

# Black-Box-Analyse- Methoden

Prof. Dr. Katharina A. Zweig

TU Kaiserslautern

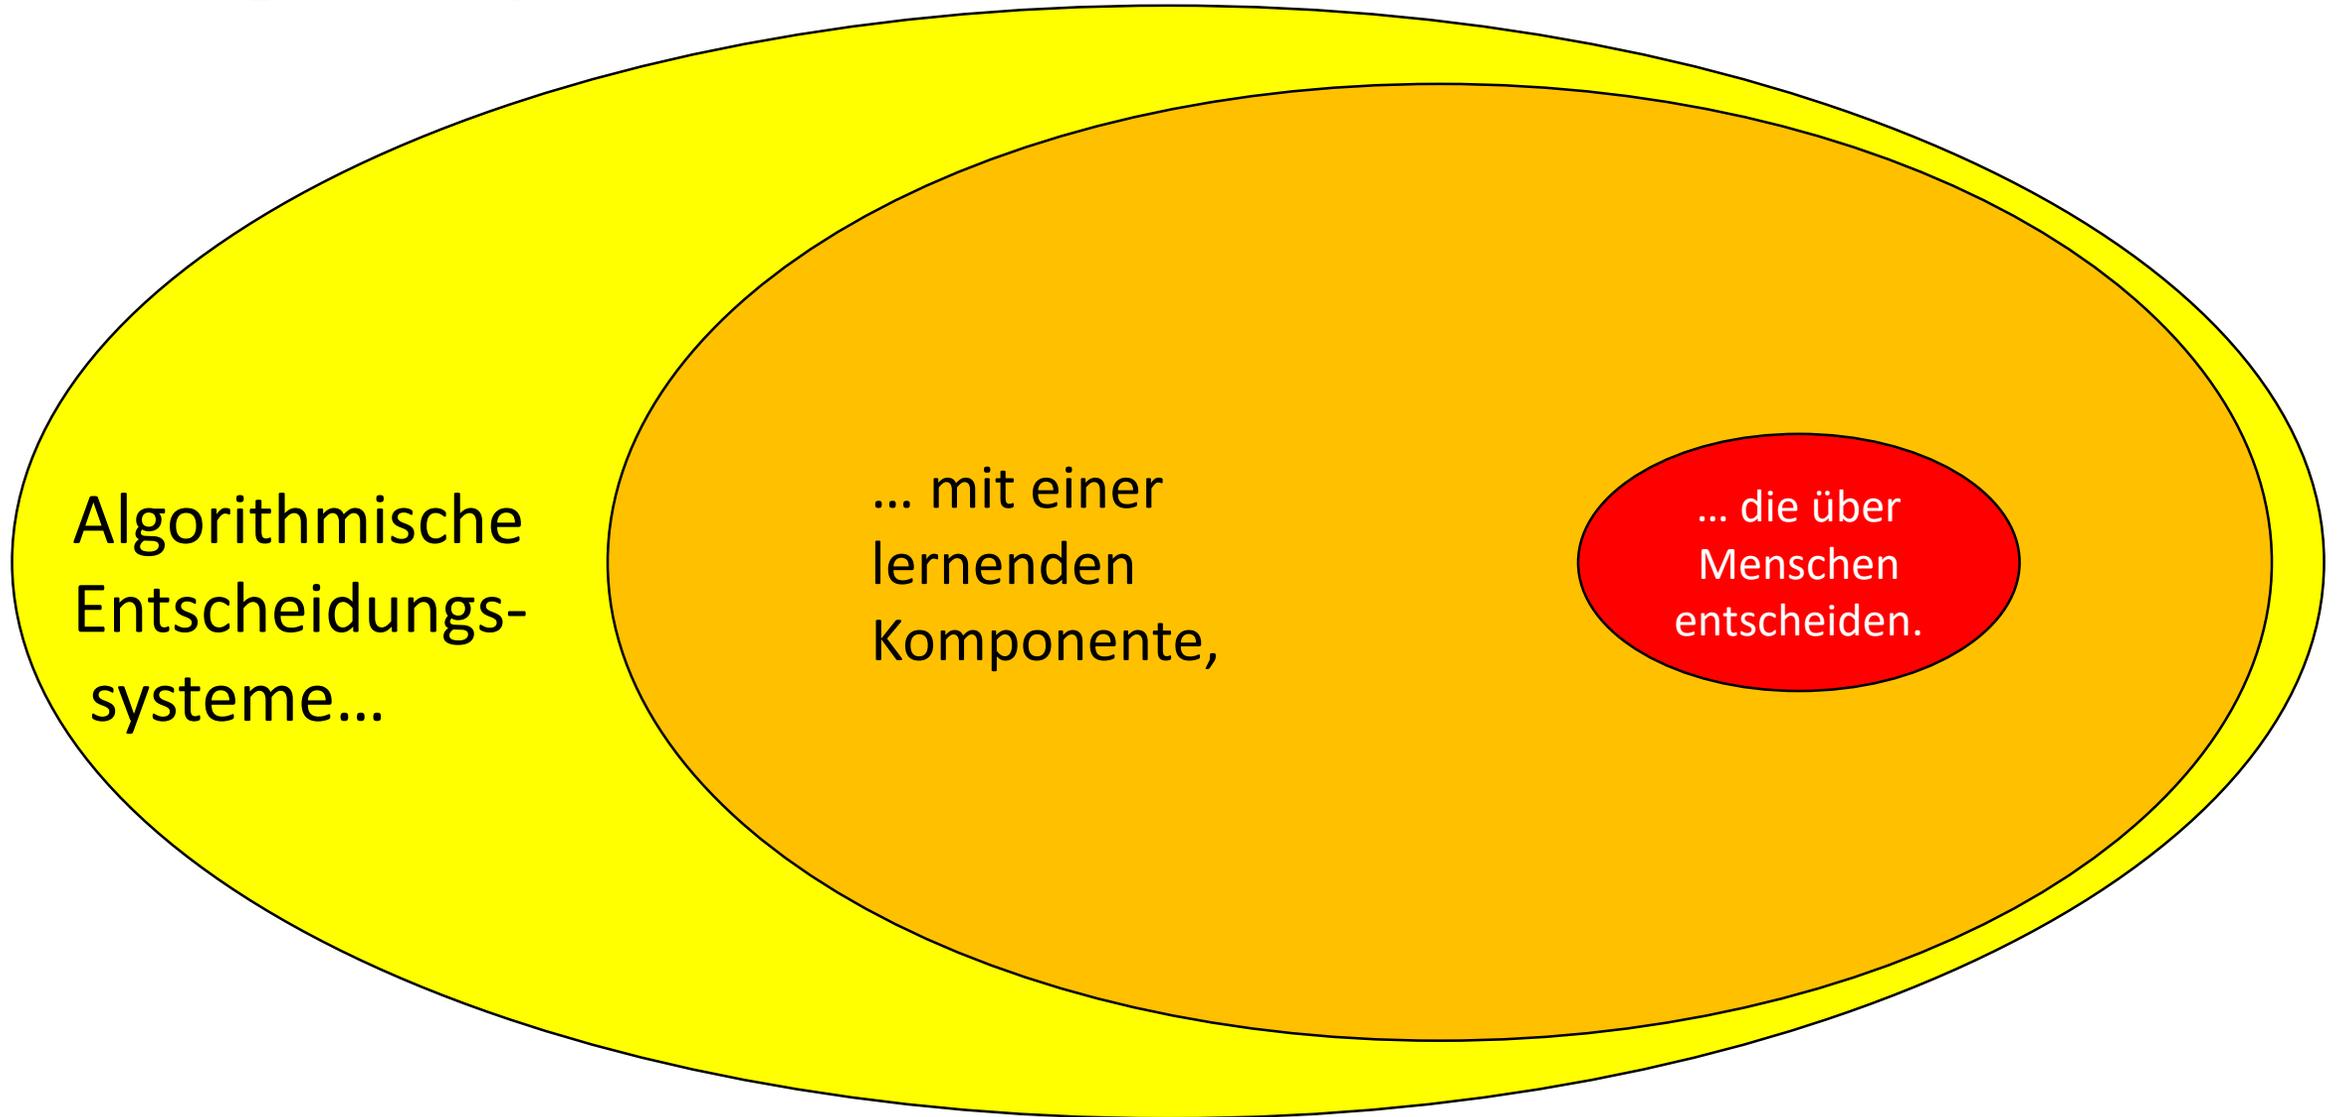


