



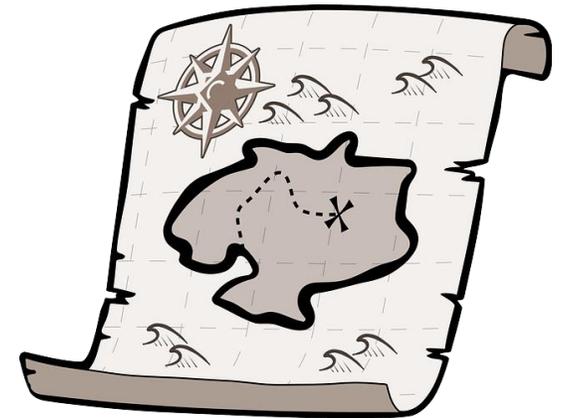
Universität Regensburg

Modellgültigkeit

Generalisierungsorientierte Modellierungskultur

Themenfelder

- Ziele einer empirischen Wissenschaft
- Kleiner Überblick Machine Learning
- Vergleich moderner und klassischer statistischer Methoden in der Forschung
- Prediction Performance: Gültigkeit für neue Daten
- Concept Drift: Verlust von Modellgültigkeit über Zeit
- Zusammenfassung und Perspektive



Ziele einer empirischen Wissenschaft

1. Beschreibung

- **Deskriptive Statistik:** Zusammenfassende Maße und Grafiken, um die Daten verständlich zu machen

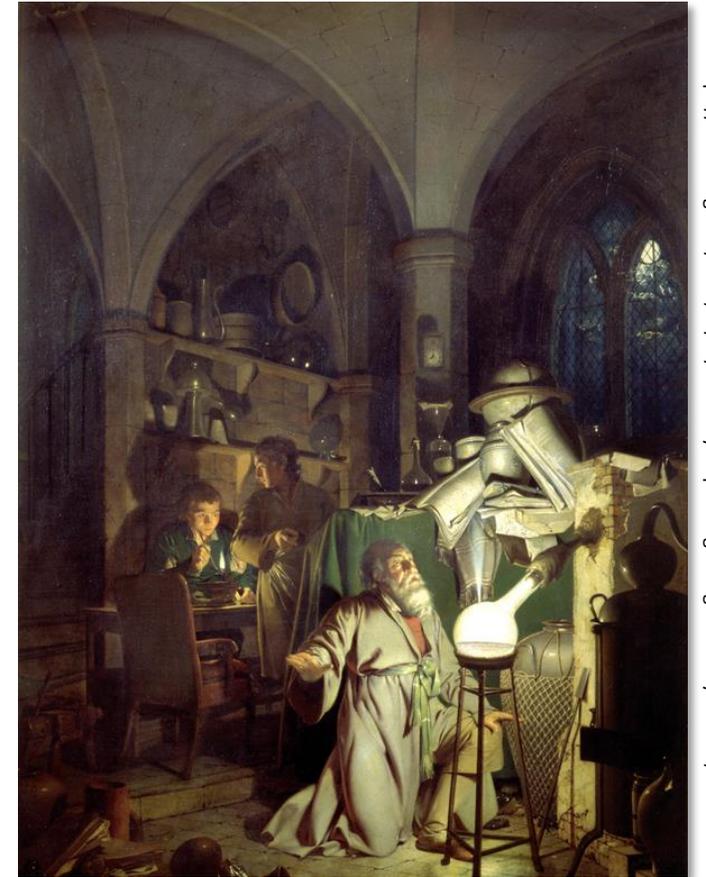
2. Erklärung

- **Inferenzstatistik:** Schätzen von Modellparametern, welche Zusammensetzung und –hänge der Daten modellieren

3. Vorhersage

- **Machine Learning:** Vorhersage neuer Daten, nachdem ein Modell durch Resampling und einen Lernalgorithmus trainiert wurde

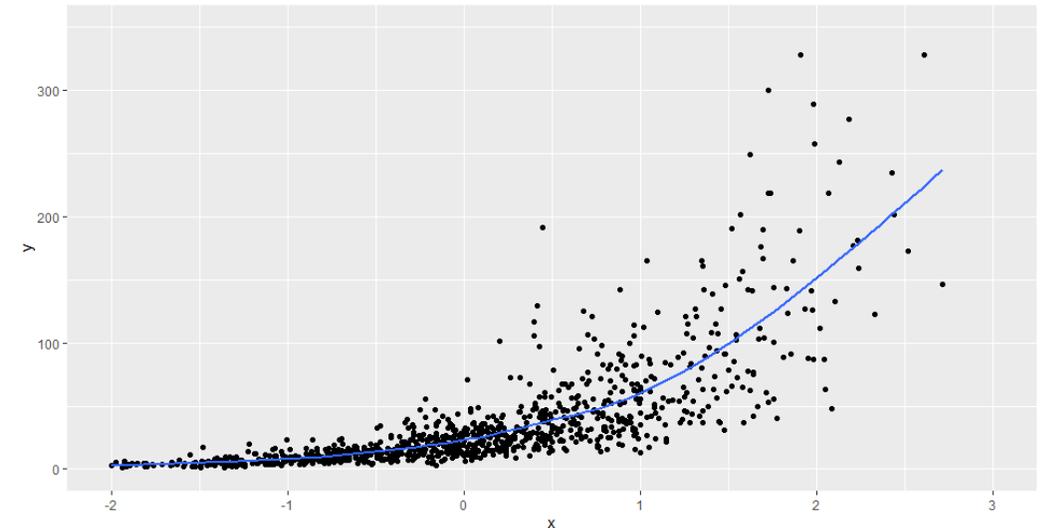
➤ Verallgemeinerung über **Raum** und **Zeit** ist Ziel



