione on-line:  
<https://goo.gl/forms/OFa0B1JYgP4UI9oE3>
- 2) Accreditarsi attraverso la piattaforma S.O.F.I.A. |  
Codice identificativo: 21760 | Codice identificativo:  
31382

# Programma di alfabetizzazione

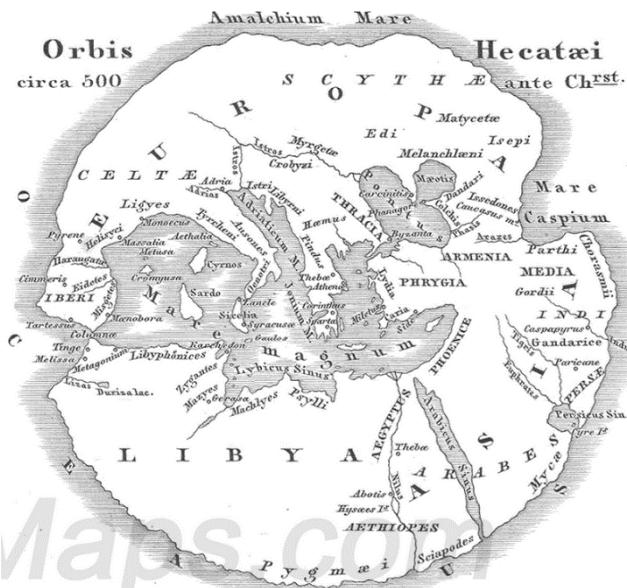
- Le **basi della Scienza dei dati**, con tecniche, applicazioni e temi metodologici
- I **linguaggi della Scienza dei dati**
  1. **Linguaggio R**
  2. **Linguaggio Python**
- **Corsi multimediali** (video + testi di approfondimento) con tutor attivo, e verifiche e certificazione finale con domande a risposta multipla

