



# Mehr Sicherheit durch Algorithmen?

Gewerkschaft

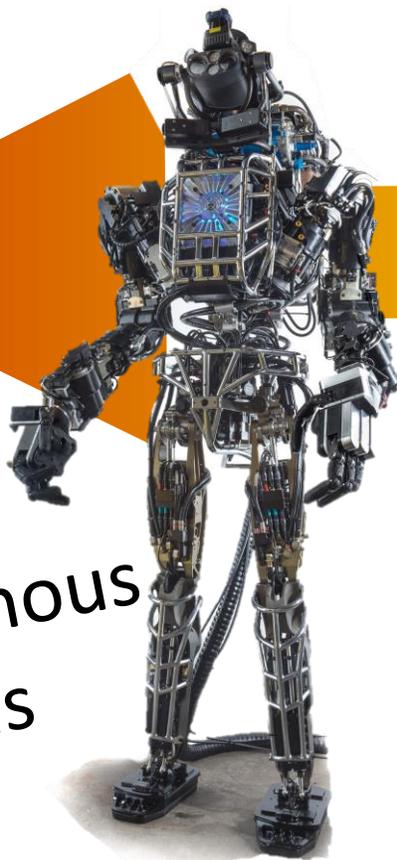
Prof. Dr. Katharina A. Zweig  
Algorithm Accountability Lab  
TU Kaiserslautern

DeepFake



LAWs

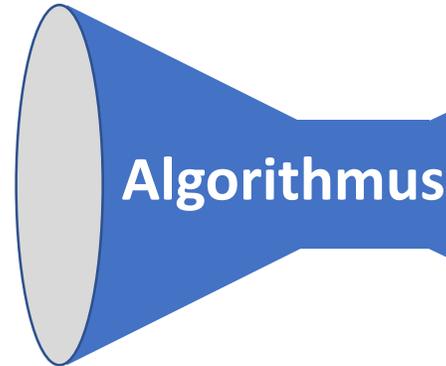
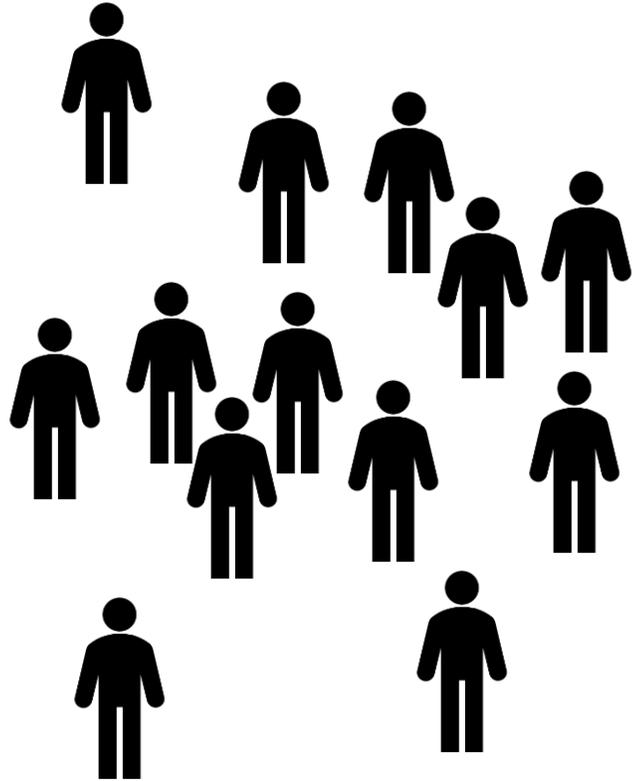
Lethal  
autonomous  
weapons



Künstliche Intelligenz  
und Sicherheit

Risk Assessment  
von Personen

# Algorithmische Entscheidungssysteme



Scoring-Verfahren

oder



Klassifikation

Wer soll richten?





# Menschen – so irrational!

- Richter müssen vorzeitige Haftentlassungsanträge begutachten.
- Studie: je weiter von der letzten Pause weg, desto weniger risikoreiche Entscheidungen<sup>1</sup>.
- Eine Vielzahl solcher Studien scheint zu beweisen:
  - Menschen sind irrational und vorurteilsbeladen.



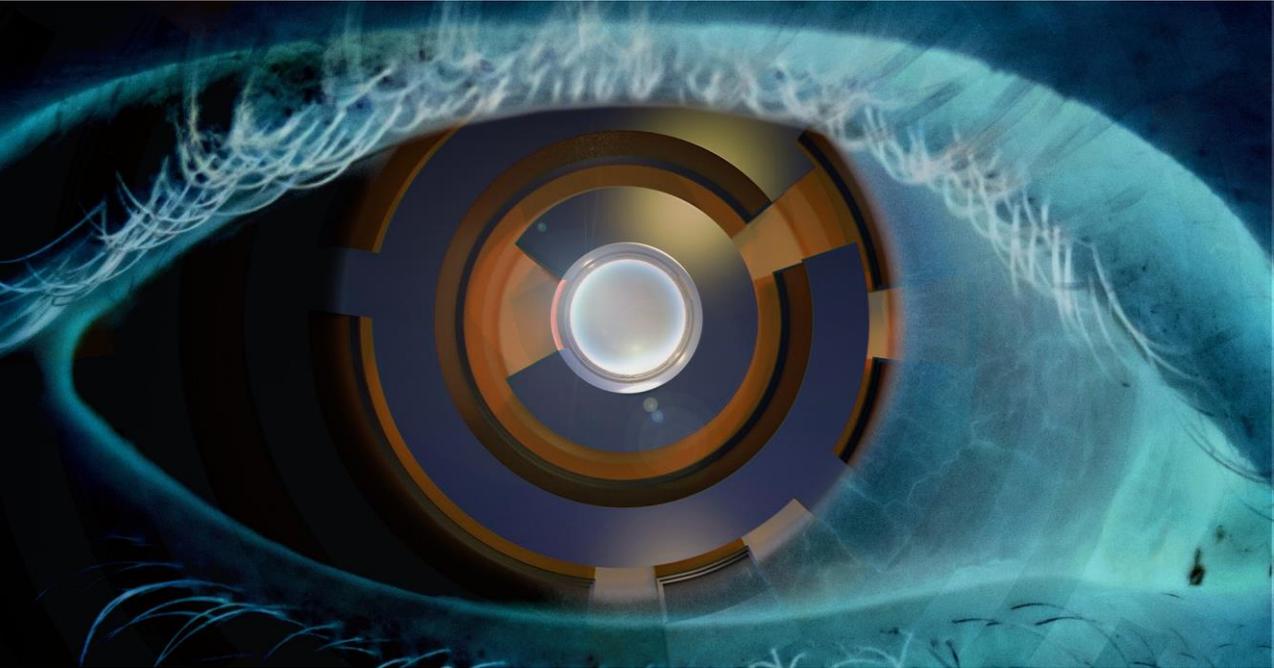
<sup>1</sup> Danziger, S.; Levav, J. & Avnaim-Pesso, L.: “Extraneous factors in judicial decisions”, Proceedings of the National Academy of the Sciences, 2011 , 108 , 6889-6892

