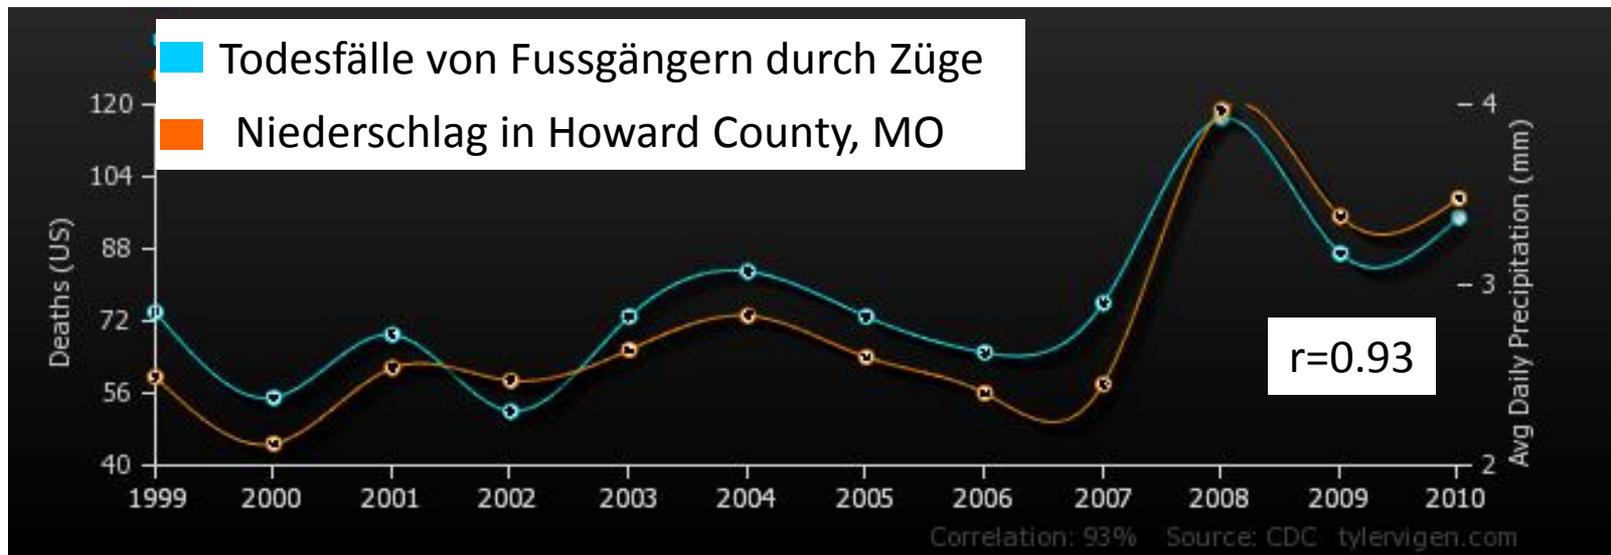


# Sieg der Korrelation über Kausalität? Methodische Fragen im Kontext von Big Data



Dr. Amke Caliebe

Institut für Medizinische Informatik und Statistik  
Christian-Albrechts-Universität zu Kiel