# Left over

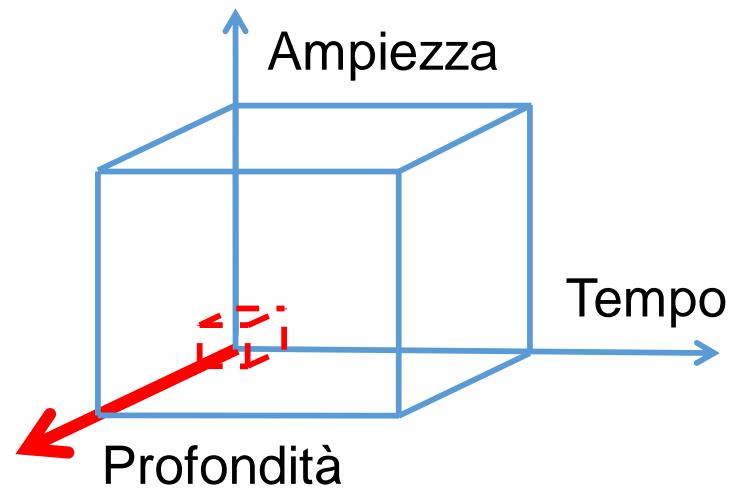


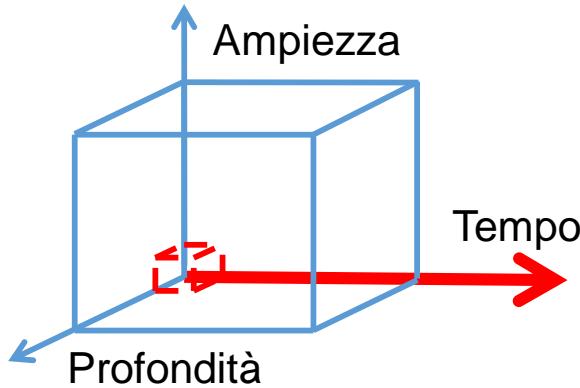
# Ampiezza

Dalla Hecateus Map (520 B.C.)... ... ai satelliti Landsat

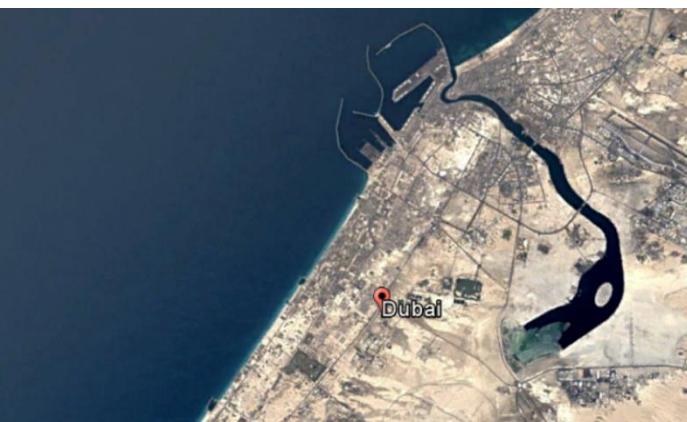


# Profondità – I Pneumatici Intelligenti





# Evoluzione nel tempo

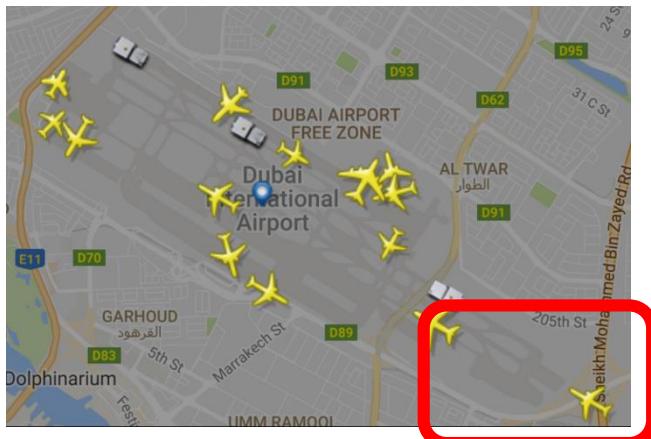


Google Earth, Dubai, 1984

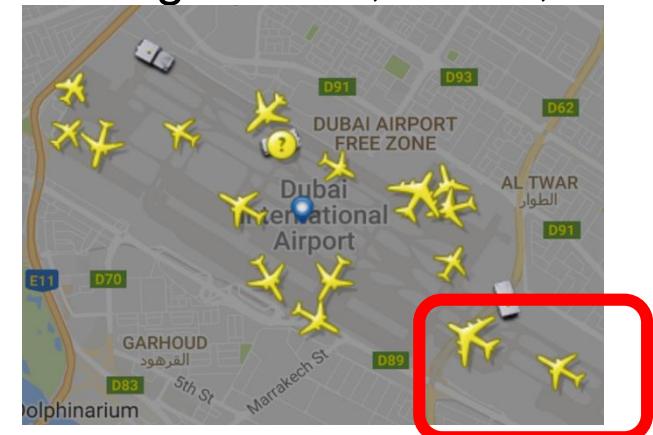
1 mese  
→



Google Earth, Dubai, 2015

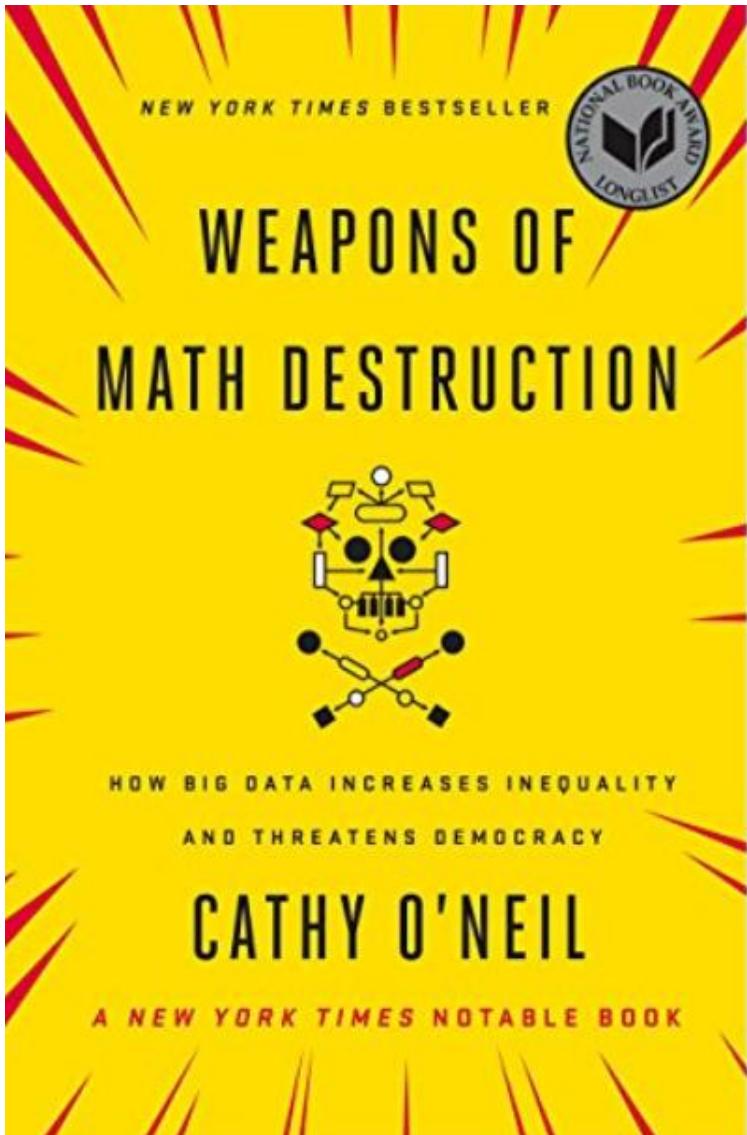


1 secondo  
→

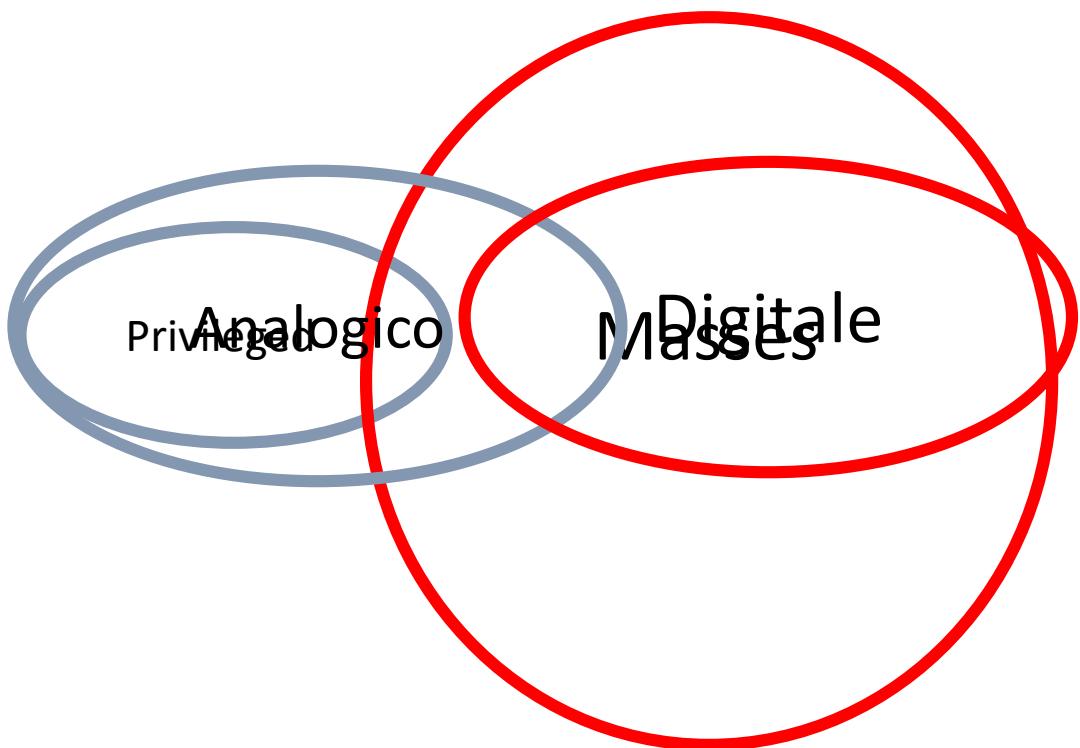


FlightRadar, Dubai 11:05:30 4:3:2017

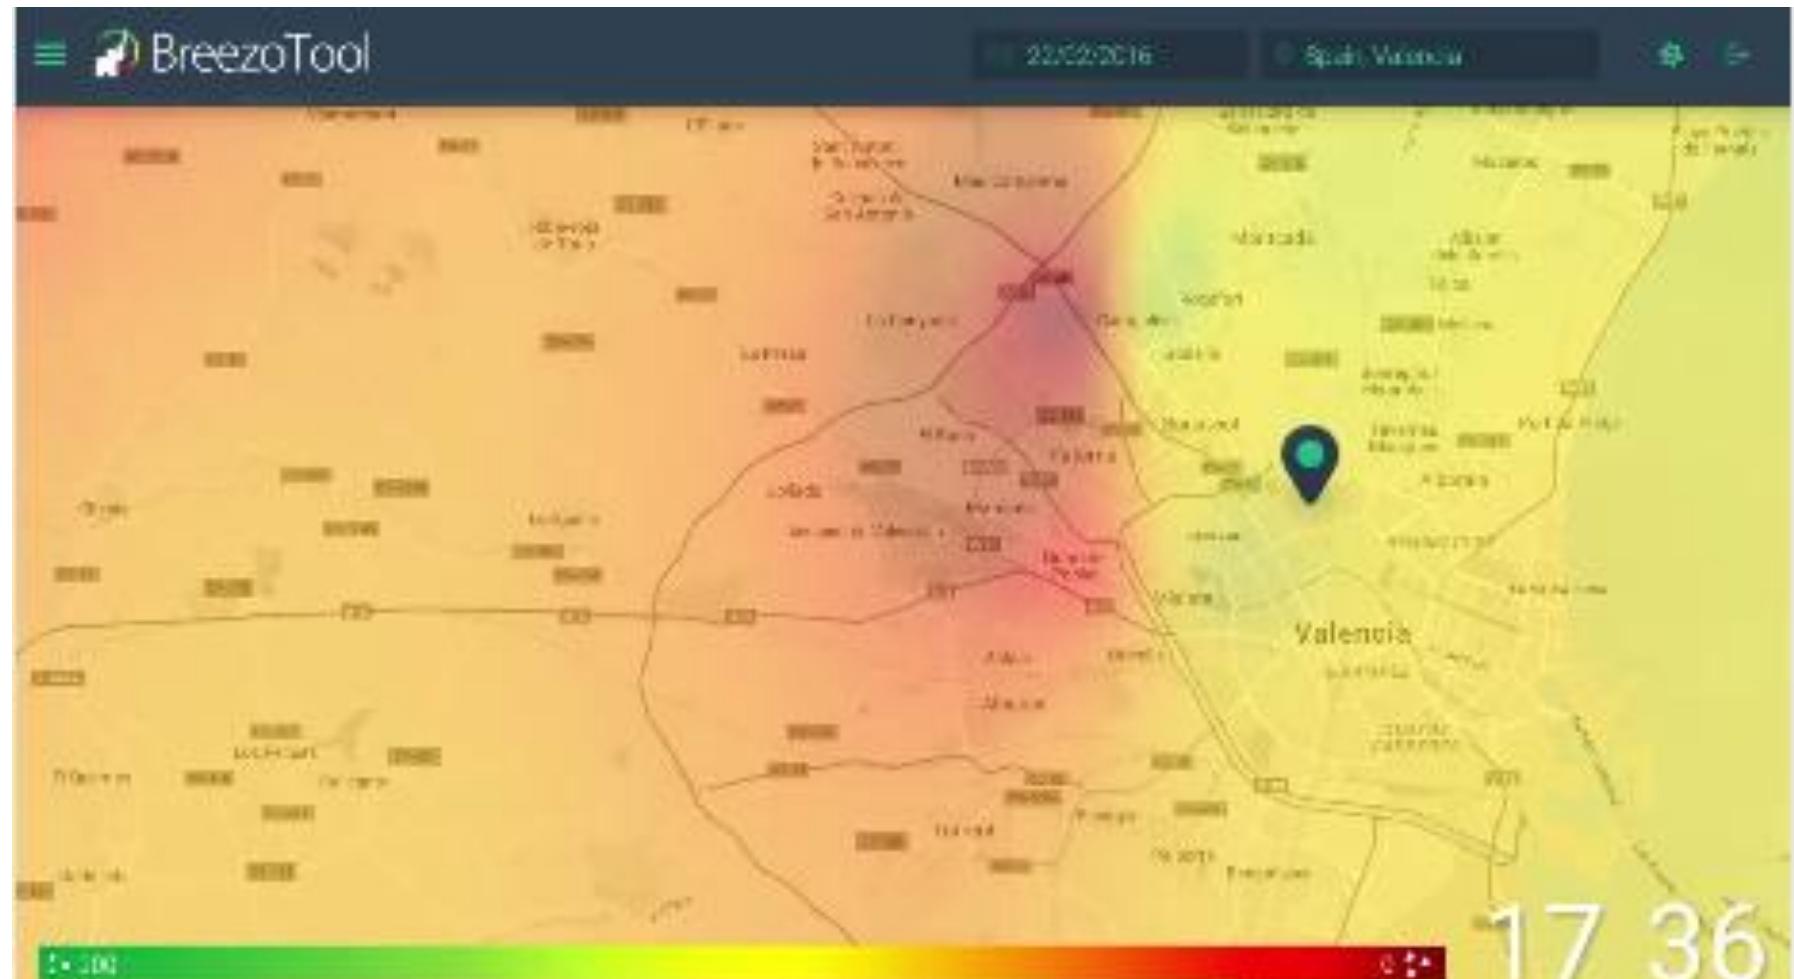
FlightRadar, Dubai 11:05:35 4:3:2017



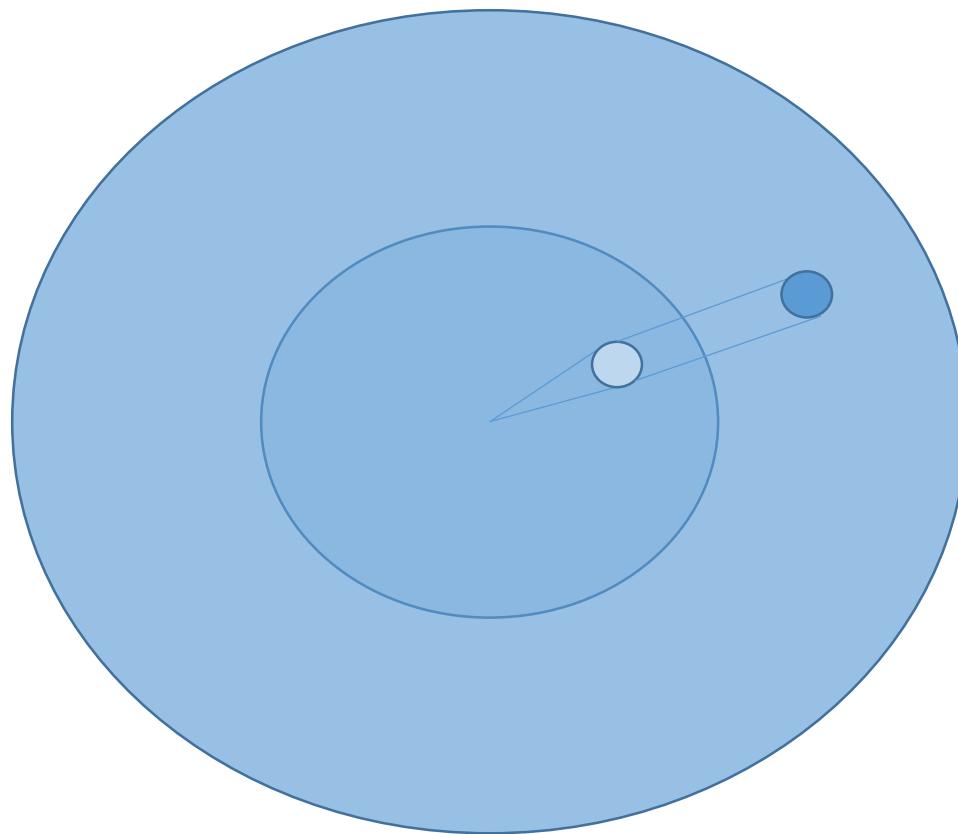
