



Funktionsweise und Fehlerquellen bei selbstlernenden Algorithmen

Prof. Dr. Katharina Zweig, TU Kaiserslautern

zweig@cs.uni-kl.de

Under CC-BY 3.0 SA

Die jeweiligen Bildrechte sind angegeben oder es handelt sich – nach bestem Wissen und Gewissen um CC 0 Bilder (meistens von Pixabay.com)

Algorithmische Entscheidungssysteme



Verständnis nötig für Sie als:

- Arbeitnehmer, Arbeitgeberin, Entscheider, Bürgerin.

Werden eingesetzt werden:

- In HR zur autom. Leistungsbewertung
- Zur Unterstützung von (Verwaltungs-)Prozessen, z.B. Hartz IV, Gefährderidentifikation
- Fahrerloses Fahren
- Entscheiden über Sie als Bürgerin und Bürger:
 - Filmempfehlungen, Suchmaschinenergebnisse, News Feed-Ergebnisse
 - Kreditwürdigkeit
 -



Am Beispiel der Rückfälligkeits-
vorhersage für Kriminelle

Wie sagt man die Rückfallrate eines
Verbrechers voraus?



Predictive Policing



Wir haben schon
auf Sie gewartet!



**Das wird gerade in
Deutschland
probeweise eingeführt.**

Vorhersagen,
wann und wo
Straftaten
wahrscheinlich
sind basierend
auf bisherigen
Fällen.

Predictive Policing



Ein **Algorithmus**
hat mir geflüstert,
dass Du **fast** ein Krimineller bist.
Dann komm mal mit!



Aber auch: Vorhersagen,
ob ein **Individuum**
straffällig werden könnte!

Beispiel USA:

- 1) Oregon
- 2) Andere Bundesstaaten




Wie können Computer lernen?


K-means clustering, Entscheidungsbäume und Regressionsansätze

Was heißt Lernen?

- In derselben Situation ein vorher gezeigtes Verhalten wiederholen.
- 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 **Generalisierung des Gelernten**.



Computer lernen

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

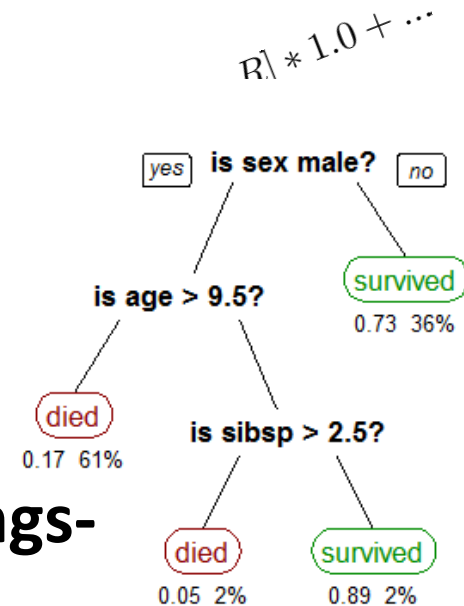
Optimal auch **Rückkopplung**.
Er lernt **generelle Regeln**.



Formel

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

Entscheidungs-bäume





Lernen mit Formeln

Am Beispiel der **individuellen** Vorhersage von zukünftigem kriminellen Verhalten

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 zugec
Zugehörigkeit.
- Wichtig: Beim Trainingsset ist bekannt, ob die Person rückfällig geworden ist oder nicht.





Regressionsansätze

- Die Algorithmen designerinnen und -designer müssen nun entscheiden, welche der Daten vermutlich mit „Rückfallwahrscheinlichkeit“ korrelieren.
- Dies sollte am besten in einer einzigen Zahl münden, so dass man direkt sortieren kann.
- 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
- Bewertet jeweils, wie viele erwiesenermaßen Rückfällige möglichst weit oben stehen.
- Die Gewichtung, die das maximiert, wird für weitere Daten genommen.



Rote Kugeln
symbolisieren
rückfällige, grüne
resozialisierte
Personen.

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





- Das oben genannte Qualitätsmaß dieses Algorithmus: 72 von 100 Paaren werden korrekt sortiert.
- Der in Oregon benutzte Algorithmus hat also, gegeben einen „Rückfall“ und einen „Nichtrückfall“, eine Chance von ca. 1:3 den Rückfall höher zu gewichten als den Nichtrückfall.
- Nur 25% aller so gemachten Prognosen sind falsch!
 - Das klingt doch ganz gut, oder?
- 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“



Das ist wie...



„Kaufen Sie diesen wunderbaren Wagen. TÜV? Brauchen Sie nicht! Und sehen Sie nur, die unglaublich gut erhaltenen Sommerreifen. Das ist noch Qualität!“





Zweig'sche 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**)