Big Data konkret - bvitg, smart data, tmf – Berlin, 13. Dezember 2016

# Big data in der Medizin

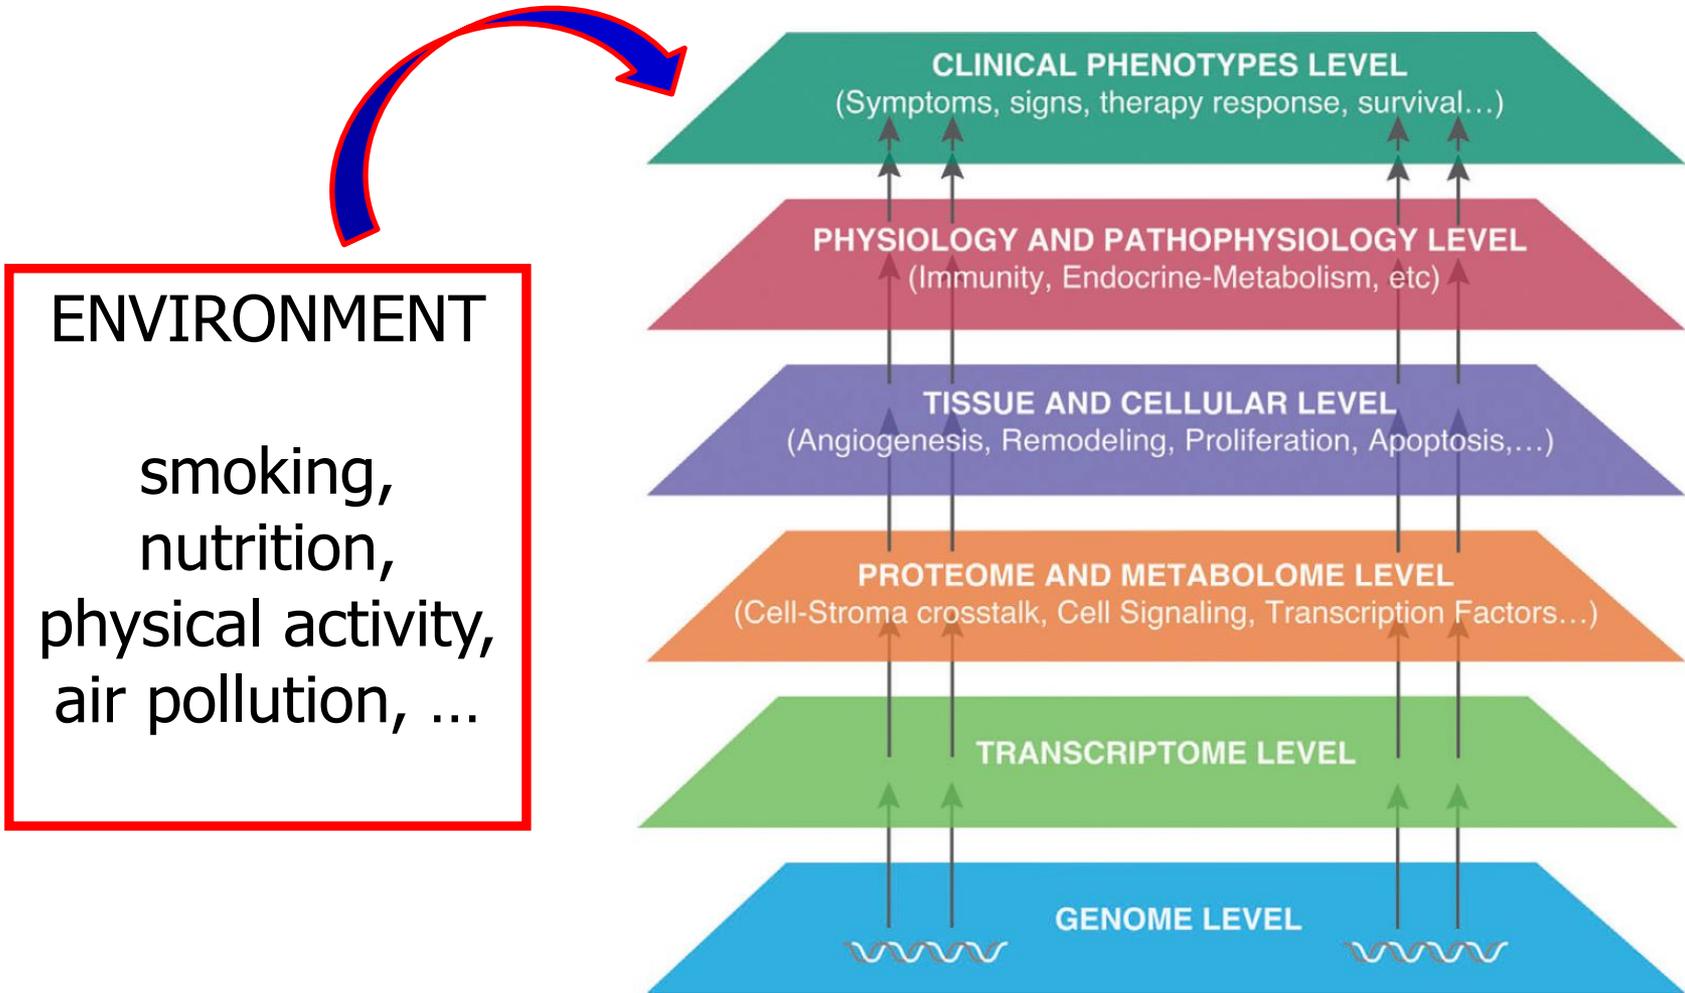
"In short, **translational research** is the process of **turning appropriate biological discoveries into drugs and medical devices** that can be used in the treatment of patients."