The privileged are processed more by people, the masses by machines



# Ore 17:36



# I limiti cognitivi



# $PB = 10^{15}$ , $EB = 10^{18}$ , $ZB = 10^{21}$ byte in quattro grandi domini dei Big Data nel 2025

<u>Data Phase</u>	<u>Astronomy</u>	<u>Twitter</u>	<u>YouTube</u>	<u>Genomics</u>
<b>Acquisition</b>	25 zetta-bytes/year	0.5–15 billion tweets/year	500–900 million hours/year	1 zetta-bases/year
<b>Storage</b>	1 EB/year	1–17 PB/year	1–2 EB/year	2–40 EB/year
<b>Analysis</b>	Infra-red detection Infrared detection Massive volumes	Topic and sentiment mining Real-time processing	Video compression Metadata analysis	Heterogeneous genome analysis Variant calling, ~2 trillion central processing unit (CPU) hours All-pairs genome alignments, ~10,000 trillion CPU hours
<b>Distribution</b>	Dedicated lines from antennae to server (600 TB/s)	Small units of distribution	Major component of modern user's bandwidth (10 MB/s)	Many small (10 MB/s) and fewer massive (10 TB/s) data movement

# Eclissi e prezzi dei biglietti



**L'osservazione delle eclissi** all'epoca dei Babilonesi portò a scoprire il **ciclo di Saros**, che dice secondo quale scansione temporale si succedono le eclissi del sole e della luna.

Il confronto tra le previsioni fatte dai babilonesi e quelle ottenute con le attuali tecnologie mostra una precisione stupefacente per l'epoca.