<https://electrlight.co/2016/02/17/the-story-in-paintings-enlightened-by-science/>

Leo Breiman: Zwei Kulturen der Statistik

- Starke **theoretische Vorannahmen** über den datengenerierenden Prozess
 - z.B.: Exponentieller Zusammenhang
 - Klassische Statistik
 - Fokus auf Erklärung und Modellannahmen
 - p -Werte für Inferenz
- Annahme eines **unbekannten** datengenerierenden Prozesses
 - Machine Learning
 - Fokus auf **Vorhersagegüte**
 - Schätzung des Generalisierungsfehlers



Annahmen klassischer Modelle

- **Allgemeines Lineares Modell**

- Normalverteilung der Fehler

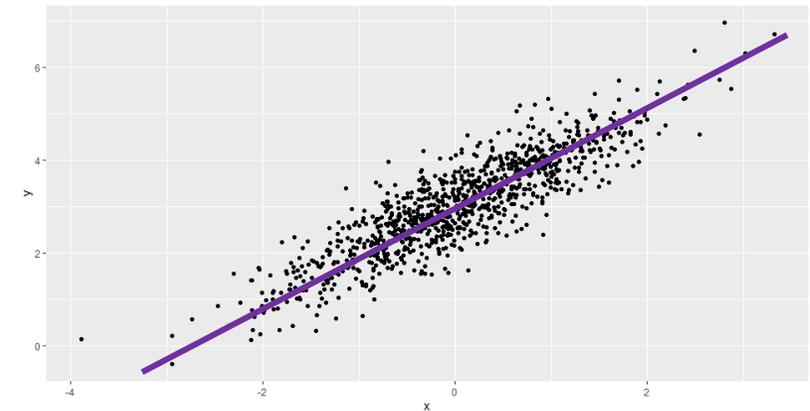
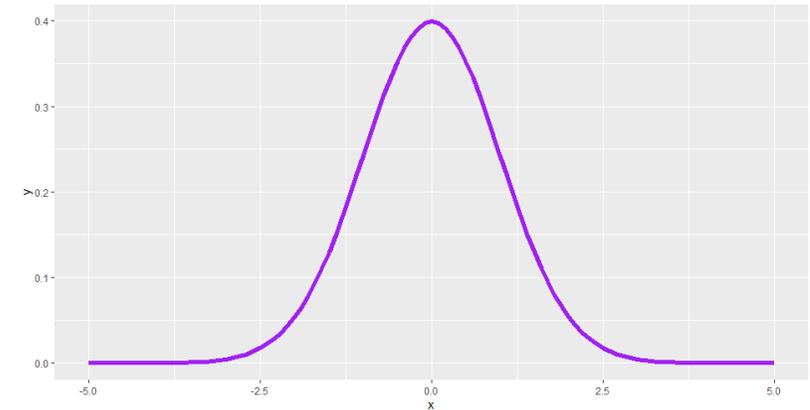
$$\varepsilon \sim N(0; \sigma^2)$$

- Lineare Zusammenhänge

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

- **Verallgemeinertes Lineares Modell**

$$y = g(\beta x + \varepsilon)$$



Drei Phasen nach Efron & Hastie

Die Phasen der statistischen Modelle im 20. und 21. Jahrhundert (grob eingeteilt):

1. Klassische Inferenzstatistik
 - ALM, GLM etc.
2. Computationale Methoden
 - Bayesianische Statistik, Bootstrap
3. Computerintensive Methoden
 - Machine Learning