# Problemfall USA

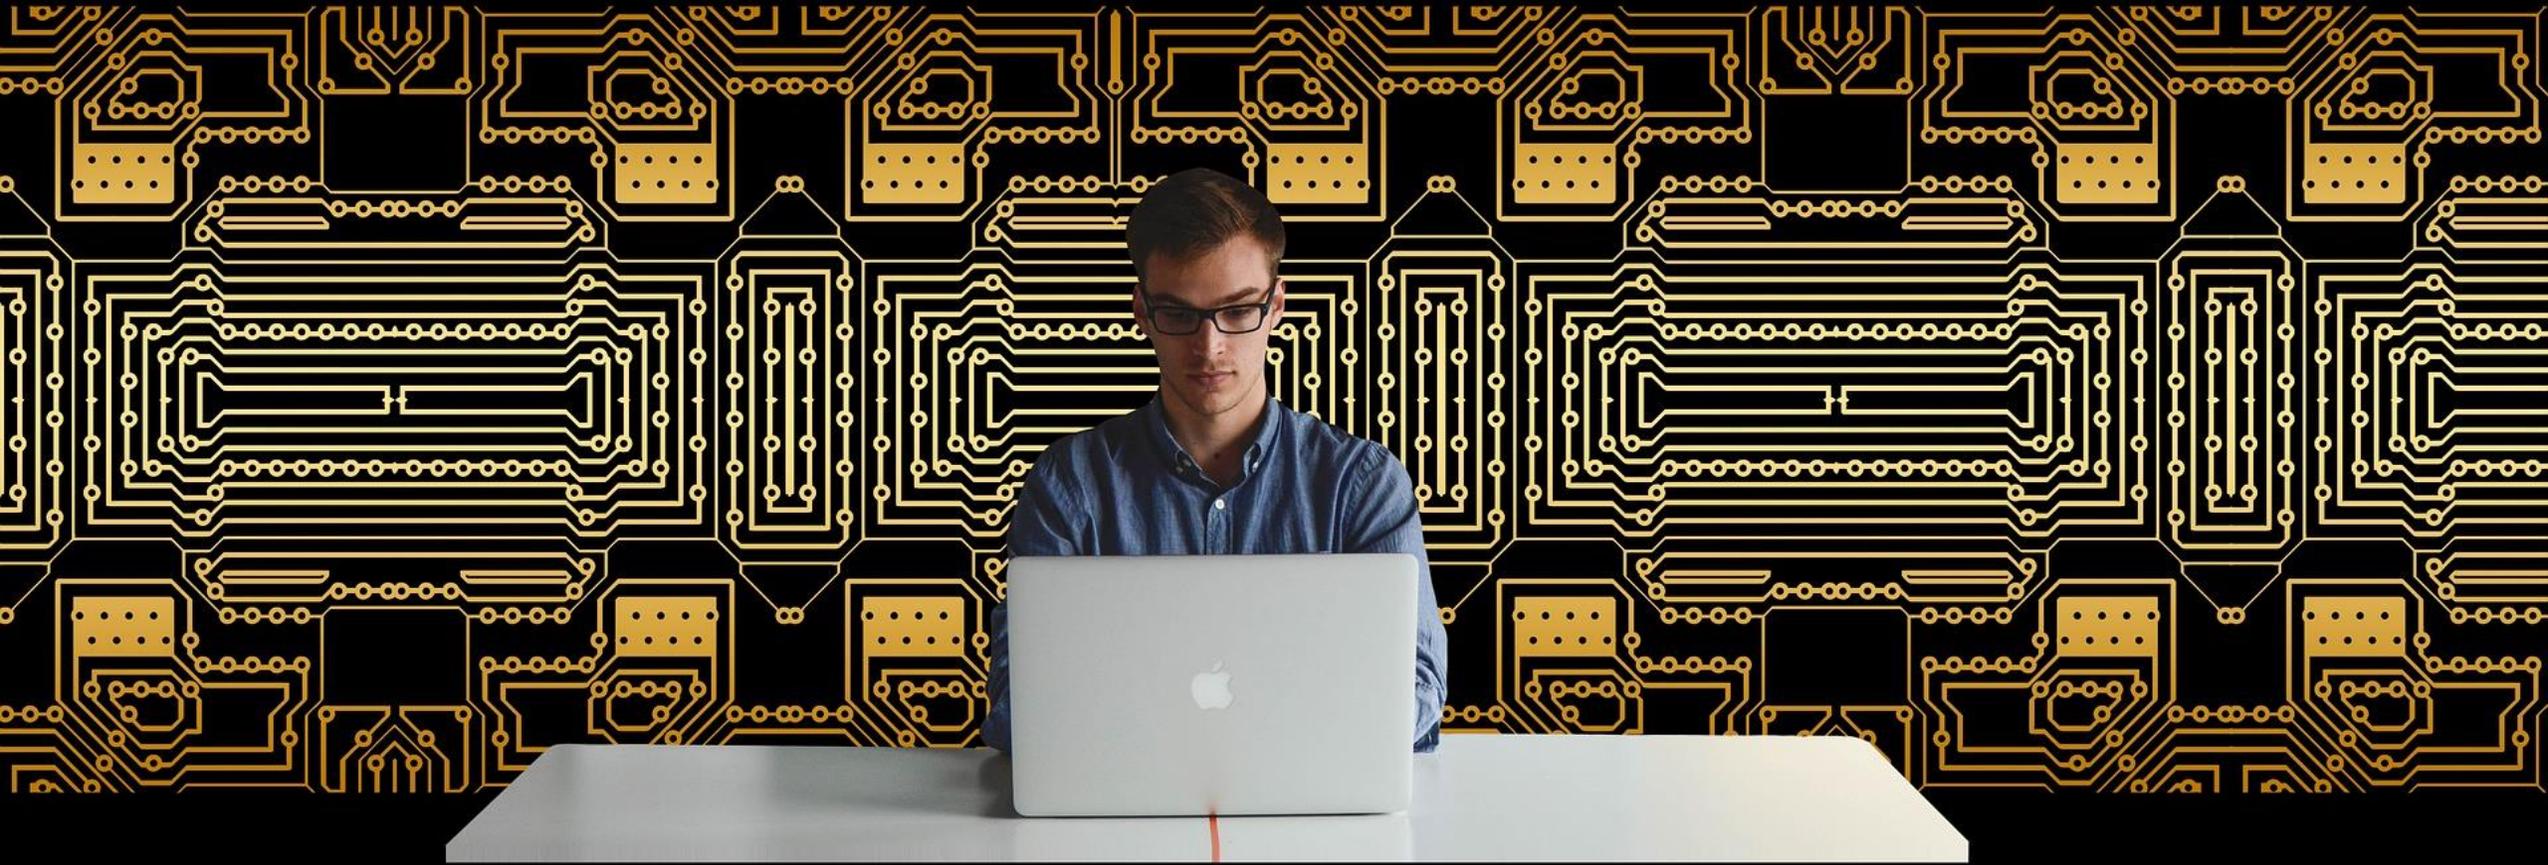
- Zweithöchste Inhaftierungsrate weltweit.
- 6x höhere Rate von Afroamerikanern und 2x höhere Rate von Latinos als von Weißen.
- Prognose: jeder dritte afroamerikanische Junge im Alter von 10 Jahren wird eine Gefängnisstrafe absitzen müssen.



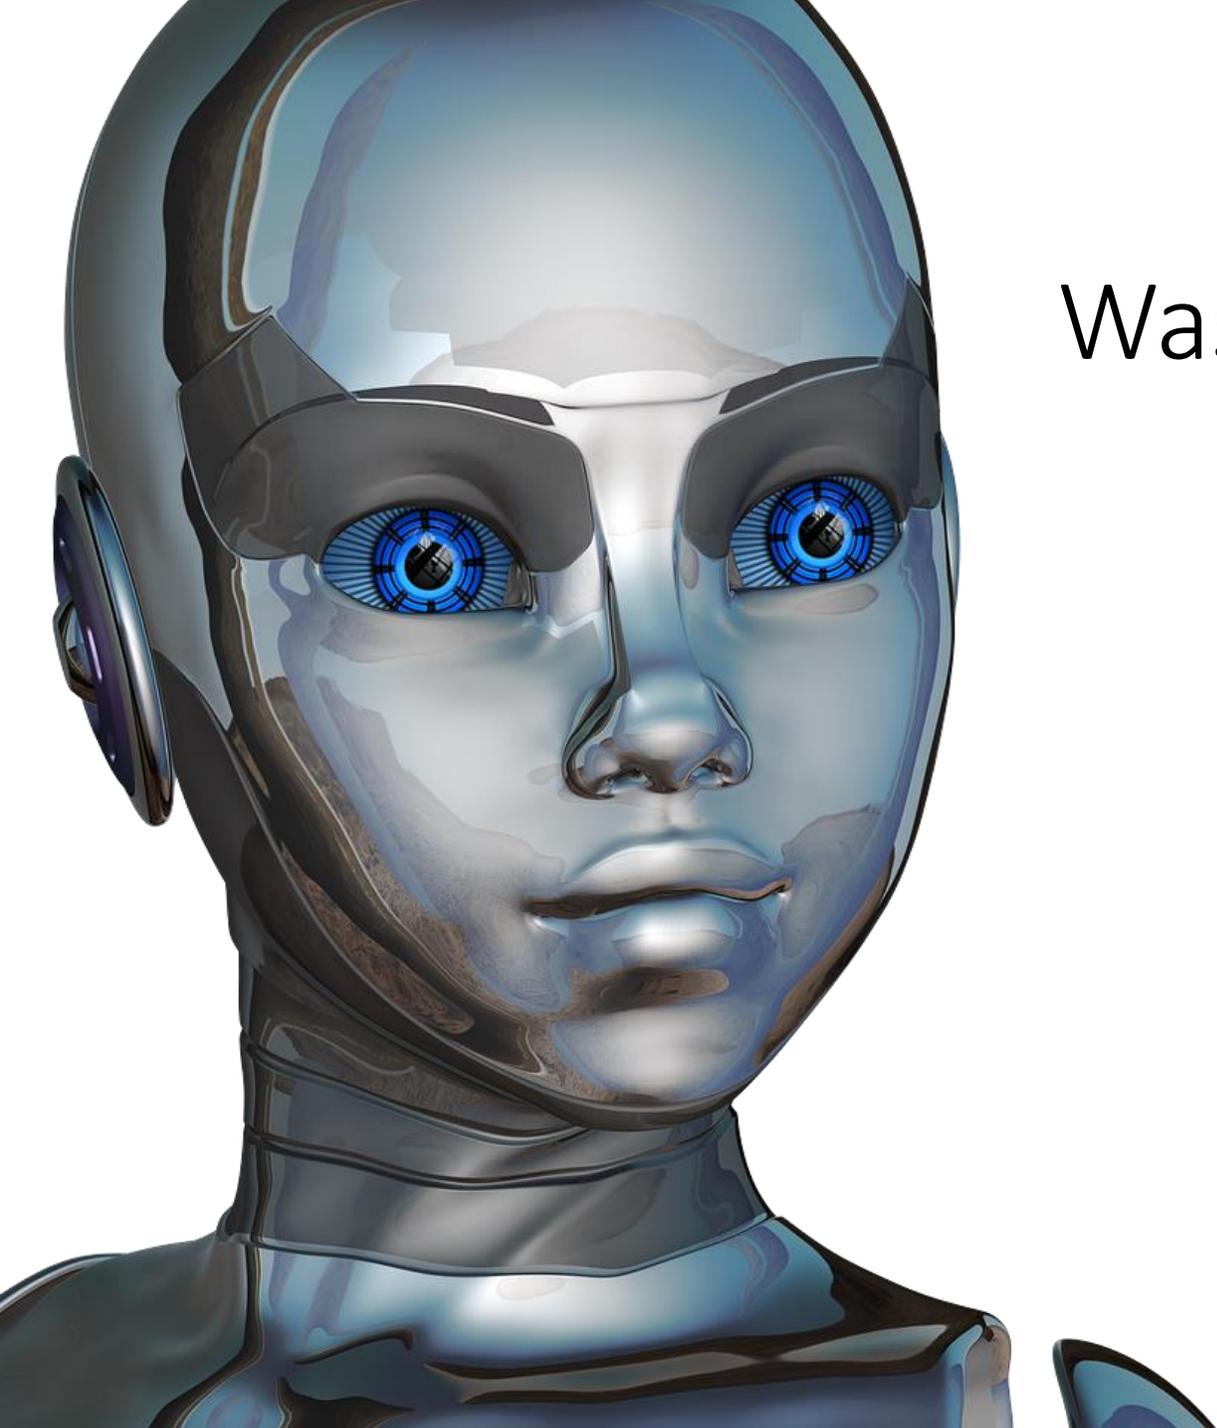
# American Civil Liberties Union



- Amerikanische Bürgerrechtsunion (seit 1920) fordert:
- Algorithmische Entscheidungssysteme sollten überall im Prozess eingesetzt werden, ...
- ... um Fairness und Objektivität zu sichern.
- Dazu sollen Computer aus Daten Entscheidungsregeln lernen.



Können Computer lernen?



