


— MATHIAS ELLMANN —

# KRITISCHES DENKEN IN DATA SCIENCE MIT PYTHON

Vom Beobachten  
zur verantwortbaren Entscheidung



## Kritisches Denken in Data Science mit Python

Vom Beobachten zur verantwortbaren Entscheidung

Mathias Ellmann

ISBN: 978-3-6952-6078-2

# Warum Data Science heute wichtiger ist als je zuvor

## Datenflut ohne Präzedenz


Sensoren, Smartphones, soziale Netzwerke und vernetzte Geräte erzeugen kontinuierlich Daten in bisher unbekanntem Ausmaß – Computer machen Muster sichtbar, die menschliche Wahrnehmung allein nicht erfassen kann.

## Datengestützte Entscheidungen überall

Unternehmen analysieren Kundenverhalten, Medizin nutzt statistische Modelle für Diagnosen, Behörden bewerten Risiken – automatisierte Entscheidungen prägen den Alltag.


## Mehr Daten $\neq$ mehr Erkenntnis

Mehr Daten bedeuten nicht automatisch mehr Wissen. Sie bedeuten vor allem: **mehr Interpretationsbedarf** – und damit mehr Verantwortung für diejenigen, die analysieren.



# Das zentrale Problem

Menschen verwechseln im Umgang mit Daten regelmäßig vier grundlegende Kategorien – mit weitreichenden Folgen für Analysen, Modelle und Entscheidungen.

 Diese Verwechslungen sind keine Ausnahme – sie sind der Regelfall unter Zeitdruck und Unsicherheit.

Daten

werden mit  
**Wirklichkeit**  
verwechselt

Korrelation

wird mit **Ursache**  
verwechselt

Kennzahlen

werden mit  
**Entscheidungen**  
verwechselt

Modelle

werden mit **Wahrheit**  
verwechselt

# Die zentrale These: Die Landkarte ist nicht das Gebiet

„Die Landkarte ist nicht das Gebiet.“ – Alfred Korzybski


Korzybski formulierte einen Satz, der bis heute in Wissenschaft, Kommunikation und Erkenntnistheorie Gültigkeit hat: Eine Darstellung darf niemals mit dem dargestellten Gebiet selbst verwechselt werden.

→ Daten sind Landkarten

Ein Datensatz enthält ausgewählte Merkmale, bestimmte Messungen und festgelegte Kategorien – und lässt unzählige Eigenschaften weg.