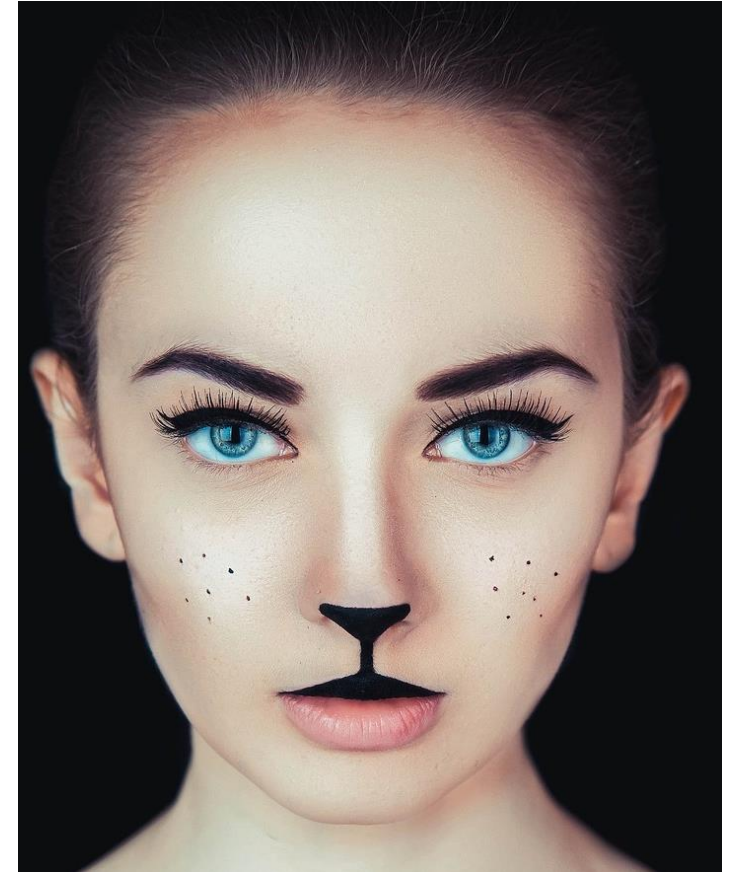
Wenn es **einfache Regeln zur Entscheidungsfindung** gäbe, **kennten wir sie schon**.



Statistische Vorhersagen über Menschen

Zu 70% ein Krimineller....

- Wenn dieser Mensch eine Katze wäre und 7 Leben hätte, würde er in 5 davon wieder rückfällig werden...
- Nein!
- **Algorithmische Sippenhaftung**
 - Von 100 Personen, die „genau so sind wie dieser Mensch“, werden 70 wieder rückfällig;
 - Mitgefangen, mitgehungen;
 - In einer dem Delinquenten (der Delinquentin) völlig unbekanntem, algorithmisch bestimmten „Sippe“.





Sozio-informatische Gesamtbetrachtung

Probleme



- Aufmerksamkeitsökonomie der Richter und Richterinnen.
- „Best practice“ erfordert Nutzung der Software.
- Eine Nichtbeachtung der Empfehlung und gleichzeitige Fehleinschätzung wirkt viel schwerer als eine Beachtung der Empfehlung.
- Grundlegende Modellierung und Datenqualität kann schlecht sein.
- Der ins Gefängnis geschickte Delinquent **kann die Vorhersage prinzipiell nicht entkräften!**
 - Dies gilt auch für: Kreditvergaben, Bildungsangebote, Jobs, Personen, die von Drohnen erschossen werden oder als Terrorist eingesperrt werden, ...

Generell




Gilt auch für:

- Automatische Leistungsbewertung, Bewerberdurchsicht
- Gefährder-, Terroristenidentifikation
- Kreditvergabe
- Schulische und universitäre Ausbildungen, die durch algorithmische Entscheidungssysteme unterstützt werden
- ...



Algorithmen in einer demokratischen Gesellschaft

Verkettete Verantwortlichkeiten



Wer überwacht die Auswirkungen auf die Gesellschaft?

Medien?
Gesellschaft?
Politik?
Institutionen?
Firmen?
Recht?



Quis custodiet ipsos algorithmos

Der „Automated Decision Making“-TÜV vulgo: „Algorithmen TÜV“ (Kenneth Cukier und Viktor Mayer-Schönberger: „Big Data“)

Gründung von „Algorithm Watch“




ALGORITHM
WATCH



Lorena Jaume-Palasi, Mitarbeiterin im iRights.Lab



Lorenz Matzat, Datenjournalist der 1. Stunde, Gründer von lokaler.de, Grimme-Preis-Träger



Matthias Spielkamp, Gründer von iRights.info, ebenfalls Grimme-Preis-Träger, Vorstandsmitglied von Reporter ohne Grenzen.



Prof. Dr. K.A. Zweig, Junior Fellow der Gesellschaft für Informatik, Digitaler Kopf 2014, TU Kaiserslautern



Notwendige Eigenschaften

- Unabhängige Prüfstelle mit Siegelvergabe
- Möglichst auch mit Forschungsauftrag
- Identifikation der **kleinstmöglichen Menge** an zu überprüfenden Algorithmen
 - Die meisten Algorithmen sind harmlos;
 - Produkthaftung ermöglicht, dass andere, z.B. Versicherungen, Interesse an korrekten Algorithmen haben;
 - Wettbewerb ermöglicht, dass andere ‚neutralere‘ Algorithmen anbieten.
 - **Kein weiteres Innovationshemmnis!**
- **Non-Profit**

Beipackzettel für Algorithmen



Welches Problem „kuriert“ der Algorithmus?

Was ist das Einsatzgebiet des Algorithmus, was seine Modellannahmen?

Welche „Nebenwirkungen“ hat der Algorithmus?

Schlussformel



... zu Risiken und Nebenwirkungen der Digitalisierung befragen Sie bitte Ihren nächstgelegenen Data Scientist oder den deutschen Algorithmen TÜV.