# Was heißt Lernen?

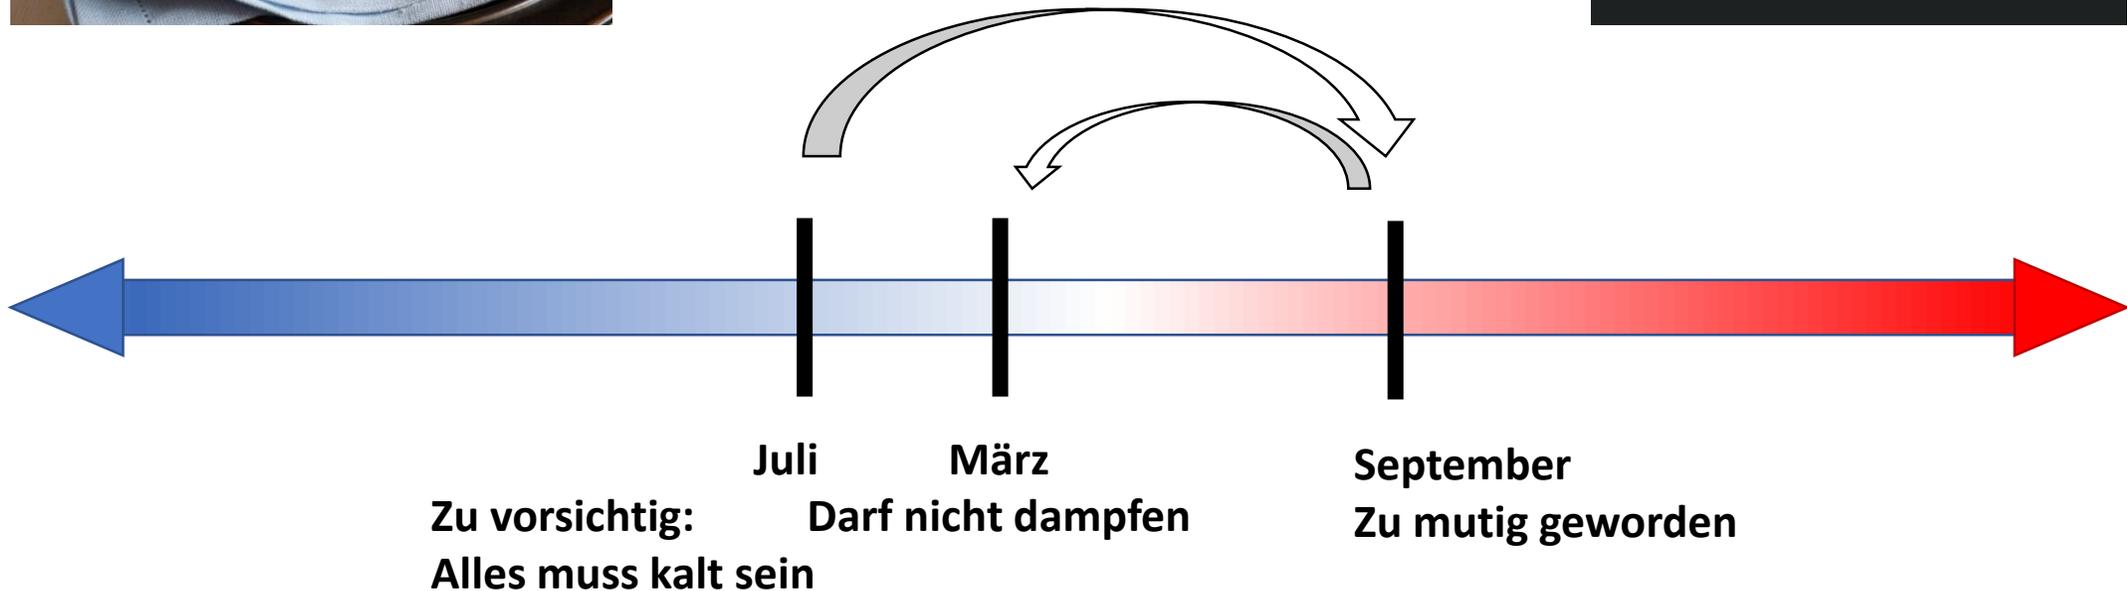
Einfach:

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“



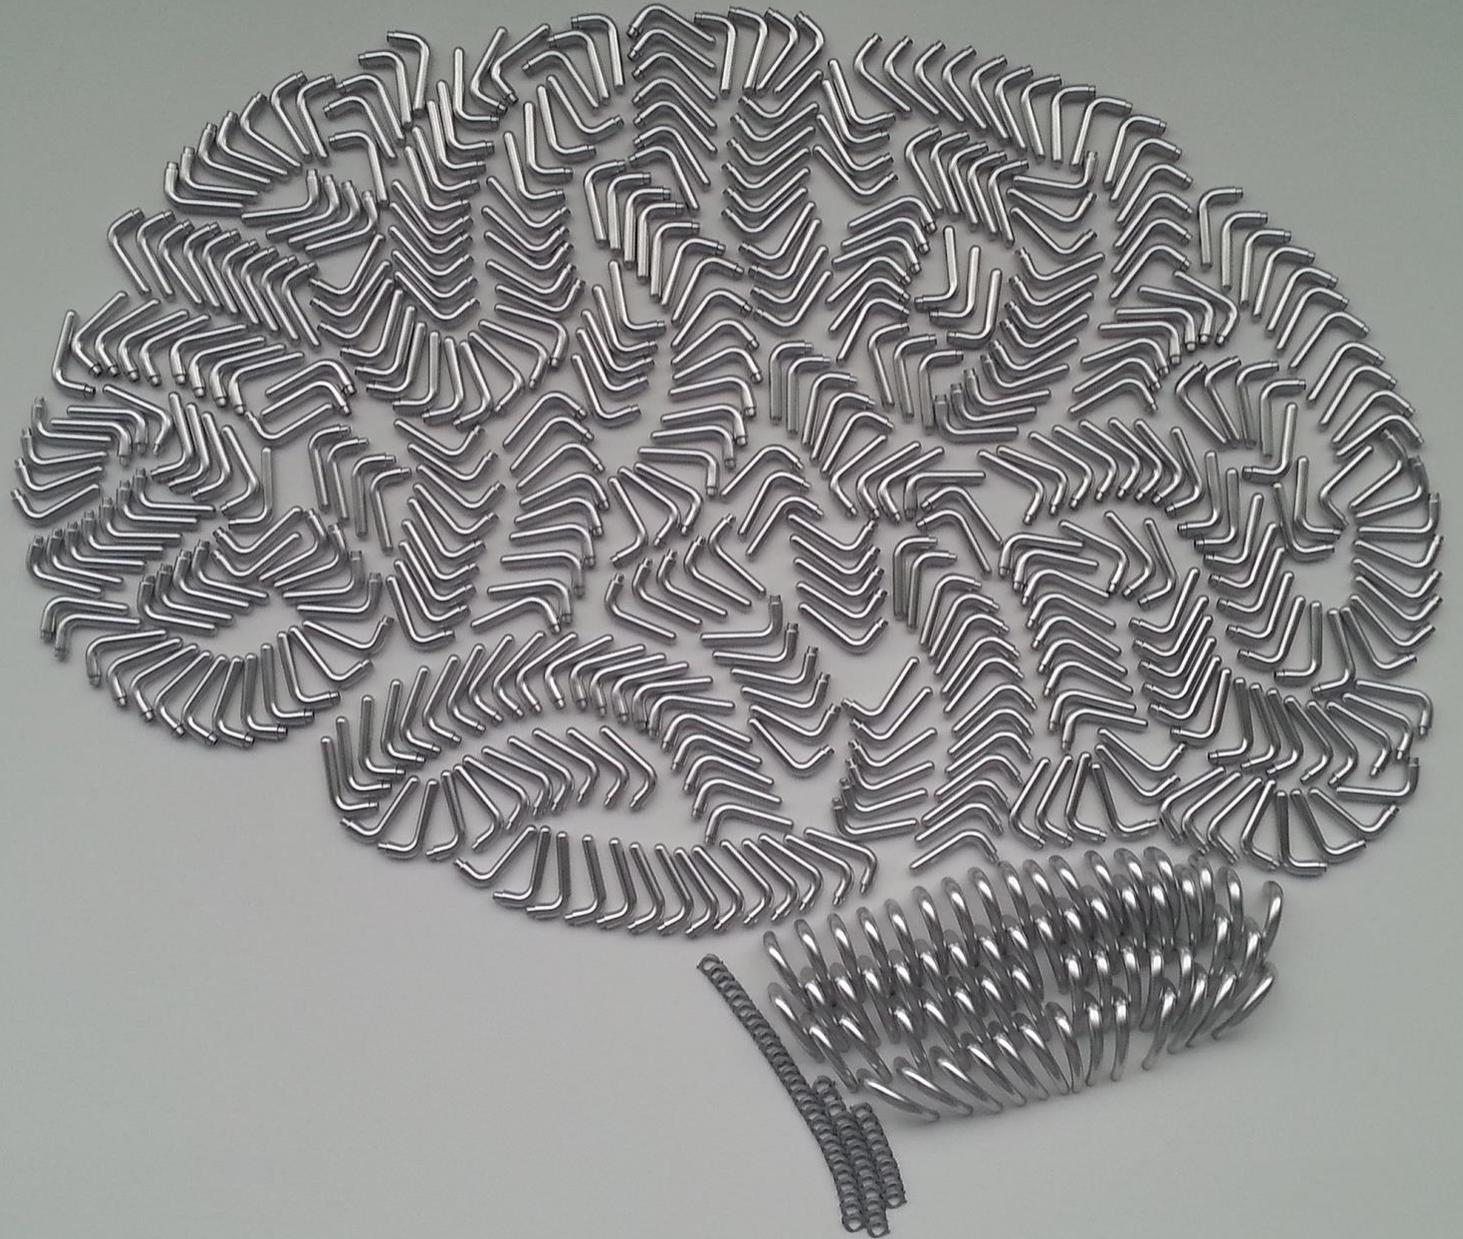
Zu vorsichtig:  
Alles muss kalt sein

Juli  
Darf nicht dampfen

September  
Zu mutig geworden

# 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**.

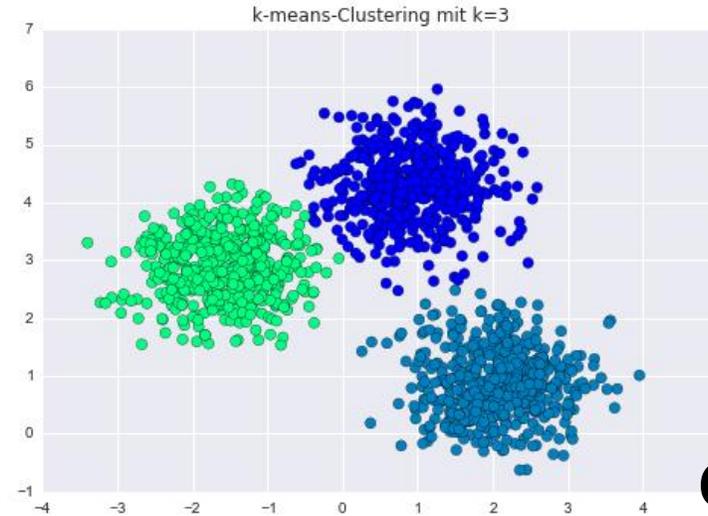
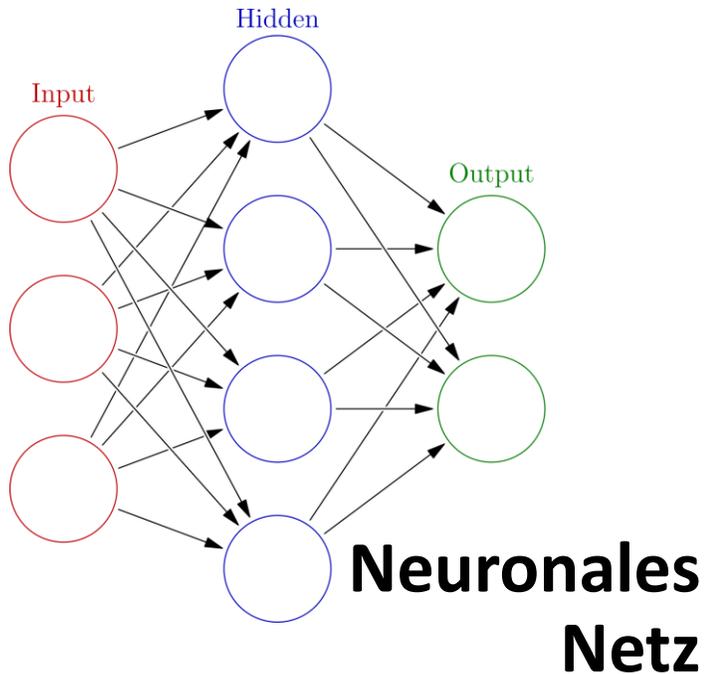


# Computer lernen

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

Optimal auch **Rückkopplung**.