# „Algoskop“

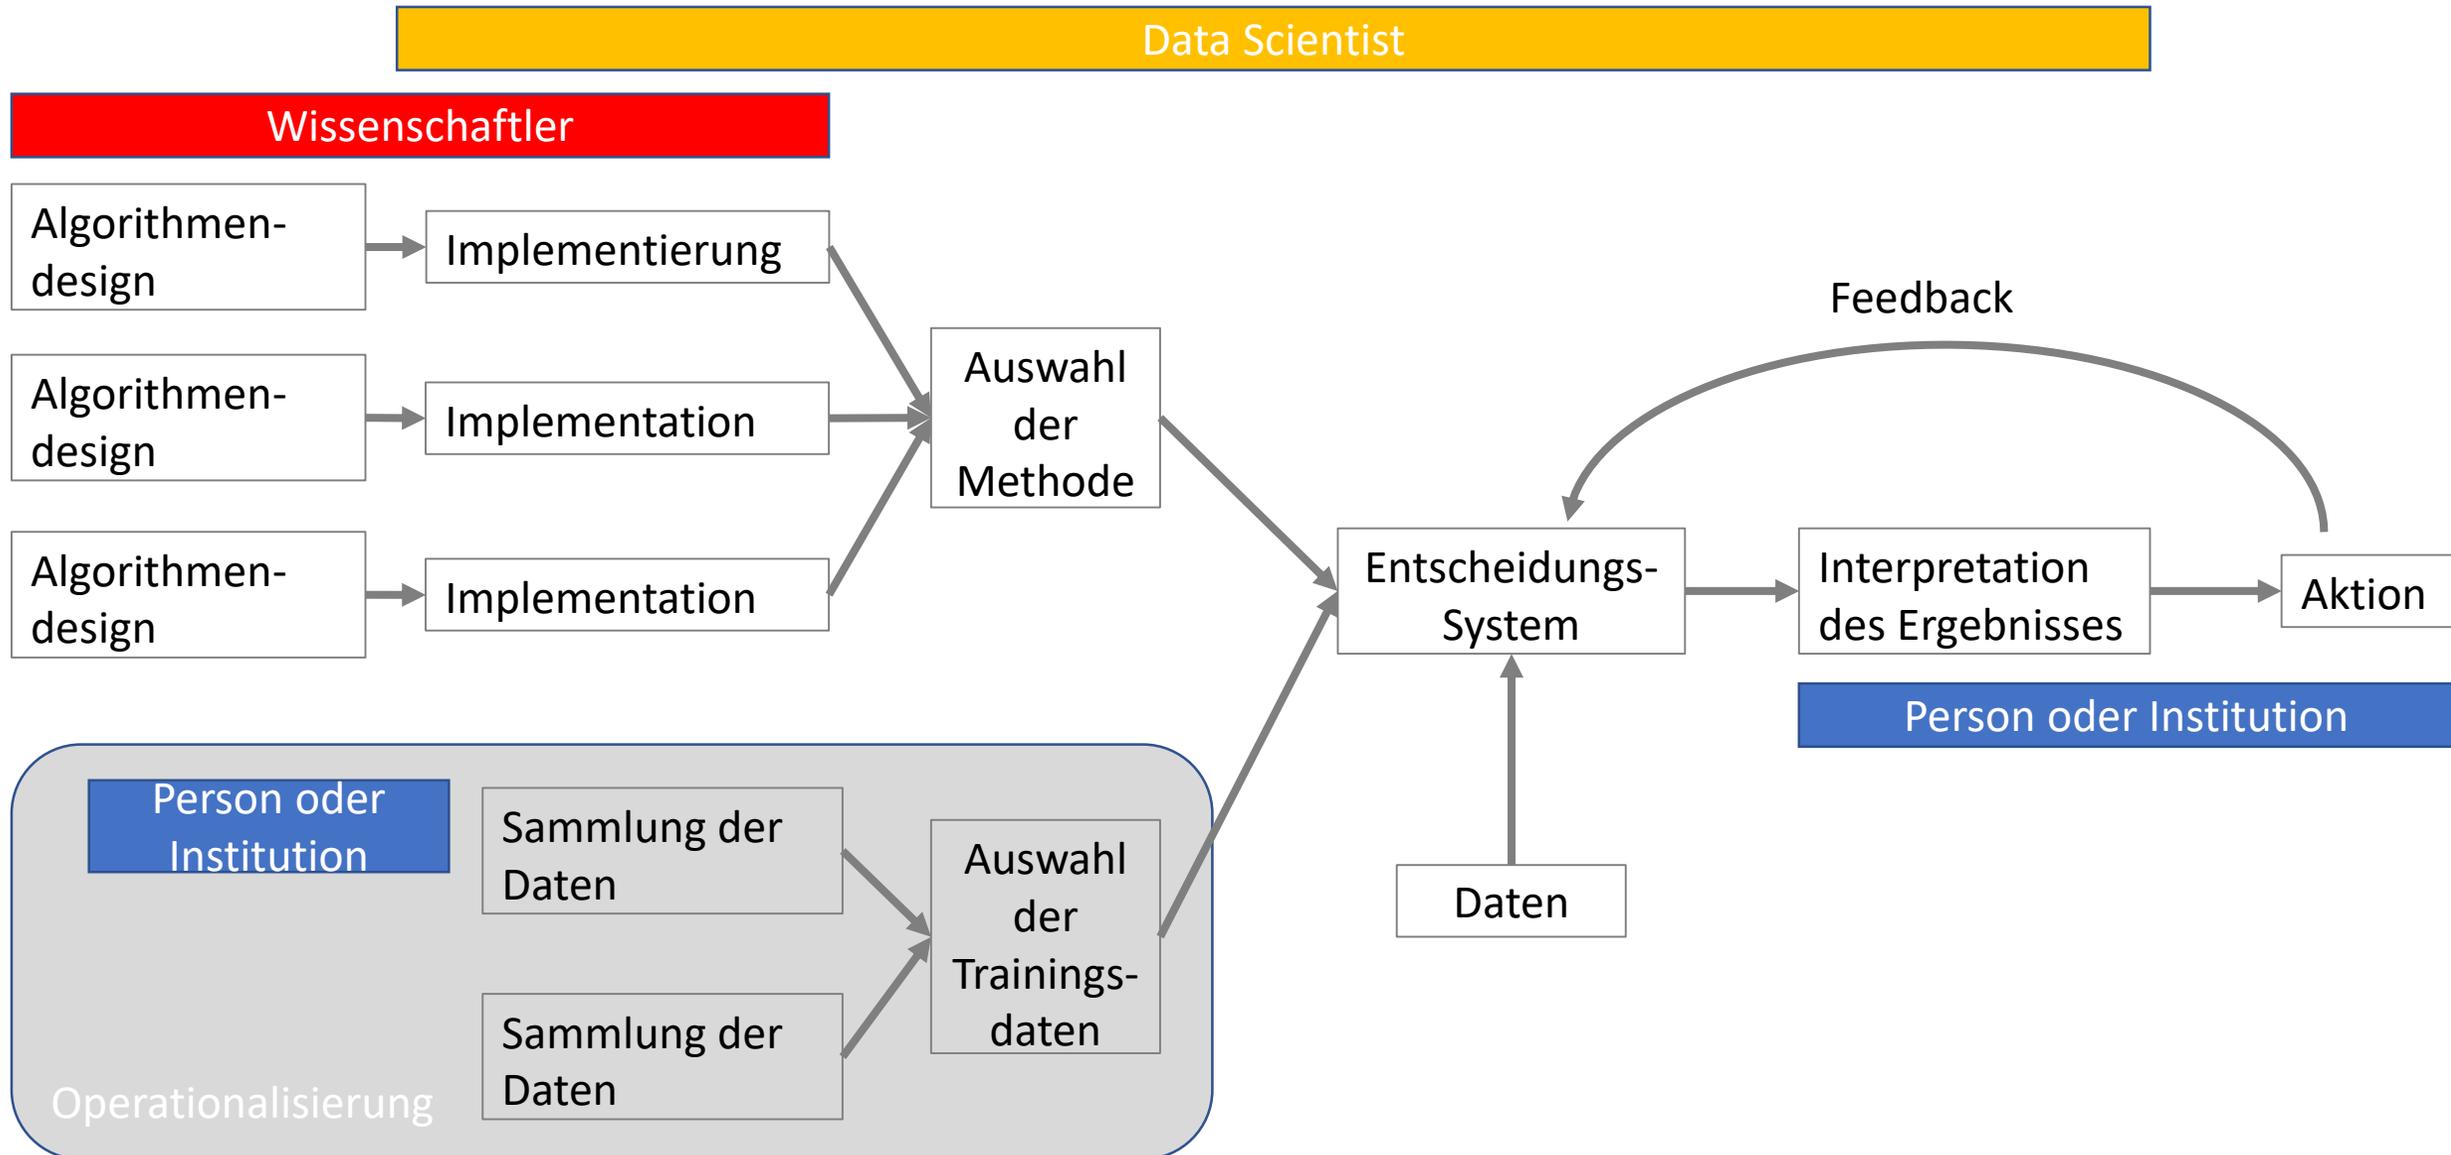
Algorithmische  
Entscheidungs-  
systeme...

