

Giver store data og data science nye (u)muligheder i samfundsvidenskaben?

David Dreyer Lassen*

Økonomisk Institut &
SODAS - Center for Social Data Science

SAMF
Københavns Universitet

VIVE
4. maj 2018

* med: Ulf Aslak, Sebastian Barfort, Andreas Bjerre-Nielsen, Kelton Minor, Sune Lehmann, Hjalmar Bang Carlsen, Snorre Ralund, Robert Klemmensen m.fl.



Google Trends

Sammenlign



"data science"

Søgeterm



econometrics

Søgeterm



"big data"

Søgeterm



Tilføj sammenligning

Hele verden ▼

01/01/2010 - 18/03/2018 ▼


Alle kategorier ▼

Websøgning ▼

Interesse over tid



Gennemsnit



● "data science"
Søgeterm

● econometrics
Søgeterm



● "big data"
Søgeterm

● "machine learning"
Søgeterm



Hele verden ▾ 01/01/2010 - 18/03/2018 ▾ Alle kategorier ▾ Websøgning ▾

Interesse over tid ⓘ



“By almost any market test, economics is the premier social science”

“The starting point in economic theory is that the individual or the firm is maximizing something [...] The emphasis on maximization is important because it allows an analyst to make predictions in new situations. [...] Other social sciences that are unwilling to assume maximization are in the position of being unable to predict in new situations.”

Lazear (2000, QJE): Economic Imperialism.

"All models are wrong, but some are useful" (Box, 1976)

"The End of Theory: The Data Deluge Makes the Scientific Method Obsolete "

Chris Anderson, *Wired*, 2008

- Traditionel tilgang: Regelbaseret, bl.a. introspektion, teori - deduktiv
- Ny tilgang (machine learning): Lær regler fra træningsdata - induktiv


Datarevolutionen: (data)udbud skaber sin egen (metode)efterspørgsel

Datakilder:


Tidligere: survey, registerdata - analog -> digital administrative data, valideret og processeret centralt. Meget data i økonomi 'andenhåndsdata' - men valideret.

Nu: digitale data fra social medier, transaktioner, smartphones, web-scrapings. Førstehåndsdata - ofte ikke-valideret. Data i hænderne på dem, der frembringer dem.

Nogle gange handler data bare om at tælle: En af de vigtigste figurer i de seneste 10 års økonomiske debat



Noget gange skal man have noget at tælle først: Uber



Road map

- Hvad er 'big data' og 'data science'?
- Hvad betyder data science for
 - måling og inferens - "økonometri"/"metode"
 - teori - nye aktører, nye ting der kan testes
 - politik
- AI / robotter / 4. industrielle revolution, arbejdsmarked
- Privacy / persondataforordningen etc.

Hvad betyder 'big data' egentlig?

- Oprindeligt: data som er for stort til at kunne håndteres i nuværende software
- fokus på
 - Volume (size: no. of obs, Gigabytes)
 - Variety/complexity (incl. text, pictures, sound etc)
 - Velocity (often high frequency)
 - Veracity ('honest signals', behavior)
- Ikke klar skillelinje: Registerdata benævnes ofte 'big data'

Hvad betyder 'data science' egentlig?

Data science

From Wikipedia, the free encyclopedia

Not to be confused with [information science](#).

Data science, also known as **data-driven science**, is an interdisciplinary field of scientific methods, processes, algorithms and systems to extract [knowledge](#) or insights from [data](#) in various forms, either structured or unstructured,^{[1][2]} similar to [data mining](#).

Data science is a "concept to unify statistics, data analysis, machine learning and their related methods" in order to "understand and analyze actual phenomena" with data.^[3] It employs techniques and theories drawn from many fields within the broad areas of [mathematics](#), [statistics](#), [information science](#), and [computer science](#), in particular from the subdomains of [machine learning](#), [classification](#), [cluster analysis](#), [uncertainty quantification](#), [computational science](#), [data mining](#), [databases](#), and [visualization](#).