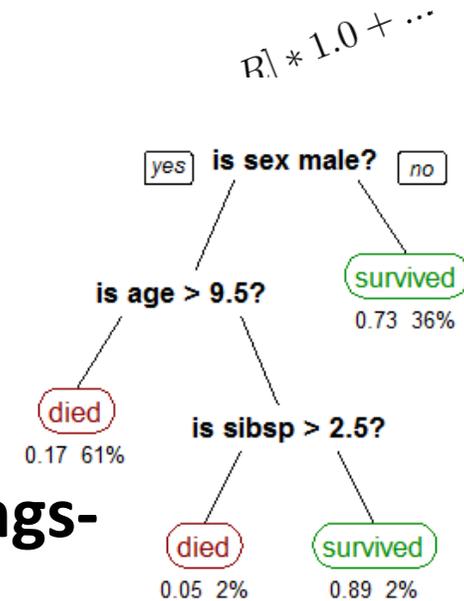
Er lernt **generelle Regeln**.

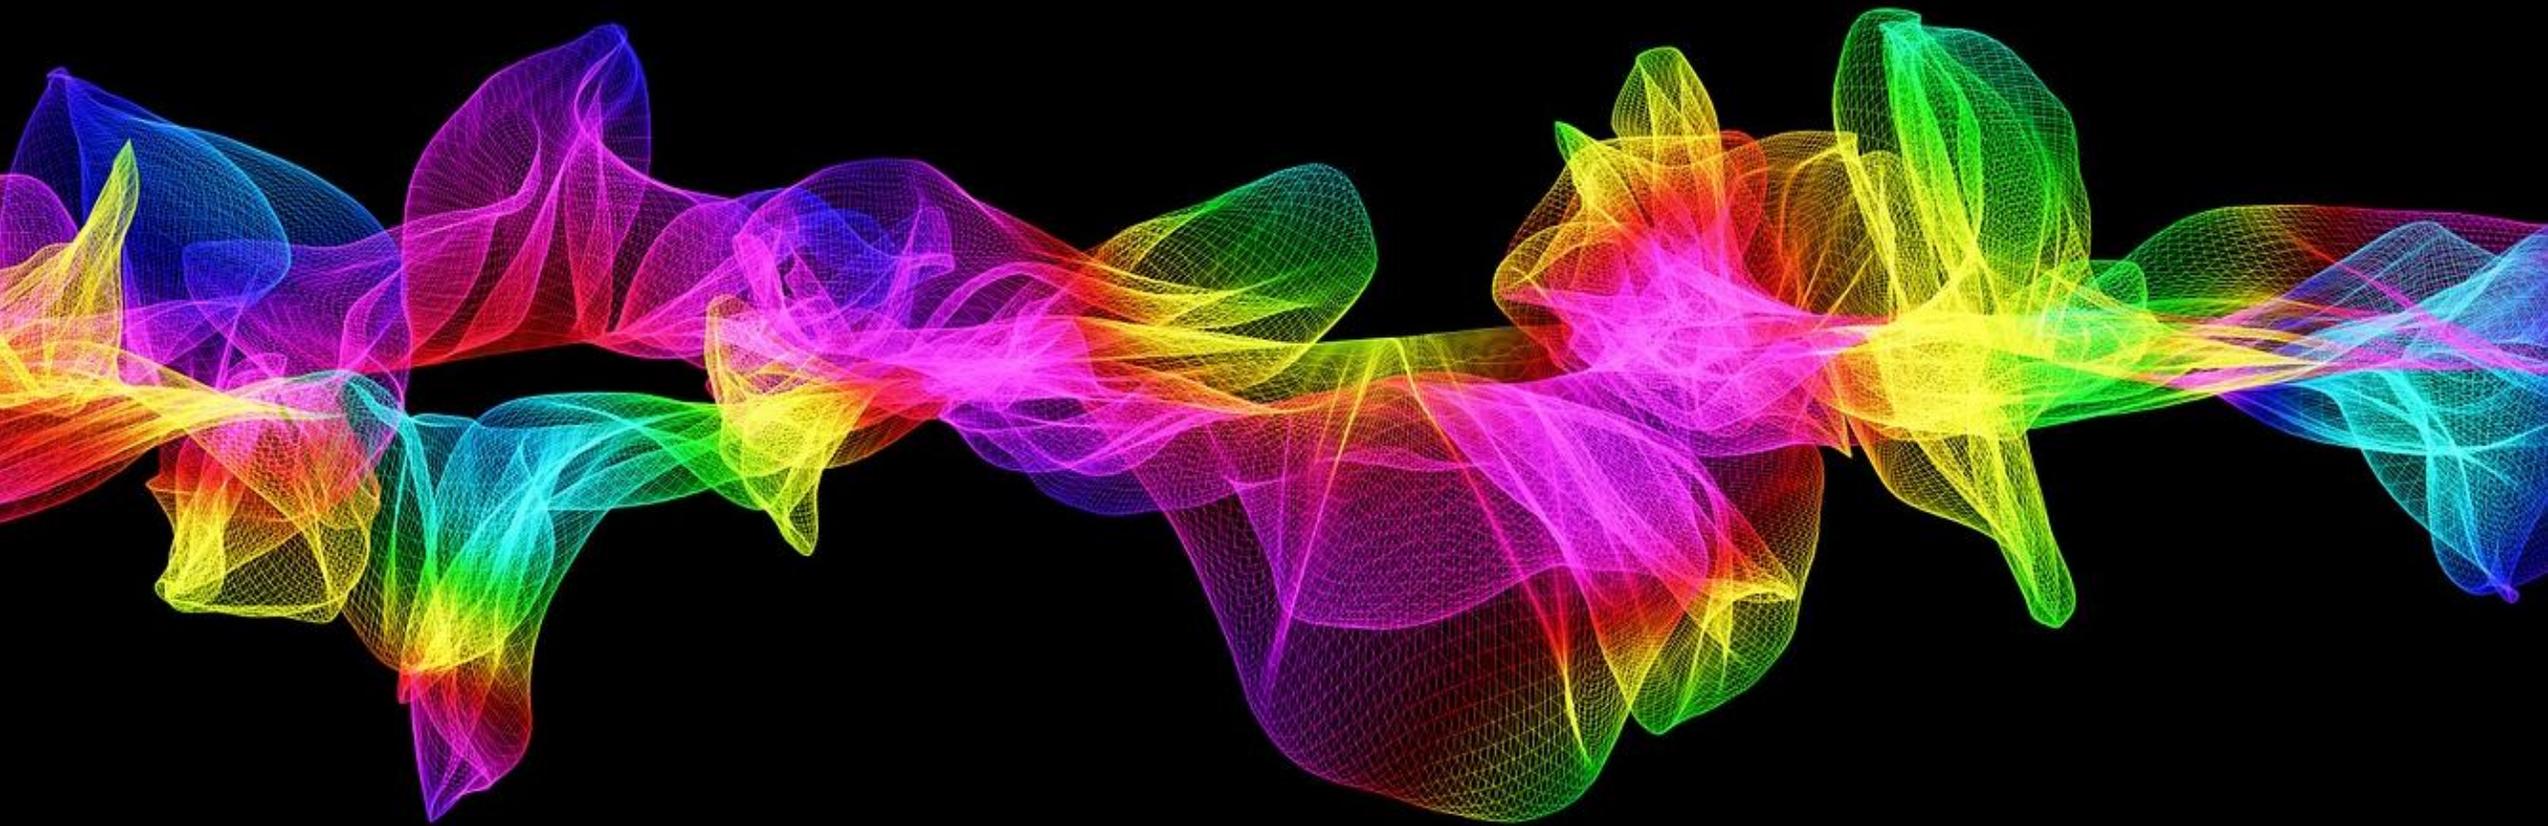


## Formel

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

## Entscheidungs- bäume



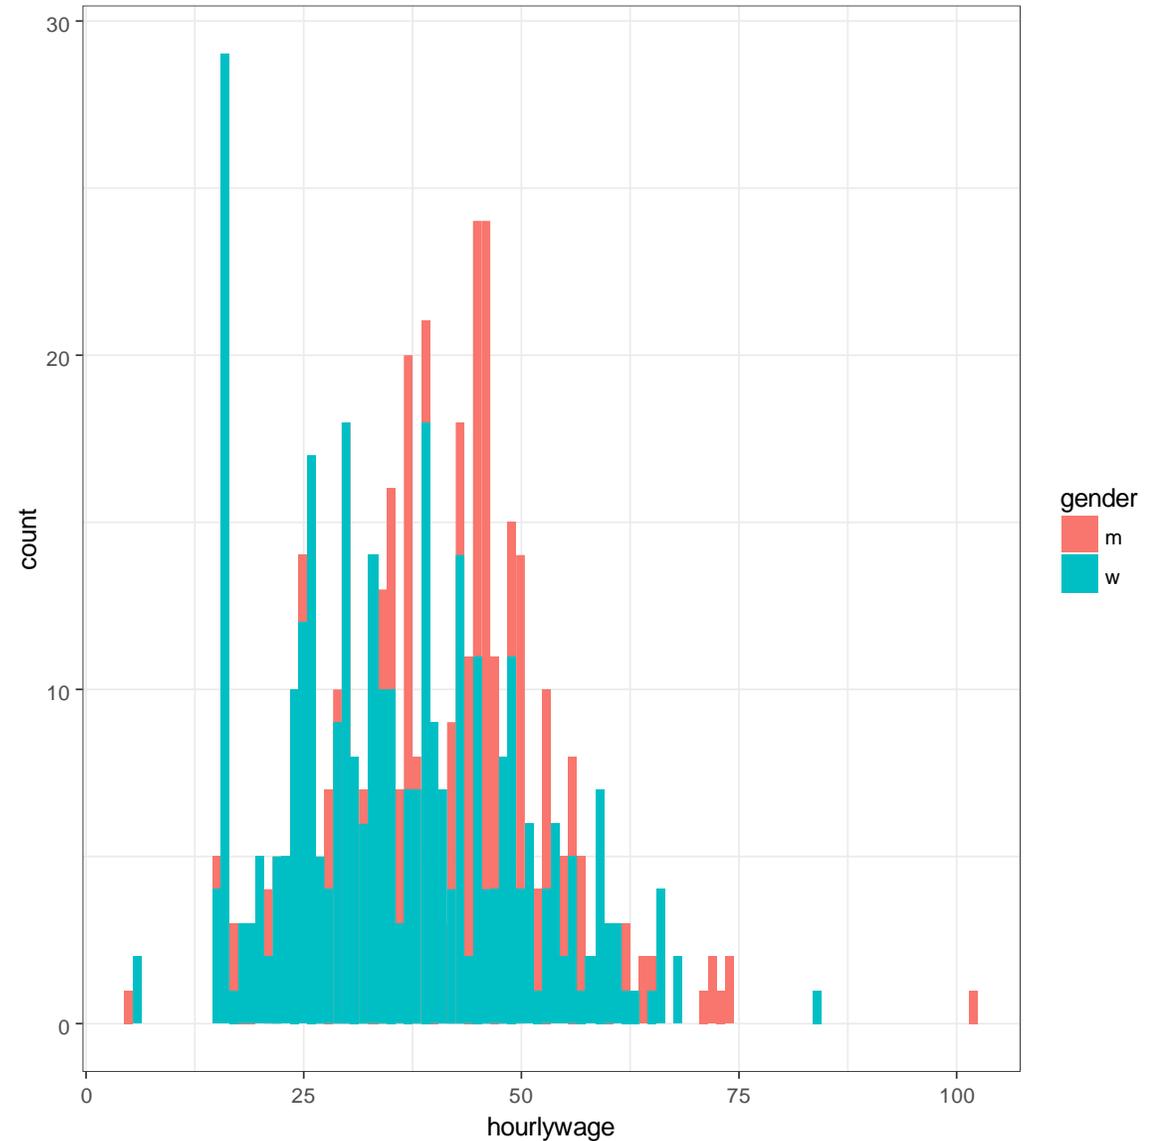


“Lernen” mit Korrelationen

# Gehälter in Seattle

Sie bekommen Daten von einer Person – diese verdient weniger als \$25 pro Stunde.

Basierend auf den Daten, ist die Person weiblich oder männlich?





Lernen mit Formeln

Individuelle  
Risikobewertung der  
Rückfälligkeit von  
Kriminellen

# 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 zugeordnete) ethnische Zugehörigkeit.
- Wichtig: Beim Trainingsset ist bekannt, ob die Person rückfällig geworden ist oder nicht.



# Regressionsansätze

- Algorithmdesigner entscheiden, welche der Daten vermutlich mit „Rückfallwahrscheinlichkeit“ korrelieren.