... mit einer  
lernenden  
Komponente,

... die über  
Menschen  
entscheiden.



# Lange Kette der Verantwortlichkeiten



# Einordnung auf Risikomatrix

## 1. Schadenstiefe

$$\Sigma \quad \begin{array}{l} \text{Schaden für Individuum(Fehlurteil)} \\ +\text{Schaden für Gesellschaft(Fehlurteil)} \end{array}$$

## 2. Anbietervielzahl, Wechselemöglichkeiten, Möglichkeiten der Anfechtbarkeit, Revisionen durch Menschen, etc.

Viele Anbieter,  
einfacher Wechsel

„Kunden, die dieses  
Produkt kauften,  
kauften auch“

Bewertung von  
Objekten ohne  
direkte  
Auswirkung auf  
Menschen

Kreditscoring

Geringer  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Hoher  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Bewerber  
aussortieren

Arbeitnehmer-  
leistung bewerten

Terroristen-  
identifikation

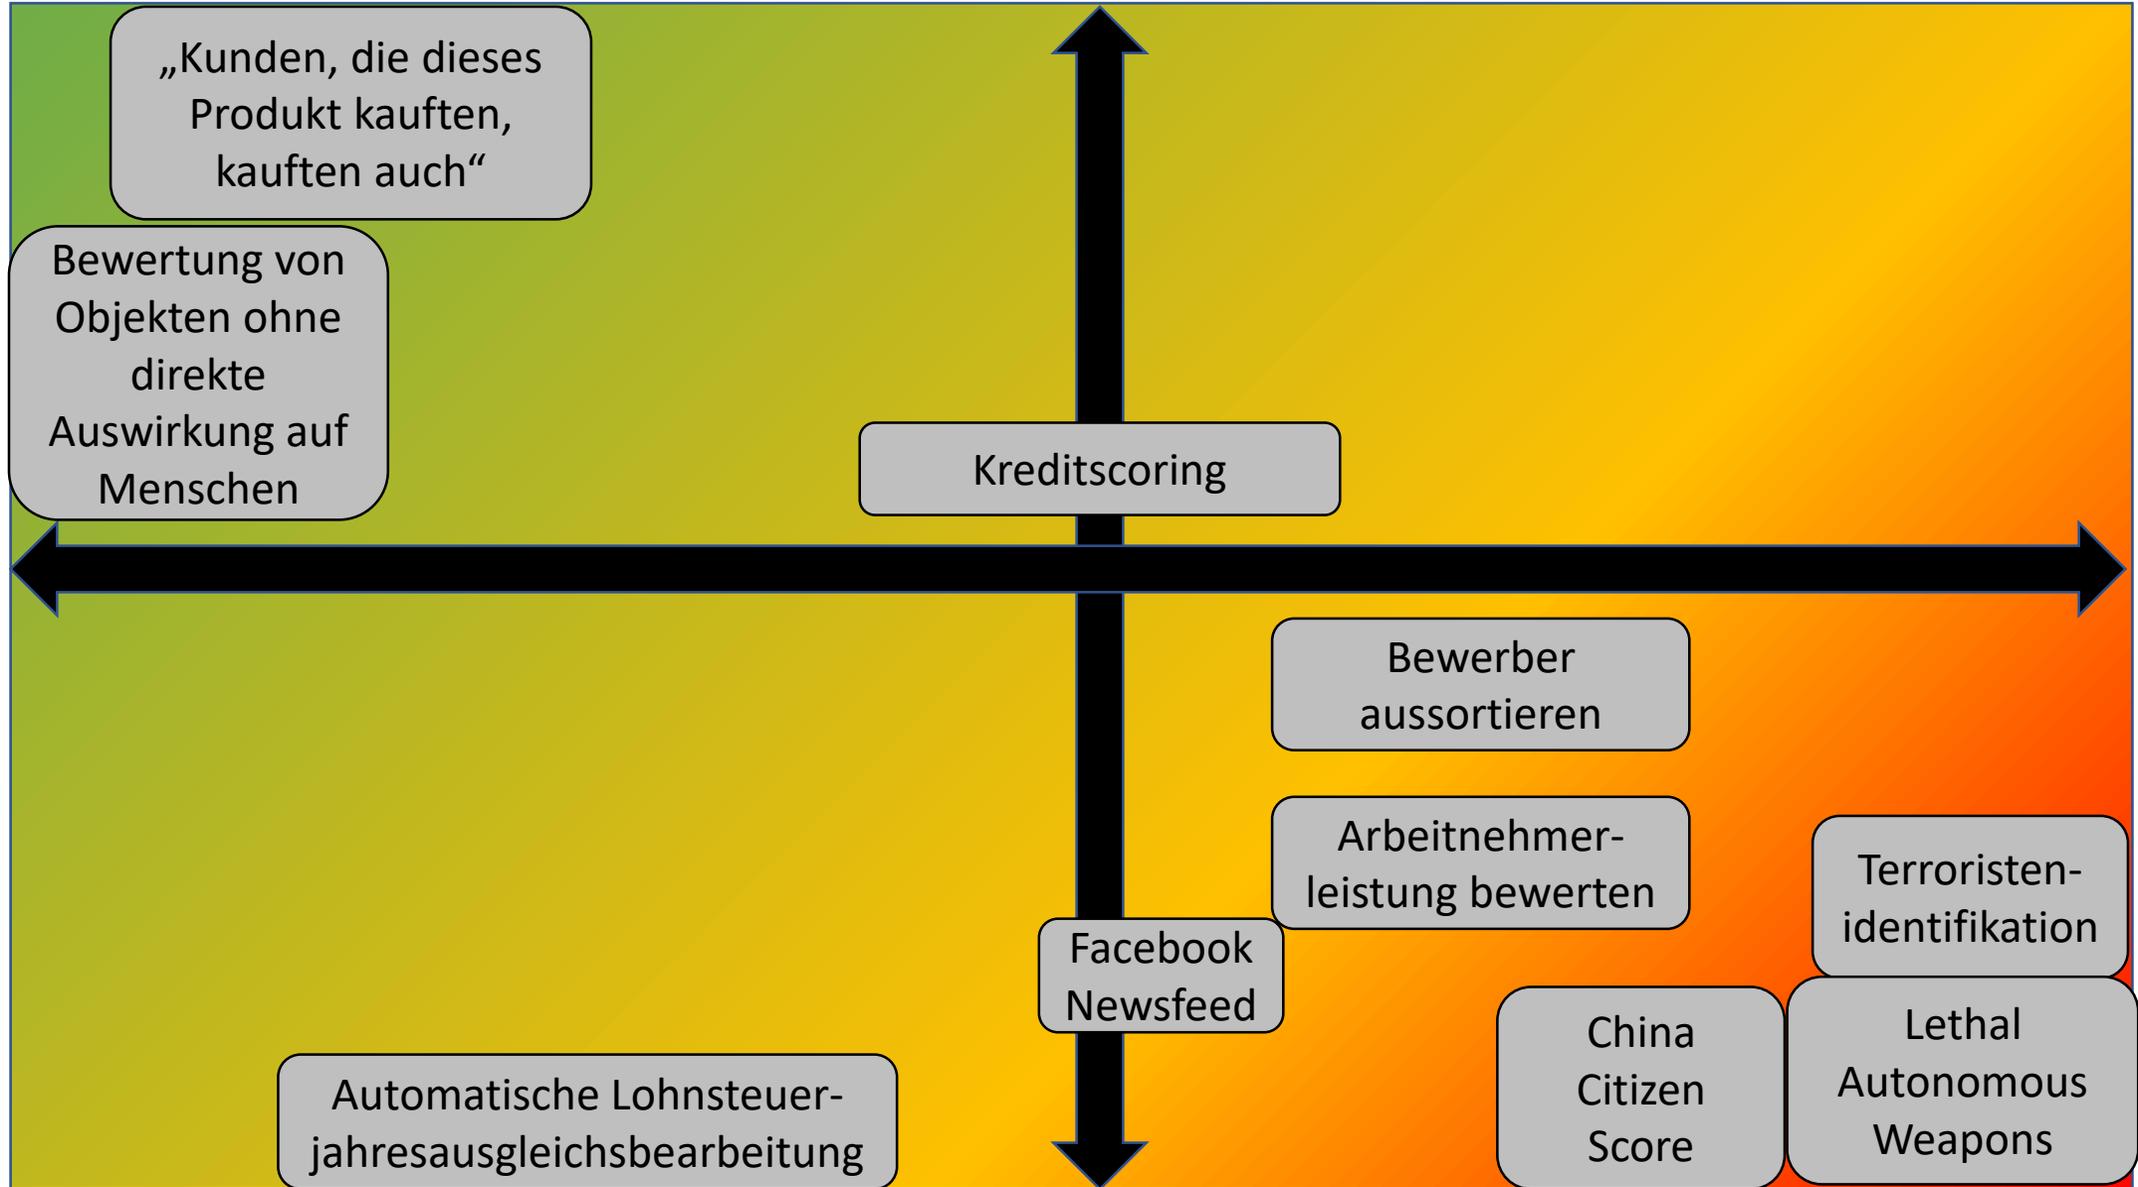
Facebook  
Newsfeed