[Turing award](#) winner [Jim Gray](#) imagined data science as a "fourth paradigm" of science ([empirical](#), [theoretical](#), computational and now data-driven) and asserted that "everything about science is changing because of the impact of information technology" and the [data deluge](#).^{[4][5]}

When [Harvard Business Review](#) called it "The Sexiest Job of the 21st Century"^[6] the term became a [buzzword](#), and is now often applied to [business analytics](#),^[7] or even arbitrary use of data, or used as a sexed-up term for statistics.^[8] While many university programs now offer a data science degree, there exists no consensus on a definition or curriculum contents.^[7] Because of the current popularity of this term, there are many "advocacy efforts" surrounding it.^[9]

data science vs. social science!
eller
data science + social science?

- “Økonomi er for vigtigt til at overlade til økonomer”
“Sociologi er for vigtigt til at overlade til sociologer”
...
- Er data science for vigtigt til at overlade til
ingeniører og dataloger?
“Det er jo bare prediktion ...”

Er prediktion vigtigt?

- hvem bliver udsatte børn?
- hvilke finansielle transaktioner er hvidvask?
- hvem reagerer på skatteændringer?
- hvem kan betale lån tilbage?
- hvilke iværksættere får succes?
- ...

data science vs. social science!

eller

data science + social science?

- “Økonomi er for vigtigt til at overlade til økonomer”
“Sociologi er for vigtigt til at overlade til sociologer”
...
- Er data science for vigtigt til at overlade til ingeniører og dataloger?
“Det er jo bare prediktion ...”
- Sammenlign med statistik vs. sociologisk metode og økonometri eller economic man vs. behavioural economics

data science vs. social science!
eller
data science + social science?

Metoder

Videnskab

Dataficering

data science vs. social science! eller data science + social science?

Metoder:

- Machine learning, neurale netværk, deep learning, AI -> prediktionsmodeller,
- datareduktion, dataindhentning
- tekstanalyse, “kvantificering” af lyd, billeder; “kvalificering” af “kvantificering”

Machine learning

- Supervised machine learning
 - $\approx$ regression, logit $\rightarrow$ kender y-variabel
 - Mange metoder: Lasso, random forests etc
 - Træner model - cross-validation, model averaging
- Unsupervised machine learning
 - kender ikke mønstre, bruges til kategorisering,
 $\approx$ faktoranalyse, typologier

$$y = \alpha + \beta x + \varepsilon$$

- Fokus i traditionel samf: $\hat{\beta}$ 
- Fokus i ML og prediktion mere generelt: $\hat{y}$ 
- Helt afgørende: metoder der minimerer bias i estimation af $\hat{\beta}$ vil typisk IKKE minimere varians i estimation af $\hat{y}$
- Trade-off mellem bias og varians

data science vs. social science! eller data science + social science?

- Videnskab
 - Kausalitet / hypotesetest vs prediktion
 - Variabelkonstruktion
 - Aktører: AI og rationalitet
- Dataficering
 - Lovgivning, etik, politik

Eksempel:

Selektion og prediktion

- Kleinberg et al. 2018: Beslutninger om varetægtsfængsling i USA.
- Dommer: skal **prediktere** om anklagede vil dukke op til retssag (og i øvrigt begå ny kriminalitet)
- Eks på problem: observerer kun outcome, hvis ikke varetægtsfængsling
- Her: naturligt eksperiment kombineret med prediktiv algoritme

Kausalitet eller prediktion?

- Simpelt eksempel: Deltagelse og karakterer på uni
- Konstruerer variable for tilstedeværelse baseret på smartphones (selvrapport vs lokation ifht skema vs lokation ifht gruppe)
- Kommer til timer hvis følelse af at få noget ud af det vs. kommer til timer og får faktisk noget ud af det
- Eksempel fra Datalogi: Håndholdt frafaldstjek
- Her: identificerer at-risk personer -> fokus årsager

Social Fabric / Sensible DTU Copenhagen Network Study

- Fulgte ca. 1000 DTU-studerende via smartphones over 1-1.5 år
- Højfrekvente målinger ($5\text{ s} < < 5\text{ min}$) af GPS, bluetooth, wifi, SMS, tlf, FB, skærmbørøring
- Dynamiske netværk, peer effects (randomisering), sortering
- Her: kender skema, estimer hvorvidt faktisk undervisning




Fig 5. Change in class attendance over a single semester. a) Trends of attendance observed in the three performer groups: low (red circles), moderate (green diamonds) and high performers (blue pentagons), according to the Danish grading system. Inset shows the distribution of slopes measured for each pairs of data point in the trends. b) Mean attendance measured among the contacts of the students based on exchanged text messages.





