

HAL übernehmen Sie!

Algorithmische Entscheidungssysteme

Sitzung der Arbeitsgruppe „Legal Tech:
Herausforderungen für die Justiz“
am 24.05.2018 in Stuttgart

Prof. Dr. Katharina Anna Zweig

TU Kaiserslautern
Leiterin des Algorithm Accountability Labs
@nettwwerkerin



...zwei verurteilte
Kriminelle...



Das sind Brisha und Vernon,....



Wer wird es wieder tun?



Menschen – so irrational!

- Richter müssen vorzeitige Haftentlassungsanträge begutachten.
- Studie: je weiter von der letzten Pause weg, desto weniger risikoreiche Entscheidungen¹.
- Eine Vielzahl solcher Studien scheint zu beweisen:
 - Menschen sind irrational und vorurteilsbeladen.



¹ Danziger, S.; Levav, J. & Avnaim-Pesso, L.: “Extraneous factors in judicial decisions”, Proceedings of the National Academy of the Sciences, 2011 , 108 , 6889-6892

Algorithmische Entscheidungssysteme



Scoring-Verfahren

oder



Klassifikation

Das kleine ABC der Informatik

Können

Algorithmen,

Big Data und

Computerintelligenz

Menschen besser bewerten und richten als
Menschen?



A wie Algorithmus

Ein Algorithmus ist ein Problemlöser

Mathematisches Problem



INPUT

**Der OUTPUT
der uns sagt,
wie Input
mit Output
zusammenhängt.**



OUTPUT



Beispiel für ein Problem: Navigation

Navigation

Gegeben das Kartenmaterial und weitere Daten, berechne die kürzeste Route zwischen Start und Ziel

Das **Problem** sagt nicht, wie man die Lösung **findet**.




Input: Straßen, Länge, Staus, ...
Start und Ziel



Output: optimale Route

Ein Algorithmus ist...

...eine für jede **erfahrene Programmiererin** ausreichend **detaillierte Lösungsvorschrift**, so dass bei **korrekter Implementierung** der Computer **für jede korrekte Inputmenge den korrekten Output** berechnet – in endlicher Zeit.



Beispiel: Sortieren




Sortieren 1: „Sortieren durch Einfügen“

- Fange mit einem Buch an, stelle es ins Regal.
- Solange es noch Bücher gibt,
 - nimm das nächste,
 - geh am Regal entlang und sortiere es an der passenden Stelle ein.
- Alle Bücher, die schon im Regal stehen, sind in der richtigen, relativen Reihenfolge.
- Daher: wenn alle im Regal stehen, sind sie vollständig sortiert.

Sortieren 2: Aufsteigendes Sortieren

- Stelle alle Bücher irgendwie ins Regal.
- Gehe das Regal entlang – wenn dabei zwei Bücher in der falschen Reihenfolge nebeneinander stehen, vertausche sie. Tue dies bis zum Ende des Regals und gehe wieder zum Anfang.
- Laufe solange immer wieder am Regal entlang, bis im letzten Durchgang kein Tausch mehr nötig war.
- Wenn kein Tausch mehr nötig war, sind alle Bücher sortiert.

Problem-Algorithmus-Lösung



- Ein mathematisches Problem kann also meist durch mehrere Algorithmen gelöst werden.
- Jeder Algorithmus löst nur genau ein mathematisches Problem.
- Im Sinne von „Alltagsproblemen“ löst derselbe Algorithmus sehr viele verschiedene Probleme:
 - Sortieren von Personen nach Anzahl ihrer Follower auf Twitter;
 - Anzeige von Nachrichten, sortiert nach Publikationsdatum;
 - Suchmaschineneinträge sortieren nach Bewertung durch Suchmaschinenalgorithmus;

Algorithmen – eine Kategorisierung

Klassische Algorithmen

Es ist genau bekannt, welche Art von Eingabe kommt und welche Eigenschaften die Lösung haben soll.

Der Algorithmus bietet eine Qualitätsgarantie: Die gefundene Lösung ist optimal/höchstens 3-mal schlechter/erwartet höchstens 3-mal schlechter.

- Sind oft mathematisch in ihrer Korrektheit bewiesen.
- Handwerkliche Fehler können passieren.
- Sie können auch explizit manipuliert werden und gesellschaftlich falsche / illegale Ziele verfolgen:
 - Beispiel Dieselskandal
- Für das korrekte Design, die korrekte Implementierung und die Auffindung von Fehlern/Manipulationen sind Informatikerinnen bestens ausgebildet.