- Resultat sollte eine einzige Zahl sein.
- Je höher die Zahl, desto höher die Rückfallwahrscheinlichkeit.
- Beispiel Formel:

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

# Allgemein

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

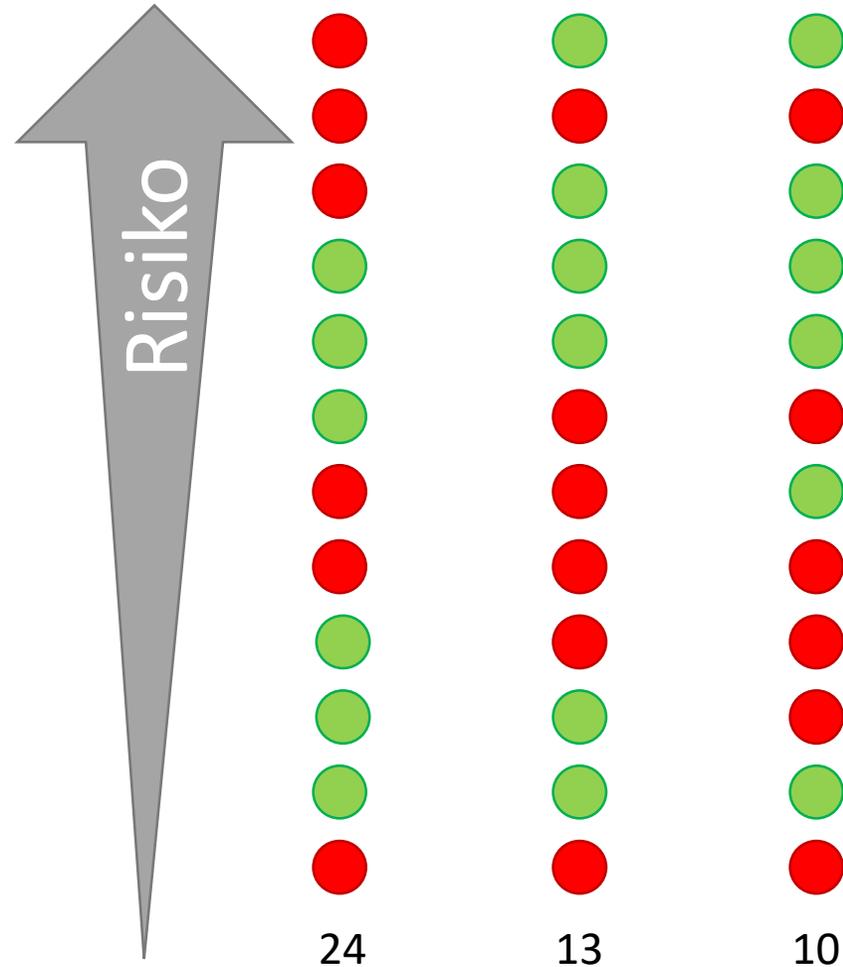
Der Computer bestimmt die Gewichte und bekommt ein Feedback (Rückkopplung), inwieweit die damit resultierende Bewertung tatsächlich mit dem (beobachteten) Verhalten übereinstimmt.



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.

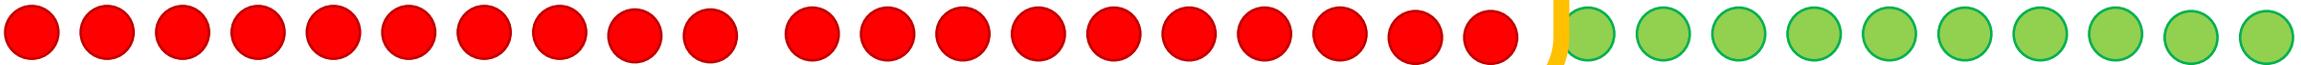
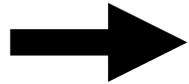
Qualitätsmaß: Paare von rot und grün, bei denen die rote Kugel über der grünen einsortiert ist.

# 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%.

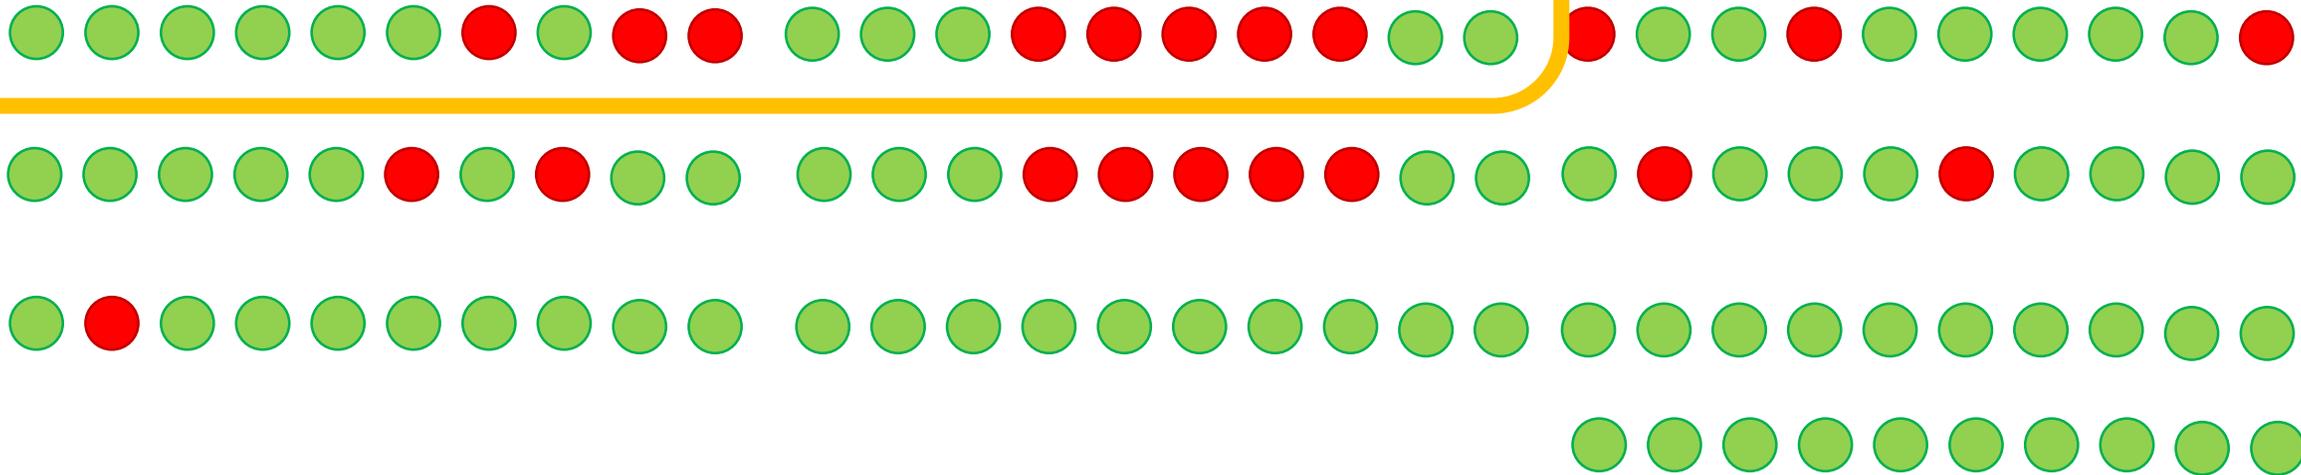
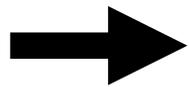
# Optimale Sortierung