China  
Citizen  
Score

Lethal  
Autonomous  
Weapons

Automatische Lohnsteuer-  
jahresausgleichsbearbeitung

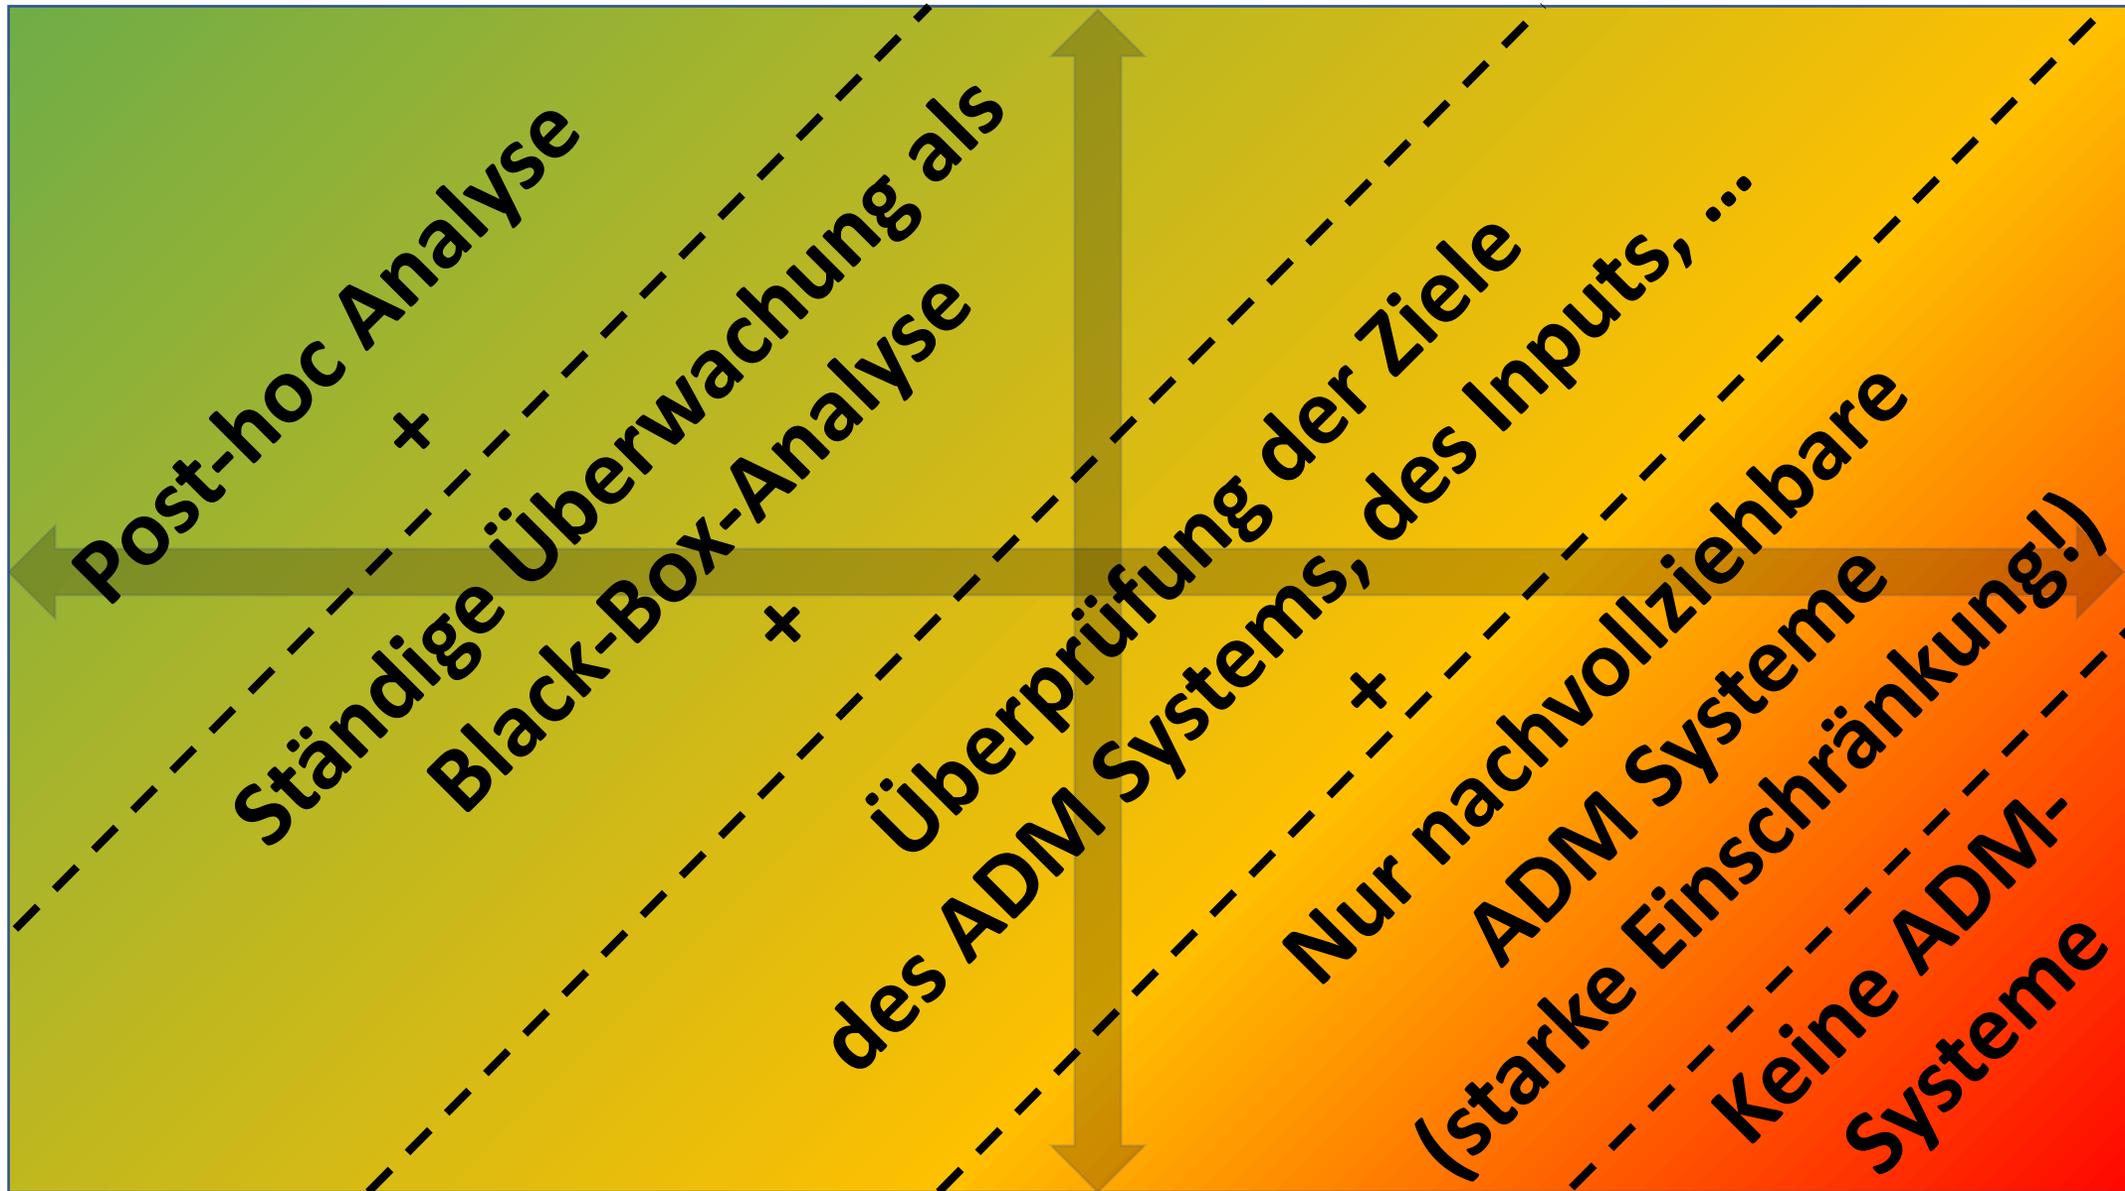
Monopol



Viele Anbieter,  
einfacher Wechsel

Geringer  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Hoher  
Gesamt-  
schaden  
bei Fehl-  
urteilen



Post-hoc Analyse

Ständige Überwachung als  
Black-Box-Analyse

Überprüfung der Ziele  
des ADM Systems, des Inputs, ...