Und worüber
reden
dann gerade alle?

Maschinelles Lernen aus Big Data



B wie Big Data

Daten als Grundlage



Von Fernanda B. Viégas - User activity on Wikipedia, CC BY 2.0, <https://commons.wikimedia.org/w/index.php?curid=10090013>

- Große Datenmengen.
- Außerhalb ihres spezifischen Zwecks genutzt.
- Daher im Einzelnen vermutlich fehlerbehaftet.
- Dank großer Masse und wenig individualisiertem Verhalten statistisch nutzbar.
- Hier werden Methoden des maschinellen Lernens benötigt.



C wie Computerintelligenz



Was heißt Lernen?


Einfach:

In derselben Situation ein vorher gezeigtes Verhalten wiederholen.

Generalisiert:


In derselben Art von Situation das richtige Verhalten aus einer Reihe von Möglichkeiten auswählen.

Sebastian lernt „heiss“ und „warm“



Sebastian lernt...

- Durch **Rückkopplung**: unerwartet heiß, unerwartet kalt
- Durch **Speicherung in einer Struktur**: in Neuronen und deren Verknüpfung.
- Durch viele **Datenpunkte**.
- Durch **Generalisierung des Gelernten**.





Computer lernen

Damit ein Computer lernen kann, benötigt er ebenfalls eine **Struktur**, um Gelerntes abzuspeichern.

Optimal auch **Rückkopplung**.

Er lernt **generelle Regeln**.





Clustering

Formel

$$w_1 * \#V_h - w_2 * \#day_i V_h + w_3 * I[g = male]$$

Entscheidungs- bäume






“Lernen” mit Korrelationen |

Heißen Sie unsere(n) neue(n) Mitarbeiter(in) willkommen!

- Anteil weiblicher Angestellter?
 - 44%
- Anteil weiblicher Angestellter mit Lohn unter \$25?
 - 55%



Algorithmen – eine Kategorisierung

Klassische Algorithmen

Es ist Ihnen bekannt, welche Art von Eingabe (Input) kommt und welche Operationen die Lösung (Output) haben soll.

Der Algorithmus garantiert eine Optimalitätsgarantie. Eine befundene Lösung ist optimal/höchstens 3-mal schlechter/erwartet höchstens 3-mal schlechter.

Algorithmische Entscheidungssysteme (mit maschinellem Lernen)

Lernen Korrelationen zwischen Input und Output.

Algorithmus ist meistens eine „Heuristik“, deren Lösungsqualität nur durch Testdaten ermittelt werden kann.



Lernen mit Formeln

Rückfälligkeitsvorhersage für (schon verurteilte) Kriminelle

Datengrundlagen

- Data Mining Methoden nutzen, z.B.:
 - Alter der ersten Verhaftung
 - Alter des Delinquenten (der Delinquentin!)
 - Finanzielle Lage
 - Kriminelle Verwandte
 - Geschlecht
 - Art und Anzahl der Vorstrafen
 - Zeitpunkt der letzten kriminellen Akte
 - Extra-Fragebogen
 - Aber bspw. nicht die (in den USA eindeutig zugehörige) Zugehörigkeit.
- Wichtig: Beim Trainingsset ist bekannt, ob die Person rückfällig geworden ist oder nicht.



Regressionsansatz

$$\begin{aligned} & 3 * \text{bisherige Verhaftungen} \\ & - 2 * \text{Anzahl Tage seit letzter Verhaftung} \\ & + 3 * (\text{Wenn Mann, dann 1, sonst 0}) \\ & + 2,5 * (\text{Wenn Raubüberfall, dann 1, sonst 0}) + \dots \end{aligned}$$

$$\begin{aligned} & w_1 * \text{bisherige Verhaftungen} \\ & - w_2 * \text{Anzahl Tage seit letzter Verhaftung} \\ & + w_3 * (\text{Wenn Mann, dann 1, sonst 0}) \\ & + w_4 * (\text{Wenn Raubüberfall, dann 1, sonst 0}) + \dots \end{aligned}$$


Der Computer bestimmt die Gewichte und bekommt ein Feedback (Rückkopplung), inwieweit die damit resultierende Bewertung tatsächlich mit dem (beobachteten) Verhalten übereinstimmt.