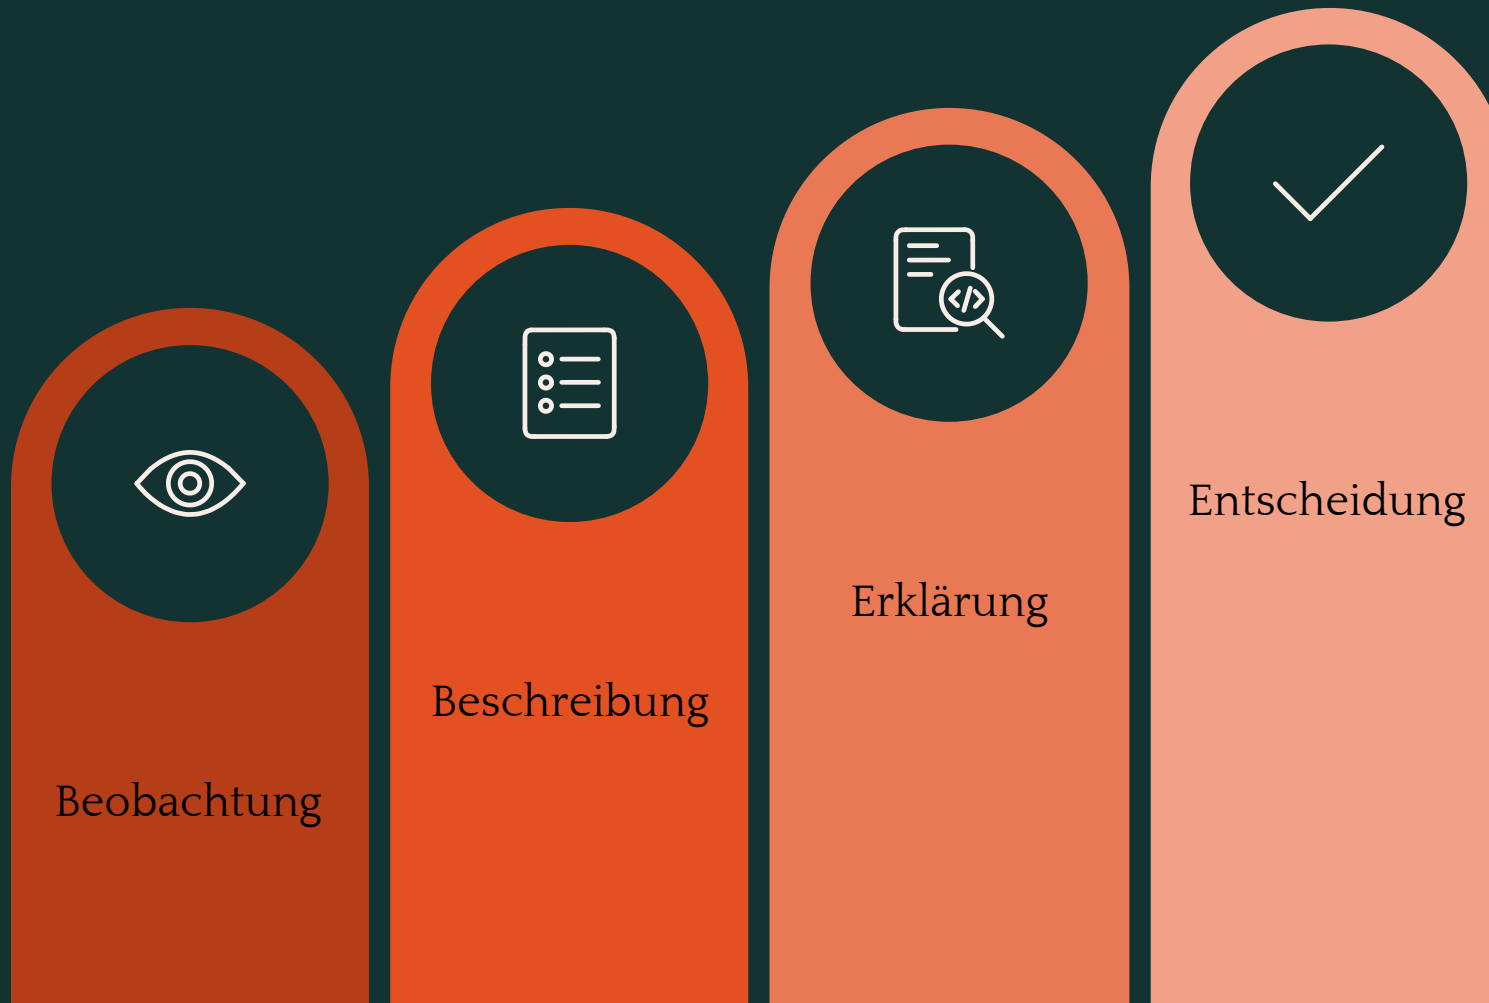
→ Hilfreich, aber unvollständig

Jede Analyse untersucht eine **Darstellung** der Welt – niemals die Welt selbst.



# Wie Erkenntnis entsteht

Data Science folgt einem Prozess, dessen Ebenen sorgfältig unterschieden werden müssen – Vermischung führt zu systematischen Denkfehlern.



Erst wenn Beobachtung, Beschreibung, Erklärung und Entscheidung klar getrennt werden, entsteht begründetes analytisches Urteilen.

# Warum Menschen Daten falsch interpretieren



## Confirmation Bias

Wir suchen bevorzugt Daten, die unsere Vorannahmen bestätigen – und ignorieren widersprüchliche Evidenz.



## Verfügbarkeitsheuristik

Leicht abrufbare Beispiele erscheinen wahrscheinlicher als sie statistisch tatsächlich sind.




## Musterillusion

Menschen erkennen Zusammenhänge, die statistisch nicht belastbar sind – Rauschen wird als Signal interpretiert.



## Kausalitätsfehler

Korrelationen werden vorschnell als Ursache-Wirkungs-Beziehungen interpretiert – besonders unter Zeitdruck und Unsicherheit.