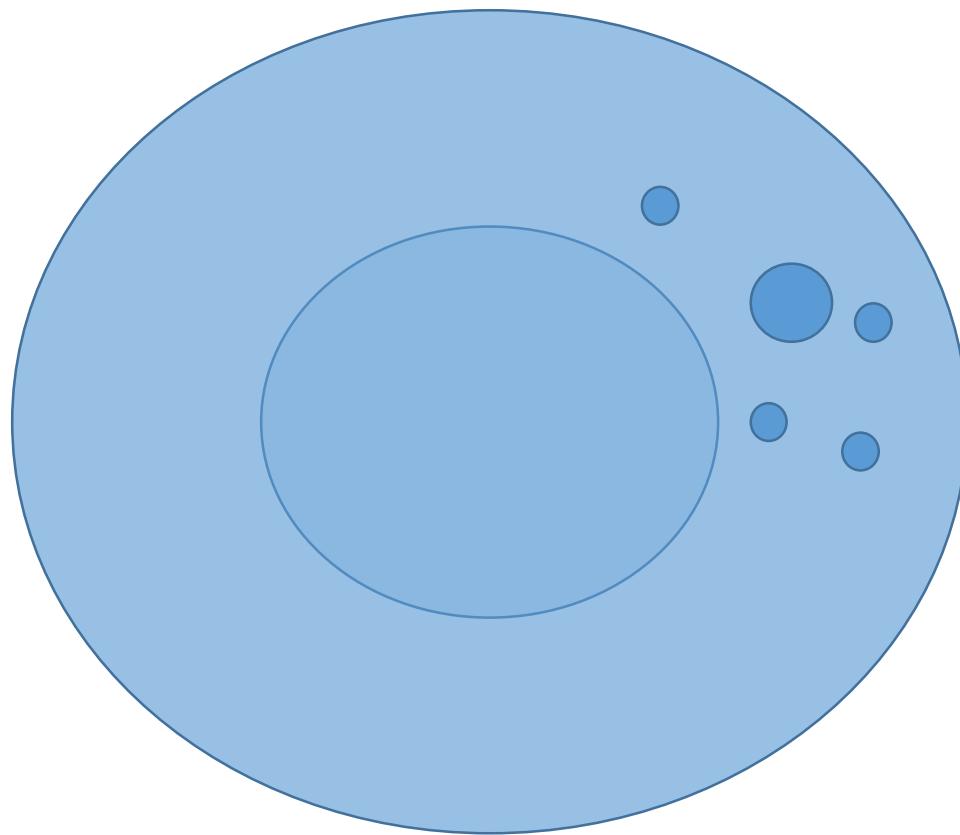


Le leggi dei prezzi dei biglietti (leggi dette di pricing) è problema più complesso, che richiede una conoscenza delle **politiche delle compagnie aeree** in genere considerate segreto aziendale.

# Determinants of Ethics in Digital Data Science

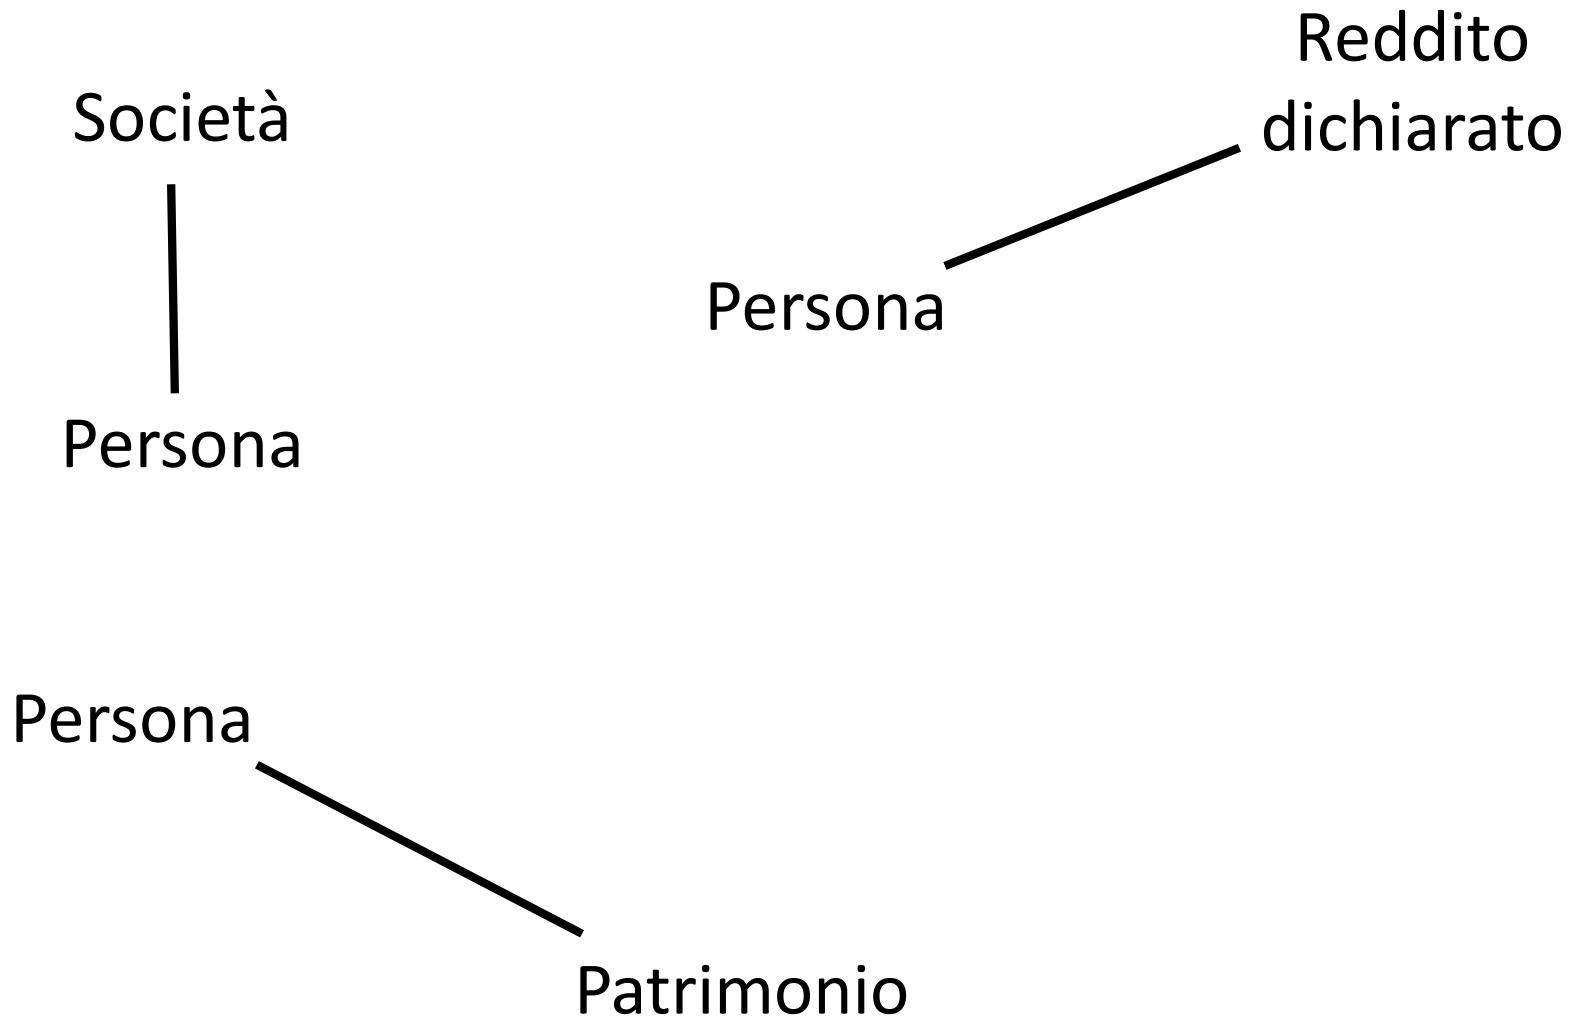
1. **Transparency vs Opacity**, it is easy for others to see from data what actions are performed.
2. **Accountability**, mechanisms are in place to determine who took a responsible action.
3. **Attribution of responsibility**, a process of cognition based on data by which moral accountability is assigned to a person believed to have produced a disapproved behavior or effect
4. **Auditability**, ability of examining or evaluating (something) thoroughly
5. **Awareness**, knowledge and understanding that something is happening or exists
6. **Data Divide**, economic and social inequality with regard to use of or impact of data
7. **Equality of Opportunity** (Non Discrimination, Egalitarianism), data should enable people to compete on equal terms
8. **Explanation**, a statement made to clarify something and make it understandable
9. **Fairness**, the state, condition, or quality of being fair, or free from bias or injustice
10. **Fairness-aware (learning techniques)**, classifiers to be independent of sensitive features.
11. **Generalization vs Personalization**, data for all vs tailoring data to accommodate specific individuals, sometimes tied to groups or segments of individuals
12. **Liability**, extends responsibility further to the area of laws.
13. **Objectivity**, state of being true even outside a subject's individual biases, interpretations and feelings
14. **Quality of information, (Accuracy, Veridicity etc. )** property of information to be adherent to reality
15. **Responsibility**, you accept the potential costs, and duties for the decision you made
16. **Privacy**, the state of personal data of being free from public attention
17. **Sharing**, ~~dividing~~ having data in common with others
18. **Statistical discrimination**, racial or gender inequality based on stereotypes