Qualität eines Algorithmus

„Lernen“ von Gewichten

- Algorithmus probiert Gewichte und berechnet Risiko für alle Personen im Datenset.
- Bewertet jeweils, wie viele erwiesenermaßen Rückfällige möglichst weit oben stehen.
- Die Gewichtung, die das maximiert, wird für weitere Daten genommen.



Grüne Kugeln symbolisieren resozialisierte, rote rückfällige Kriminelle.

Optimale Sortierung: Alle roten oben, alle grünen darunter.



Qualitätsmaß: Paare von rot und grün, bei denen die rote Kugel über der grünen einsortiert ist.

Oregon Recidivism Rate Algorithm

- 72 von 100 Paaren werden korrekt sortiert.
- So werden aber keine Urteile gefällt!
- Sondern: Reihe von Angeklagten, von denen diejenigen mit dem höchsten Rückfallrisiko benannt werden sollen.
- Rückfallquote bei jugendlichen Kriminellen liegt z.B. bei 20%.



Optimale Sortierung

Erwartete 20% „Rückfällige“



Mögliche Sortierung eines Algorithmus mit dieser „Güte“ (75/100 Paaren)

Erwartete 20% „Rückfällige“





einen Jagdhund zu kaufen,



um Schafe zu hüten.

Das ist wie...


Vom Scoring zur Klassifikation

- ACLU fordert: Es soll drei Klassen geben.
- Niedriges, mittleres, hohes Risiko.

$$10/24 = 42\%$$

$$9/29 = 31\%$$


$$2/37 = 5\%$$





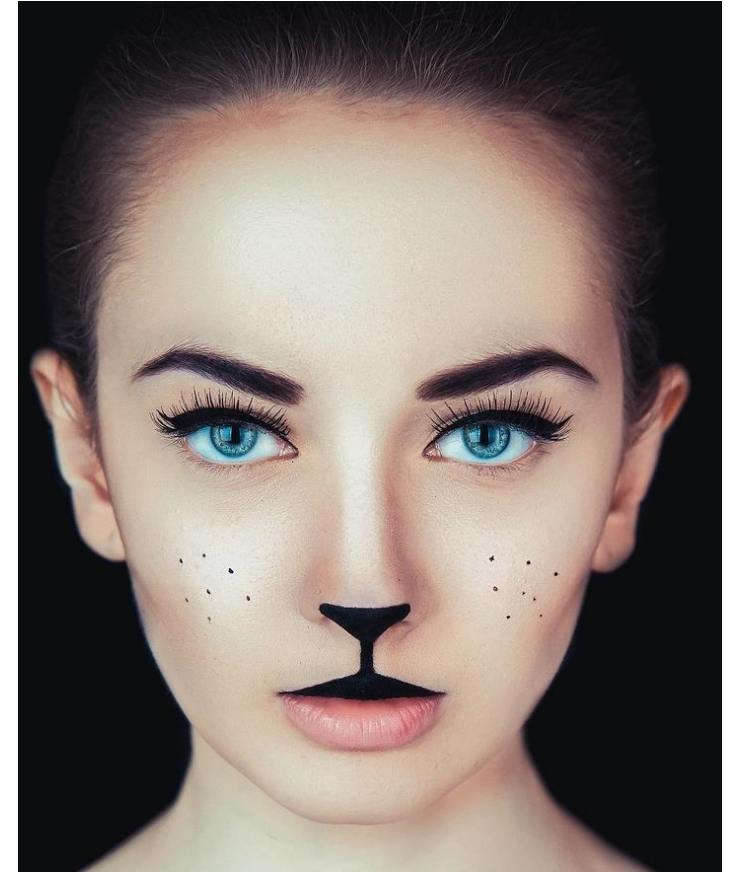
Statistische Vorhersagen
über Menschen

Statistische Prognosen beim Wetter



Zu 40% ein Krimineller....

- Wenn dieser Mensch eine Katze wäre und 7 Leben hätte, würde er in 3 davon wieder rückfällig werden...
- Nein!
- **Algorithmische Sippenhaftung**
 - Von 100 Personen, die „genau so sind wie dieser Mensch“, werden 40 wieder rückfällig;
 - Wir folgen einem *algorithmisch legitimierten Vorurteil*.