*Bakir M. (2011) Bosn J Basic Med Sci 11: 73*

"**Precision medicine** is an emerging approach for disease treatment and prevention that takes into account **individual variability in genes, environment, and lifestyle** for each person."

*www.nih.gov, 2016*

# Big data in der Medizin



*Blanco-Gomez A et al. (2016) Bioessays 38: 664-673*

# US Präsidentenwahl 1936

## Landon vs. Roosevelt



60% Landon



Literary Digest-Umfrage (**10,000,000** Wähler):  
60% Landon

# US Präsidentenwahl 1936

## Landon vs. Roosevelt



60% Roosevelt

Ergebnis: 60% Roosevelt

# US Präsidentenwahl 1936

## Landon vs. Roosevelt

“The answer, very simply, was the Digest's reliance on **voluntary response**. Ten million sample ballots were mailed to prospective voters, but only 2.3 million were returned. As everyone ought to know, such samples are practically always **biased**.”

*Bryson MC (1976) Am Stat 30: 184-185*

garbage in – garbage out

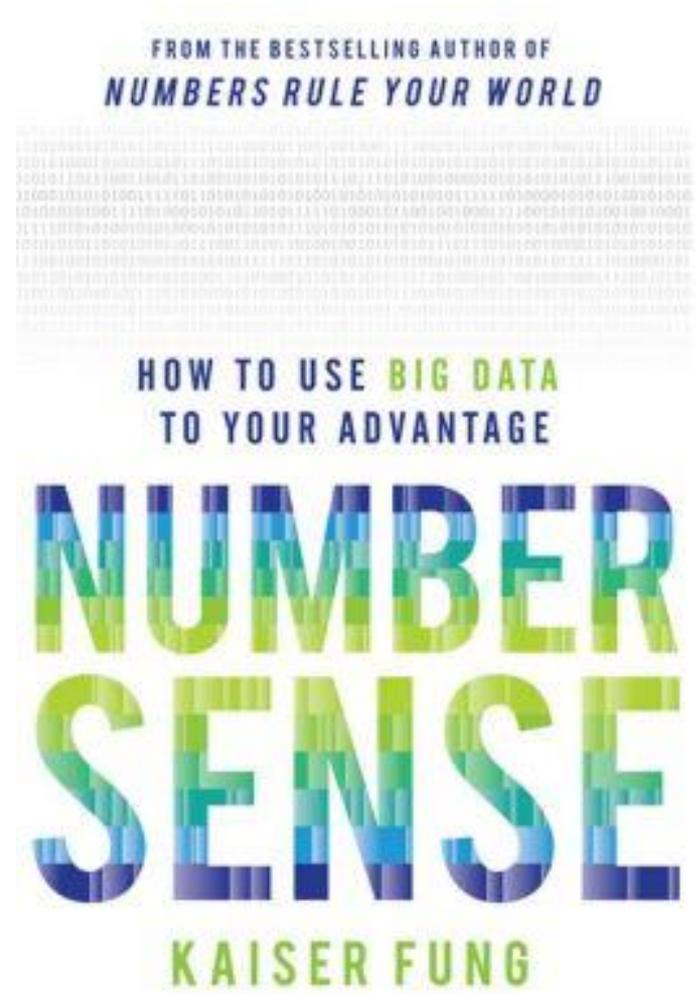


big garbage in – big garbage out

# Datenqualität

Big data ist typischerweise

- observational
- ohne Kontroll-Daten
- scheinbar vollständig
- aus dritter Hand
- zusammengemischt



# Datenqualität

- Wenn die Datenerfassung nicht verstanden ist, werden unzutreffende Schlüsse gezogen und die Evidenz der Ergebnisse ist zweifelhaft
- “Rebuttal to Simply Aggregating Data”  
*Brian S. Yandell, Head of Department of Statistics, University of Wisconsin-Madison, 2013*

→ Good Data ist wichtiger als Big Data

# Datenqualität

- **Veracity**  
Sind die Daten für das Problem angemessen?
- **Validity**  
Sind die Daten valide und von hoher Qualität?
- **Volatility**  
Wie lange sind die Daten aktuell?