# La parcellizzazione della conoscenza

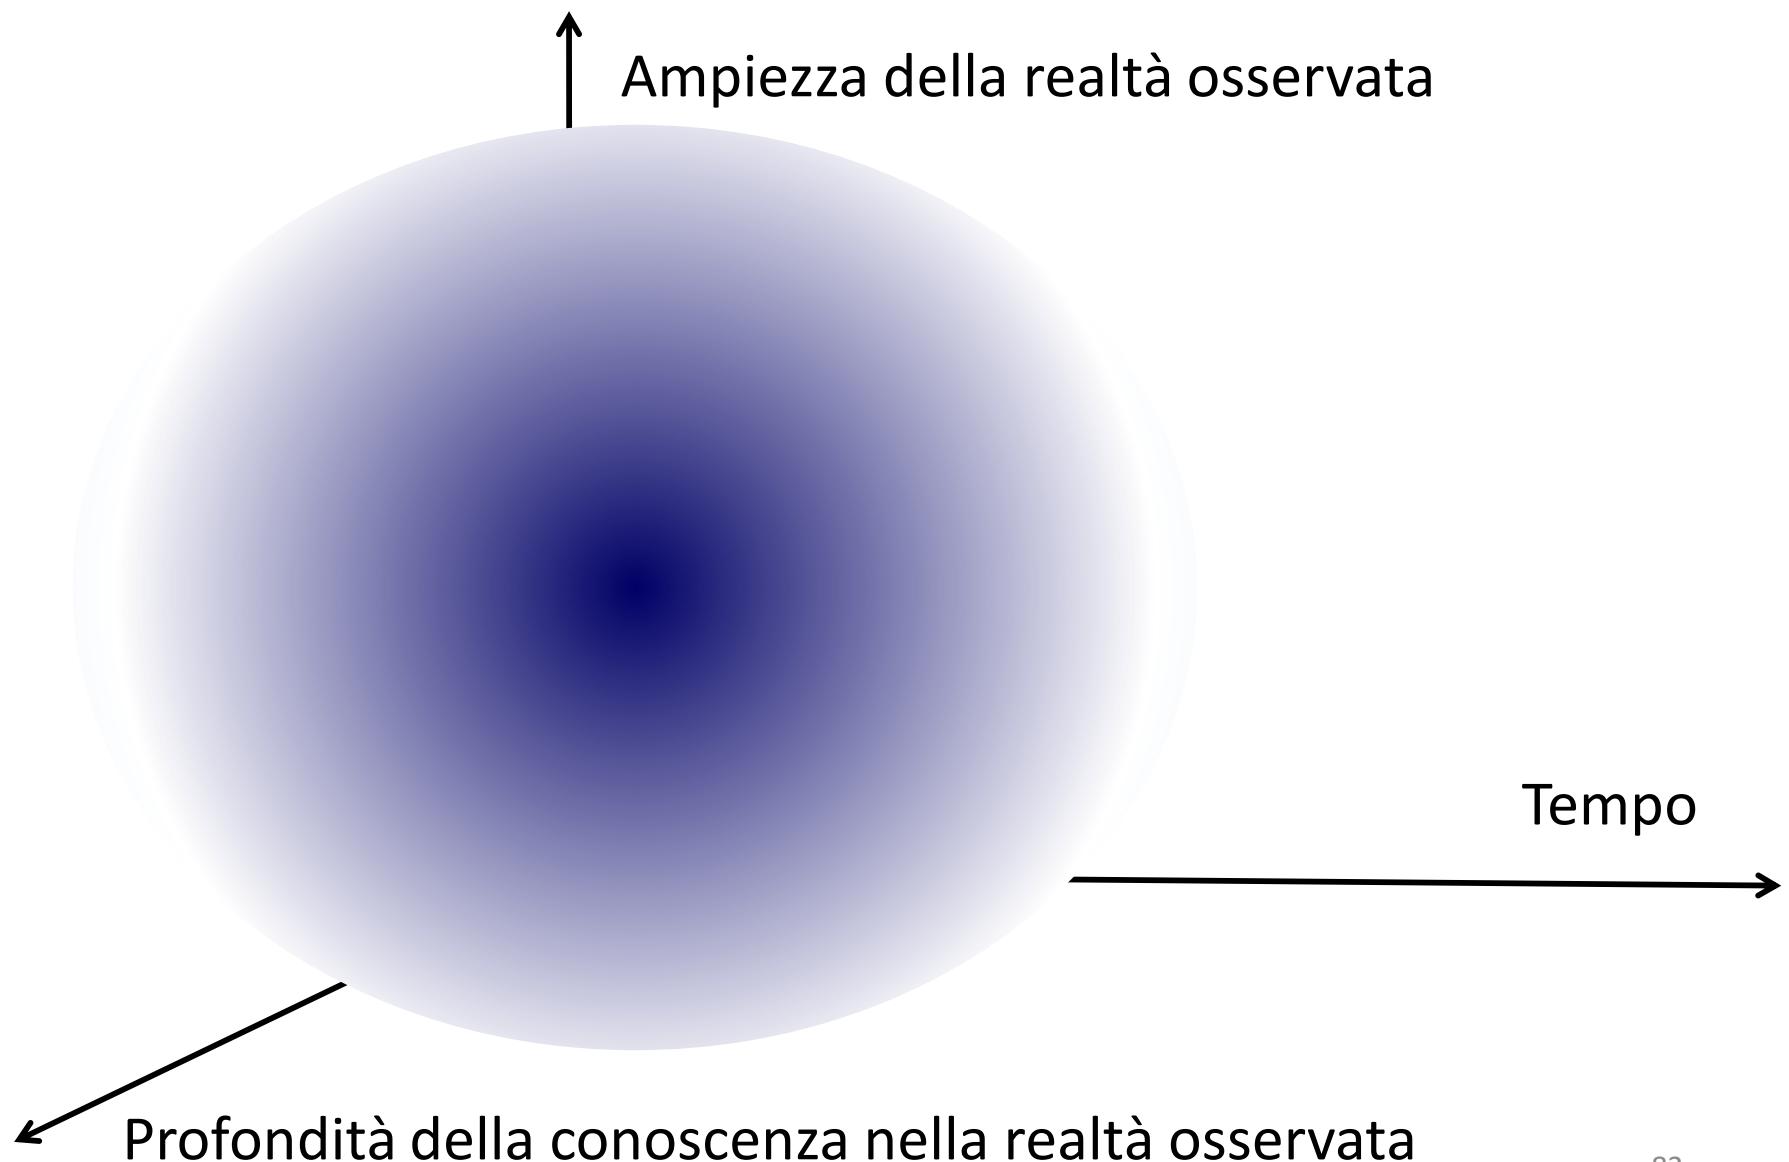


# Valorizzazione

Integrare i dati porta valore

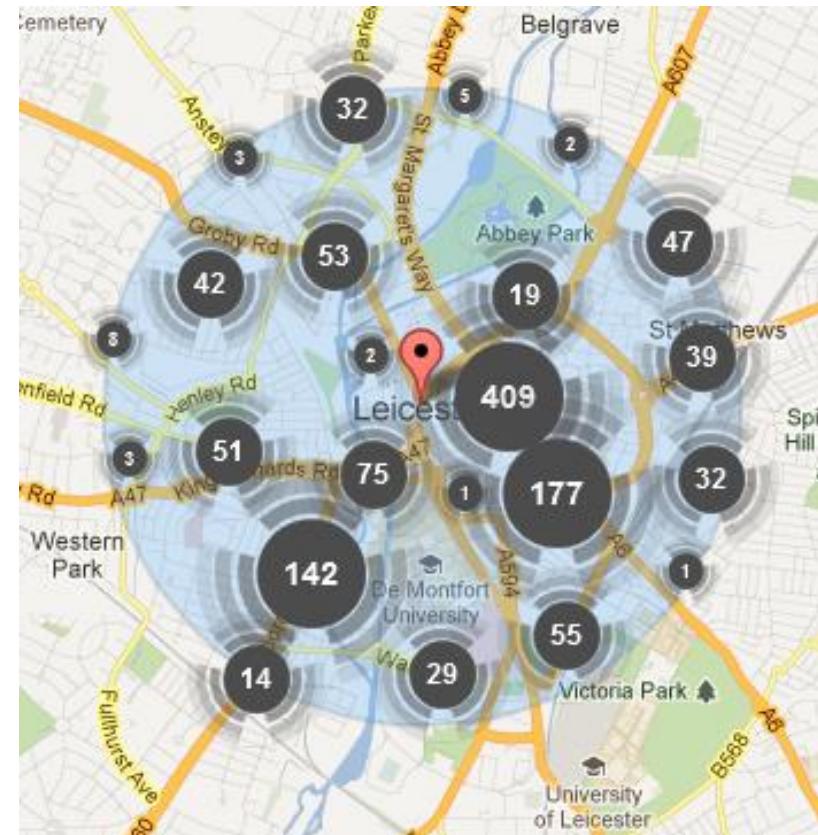


# I grandi dati restituiscono una realtà opaca e confusa



# Reati a Leicester: valore per una persona residente e valore per un affittuario

All crime	1241
Burglary	75
Anti-social behaviour	317
Robbery	12
Vehicle crime	57
Violent crime	181
Public disorder and weapons	45
Shoplifting	172
Criminal damage and arson	102
Other theft	178
Drugs	48
Other crime	54