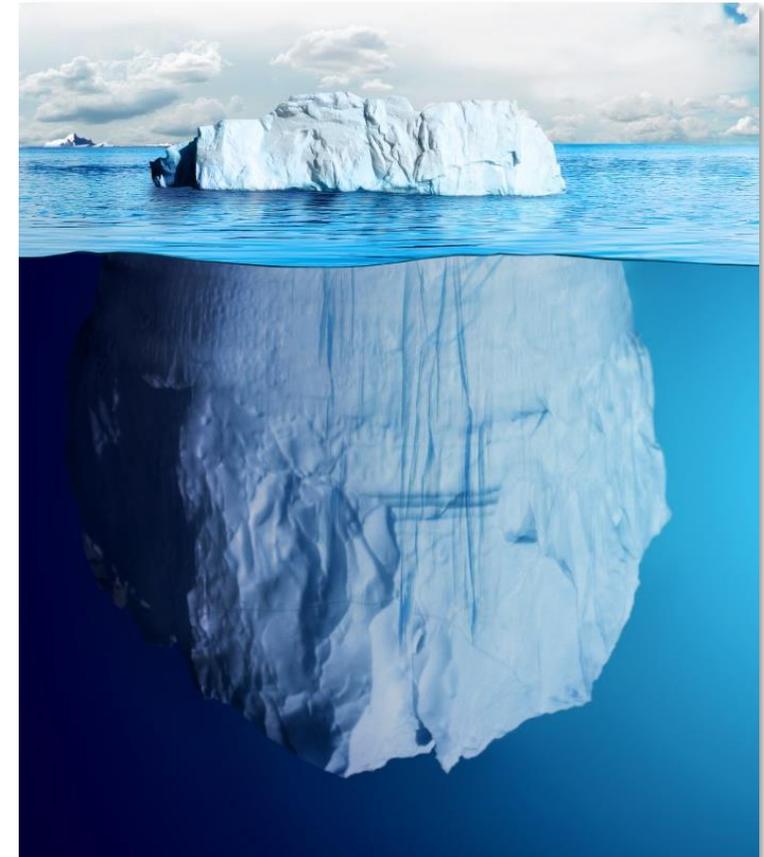
Kleiner Überblick Machine Learning

Modellarten

- Baumbasierte Modelle
 - Random Forest, Boosting
- Kernelbasierte Modelle
 - Support Vector Machines
- Deep Learning
 - Neuronale Netzwerkmodelle

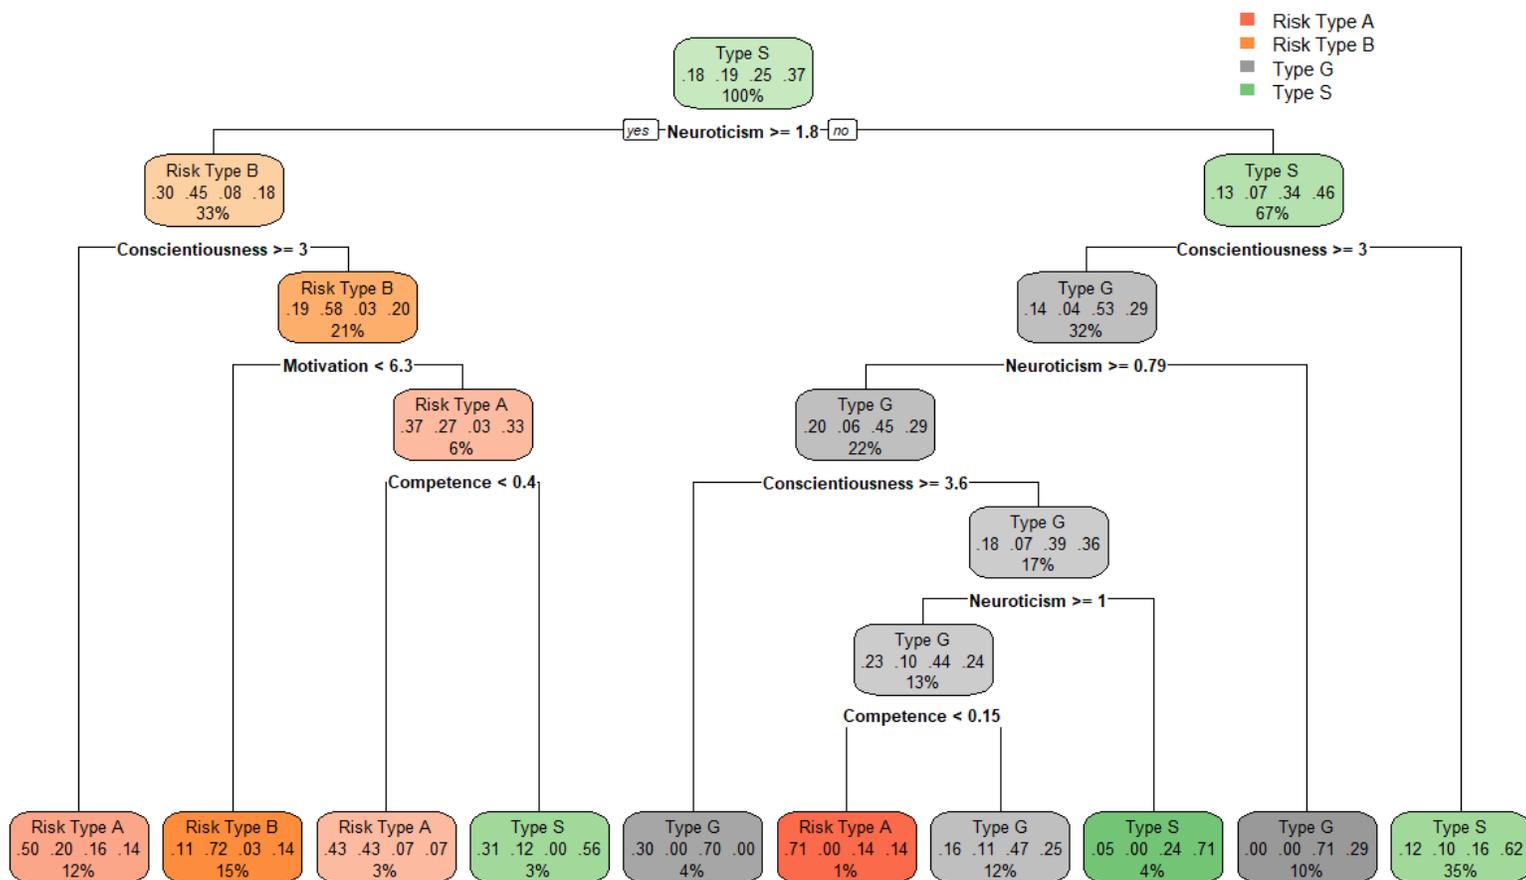
Eigenschaften

- Nutzen von **Resampling**
- **Optimiert auf Vorhersage** neuer Daten
- Weitgehend ohne direkt interpretierbare Parameter
- Hohe Funktionalität mit vielen Variablen und Daten