# Fallzahlen

- Overfitting
- Google Flu Trends (GFT):

**50 Mio Suchbegriffe** für **1152 Datenpunkte**

„What's exciting about Flu Trends is that it lets anybody -- epidemiologists, health officials, moms with sick children -- learn about the current flu activity level in their own state based on data that's coming in this week.“

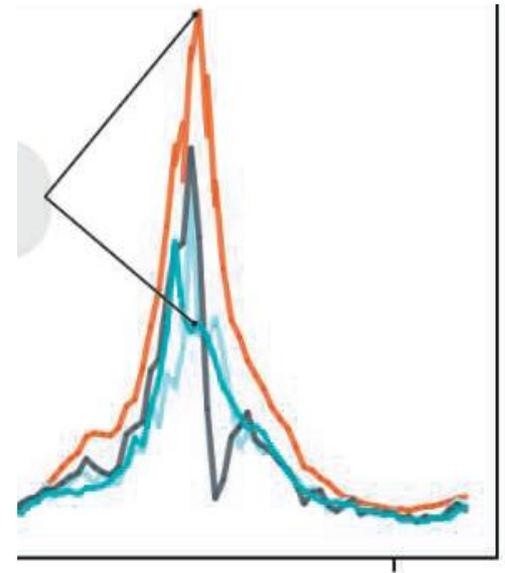
*Jeremy Ginsberg, Google, CNN, 2008*

# Fallzahlen

GFT überschätzte die Prävalenz für Grippe für 100 von 108 Wochen in der Saison 2011/2012.

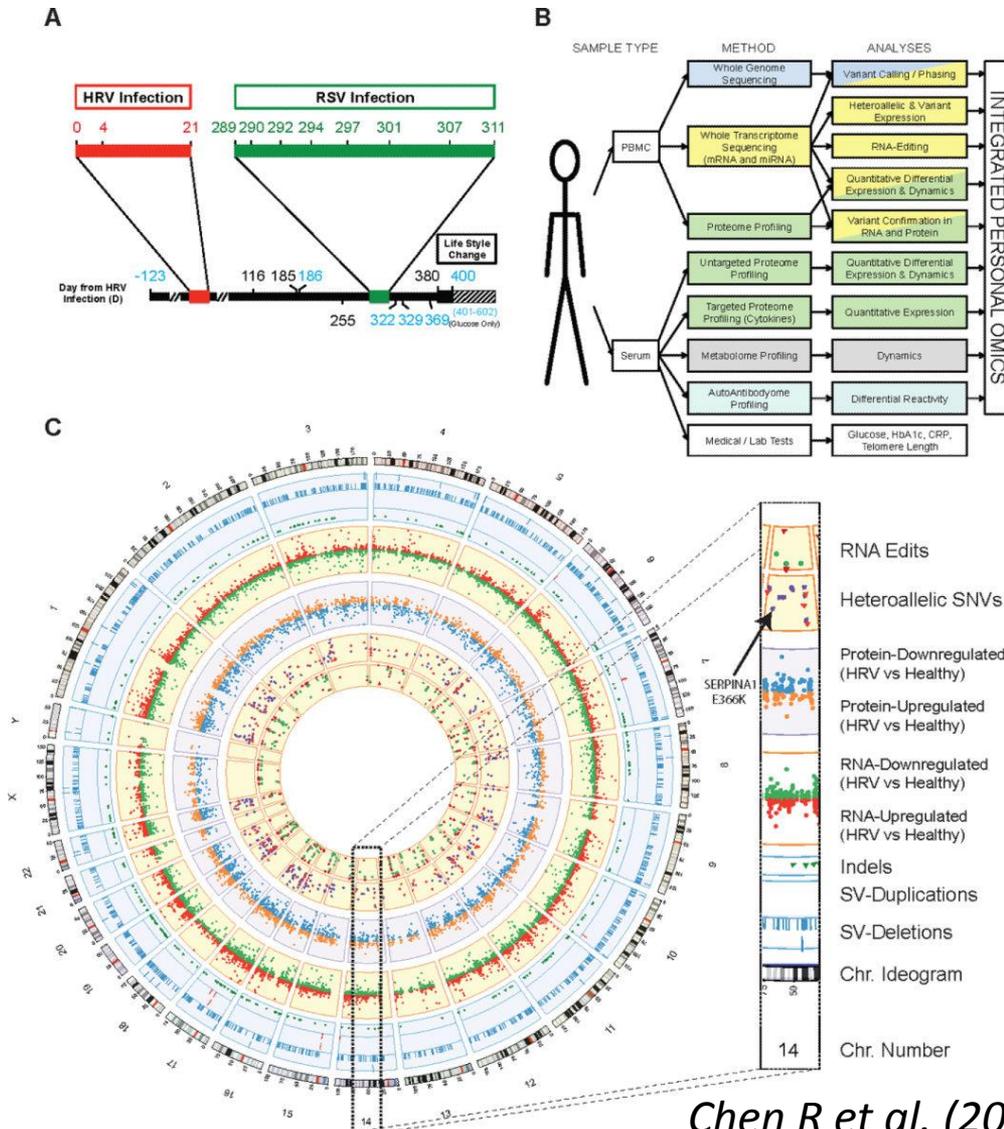
Ein einfaches Vorhersagemodell – wie ein Modell das die Temperatur aus den Temperaturen der letzten Woche vorhersagt – erzielte deutlich bessere Resultate.

