

---

# **Funktionen, Daten und Modelle – Vernetzende Themen zu zentralen Themen der (Schul-) Mathematik**

Joachim Engel  
Pädagogische Hochschule Ludwigsburg

Stochastik in den Sekundarstufen – Daten,  
Wahrscheinlichkeit und (Un-)Sicherheit

5. Karlsruher Didaktik Workshop

19. Februar 2026

# Funktionen in der Schule

---

- Zentrales Thema des MU:

- Durchzieht Schulcurriculum von 1 – 12 (13) (selbst, wenn nicht immer explizit benannt)
- Instrument zur Beschreibung von Mustern und Strukturen in der Mathematik
- Instrument zur Umwelterschließung

*Zusammenhänge in der Umwelt mit Hilfe von Funktionen beschreiben, untersuchen, verstehen.*

- **Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?**
- **Was haben Funktionen mit Daten und Stochastik zu tun?**



# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

---

## Gliederung:

1. Deterministische Welt: alles passt so schön
2. Stochastisch-funktionale Zusammenhänge: Kurvenanpassung
3. Daten glätten: Ausgleich zwischen Signal und Rauschen
4. Big Data und Algorithmen: von Classification and Regression Trees zu Random Forests



# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

---

Mathematisierung eines real world problem: ein kreativer Akt

- Strukturelle Analyse der Situation
- Systemanalyse
- Inspiration

Sammele Daten und analysiere sie

- Genetischer Ansatz: graduell in Richtung Abstraktion gehen
- Verknüpfungen herstellen zwischen Sachkontext und verfügbarem mathematischen Wissen



# 1. Deterministische Welt: alles passt so schön

---

## Strukturorientiert



- Global:
  - Annahmen für Funktionstyp (linear, quadratisch, exponentiell , .)
    - Menge und Einkaufspreis
    - Flugbahnen
    - Bakterien in Petrischale
- Lokal:
  - Annahmen über lokales Änderungsverhalten (Differenzengleichungen, Differentialgleichungen)
    - Temperaturanpassung
    - Verbreitung eines Gerüchtes



# 1. Deterministische Welt: alles passt so schön

---

- Was tun, wenn Situation komplex, ohne
  - Etabliere Theorie
  - Plausible Heuristik
- Datenorientiert
  - Interpolation durch Polynome, Splines, etc.