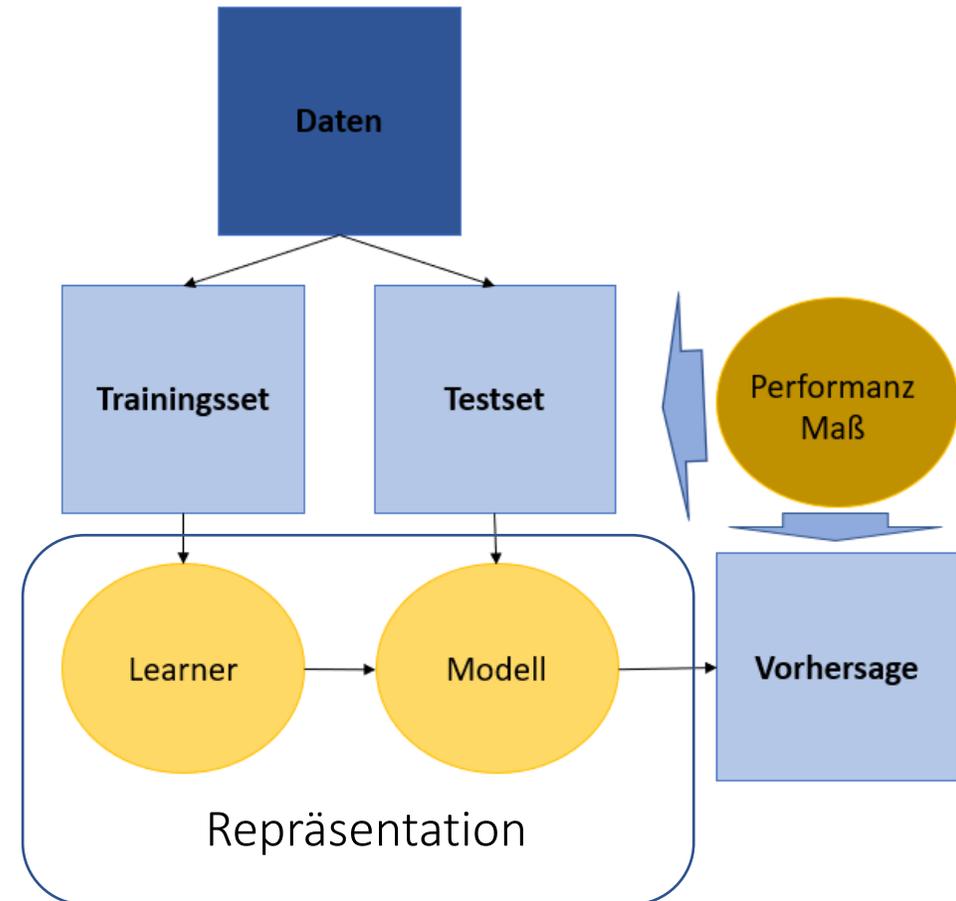
Beispiel Entscheidungsbaum

Klassifizierung von vier Arbeitstypen



Resampling

- **Nutzen von Trainings- und Testsets**
 - Durch Resampling wird ein Learner zum Modell trainiert
 - **Performanzmaß für den Generalisierungsfehler**
 - Vergleich verschiedener Modelltypen
- Modell mit **akkuratester Vorhersage** wird genutzt