Dall' Economist, Nov. 10th, 2016

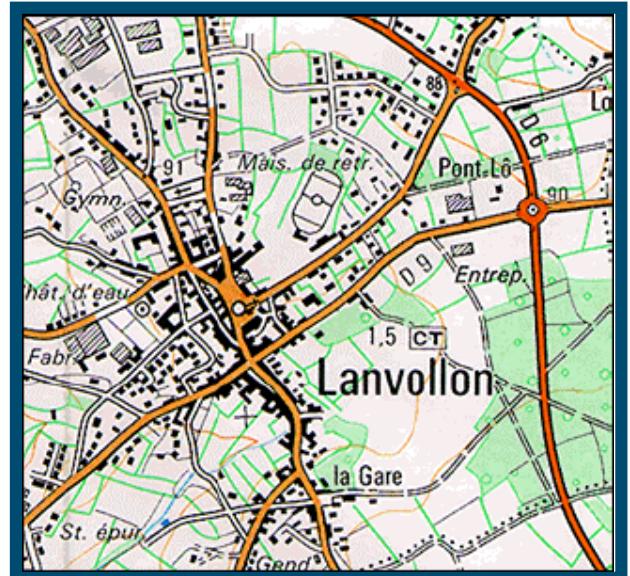
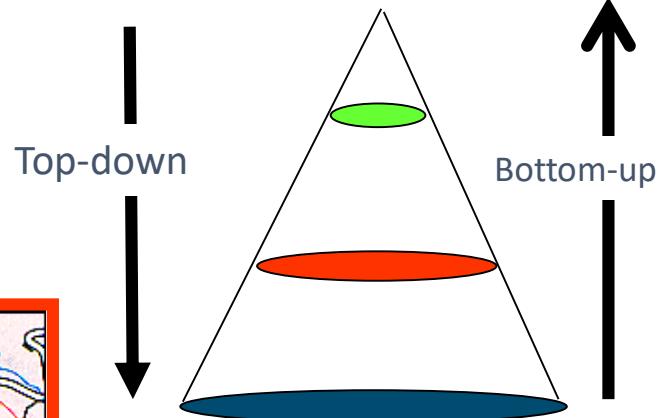
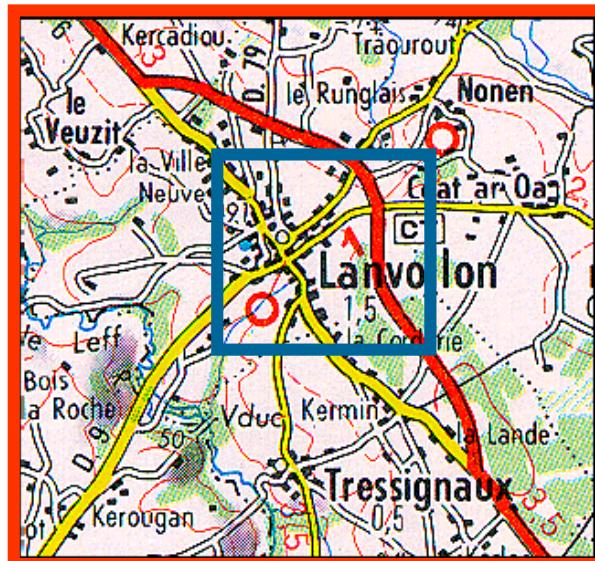
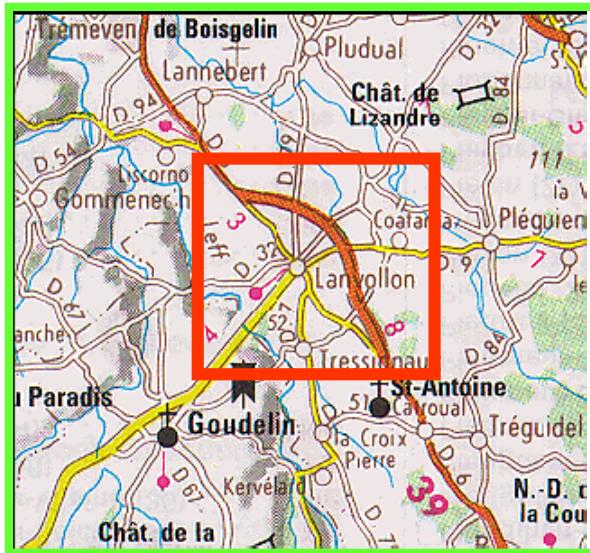
Le tecnologie costano molto meno delle persone...

- The agencies not only do more, they also spend less.
- To **deploy agents on a tail** costs \$ 175.000 a month because it takes a lot of manpower.
- To **put a GPS receiver in a someone's car** takes \$ 150 a month.
- To **tag a target's mobile phone**, with the help of a phone company, costs only \$ 30 a month.

# Questa mappa è troppo dettagliata...



# Tre mappe a differenti livelli di scala



# Walter Quattro orecchi

- “Ci stiamo isolando. Per la prima volta, attraverso l’analisi di 920 agenzie di stampa e 376 milioni di utenti, abbiamo esplorato l’anatomia del consumo di notizie su Facebook su scala globale.”
- Questi numeri ci hanno dimostrato che gli utenti tendono a focalizzare la loro attenzione su **un numero limitato di pagine**, andando a selezionare un gruppo ristretto di media da cui attingere informazioni e rafforzando così le proprie opinioni, **senza mai metterle in discussione**.
- Di fatto, **si chiudono nella loro camera dell’eco**”.