Können Algorithmen |
diskriminieren? |

Diskriminierung bei Bewerbungen



- Lebensläufe mit „deutschen“ Namen bekommen 14% mehr Vorstellungsangebote als solche mit „türkischen“ Namen¹.
- US-amerik. Studie: Frauen mit Kopftuch erhalten weniger Jobangebote als solche ohne².



¹ Kaas, L. & Manger, C.: “Ethnic Discrimination in Germany's Labour Market: A Field Experiment”, German Economic Review, 2011 , 13 , 1-20

² Ghumman, S. & Ryan, A. M.: “Not welcome here: Discrimination towards women who wear the Muslim headscarf , human relations, 2013 , 66(5) , 671-698

„Employment asse_ + software“

Let's take the emotion out of the process and replace it with a data-driven approach...

No more people problems


We deal with employee issues so you can focus on what you do best.



READ MORE



iNostix (by Deloitte),
16.11.2017


$$= a^2 \frac{(p(\theta) - Ci)^2}{(1 - C)^2}$$

Assessfirst.com,
16.11.2017

Screenshot einer Anzeige auf der Webseite von dreamhr.co.uk
16.11.2017

The background of the slide is a dense, repeating pattern of red roses. The roses are in various stages of bloom, creating a rich, textured appearance. The color is a deep, vibrant red.

Eine rosige Zukunft

„Below are a few of our solutions, but in the end, with the availability of good data, the **predictive possibilities are virtually unlimited** (emphasis by me): candidate demographics & background data, psychometric data, structured interview data, assessment data, performance data, on boarding evaluation data, training data, etc.”

Magie der Algorithmen?



Wenn man auf Google nach „CEO“ sucht...



Und das, wenn ich auf Pixabay nach „Chef“ suche...

Diskriminierung

- Google zeigt weiblichen Surfern schlechtere Jobs an.
 - Wer ist dafür verantwortlich?
- Rückfälligkeitsvorhersagealgorithmen sagen Afroamerikaner öfter fälschlicherweise als „hochwahrscheinlich rückfällig“ vorher.
- Diskriminierungen in Trainingsdaten werden „mitgelernt“, auch wenn Geschlecht, Herkunft, ... geheim bleiben.
- Wenn Trainingsdaten zu wenig Daten über Minderheiten enthalten, werden deren Eigenschaften nicht „mitgelernt“.



Regel

Algorithmen der künstlichen Intelligenz werden da eingesetzt, wo es **keine einfachen Regeln** gibt.


Sie suchen **Muster** in hoch-verrauschten Datensätzen.

Die Muster sind daher grundsätzlich **statistischer Natur**.

Versuchen fast immer, eine **kleine Gruppe** von Menschen zu identifizieren (Problem der **Unbalanciertheit**)