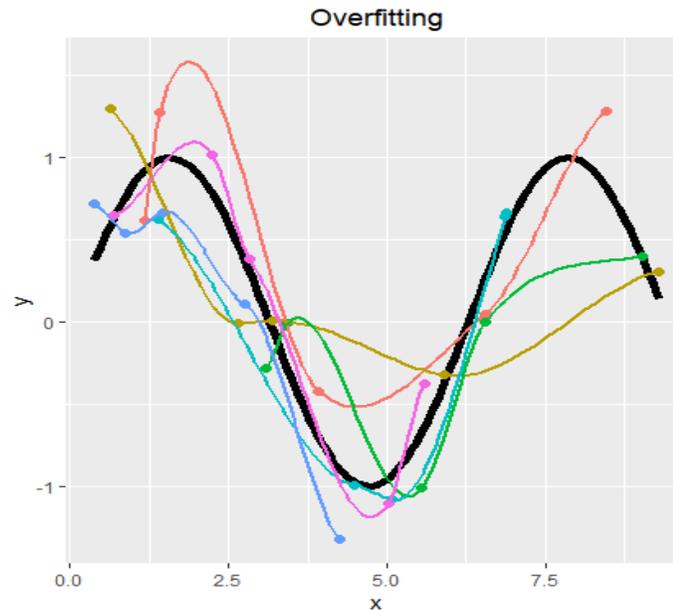
Over- und Underfit

- **Overfitting**

- Zu starke Anpassung an die Stichprobendaten

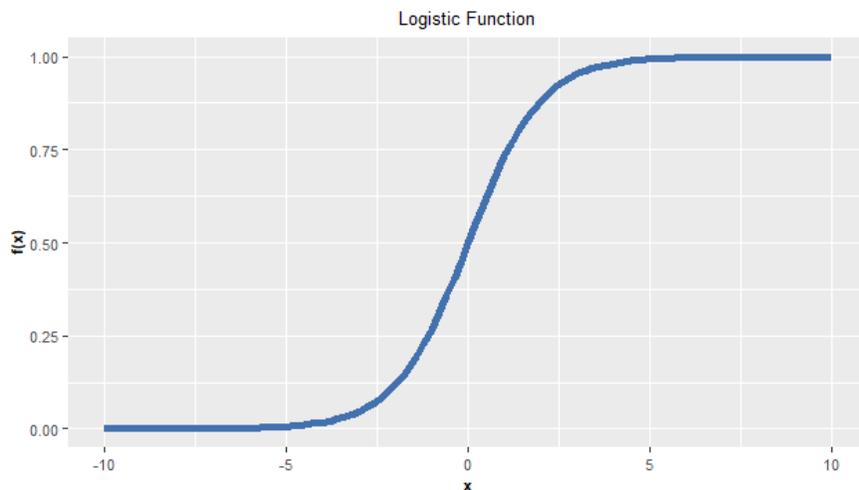
- **Underfitting**

- Zu geringe Anpassung an die Stichprobendaten

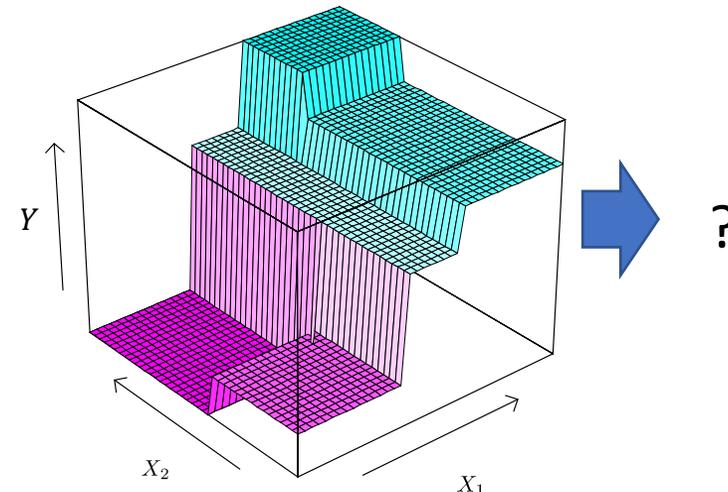


Vergleich Klassifizierungsmodelle

- Klassischerweise wird die **logistische Regression** zur (dichotomen) Kategorisierung genutzt
 - Interpretierbare Parameter, allerdings wenig flexibel beim Datenfit
- **Baumbasierte Machine Learning Modelle** sind flexibler
 - Allerdings Interpretierbarkeit oft schwierig und Extrapolation begrenzt



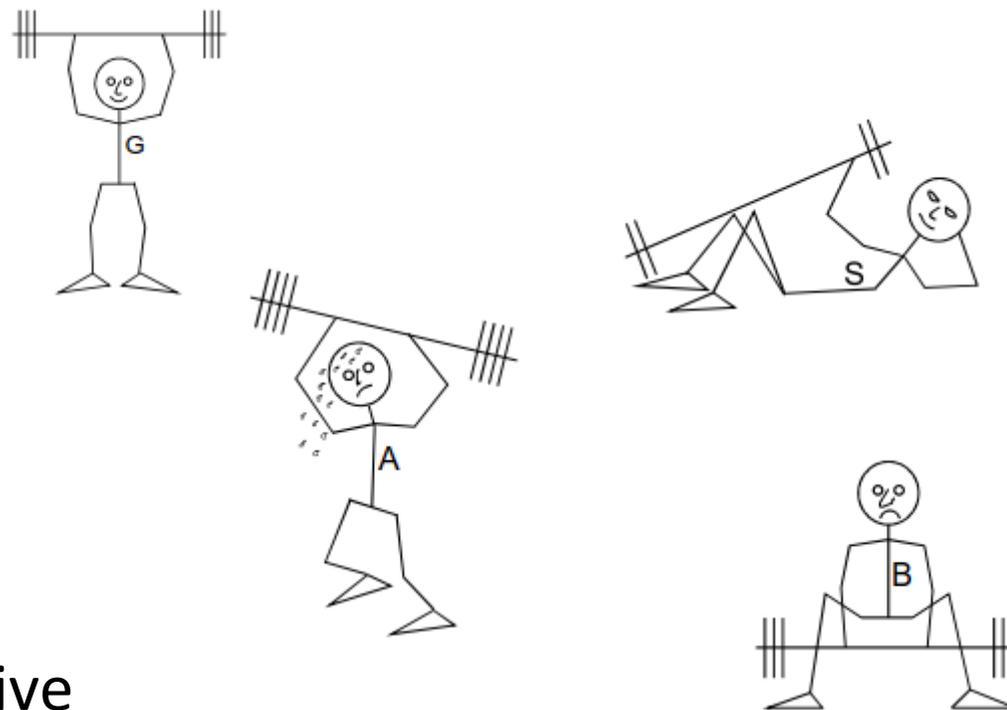
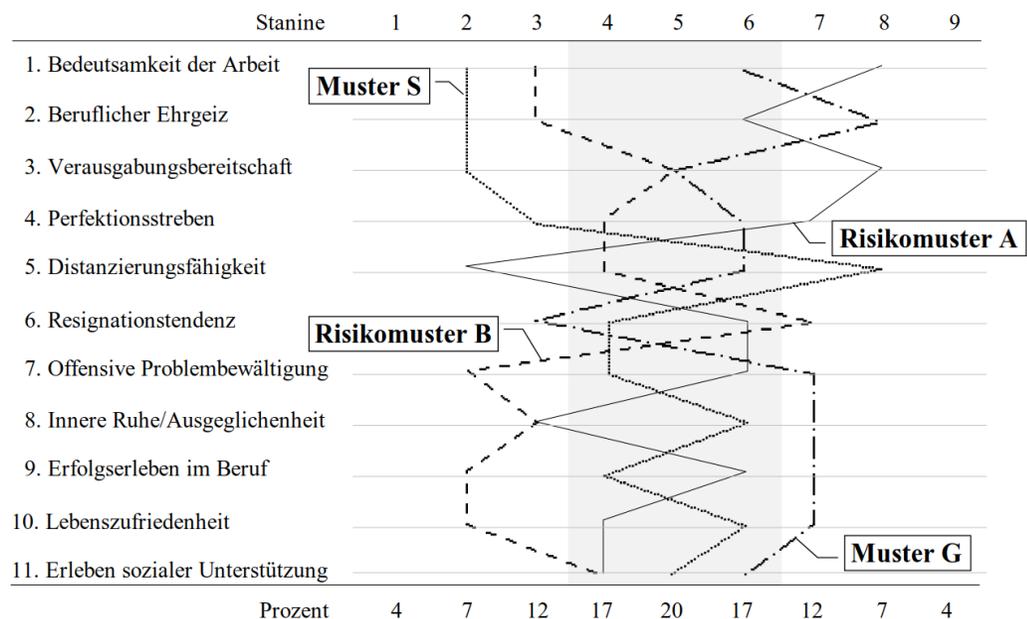
$$\frac{e^x}{1 + e^x}$$