# Vom Datensatz zur Hypothese

Daten allein sind kein Wissen. Erst eine Frage macht einen Datensatz zur Erkenntnisquelle – sie entscheidet, welche Daten relevant sind und welche Auswertung sinnvoll ist.

01

---

## Muster erkennen

Überraschende Beobachtungen im Datensatz

03

---

## Prüfung

Hypothese an neuen Daten testen

02

---

## Abduktion

Aus der Beobachtung eine mögliche Erklärung vorschlagen

04

---

## Begründetes Urteil

Nachvollziehbare, prüfbare Schlussfolgerung

# Argumentieren mit Daten

Jede Datenanalyse ist letztlich ein Argument – sie behauptet etwas und muss es begründen. Eine Zahl ist noch kein Argument, ein Diagramm noch keine Erklärung, ein Modell noch kein Urteil.

<b>Deduktiv</b>  <b>Zwingend</b> – aus allgemeinen Regeln auf den Einzelfall schließen	<b>Induktiv</b>  <b>Wahrscheinlich</b> – vom Einzelfall auf allgemeine Muster schließen
<b>Abduktiv</b>  <b>Erklärend</b> – die plausibelste Hypothese für eine Beobachtung bilden	

## Typische Fehlschlüsse

- **Post-hoc-Fehler:** Nach dem Ereignis erscheint Kausalität selbstverständlich
- **Überhastete Verallgemeinerung:** Einzelbeobachtungen werden zu Regeln
- **Scheingenauigkeit:** Hohe Dezimalstellen täuschen über Unsicherheit hinweg

📌 Erst wenn Fragestellung, Daten, Annahmen und Bedeutung explizit gemacht werden, entsteht eine nachvollziehbare Aussage.

# Korrelation $\neq$ Kausalität

## Die häufigste Denkfalle

Menschen neigen dazu, Beobachtungen und Beschreibungen unmittelbar als Erklärungen zu interpretieren. Die Daten zeigen zunächst nur ein Muster – die Ursache muss gesondert untersucht werden.

⚠ Genau deshalb ist die Unterscheidung zwischen Korrelation und Kausalität in der Data Science so grundlegend.

### Beobachtung

Höheres Einkommen korreliert mit Premiumkäufen


### Konfundierung

Bildung, Alter und soziales Umfeld spielen ebenfalls eine Rolle

### Schlussfolgerung

Korrelation beschreibt ein Muster – Kausalität erfordert eine **geprüfte** Erklärung

# Python als Werkzeug kritischer Analyse




Python macht Denkprozesse sichtbar und reproduzierbar. Mit Bibliotheken wie `pandas`, `NumPy` und `scikit-learn` lassen sich Daten untersuchen, Muster sichtbar machen und Hypothesen prüfen.

Python unterstützt Denken – Python ersetzt Denken nicht.


- Python entscheidet nicht, welche Frage sinnvoll ist
- Python erkennt nicht, ob eine Interpretation angemessen ist
- Python übernimmt keine Verantwortung für Folgen

**i** Diese Verantwortung liegt bei der Person, die Data Science betreibt – immer.

# Modelle als vereinfachte Wirklichkeit




**Modelle sind Landkarten**  
Jedes Modell vereinfacht, um handhabbar zu sein. Diese Vereinfachung ist Stärke und Schwäche zugleich.



**Verzerrte Daten, verzerrte Modelle**

Modelle lernen ausschließlich aus den Daten, die ihnen zur Verfügung stehen. Unvollständige oder fehlerhafte Daten spiegeln sich direkt im Modell wider.



**Vorhersage  $\neq$  Erklärung**

Ein Vorhersagemodell beschreibt statistische Zusammenhänge – es erklärt keine Ursachen und liefert keine Urteile.


# Overfitting als Denkfehler

Overfitting bezeichnet den Fall, in dem ein Modell Muster aus den Trainingsdaten lernt, die in der Realität nicht existieren. Es ist technisch präzise – und inhaltlich bedeutungslos.

Eine präzise Messung eines ungeeigneten Merkmals bleibt eine ungeeignete Messung.

Selbst perfekte Analysen können keine Informationen erzeugen, die nie erhoben wurden.

Overfitting  
Anpassung an  
Trainingsdaten,  
keine  
Generalisierung.



Train-Test-Split  
Zielt auf  
Generalisierbarkeit  
und Robustheit.