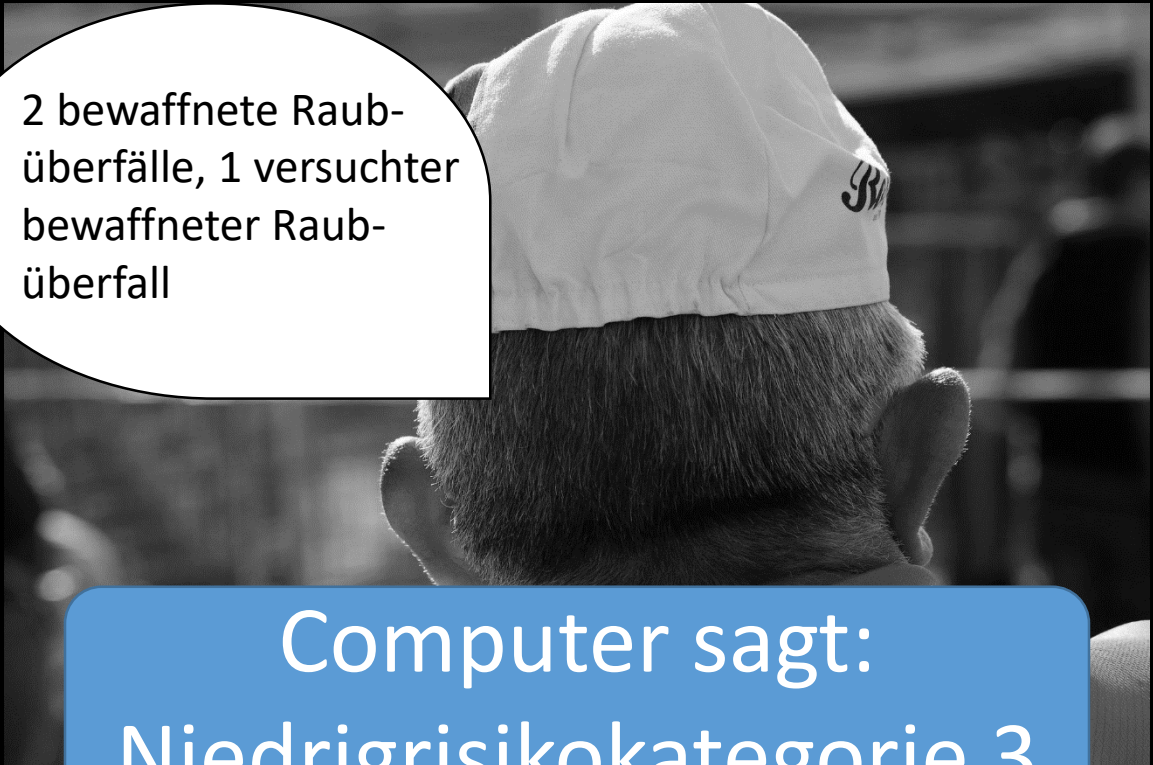


Sozio-informatische |
Gesamtbetrachtung



Viermal Strafe nach
Jugendrecht
(„misdemeanor“)

Computer sagt:
Hochrisikokategorie 8



2 bewaffnete Raub-
überfälle, 1 versuchter
bewaffneter Raub-
überfall

Computer sagt:
Niedrigrisikokategorie 3

Wer wird es wieder tun?

Probleme der Einbettung der ADM in den sozialen Prozess

- **Aufmerksamkeitsökonomie** von Entscheiderinnen und Entscheidern.
- „**Best practice**“ erfordert Nutzung der Software.
- Eine Nichtbeachtung der Empfehlung und gleichzeitige Fehleinschätzung wirkt oft schwerer als eine Beachtung der (falschen) Empfehlung. **Delegierung von Verantwortung!**
- Manchmal kann ein(e) falsch-negativ Beurteilte(r) **die Vorhersage prinzipiell nicht entkräften!**
 - Z.B. abgelehnte Bewerberin, eingesperrte Kriminelle



Schwerer
Diebstahl



Wer hat es wieder getan?



Algorithmen in einer demokratischen Gesellschaft

Generell

Prinzipiell können ADM Systeme vieles entscheiden:

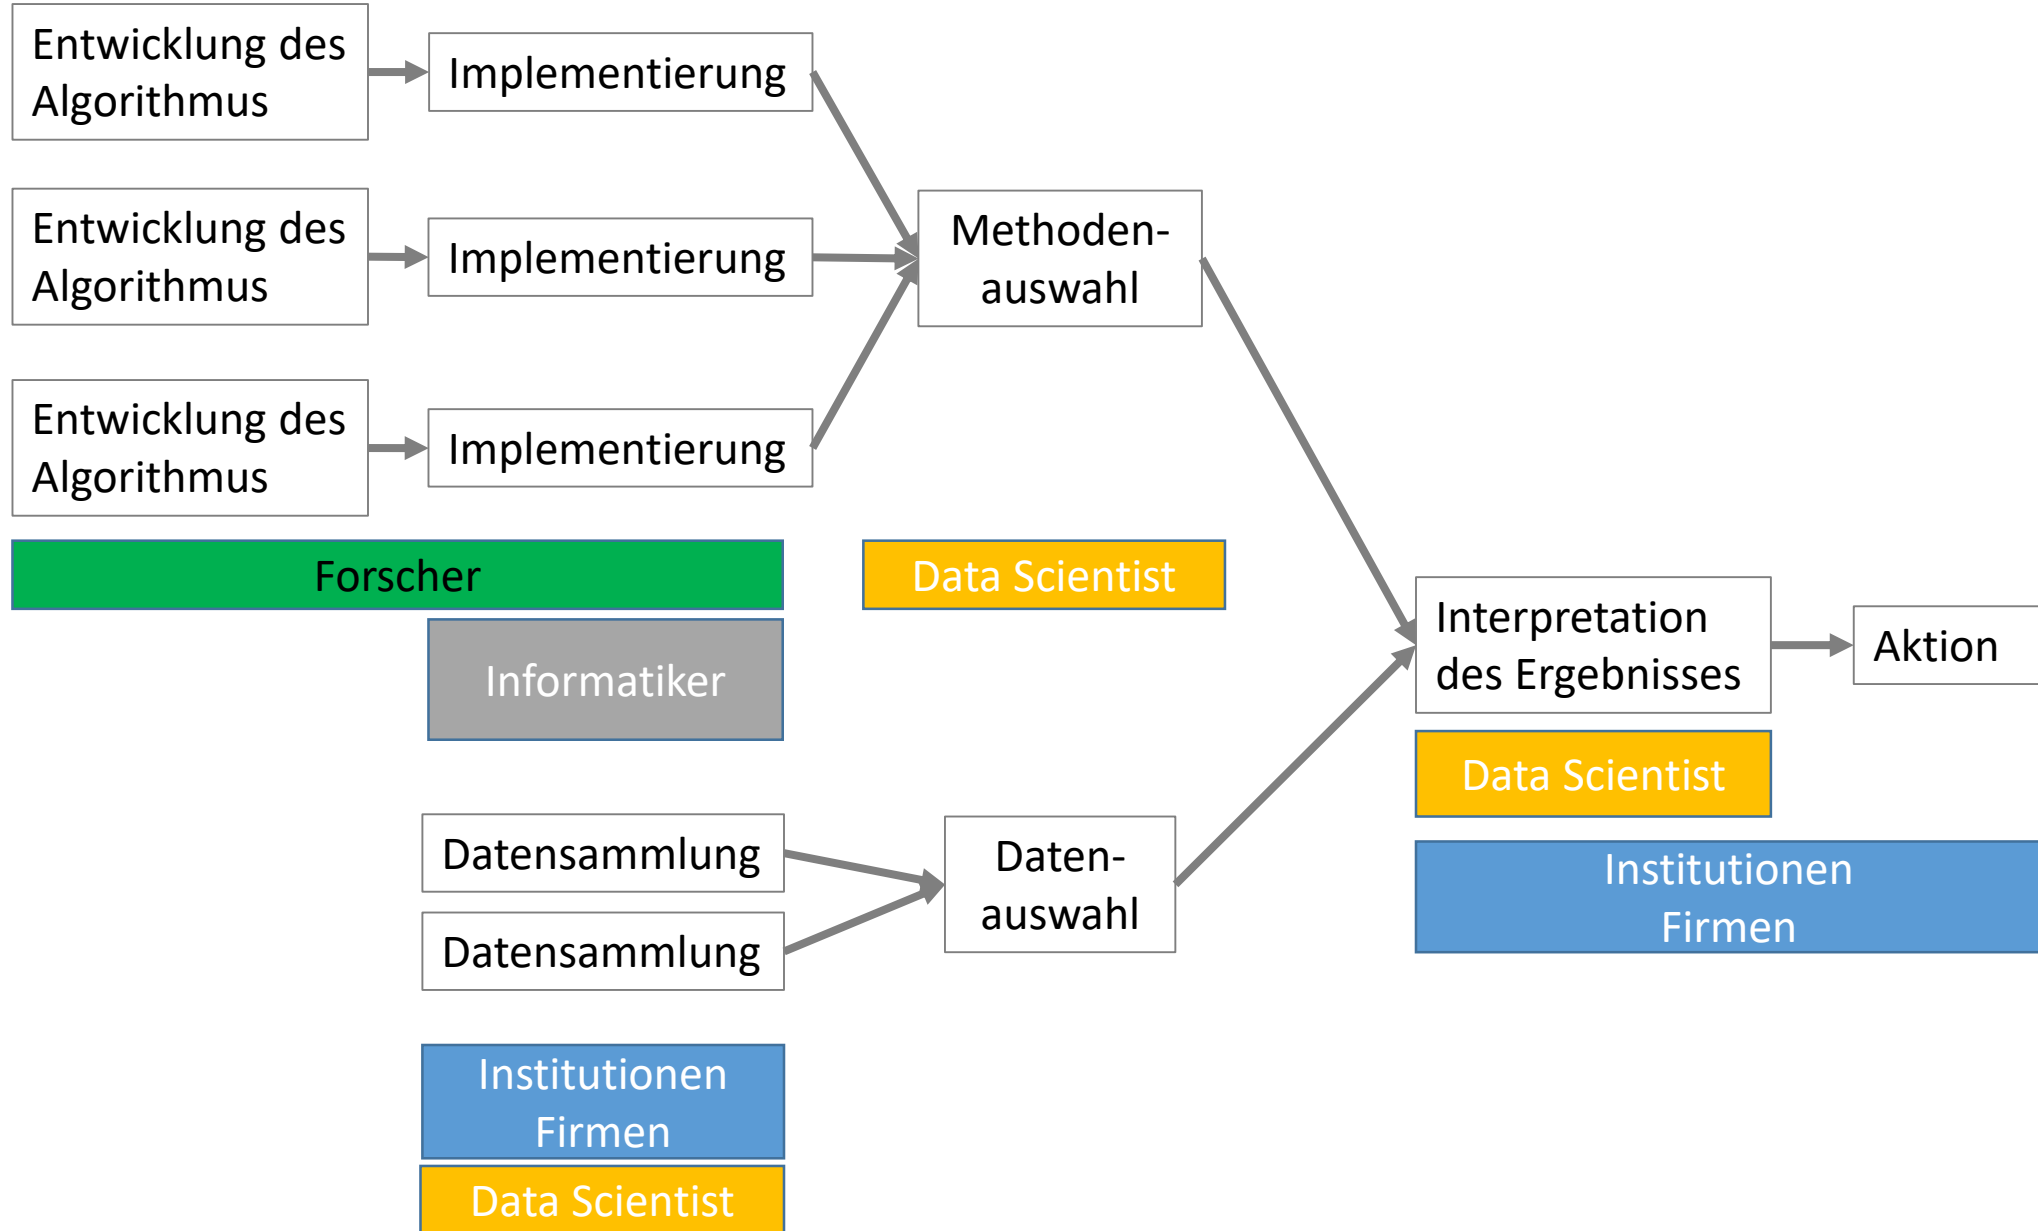
- Automatische Leistungsbewertung
- Kreditvergabe
- Schulische und universitäre Ausbildungen, die durch algorithmische Entscheidungssysteme unterstützt werden
- Algorithmen, die das Sterberisiko von Kranken bewerten
- Gefährder-, Terroristenidentifikation
- ...