**Erwartete 20% „Rückfällige“**



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

**Erwartete 20% „Rückfällige“**





einen Jagdhund zu kaufen,

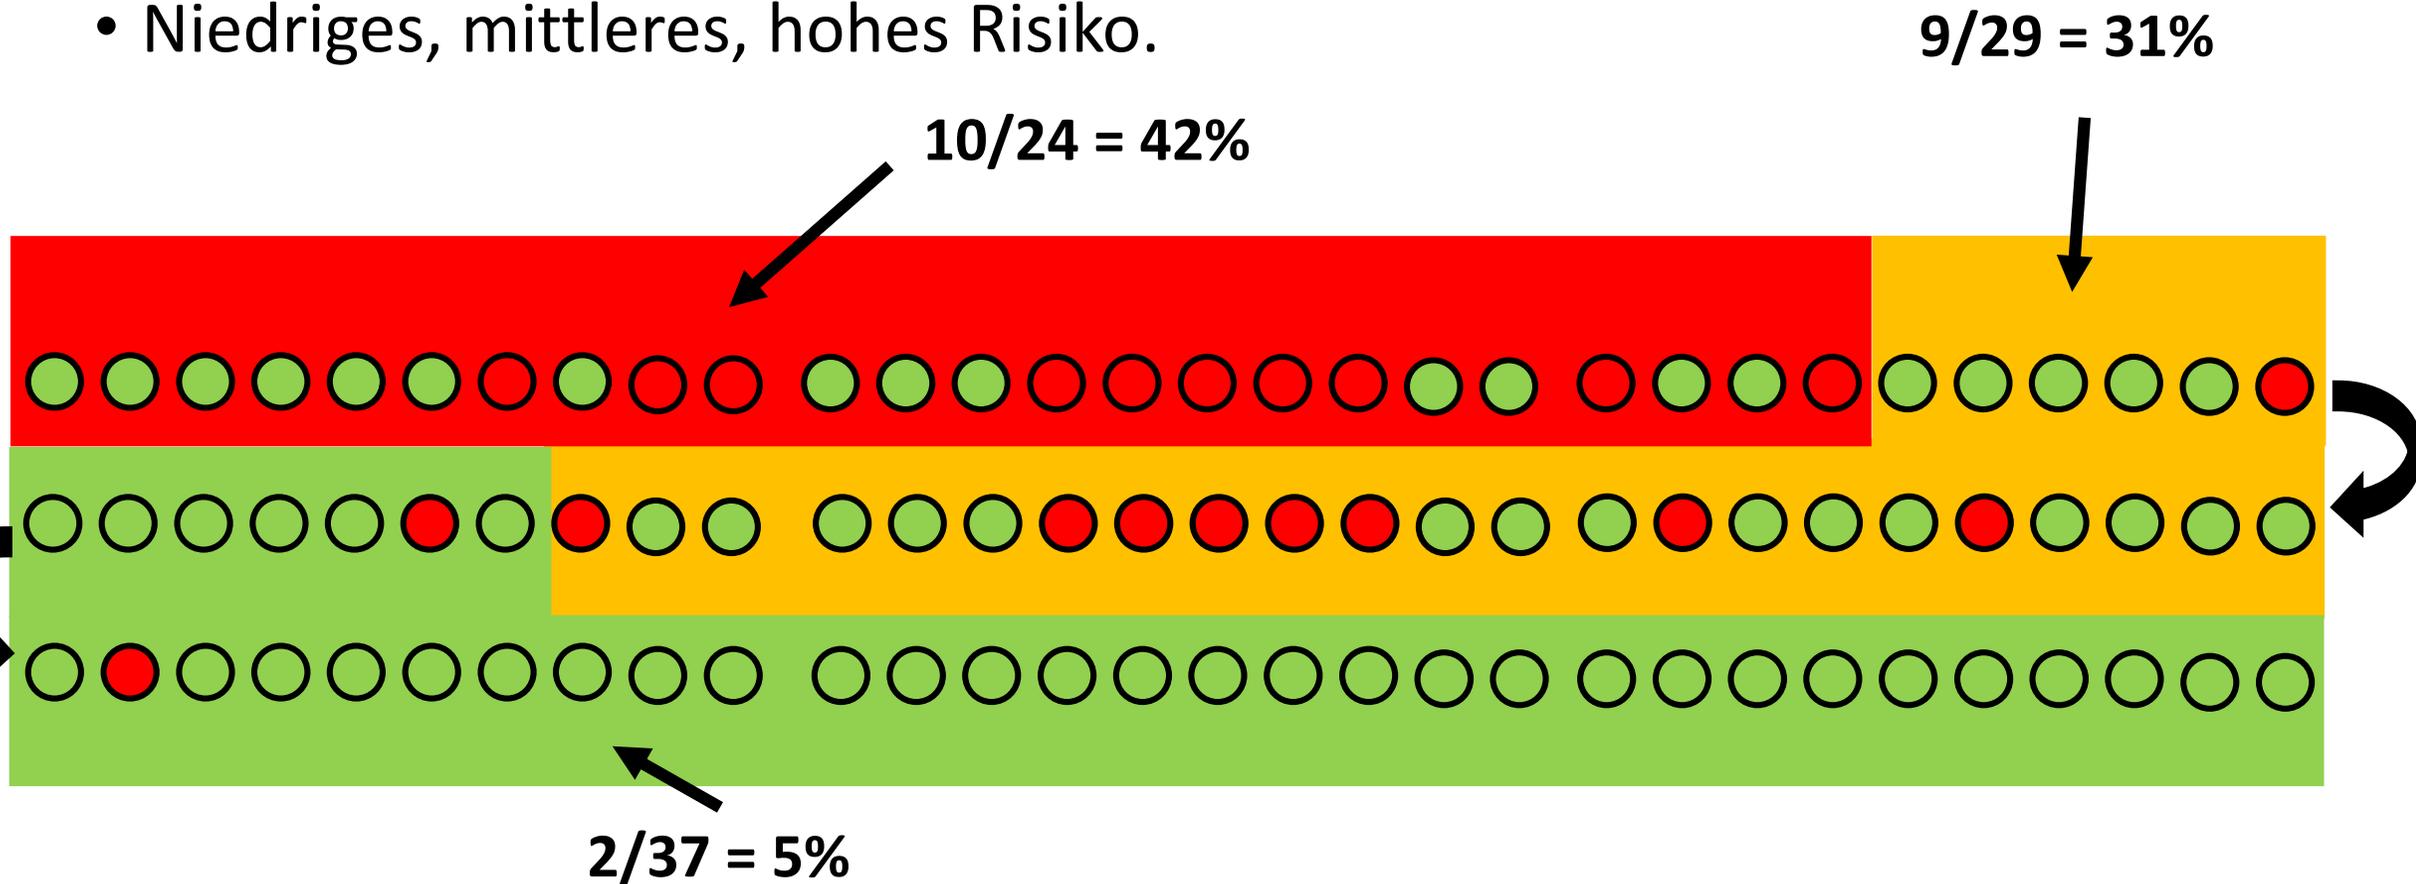


um Schafe zu hüten.

Das ist wie...

# Vom Scoring zur Klassifikation

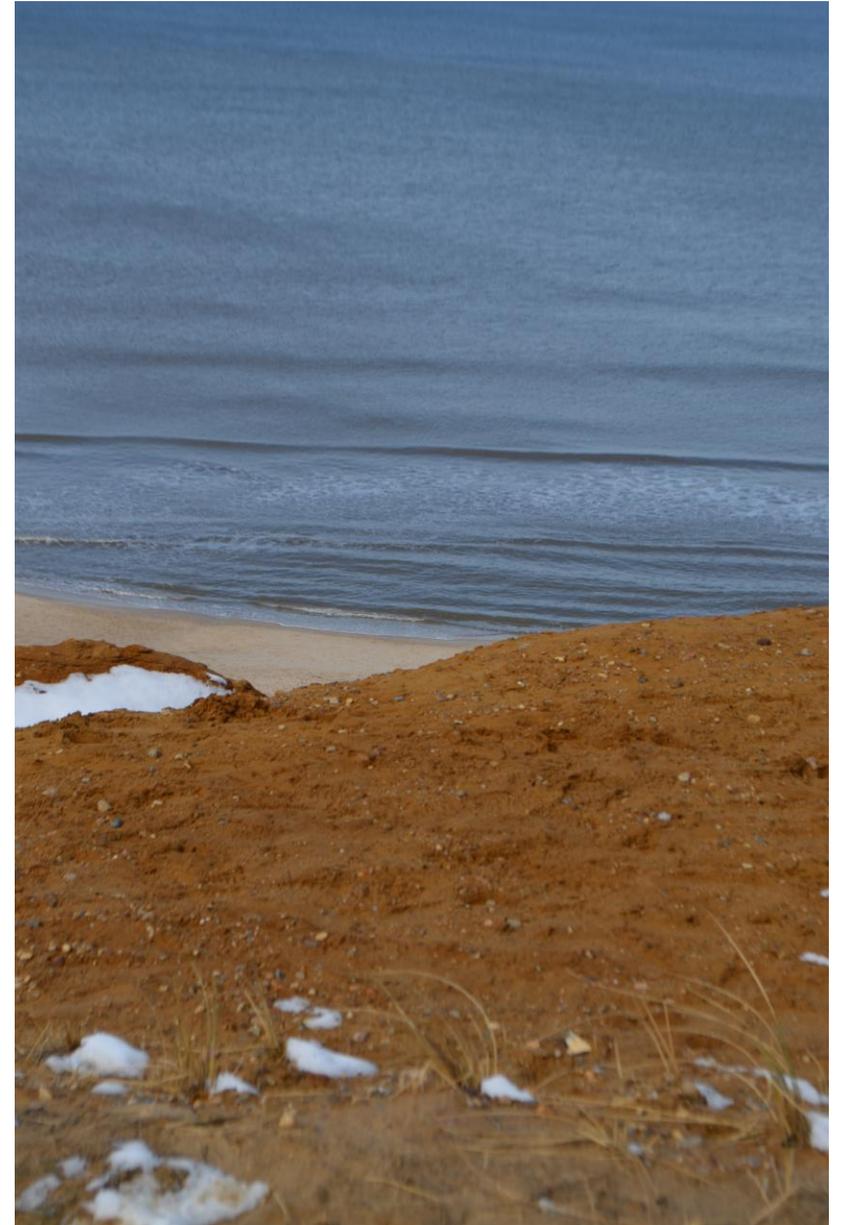
- ACLU fordert: Es soll drei Klassen geben.
- Niedriges, mittleres, hohes Risiko.