Generalisierbarkeit ist das eigentliche Ziel – nicht maximale Anpassung an bekannte Daten.

# Entscheidungen unter Unsicherheit

Data Science liefert Wahrscheinlichkeiten, Hinweise und Gründe – keine Gewissheit. Sie leistet Orientierung, hilft Unsicherheit zu reduzieren und Entscheidungen besser zu begründen. Sie ersetzt weder Denken noch Verantwortung.

**i** Unsicherheit offen zu kommunizieren ist Teil professioneller Data Science – nicht ihr Versagen.

PrOACT-Framework nach Hammond et al.

---

## Problem

Was ist die eigentliche Frage?

---

## Objectives

Welche Ziele sollen erreicht werden?

---

## Alternatives

Welche Optionen stehen zur Verfügung?

---

## Consequences

Was sind die Folgen jeder Option?

---

## Trade-offs

Welche Abwägungen sind notwendig?

# Bias, Fairness und Verantwortung



Bias beginnt vor dem Modell  
Historische Daten sind keine  
neutrale Wahrheit. Sie spiegeln die  
Unvollständigkeiten, Verzerrungen  
und strukturellen Ungleichheiten  
wider, unter denen sie entstanden  
sind.




Fairness als  
Entscheidungsproblem

Fairness ist kein technisches  
Problem, das sich optimieren lässt.  
Es ist ein Entscheidungsproblem  
mit konkurrierenden Kriterien, das  
Transparenz und explizite  
Wertabwägungen erfordert.



Automatisierung  $\neq$   
Entbindung

Automatisierung entbindet nicht  
von Verantwortung. Der Mensch  
bleibt im Entscheidungsprozess –  
Verantwortung bedeutet  
Rechenschaft, nicht nur Technik.



# Vertrauen in Daten und Modelle

Vertrauen ist keine Gewissheit. Es entsteht durch Nachvollziehbarkeit, Erklärbarkeit und Datenqualität – nicht durch Behauptung.

## Kalibriertes Vertrauen

Weder blindes Vertrauen noch pauschales Misstrauen ist angemessen. Vertrauen muss dem tatsächlichen Evidenzstand entsprechen.

## Transparenz als Pflicht

Transparenz ist eine ethische Verpflichtung – nicht nur eine technische Option. Sie fördert gesellschaftliches Vertrauen in datengestützte Systeme.

# Der Informationseisberg

Ein zentrales Framework nach Karpman des Buches für verantwortungsvolle Kommunikation von Analyseergebnissen – von der sichtbaren Zahl bis zur zugrunde liegenden Absicht:



# Was Leser aus dem Buch mitnehmen

## → Bessere Analysen

Daten kritisch lesen, Annahmen explizit machen, Grenzen der Aussage klar benennen

## → Bessere Argumente

Ergebnisse begründet und nachvollziehbar kommunizieren – nicht nur präsentieren

## → Bessere Entscheidungen

Unsicherheit einkalkulieren statt ignorieren – strukturiert mit dem PrOACT-Framework

## → Mehr Urteilskraft

Zwischen Beobachtung, Interpretation und Bewertung sicher unterscheiden

## → Mehr Verantwortung

Data Science als reflektierte Erkenntnisarbeit verstehen – kritisches Denken ist ihre notwendige Grundlage, keine Ergänzung

# Fazit

## Data Science ist kritisches Denken mit Daten.

Der Kern dieses Buches: Data Science ist nicht nur Rechnen mit Daten. Data Science ist **begründetes Denken** mit Daten.

### Die zentrale Botschaft

- Daten liefern keine Urteile  
Menschen müssen lernen, Daten verantwortungsvoll zu interpretieren – Technik allein genügt nicht.
- Kritisches Denken als Fundament  
Kritisches Denken ist die eigentliche Grundlage guter Data Science – nicht ihre optionale Ergänzung.

# Quellen und theoretische Grundlagen I

## Kritisches Denken, Wahrnehmen und Entscheiden

Soentgen, Jens: *Selbstdenken! 20 Praktiken der Philosophie*. Beltz & Gelberg, Weinheim und Basel, 2007.

Grundlage für die Idee, dass kritisches Denken nicht bloß aus Skepsis besteht, sondern aus aktivem Prüfen, Vergleichen, Hinterfragen und begründetem Urteilen.