<https://doi.org/10.1371/journal.pone.0187078.g005>

Eksempel: Peer effects

- Er der peer effects? hvordan virker de? hvorfor (ikke)? Kan man sammensætte grupper og hvad med compliance?
Litteratur peger i alle retninger (Carrell et al; Angrist)
- Hypoteser: Nogle grupper “virker”, andre “virker ikke” -> effekt = 0? Peer effects kan være forskellige ifht kontekst og outcomes (studievenner -> karakterer eller fredagsbarvenner-> sundhedsoutcomes)

Eksempel: Peer effects

- Metode:
 - Trin 1: Randomiser studerende ind i 'vektorgrupper'
 - Trin 2: Hvilke faktorer gør at grupper 'virker' - og hvordan måler man 'virker'?
 - Trin 3: Estimer peer effects i forskellige dimensioner udfra 'kontakt'
- Møder in {IRL, sms, tlf, FB}. Fokus her på 3 mio møder IRL over 3 måneder



Bjerre-Nielsen, Harmon, Lassen. 2018. "Effective Peer Effects."
 Aslak, Bjerre-Nielsen, Lassen. 2018.

Eksempel: Peer effects

- Foreløbige resultater: Gruppeinddeling (first stage) virker
- Tegn på dynamisk sortering på karakterer
- Peer effects?


datakonstruktion

1. objekt (teori, politik)
2. Dataindsamling: feasibility (jura, etik, (programmerings-) evner, samarbejde, tid), omkostninger
3. Data-rensning: hvad er objekt, hvad er outliers og fejl (perspektiv: Latour, Pandora's Hope)
4. Variabelkonstruktion, undertiden probabilistisk
5. Validering
6. Analyse

Eksempel: Transportadfærd

- Hvordan transporterer folk sig?
 - Anonyme tællere - ingen individdata (incidens?)
 - Transportsurveys - upræcise, for små?
 - Registerdata om ejerskab af bil - men ikke om brug; potentielt rejsekortdata
 - Automatiseret via smartphones

Eksempel: Transportadfærd



Merged Location

PROJECT 1

By mapping all of the streetside Wi-Fi router locations across Copenhagen we improved the temporal resolution of the location data.



Merged Location

PROJECT 1

By mapping all of the streetside Wi-Fi router locations across Copenhagen we improved the temporal resolution of the location data.



Eksempel: Transportadfærd

- Mål: at inferere transport-type alene fra mobildata
- Hvordan infereres transport-type?
- Supervised ML kræver 'labeled data'

korrespondance mellem 'ground truth' og
mobilsignal, detaljeret mobil-rejse-dagbog ->
træningsdata


Machine Learning

PROJECT 1

Classification

Identify how many of these trips were taken on a bus

■ = 1 trip




Machine Learning

PROJECT 1

Classification

Identify how many of these trips were taken on a bus




Machine Learning

PROJECT 1

Classification

Identify how many of these trips were taken on a bus

●──●
relevant items




Machine Learning

PROJECT 1

Classification

Identify how many of these trips were taken on a bus






Machine Learning

PROJECT
1

Precision - Exactness

how many selected items are relevant?






Machine Learning

PROJECT
1

Recall - Completeness

how many relevant items are selected?



Eksempel: Transportadfærd

- $F1$ = “gennemsnit” af precision og recall
- Rugbrødsmotor vs. ikke-rugbrød: $F1 = 0.89$
- Lige nu:
 - Ekstremt vejr og transport - Klimaforandringer og adfærd
 - Real-tid app til cykling m Københavns Kommune

(mere kompliceret) eksempel: Den offentlige samtale

- Hvordan udvikler 'stemningen' i Danmark sig?
- Kan man måle sammenhængskraft over tid?
- Samarbejde: SODAS + Kraka
- Data: 45 mio. opslag fra 153K forskellige Facebook-sider med 300 mio kommentarer fra mere end 3,5 mio danskere 2008-17
- Idé: måle åben debat vs grøftegravning på SoMe
- Fx: Hvad betyder flygtningekrisen?