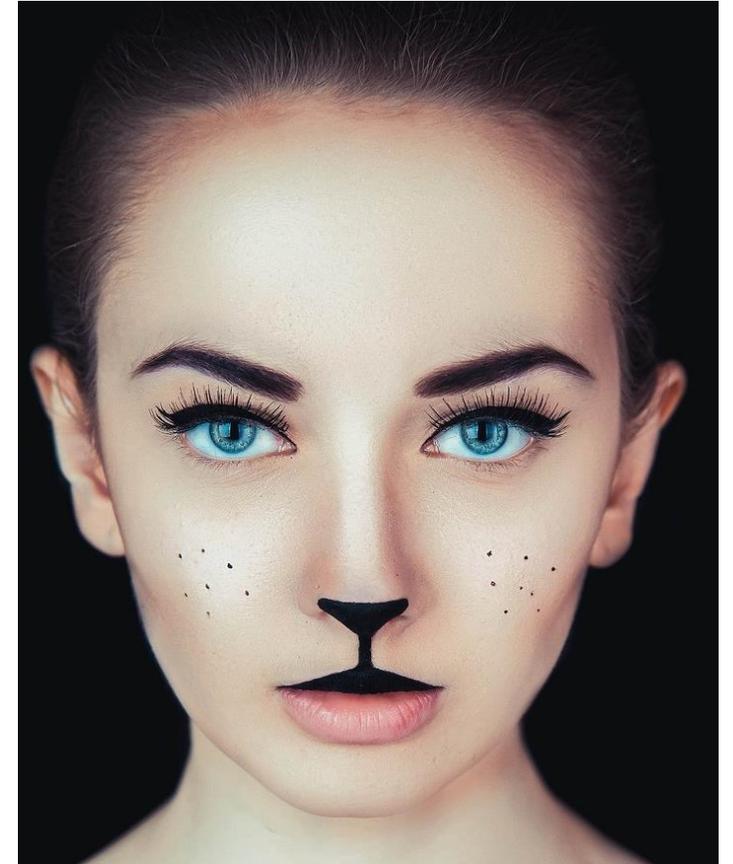
Statistische Vorhersagen |  
über Menschen |

# 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*.



# 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**)



Können uns Algorithmen vor “racial profiling” bewahren?



Können Algorithmen diskriminieren?





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



## Diskriminierung

- Google zeigt weiblichen Surfern schlechtere Jobs an.
- Rückfälligkeitsvorhersagealgorithmen sind rassistisch.
- Diskriminierungen in Trainingsdaten werden „mitgelernt“.
- Wenn Trainingsdaten zu wenig Daten über Minderheiten enthalten, werden deren Eigenschaften nicht „mitgelernt“.



# Algorithmen in einer demokratischen Gesellschaft

# Generell

Prinzipiell können algorithmische Entscheidungssysteme für sehr viele, schwierige Fragestellungen in derselben Art gebaut werden:

- 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....

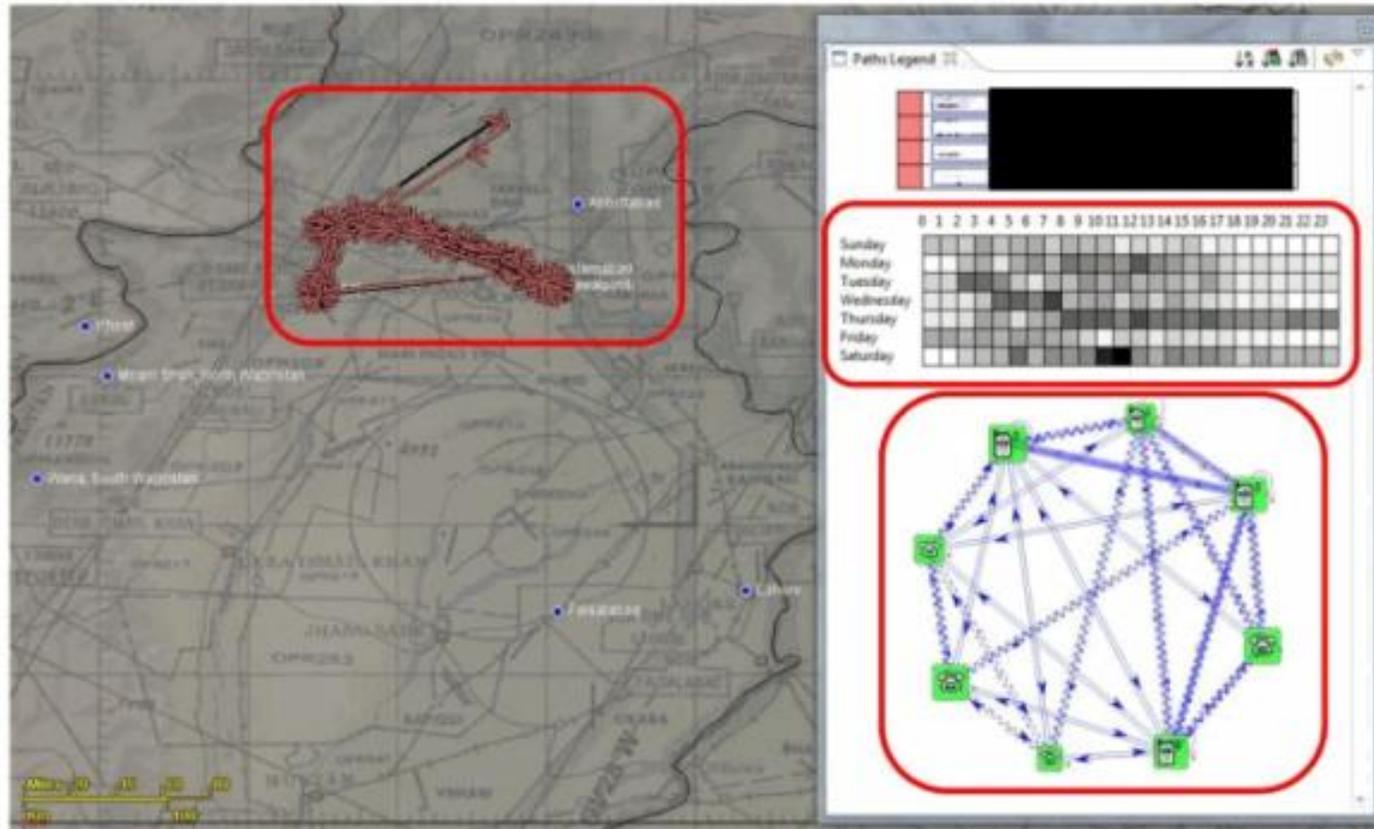
Entwickeln Sie ein  
algorithmisches Entscheidungssystem,  
dass **gewaltbereite Extremisten**  
frühzeitig identifiziert!



# 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		
		Outgoing	43%	1/27k		
+ Anchory Selectors	Random Forest		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

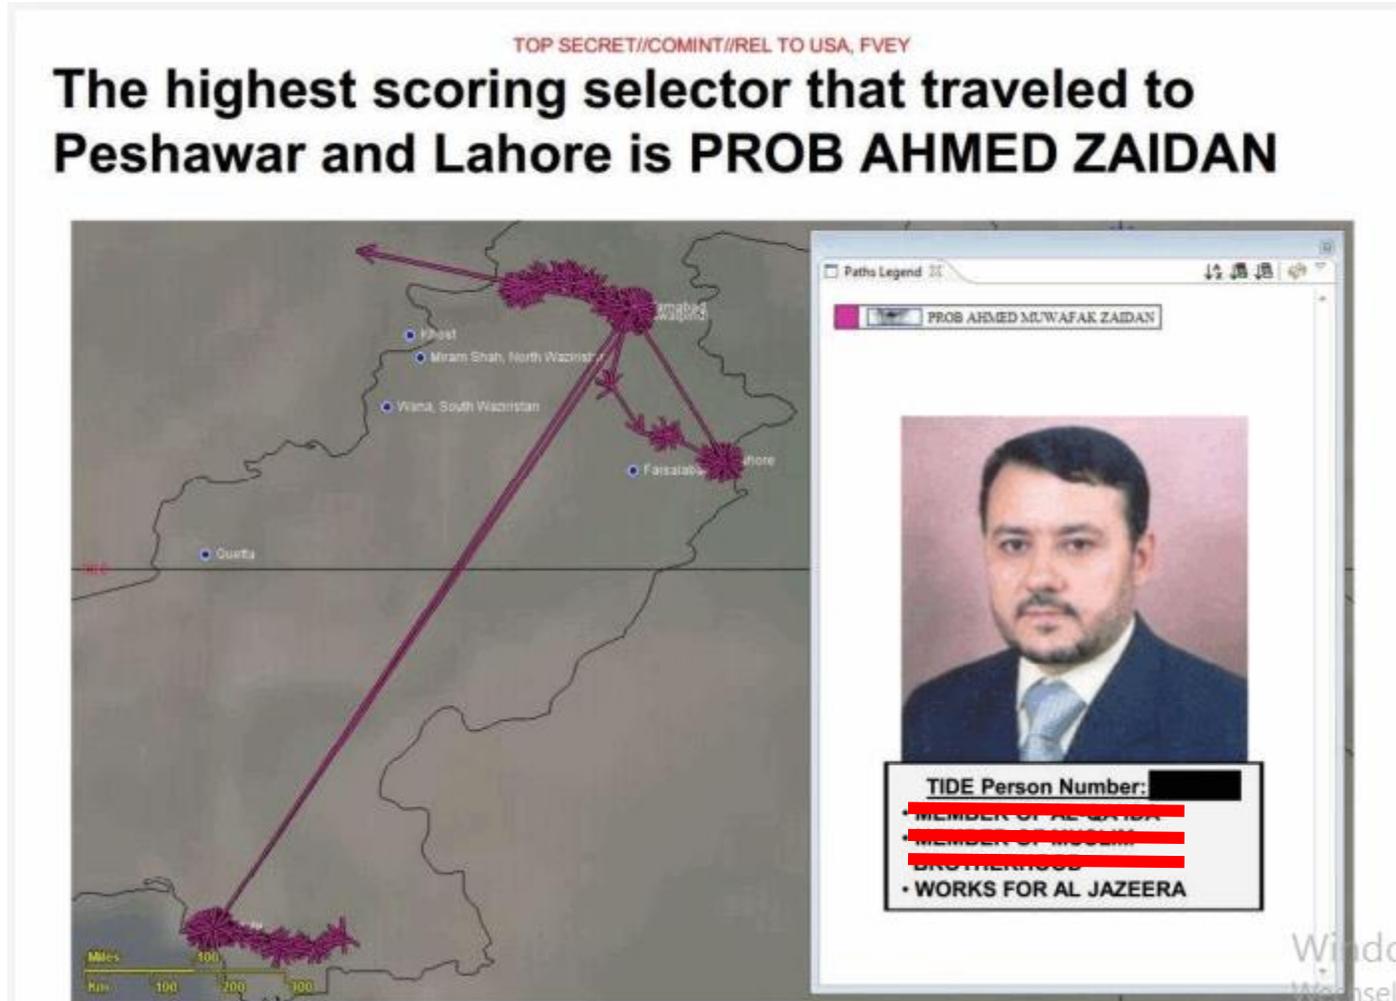
Windows  
Wechseln  
aktivieren

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...