Nur nachvollziehbare  
ADM Systeme  
(starke Einschränkung!)  
Keine ADM-  
Systeme

Monopol



veröffentlicht



Viele Anbieter,  
er Wechsel

Geringer  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Hoher  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Bis 2001

Google  
Suchmaschine

2017:  
Datenspende #btw17

Monopol

# Scott's Search

Egypt

About 350,000,000 results (0.24 seconds)

**Crisis in Egypt**  
Voices in **Egypt** have been muted but will not be silenced. Listen.  
humanrightsfirst.org/Egypt

**Egypt - Wikipedia, the free encyclopedia**  
Egypt officially the Arab Republic of **Egypt**, is a country mainly in North Africa, with the Sinai Peninsula forming a land bridge in Southwest Asia. ...  
Hosni Mubarak - Ancient Egypt - Female genital cutting - History of modern Egypt  
en.wikipedia.org/wiki/Egypt - Cached - Similar

**Egypt News - The Protests of 2011 - The New York Times**  
World news about **Egypt** and the protests of 2011. Breaking news and archival information about its people, politics and economy from The New York Times.  
topics.nytimes.com › World › Countries and Territories - Cached - Similar

**Egypt Travel, Tours, Vacations, Ancient Egypt from Tour Egypt**  
Information for travelers, resources on history, monuments and activities.  
www.touregypt.net/ - Cached - Similar

**News for Egypt**

**Why Lara Logan Was Eager to Return to Egypt**  
1 hour ago  
By Charlotte Triggs AP Lara Logan had already had one troubling experience in **Egypt** before last Friday's "brutal and sustained" sexual assault, ...  
People Magazine - 1658 related articles - Shared by 20+

**In Egypt, renewed hope for gender equality**  
USA Today - 24874 related articles - Shared by 1

**Realtime updates for Egypt (390)**

**Favnt Daily News Favnt News**

# Daniel's Search

Egypt

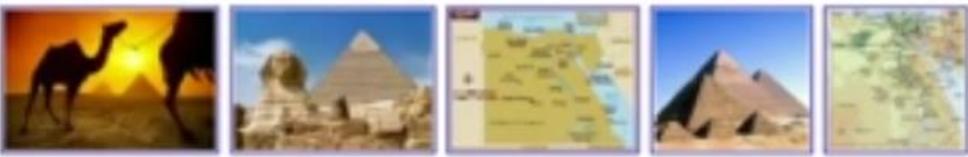
About 321,000,000 results (0.15 seconds)

**Egypt - Wikipedia, the free encyclopedia**  
Egypt officially the Arab Republic of **Egypt**, is a country mainly in North Africa, with the Sinai Peninsula forming a land bridge in Southwest Asia. ...  
Hosni Mubarak - Ancient Egypt - Female genital cutting - History of modern Egypt  
en.wikipedia.org/wiki/Egypt - Cached - Similar

**Egypt Travel, Tours, Vacations, Ancient Egypt from Tour Egypt**  
Information for travelers, resources on history, monuments and activities.  
www.touregypt.net/ - Cached - Similar

**Egypt Daily News, Egypt News**  
Egypt Daily News, covering **Egypt** News, Arab news, Middle East news and World news. Egyptian Guides, egyptian recipes, egyptian food, egyptian airforce, ...  
www.egyptdailynews.com/ - Cached - Similar

**Images for egypt** - Report images



**Egypt - CIA - The World Factbook**  
Feb 1, 2011 ... Features a map and brief descriptions of geography, economy, government, and people.  
https://www.cia.gov/library/publications/the-world.../eg.html - Cached - Similar

**Egypt State Information Service**  
Official government site provides information on the country's government, politics, culture, history, economy and tourism. [Arabic, English, French]



Viele Anbieter,  
einfacher Wechsel



**Merke: Personalisierung von Services  
führt IMMER zur Rechtsverschiebung**

Geringer  
Gesamt-  
schaden  
bei Fehl-  
urteilen

Hoher  
Gesamt-  
schaden  
bei Fehl-  
urteilen

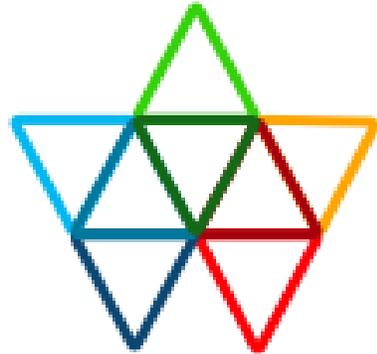
Monopol



# Datenspende: **BTW17**



+



ALGORITHM  
WATCH

+

## Landesmedienanstalten der Länder:

Bayern ([BLM](#))

Berlin und Brandenburg ([mabb](#))

Hessen ([LPR Hessen](#))

Rheinland-Pfalz ([LMK](#))

Saarland ([LMS](#))

Sachsen ([SLM](#))

Medienpartner war [Spiegel Online](#).

## Browserplugin

Zu festen Suchzeitpunkten

- (4, 8, **12, 16, 20**, 24 Uhr)

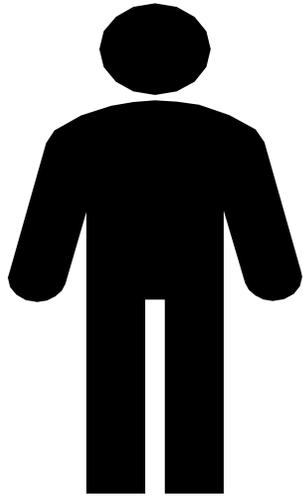
Feste Suchbegriffe:

Personen
Alexander Gauland
Alice Weidel
Angela Merkel
Cem Özdemir
Christian Linder
Dietmar Bartsch
Katrin Göring-Eckhardt
Martin Schulz
Sahra Wagenknecht

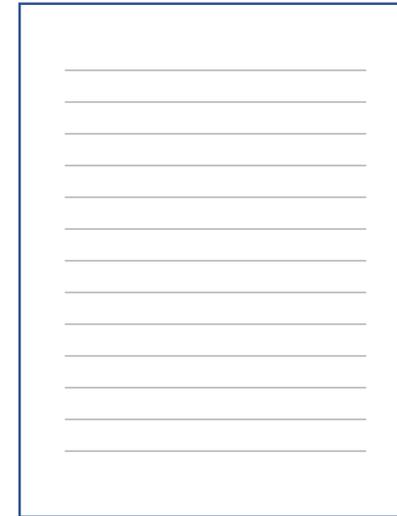
Parteien
AfD
CDU
CSU
Bündnis 90/Die Grünen
Die Linke
FDP
SPD