Exemplarische Studie Persönlichkeitstypen

Universität Regensburg

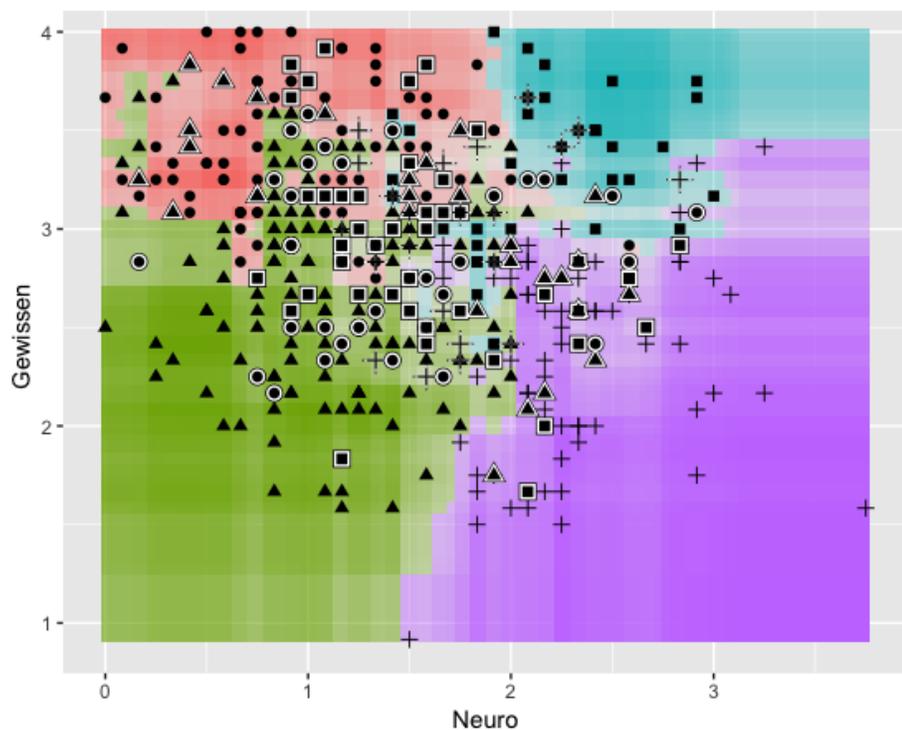
- AVEM: arbeitsbezogene Verhaltens- und Erlebnismuster (Schaarschmidt & Fischer, 1996) Modell an $N = 478$ Lehrern erhoben