*Lazer et al. (2014) Science 343: 1203-5*



GFT mehr als doppelt so hoch

# iPOP – Snyder



→ n=1

# Fallzahlen

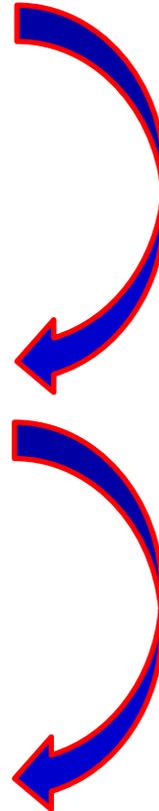
Fallstudie

gut geplante, gut  
durchgeführte Studie

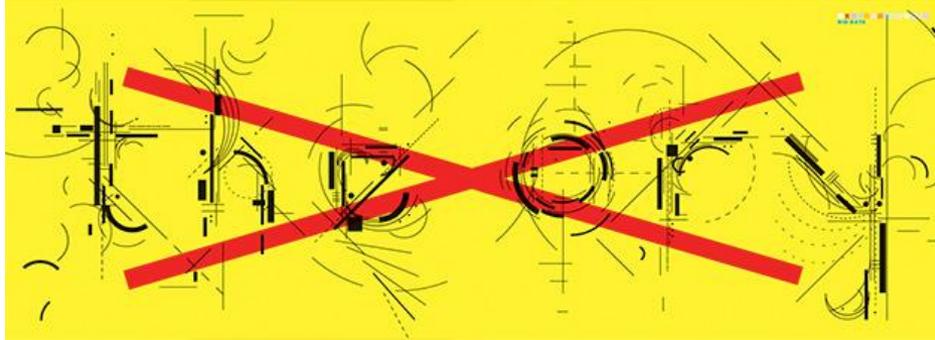
Fallstudie ?

Evidenzbasierte  
Medizin

Big Data ?



# Kausalität vs. Korrelation



© Wired Magazine

“All models are wrong, but some are useful.”

*George Box, Statistiker, University of Wisconsin, 1978*

“All models are wrong, and increasingly you can succeed without them.”

*Peter Norvig, Director of Research, Google Inc., 2008*

“Correlation supersedes causation, and science can advance even without coherent models, unified theories, or really any mechanistic explanation at all.”

*Chris Anderson, Chief Editor, Wired Magazine, 2008<sup>14</sup>*

# Kausalität vs. Korrelation

Vergleich der Medikamente  $M_1, \dots, M_n$   
zur Behandlung einer Krankheit

Big-Data-Analyse:

$M_5$  hat die höchste Korrelation mit Behandlungserfolg

  ~~$M_5$  ist das Medikament der Wahl~~

**Confounders:** Schweregrad der Krankheit,  
nationale Besonderheiten, sozialer Status, Preis der  
Medikamente, Subtyp der Krankheit,  
Vor/Begleiterkrankungen, Vorlieben der Ärzte,...