Ihre Aufgabe heute....

Entwickeln Sie ein
algorithmisches Entscheidungssystem,
dass **gewaltbereite Extremisten**
frühzeitig identifiziert!


Designprozess



Capturing terrorists with network analysis

TOP SECRET//COMINT//REL TO USA, FVEY

From GSM metadata, we can measure aspects of each selector's **pattern-of-life**, **social network**, and **travel behavior**



Terroristenidentifikation SKYNET

TOP SECRET//COMINT//REL TO USA, FVEY
We've been experimenting with several error metrics on both small and large test sets

Training Data	Classifier	Features	100k Test Selectors		55M Test Selectors	
			False Alarm Rate at 50% Miss Rate	Mean Reciprocal Rank	Tasked Selectors in Top 500	Tasked Selectors in Top 100
None	Random	None	50%	1/23k (simulated)	0.64 (active/Pak)	0.13 (active/Pak)
Known Couriers	Centroid	All	20%	1/18k		
			43%	1/27k		
+ Anchory Selectors	Random Forest	Outgoing	0.18%	1/9.9	5	1
			0.008%	1/14	21	6

Random Forest trained on Known Couriers + Anchory Selectors:

- 0.008% false alarm rate at 50% miss rate
- 46x improvement over random performance when evaluating its tasked precision at 100

Windows
Wechseln
aktivieren

TOP SECRET//COMINT//REL TO USA, FVEY

Das sind 4.400
Unschuldige,
um die Hälfte der
vermeintlichen
Terroristen
zu identifizieren!