➤ Versuch der Vorhersage durch die Big Five

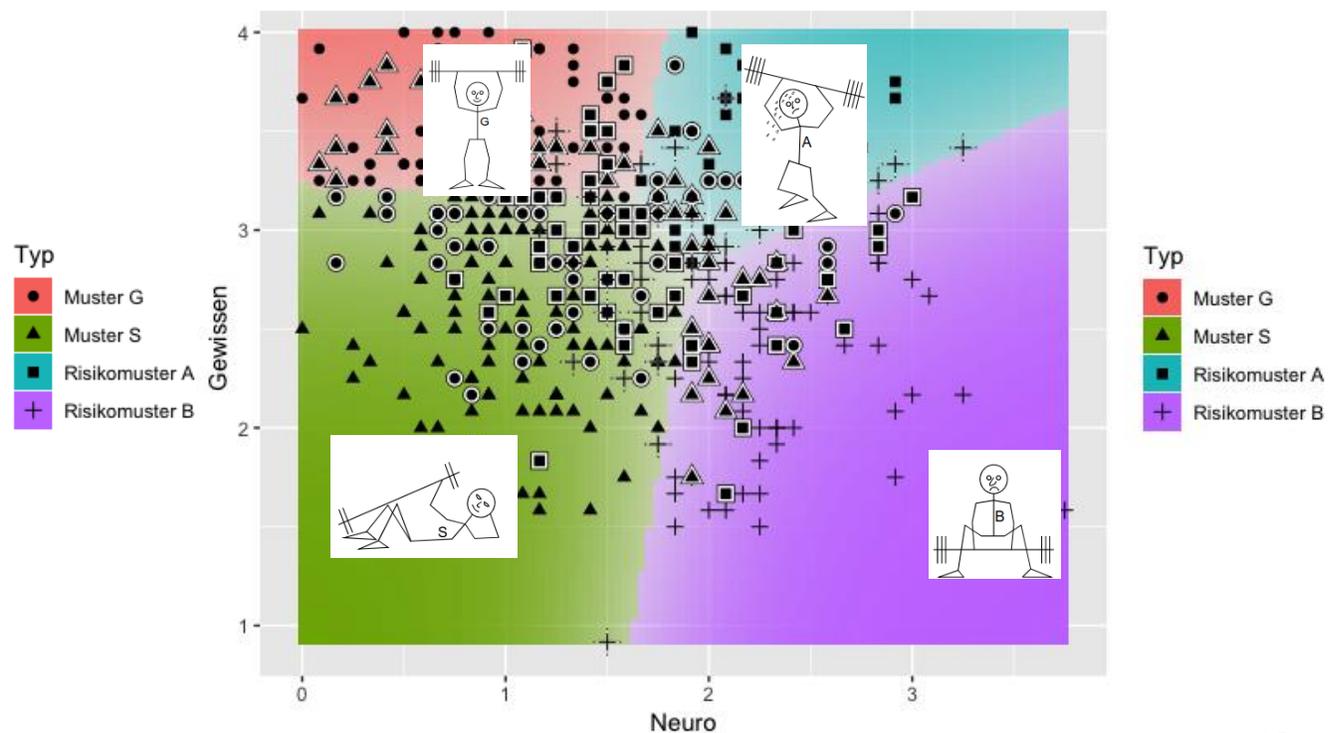
Zwei Modellierungen: **Random Forest** und **Regressionsmodell**

Modell mit höchster Vorhersagekraft



Sven Hilbert

Modell mit bester Interpretierbarkeit



Modellgültigkeit über Zeit

- Vorhersagegüte eines Modells gilt nur für den Zeitpunkt der Modellbildung
- Auch Modelle können Anachronismen werden
 - Gültigkeit von Modellen lässt in manchen Fällen nach
- Phänomen ist unter dem Namen **Concept Drift** bekannt



Gründe für Concept Drift

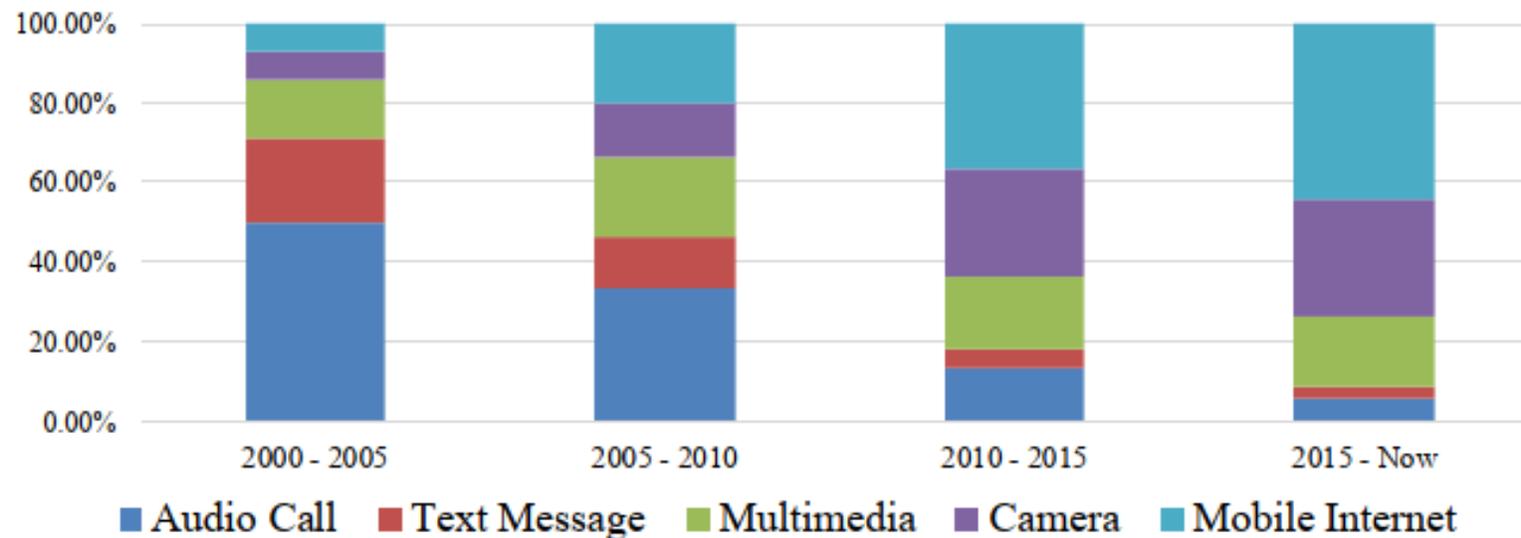
- Fragebogenitems können aus der Zeit fallen
 - **Anzahl von Fachbüchern** im Regal wird durch digitale Medien weniger aussagekräftig
- Es können plötzliche Veränderungen auftreten
 - Bildungsreformen
 - Lehrpläne können sich ändern
- Datenströme können sich ändern
 - Facebook Nutzung wird ein immer schlechterer Prädiktor für Prokrastination