# Kausalität vs. Korrelation

“Most studies in the health sciences aim to answer causal rather than associative questions.”

*Pearl J (2010) Causal Inference 6: 1-59*



# Kausalität vs. Korrelation

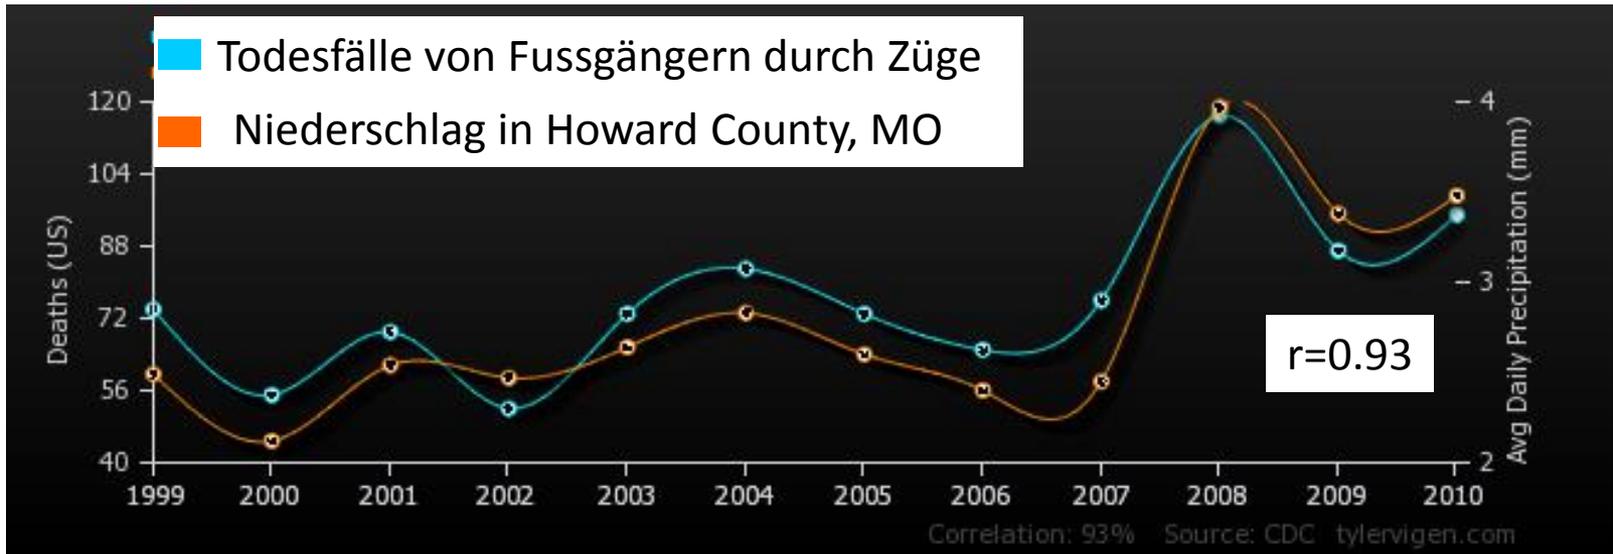
- **Assoziation:** aus den Daten allein zu berechnen  
Korrelation, Regression, Odds Ratio,  
Adjustierung
- **Kausalität:** Annahmen außerhalb der Daten  
Randomisierung, Einfluss, Effekt, Confounding,  
Intervention

# Von big data zu good data

- Ergebnisse von Big-Data-Analysen sind explorativ
- Bestätigung durch klinische Studien nötig
  - Randomisierte klinische Studien (Goldstandard)
  - Sinnvolle Fallzahl, sinnvolle Stichprobe
  - Definierte primäre/sekundäre Zielgrößen
- “To use big data in medicine, the results obtained from the analysis of big data should be validated by clinical studies.”

# Fazit

- Big data in der Medizin benötigt qualitativ hochwertige, reichhaltige und umfangreiche Patientenkollektive
- Exzellenter Datenschutz ist ethisch und für die Akzeptanz unabdingbar
- Big-Data-Analysen können kontrollierte klinische Studien ergänzen, aber niemals ersetzen



**Vielen Dank für Ihre Aufmerksamkeit!**