(mere kompliceret) eksempel: Den offentlige samtale

- egentlig kvalitativ metode: forsker vurderer 'tone' (fx imødekommende, aggressiv, hånende, indifferent) i indlæg i FB-debat
 - men der er > 300 mio kommentarer ...
- Koder fx 60,000 kommentarer i hånden -> træner model der relaterer kombinationer af ord til tone
- Kører model på hele datasættet ...

Fagre nye verden I

- “Gladsaxe-modellen”
- Predikter udsatte børn vha “registersamkøring”, fx arbejdsmarkedstilknytning, tandlægebesøg etc.
 - Offentlig administration kræver tilladelse
 - Forskning: Kan lave model/algoritme t kommunalt plug-in
- Gladsaxe: “Målet helliger midlet.” Datadagsorden får praktikere til at tænke over hvad man kan gøre med data
- Problemer: Politik, Etik

Fagre nye verden II

- “Glagsaxe-modellen”
- Hvor meget i en sådan risikomodel foregår allerede?
 - indberetninger fra skolelærere, sociale myndigheder
- Algoritmer
 - Positivt: horisontal lighed, alle underlægges samme model
 - Negativt: Neurale netværk, AI uigennemskuelige
- DK: skøn vs. regel

Fagre nye verden III

- “Gladsaxe-modellen”
- Er algoritmer biased?
 - Hvis model trænes på biased data (eks: race i USA) kan prediktioner være biased imod særlige karakteristika
 - Men: Ex fra USA om beslutning om varetægtsfængsling finder at algoritmiske beslutninger reducerer kriminalitet, antal indsatte - *og bias mod minoriteter*
 - Kleinberg et al. QJE 2018: kombination af SAMF (selektion, counterfactuals) og ML nødvendig

Uddannelse

- *Social Data Science* (> 350 studerende)
 - 2015-6: Sebastian Barfort, David; 2017-8: Andreas, David, Snorre Ralund
- *Topics in Social Data Science*
 - 2018: Andreas, Snorre, Ulf Aslak
- ML som del af *Advanced Microeconometrics*
- Specialer: Mærsk, Danske Bank, Finansiell Stabilitet, Chr. Hansen, Zetland, Kbh Politi
- Andre steder (eksempler)
 - Harvard 2018: *The Econometrics of Machine Learning (and other 'Big Data' Techniques)*
 - Coursera
 - MIT 2018- uddannelse i *Computer Science and Economics*

Uddannelse

- *Social Data Science (Avisen DK)*
 - 2015-6: Sebastian Ralund
- *Topics in Social Data*
 - 2018: Andreas, Sørensen
- ML som del af *Advanced Data Science*
- Specialer: Mærsk, Data Science
- Andre steder (eksempler)
 - Harvard 2018: *The Big Data Techniques*
 - Coursera
 - MIT 2018- uddannelse



Bottom line

- sociologi, økonomi, psykologi: veletablerede teorirammer til at forstå adfærd -> selektion, endogenitet, ...
- Mere generelt: bud på mekanismer
- Data science: flere ting i værktøjskassen. Tillader
 - test af nye, endnu ikke udviklede sammenhænge
 - test af etablerede, men ikke empirisk undersøgte, sammenhænge
- Data science: gode/bedre bud på prediktion, vigtigt til nye/flere variable, tættere på hvad vi vil måle

Bottom line

- SAMF-forskere gode bud på folk som kan forstå og bruge data science
- Erfaringer fra samarbejder m fysikere, ingeniører:
 - Kræver at begge sider investerer i at forstå de andres metoder
 - Hvis SAMFere ikke er med kører de andre bare videre - uden os
- SODAS: hjælper SAMFere med at hjælpe sig selv ...

Litteratur

- Big Data and Social Science: A Practical Guide to Methods and Tools
- Kleinberg, J., Lakkaraju, H., Leskovic, J., Ludwig, J., & Mullainathan, S. “Human Decisions and Machine Predictions.” NBER Working PaperAbstract w23180.pdf, forthcoming *QJE*.
- Mullainathan and Spiess. “Machine Learning: An Applied Econometric Approach”. *J. of Ec. Perspectives* 2017.
- Social Data Science, UCPH. Available at <https://abjer.github.io/sds/>

Tak!

Synspunkter og kommentarer til
ddl@econ.ku.dk

Slides på
<https://davidddlassen.github.io>

Mere om SODAS på
<http://sodas.ku.dk>