Visualisierung Concept Drift

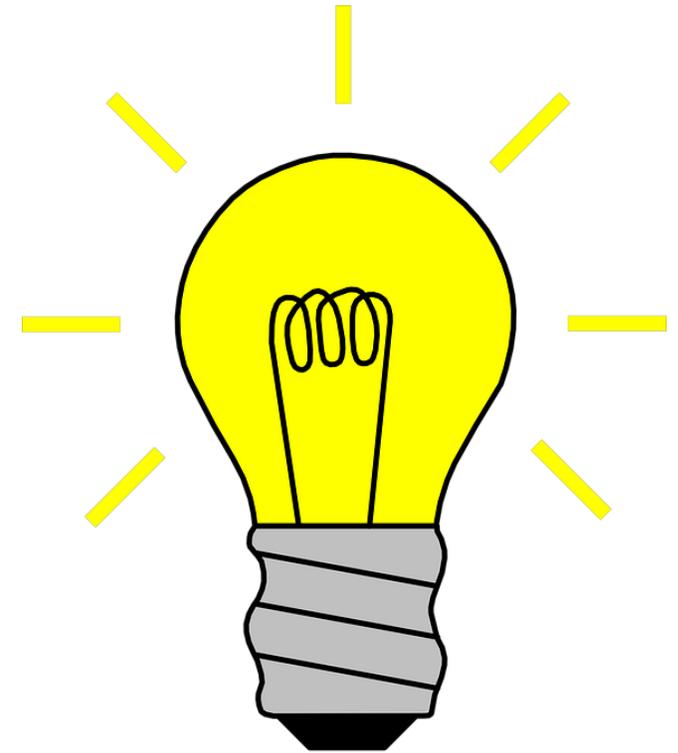
Studien zur Smartphone Nutzung

- Lu et al. (2018)



Methoden gegen den Concept Drift

- Zusammenfassen von Daten zu Kategorien
 - Nutzung von Kommunikationsmedien als Kategorie
- Technische Lösungsansätze
 - Beobachtung der Stabilität der Vorhersagegüte
 - Implementation in den Algorithmus
- Kontinuierliche Überprüfung mit Testsamples
 - Den bei Modellerstellung etablierten Generalisierungsfehler als Benchmark nutzen



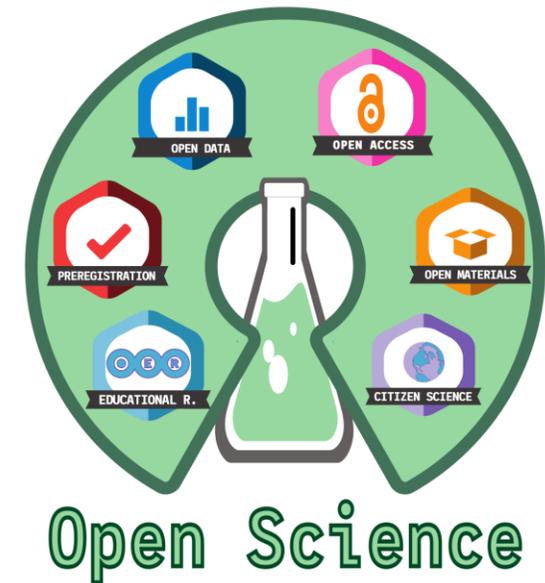
Techniken zur **Erhöhung** der **Modellgültigkeit**

- Modellgültigkeit durch Vorhersagegüte **überprüfen**
 - **Overfitting** und Überinterpretation von p -Werten vermeiden
 - **Vorhersage** mit **Beschreibung** und **Erklärung** verbinden
- **Kontinuierliche Überprüfung** der Modelle
 - Generalisierungsfehler wiederholt schätzen
- Weiterer wichtiger Punkt: **Open Science**



Open Science

- Open Science ist ein wichtiger Aspekt glaubwürdiger empirischer Forschung
 - Bereitstellung der Daten ist ein wichtiger Beitrag zu Überprüfbarkeit der Modelle
 - Möglichkeit zur Bildung neuer Modelle anhand von Daten
- Eine breite Datenbasis ist die wichtigste Grundlage für die Schätzung gültiger Modelle



www.osf.io



Universität Regensburg

Vielen Dank

Literatur

Efron, B., & Hastie, T. (2016). *Computer age statistical inference* (Vol. 5). Cambridge University Press.

Lu, J., Liu, A., Dong, F., Gu, F., Gama, J., & Zhang, G. (2018). Learning under concept drift: A review. *IEEE Transactions on Knowledge and Data Engineering*, 31(12), 2346-2363.

Schaarschmidt, U., & Fischer, A. (1996). *AVEM: arbeitsbezogene Verhaltens- und Erlebnismuster*. Swets Test Services.