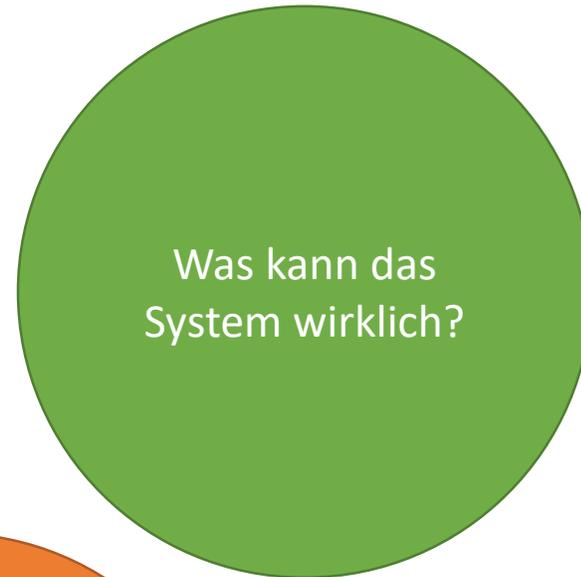
# Sozio-informatische Gesamtbetrachtung

# Probleme der Einbettung der ADM in den sozialen Prozess

- **Aufmerksamkeitsökonomie** von Entscheiderinnen und Entscheidern.
- „**Best practice**“ erfordert Nutzung der Software.
- **Delegierung von Verantwortung!**
- Manchmal kann ein(e) falsch-negativ Beurteilte(r) **die Vorhersage prinzipiell nicht entkräften!**
  - Abgelehnte Bewerber und Bewerberinnen,
  - in Lager verschleppte Verdächtige.



# Sozioinformatische Gesamtbetrachtung

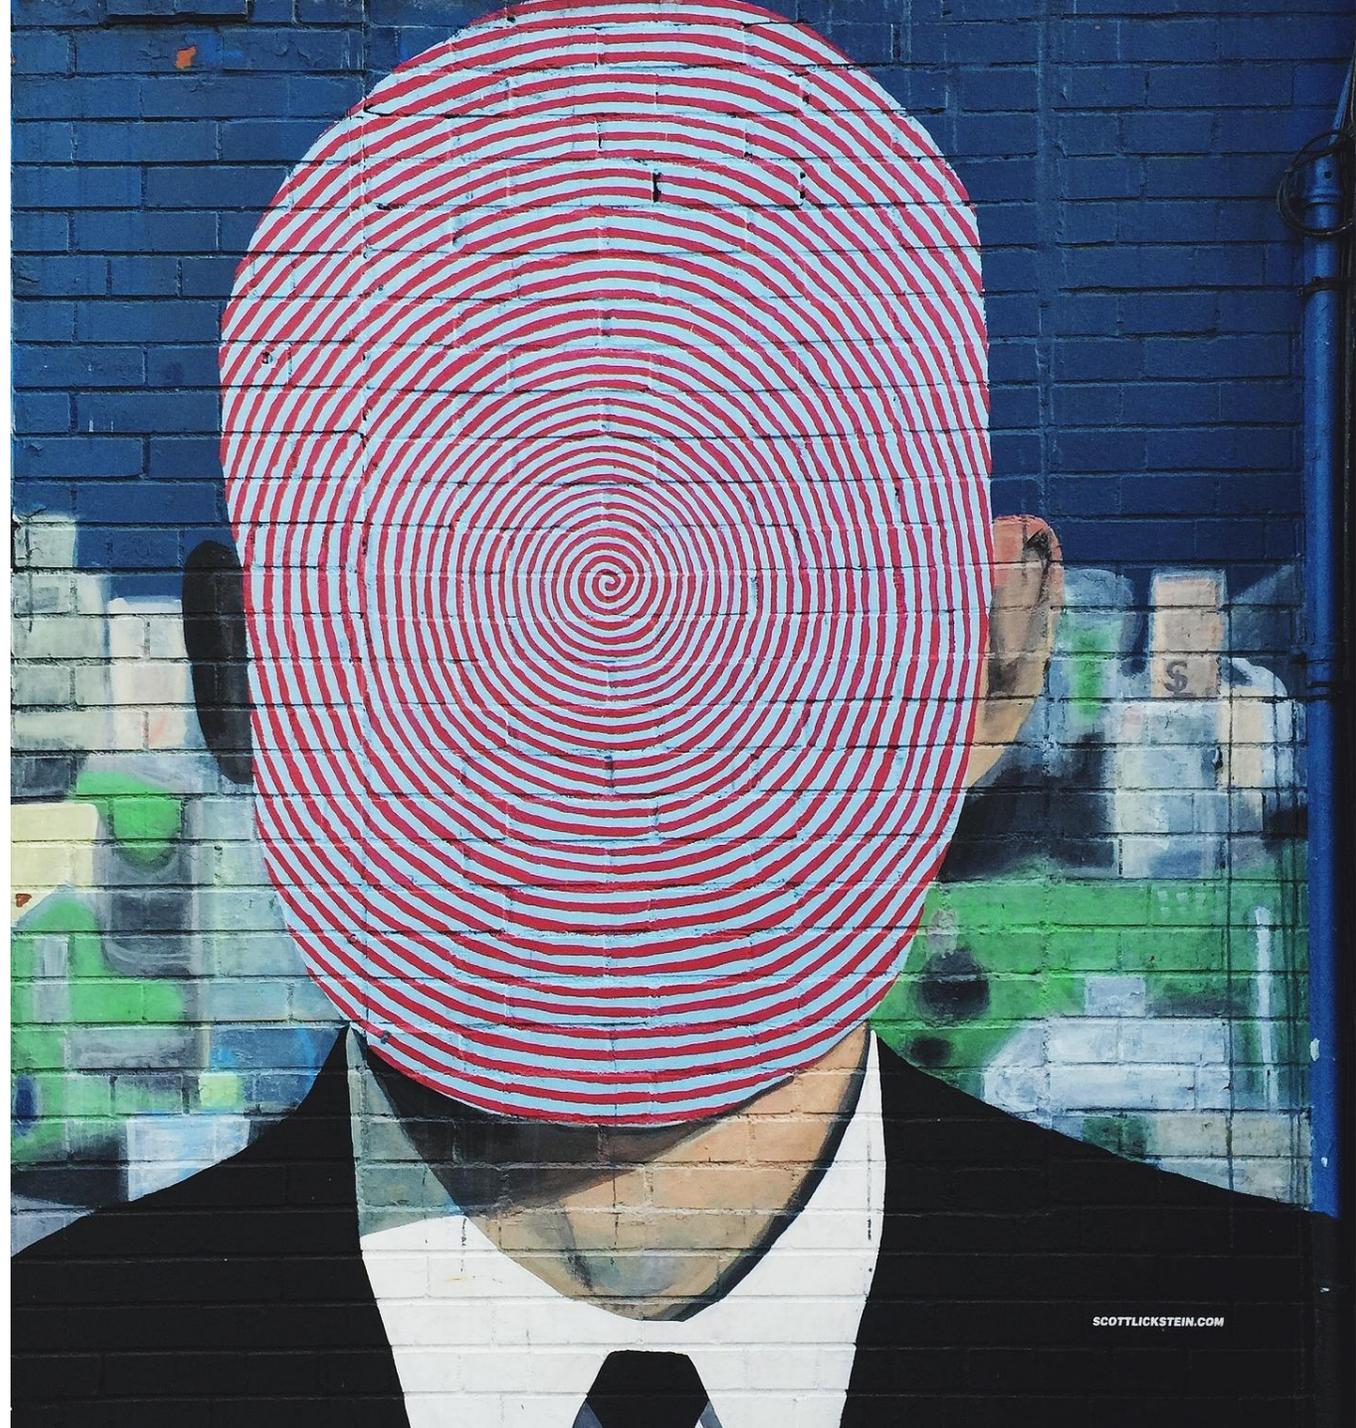


# Ein Beispiel

- **Glaube:** Softwarefirmen vermitteln den Eindruck, „echte“ AI wäre quasi nur noch eine Frage von Jahren:
  - Z.B. Sophia, der erste Roboter, der eine Staatsbürgerschaft erhielt.
  - Aber auch Elon Musk, der warnt vor LAWs, die automatisch ihr menschliches Ziel erkennen und gezielt töten.
- **Fakt:** Die Bilderkennung ist sehr gut bei Standardfotos, weniger gut im Video und in Menschenmengen.
- **Reaktion:**
  - Camouflage-Makeup, veränderter Gang, Haltung, .... machen es noch wahrscheinlicher, dass die falsche Person attackiert wird.
  - „Adversarial AI“: Gegenlernen von Beispielen, die von der ursprünglichen AI falsch interpretiert werden.

# Einschätzung

- Algorithmisch Verfahren **könnten** dabei helfen, bessere Entscheidungen zu treffen.
  - Sie können riesige Datenmengen durchsuchen.
  - Sie könnten neue “Muster” entdecken.
  - Könnten Diskriminierung vermeiden.
- Allerdings sind sie heute oft noch nicht gut genug, insbesondere da, wo sehr wenige Menschen identifiziert werden müssen unter vielen Unschuldigen.



# 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. **Sie helfen kleine Gruppen zu identifizieren, aber mit vielen „falsch Positiven“ (falsch Verdächtigen).**
5. **ADM Systeme können soziale Prozesse verändern.**
6. **Die Reaktionen können das Problem enorm verschärfen.**



# Weitere Informationen



1. Broschüre der Bayerischen Landesmedienanstalt  
Kostenlos zu beziehen von der BLM  
Googlen nach „BLM Dein Algorithmus - meine  
Meinung“

Prof. Dr. Katharina A. Zweig  
[zweig@cs.uni-kl.de](mailto:zweig@cs.uni-kl.de)  
@nettwwerkerin bei Twitter

2. Studie für die  
Bertelsmann-Stiftung (2018)