# Datenspende: BTW17



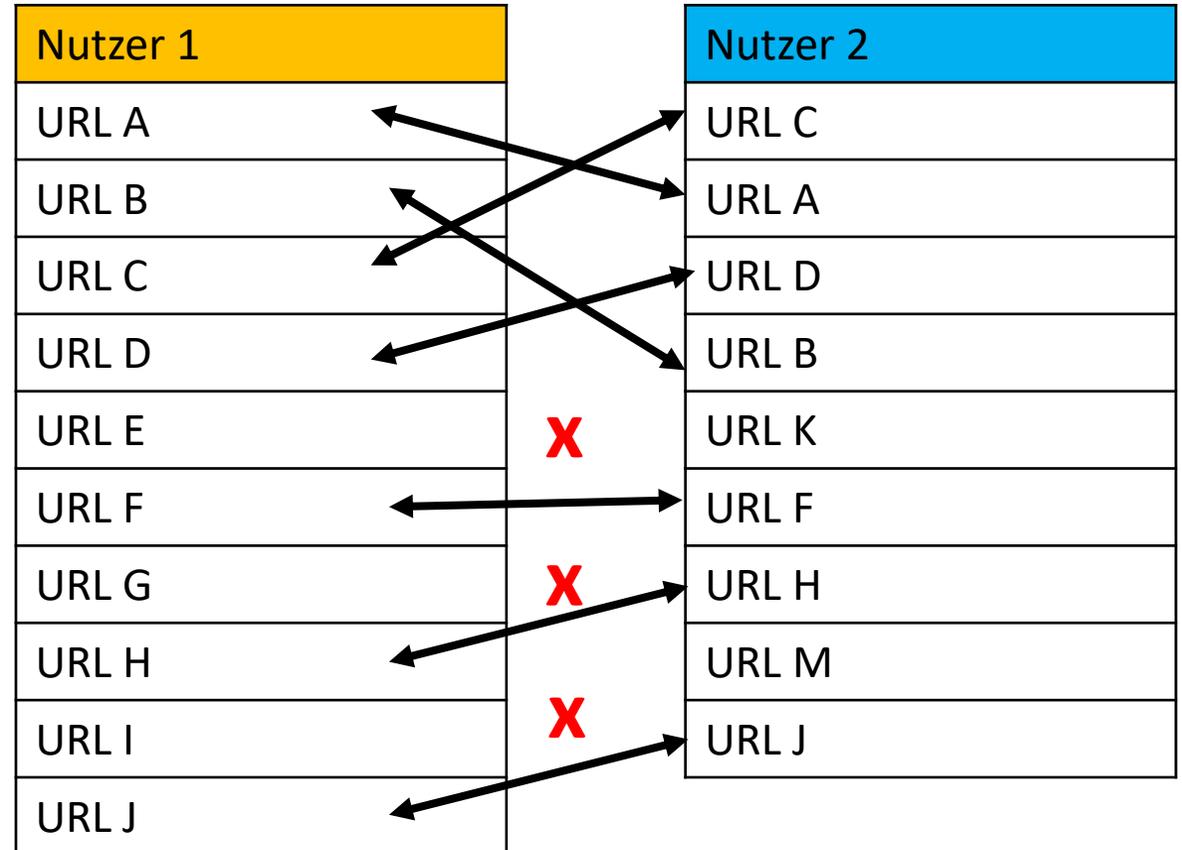
4384 TeilnehmerInnen



5.991.500 (!)  
gespendete  
Ergebnislisten

# Messung der Personalisierung

- Für alle Paare von Nutzern:
  - Bestimme Anzahl nicht-geteilter Links
- Im Beispiel:
  - Nutzer 1 teilt drei URLs nicht mit Nutzer 2
  - Nutzer 2 teilt zwei URLs nicht mit Nutzer 1



# Busted Filterbubble

- Die Grundlage für eine Personalisierung ist weit kleiner als gedacht.
- Bei den Politikern waren im Durchschnitt für je zwei Nutzer **nur 1-2 Links nicht** geteilt von 9-10 Ergebnissen.
- Auf news.google.com sind es 3-4 Links auf 20 Ergebnisse.

## Anzahl nicht geteilter Links

Katrin Göring-Eckardt	<b>0.9</b>
Dietmar Bartsch	<b>1.0</b>
Angela Merkel	<b>1.0</b>
Sahra Wagenknecht	<b>1.1</b>
Cem Özdemir	<b>1.1</b>
Alexander Gauland	<b>1.2</b>
Alice Weidel	<b>1.4</b>
Christian Lindner	<b>1.7</b>
Martin Schulz	<b>1.8</b>

# Busted Filterbubble

- Für **Parteien** gibt es **weniger Überlappung**.
- Webseiten der **Ortsverbände**
- Eher **Regionalisierung**

Durchschnittliche Anzahl nicht-geteilter Links

AfD	2.6
Die Linke	3.1
Bündnis 90/Die Grünen	3.3
CSU	3.4
SPD	3.4
FDP	3.6
CDU	3.7

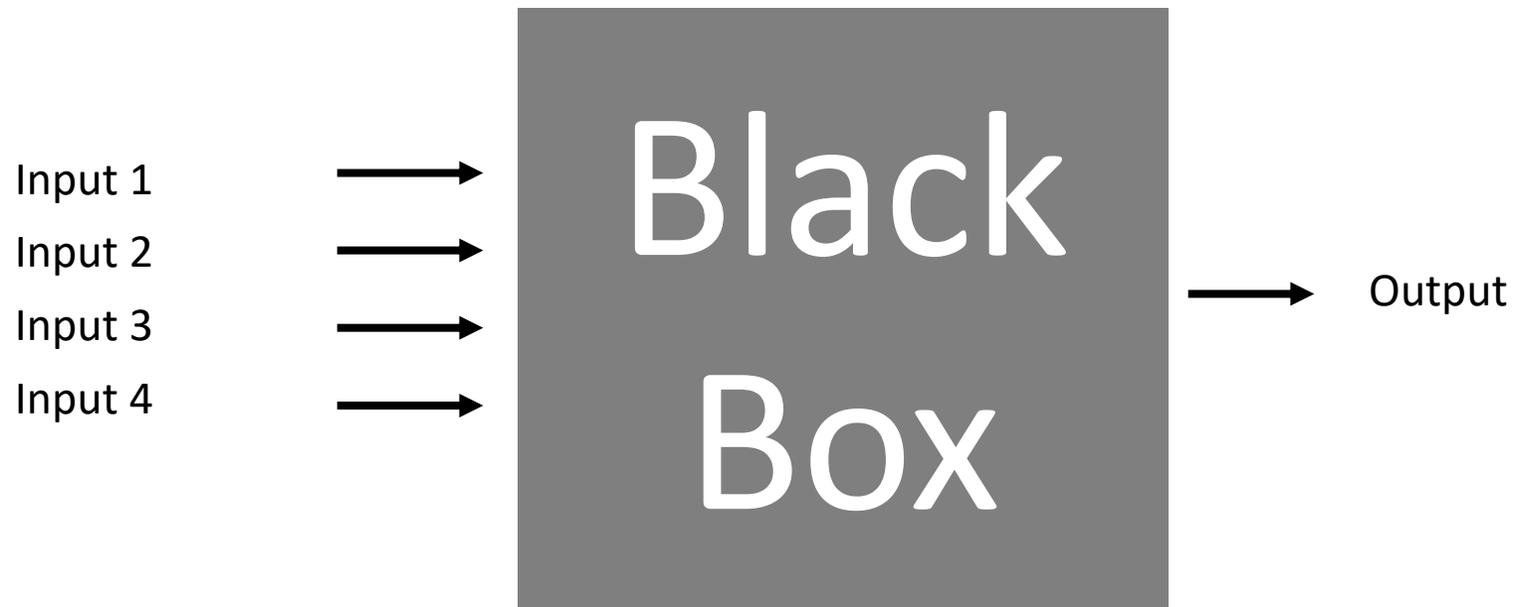
A hand on the left side of the frame holds a thin, silver pin, poised to pierce an orange egg. The egg is the central focus, featuring the multi-colored Google logo (G in blue, O in red, O in yellow, g in blue, l in green, e in red) printed on its surface. The background is a solid, vibrant blue. The lighting is bright, highlighting the texture of the egg and the skin of the hand.