Szudek, Anna; Baiasu, Sorin; Talbot, Michael; Fletcher, Richard; Weeks, Marcus: *#dkinfografik: Philosophie im Alltag: Vom Wahrnehmen, Erkennen und Entscheiden*. Dorling Kindersley, München, 2020.

Grundlage für die anschauliche Darstellung philosophischer Grundfragen zu Wahrnehmung, Erkenntnis, Wahrheit, Entscheidung und Verantwortung.

Korzybski, Alfred: *Science and Sanity: An Introduction to Non-Aristotelian Systems and General Semantics*. Institute of General Semantics, Lakeville, Connecticut, 1958.

Grundlage für die Unterscheidung zwischen Wirklichkeit und Beschreibung: Daten, Modelle und Diagramme sind Landkarten der Wirklichkeit, nicht die Wirklichkeit selbst.

# Quellen und theoretische Grundlagen II

## Denkfehler, Urteile und Unsicherheit

Kahneman, Daniel: *Schnelles Denken, langsames Denken*. Siedler Verlag, München, 2012.

Grundlage für die Unterscheidung zwischen schnellem, intuitivem Denken und langsamem, prüfendem Denken sowie für viele typische Verzerrungen in Urteilen.

Tversky, Amos; Kahneman, Daniel: *Judgment under Uncertainty: Heuristics and Biases*. *Science* 185(4157), 1974, S. 1124–1131.

Grundlage für Heuristiken und Denkfehler unter Unsicherheit, besonders bei Wahrscheinlichkeiten, Prognosen und datenbasierten Entscheidungen.

Nickerson, Raymond S.: *Confirmation Bias: A Ubiquitous Phenomenon in Many Guises*. *Review of General Psychology* 2(2), 1998, S. 175–220.

Grundlage für den Bestätigungsfehler: Menschen suchen, gewichten und interpretieren Informationen häufig so, dass bestehende Annahmen bestätigt werden.

# Quellen und theoretische Grundlagen III

## Argumentation und Hypothesenbildung

Toulmin, Stephen: *The Uses of Argument*. Cambridge University Press, Cambridge, 1958.

Grundlage für die Analyse von Argumenten: Daten werden erst durch Begründungen, Annahmen und Schlussfolgerungen zu tragfähigen Argumenten.

Peirce, Charles Sanders: *Collected Papers of Charles Sanders Peirce*. Harvard University Press, Cambridge, 1972.

Grundlage für abduktives Denken: Aus Beobachtungen werden mögliche Erklärungen und Hypothesen entwickelt.

# Quellen und theoretische Grundlagen IV

## Data Science, Modelle und Verantwortung

Provost, Foster; Fawcett, Tom: *Data Science for Business*. O'Reilly Media, Sebastopol, 2013.

Grundlage für Data Science als Prozess, der nicht bei Daten oder Modellen endet, sondern Entscheidungen vorbereitet.

Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome: *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, New York, 2009.

Grundlage für Modellbildung, Vorhersage, Generalisierung, Overfitting und die kritische Bewertung statistischer Lernverfahren.

O'Neil, Cathy: *Weapons of Math Destruction*. Crown, New York, 2016.

Grundlage für die Risiken datenbasierter Entscheidungen, insbesondere wenn Modelle intransparent, unfair oder gesellschaftlich folgenreich eingesetzt werden.

Binns, Reuben: *Fairness in Machine Learning: Lessons from Political Philosophy*. Proceedings of Machine Learning Research 81, 2018, S. 149–159.

Grundlage für die Verbindung von Machine Learning, Fairness und politischer Philosophie.

# Quellen und theoretische Grundlagen V

## Entscheidungs- und Kommunikationsmodelle

Hammond, John S.; Keeney, Ralph L.; Raiffa, Howard: **Smart Choices. A Practical Guide to Making Better Decisions.** Harvard Business Review Press, Boston, 2015.

Grundlage für das PrOACT-Framework zur strukturierten Entscheidungsfindung unter Unsicherheit.

Karpman, Stephen B.: **Ein Leben ohne Spiele. Die neue Transaktionsanalyse der Vertrautheit, der Offenheit und der Zufriedenheit.** Process Training und Consulting, Weilheim, 2016. ISBN: 978-3-937471-03-7.

Grundlage für den Informationseisberg zur Unterscheidung von Punkt, Information, Bedeutung und Absicht.