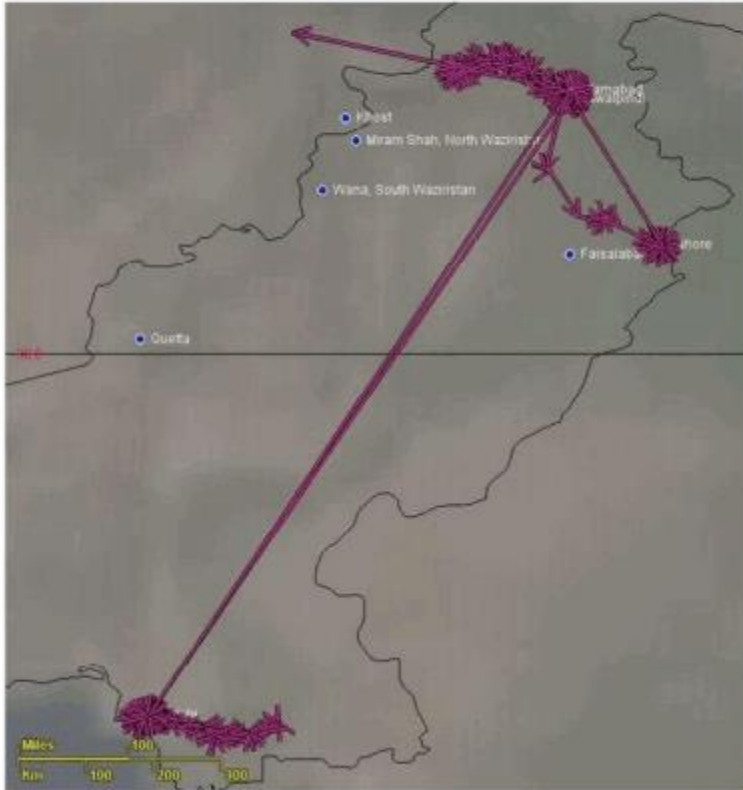
<https://theintercept.com/document/2015/05/08/skynet-courier/>

<https://theintercept.com/2015/05/08/u-s-government-designated-prominent-al-jazeera-journalist-al-qaeda-member-put-watch-list/>

Top-“Kurier“ der Terroristen laut Algorithmus ist...

TOP SECRET//COMINT//REL TO USA, FVEY

The highest scoring selector that traveled to Peshawar and Lahore is PROB AHMED Z Aidan



TIDE Person Number: [REDACTED]

- MEMBER OF AL QATA
- MEMBER OF MUJAH
- BROTHERHOOD
- WORKS FOR AL JAZEERA

Windows
WinseIn

Soziale Konzepte können hinreichend operationalisiert werden, so dass der Computer damit arbeiten kann.

Ein Mensch wird durch seine ihm zugehörigen Daten hinreichend beschrieben, um ihn zu bewerten oder zu kategorisieren.



Menschen können durch eine einzige Zahl hinreichend beschrieben werden (für jeweils eine spezifische Fragestellung).

Menschen sind irrational und vorurteilsbeladen.
Maschinen sind die besseren Entscheider.
Sie sollen Entscheidungen aus Daten ableiten.
Wenn Menschen entscheiden, müssen sie ge“nudged“ werden.

Ein Mensch sollte in seinem Verhalten durch das Verhalten einer Gruppe von ihm ähnlichen Personen bewertet werden.

Probleme von algorithmischen Entscheidungssystemen (ADM Systemen) im People und Risk Assessment


- 1. Wer entscheidet, wann ein ADM System „gut“ ist?**
- 2. ADM Systeme ergeben nur Wahrscheinlichkeiten, keine Wahrheiten.**
- 3. ADM Systeme können diskriminieren.**
- 4. ADM Systeme können soziale Prozesse verändern.**



Einschätzung

- Algorithmen **könnten** dabei helfen, bessere Entscheidungen zu treffen.
 - Sie sind zuverlässig.
 - Können Entscheidungswege transparenter machen.
 - Könnten Diskriminierung vermeiden.
- Allerdings sind sie heute oft noch nicht gut genug.





Was muss reguliert werden?

- Nicht Algorithmen per se!
- Algorithmische Systeme, die Entscheidungen über Menschen treffen.
- Nicht ohne sozio-informatische Gesamtsicht!
- Daher: Qualitätssicherung der Entwicklung und Einbettung!

Screenshots on first slide taken from:

1. <https://www.creamhr.co.uk>
2. <https://www.inostix.com/predict-hiring-success/>
3. <http://www.assessfirst.com/predictive-recruitment-discovers-the-best-employees-through-algorithms/>