Google



# Black-Box-Methoden

- Variieren systematisch Input und beobachten Output.
- Inferieren Verhältnis zwischen Input und Output.
- Klassische Methodik aus den Naturwissenschaften, aber auch im Softwaretesting etabliert.



Input 1'

Input 2

Input 3

Input 4



Result'

Einstellung 1“

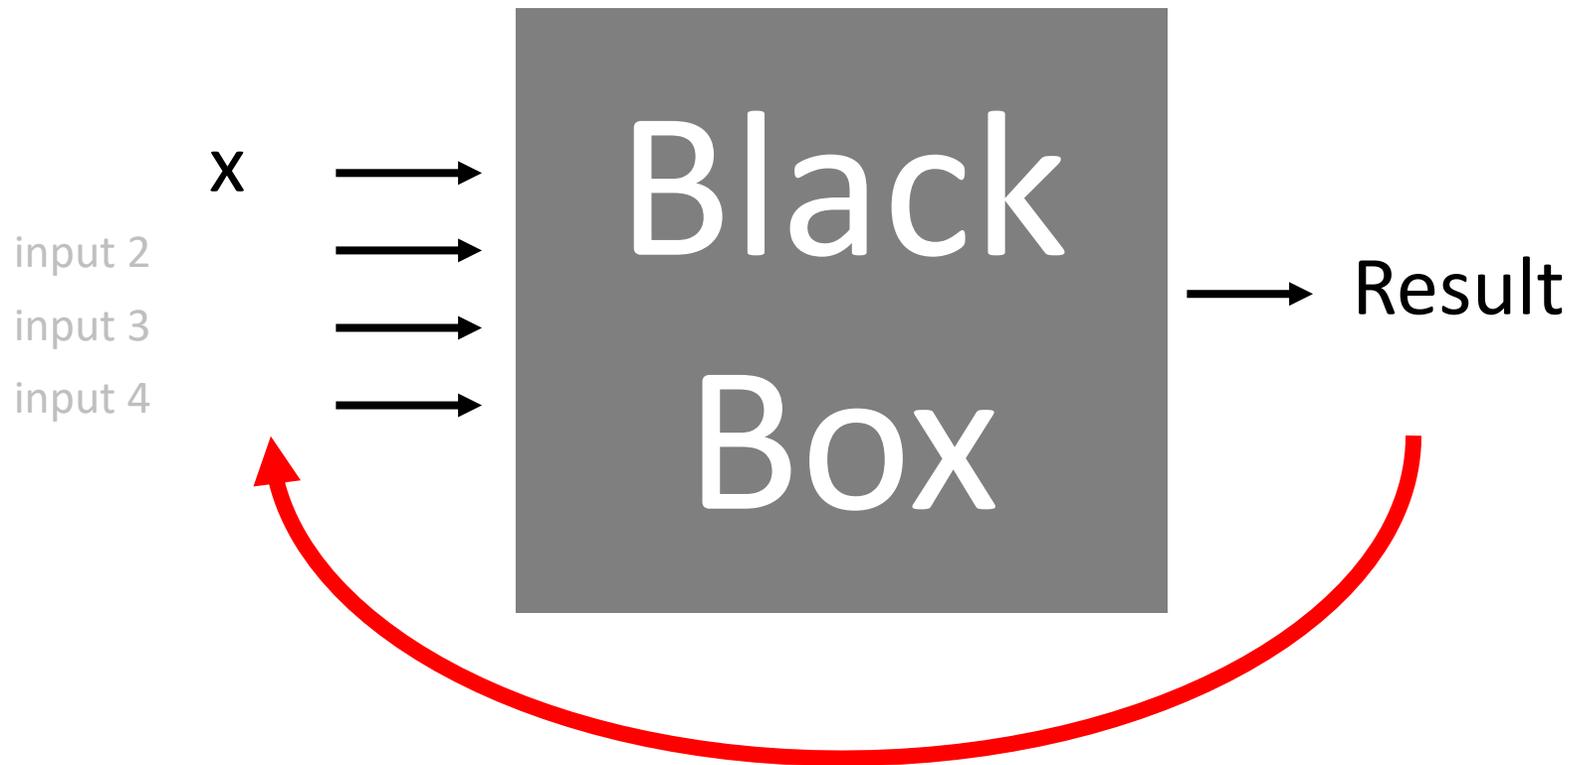
Einstellung 2

Einstellung 3

Einstellung 4



Result“



**Result = Function (x, input 2, input 3, input 4)**

# Was kann damit sonst noch analysiert werden?

- Test auf Diskriminierung im Sinne von „*disparate impact*“ (siehe Prof. Basts Vortrag).
  - Geringerer Durchschnittslohn von Jobanzeigen für Frauen als für Männer<sup>1</sup>.
  - Rückfälligkeitsvorhersage Kriminelle im COMPAS Algorithmus, der vor Gericht verwendet wird<sup>2</sup>.
  - Diskriminierende Werbeanzeigen bei Personensuche mit Namen afroamerikanischen Ursprungs<sup>3</sup>.
  - Test auf Diskriminierung bei durch AI unterstütztem Bewerbungsprozess denkbar.
- Test auf Medienvielfalt, Verbreitung illegalen Contents, Überprüfung Netz-DG: z.B. Anteil Löschungsgrad.
- Test auf Personalisierungsausmaß bei allen personalisierten ADM-Systemen, z.B. politische Nachrichten im NewsFeed bei facebook.
- ...

1) Datta, A.; Tschantz, M. C. & Datta, A.: „Automated Experiments on Ad Privacy Settings“, *Proceedings on Privacy Enhancing Technologies, Proceedings on Privacy Enhancing Technologies*, **2015**, 2015, 92-112

2) <https://www.propublica.org/article/machine-bias-risk-assessments-in-criminal-sentencing>

3) Sweeney, L.: “Discrimination in Online Ad Delivery”, *ACM Queue*, **2013**, 56, 44-54

# Was ist dazu notwendig?

- Unlimitierter und „anonymer“ Zugang zum AI-System
  - Der Anbieter darf nicht „wissen“, dass dies die Testanfragen sind
- Kenntnis über genaue Input-Struktur und Output-Struktur.
- Bei Personalisierungsgradanalysen, u.U. Datenspenden von ‚echten‘ Nutzern notwendig wegen Datenhistorie (**Typ „Datenspende“**).
  - Kann oft durch „gefakte“ Nutzer simuliert werden.
  - Dann: Unlimitierte Anzahl von nicht erkennbaren Fake-Accounts notwendig.



# Zusammenfassung

- Black-Box-Methode: Oft der einfachste Weg, um Verhalten von Algorithmen zu verstehen (es sei denn, Code ist sehr, sehr kurz).
- Transparenz von Code (=„Offenlegung“) nicht zielführend und oftmals schädlich (wirtschaftlich, aber auch wegen Manipulationsmöglichkeiten).
- Weitere Forschung zu Anwendungsbedingungen und Grenzen der Methodik notwendig.