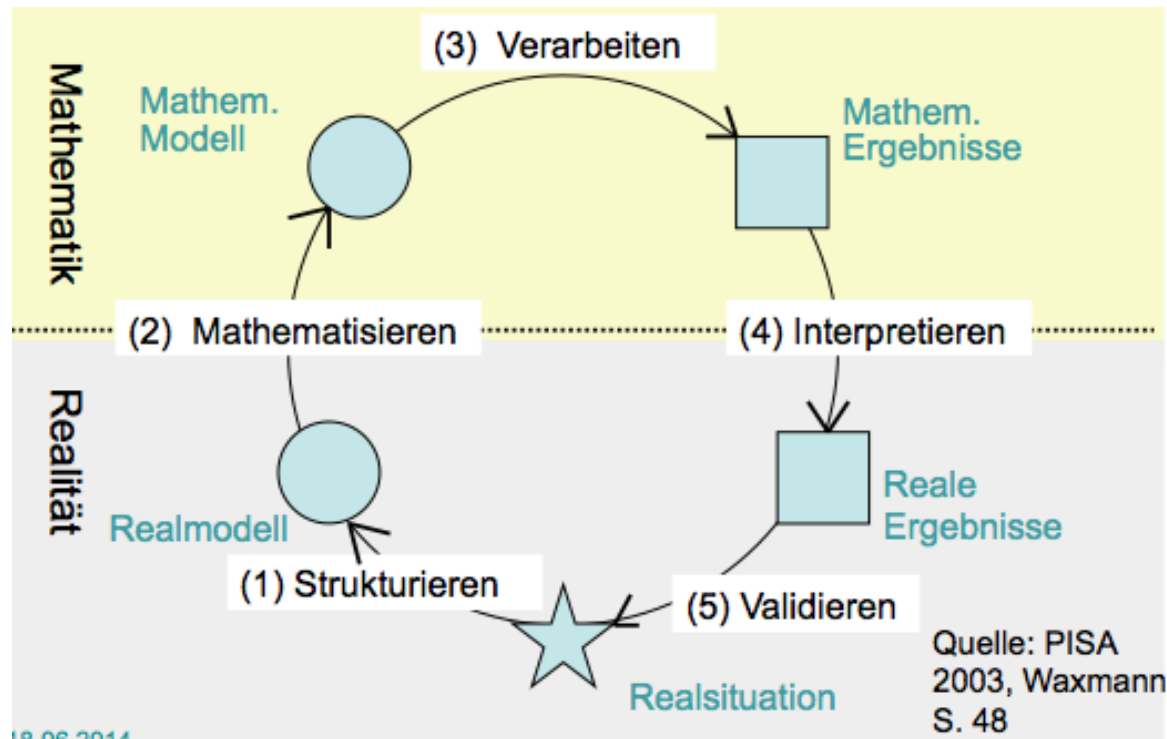


# 1. Deterministische Welt? Nein, nichts passt so schön

Modelle sind Werkzeuge im Erkenntnisprozess zur:

- Beschreibung
- Vorhersage
- Erklärung

## ■ Modell $\neq$ Realität



■ *Alle Modelle sind falsch, aber einige sind nützlich*

George Box, 1979

# 1. Deterministische Welt? Nein, nichts passt so schön

---

## Modell $\neq$ Realität

- Daten. = Modell + Abweichungen  
= Anpassung + Residuen  
= Signal + Rauschen  
= Struktur + Zufall

Wie damit umgehen?

- Ignorieren ?
- Modellieren?

Wenn die Anpassung die bedeutsamsten Aspekte der Daten erfasst, dann sollten die Residuen keine Struktur mehr erkennen lassen. Sie sollten „**reasonably irregular**“ (Tukey 1977)



## 2. Stochastisch-funktionale Zusammenhänge:

---

### Strukturorientiert

#### ■ Global:

- Annahmen für Funktionstyp (Regression, linear und nichtlinear ..)
  - Lineare Regression
  - Geradebiegen krummer Beziehung per Transformation-Rücktransformation
  - Parameterwahl über Schieberegler

#### ■ Lokal:

- Annahmen über lokales Änderungsverhalten
  - Autoregressive Zeitreihen, Markov-Prozesse, Stochastische Differentialgleichungen



## 2. Stochastisch-funktionale Zusammenhänge:

---

### Datenorientiert

- Gleitende (gewichtete) Mittelwerte, Datenglätter, lokale Regression

Gegeben Beobachtungen (Daten),  $(x_1, y_1), \dots, (x_n, y_n)$ , Realisierungen zweier Zufallsvariabler  $X, Y$ , die in einem (stochastisch-) funktionalen Zusammenhang  $f$  stehen.

Gesucht: Funktion  $f$

Ansatz:  $y_i = f(x_i) + \varepsilon_i, \quad i = 1, \dots, n, \quad \text{wobei}$

- Daten = Signal + Rauschen  
= Struktur + Zufall




# 3. Glätten: Ausgleich zwischen Signal und Rauschen

## Datenorientiert

- Gleitende (gewichtete) Mittelwerte, Datenglätter, lokale Regression

Gegeben Beobachtungen (Daten)  
 $(x_1, y_1), \dots, (x_n, y_n)$ , Realisierungen  
zweier Zufallsvariabler  $X, Y$ , die in  
einem (stochastisch-)funktionalen  
Zusammenhang stehen.

## Zahnbelag versus Putzzeit







## Gesucht: Funktion $f$

Ansatz:  $y_i = f(x_i) + \varepsilon_i, \quad i = 1, \dots, n$  wobei

- Daten = Signal + Rauschen
- <http://127.0.0.1:7089>
- = Struktur + Zufall

# 3. Glätten: Ausgleich zwischen Signal und Rauschen



# 3. Glätten: Ausgleich zwischen Signal und Rauschen

---

- **Nicht:** neuere Entwicklungen um jeden Preis schulfällig zu machen
- **Sondern:** Beitrag zu statistischen Denken:  
Daten = Signal + Rauschen  
= Struktur + Zufällige Abweichungen
- Wie filtert man aus verrauschten Daten Signale heraus?
  - **Große Fenster:** Rauschen weitgehend eliminiert, allerdings wird auch Struktur weg-geglättet
  - **Kleine Fenster:** Struktur bleibt erhalten, allerdings weitgehend auch das Rauschen
- Unterstützt das Bewußtsein um zufällige Variabilität in allen empirischen Daten
- Adressiert direkt die Frage
  - Signale in verrauschten Daten zu finden  
oder
  - Strukturen in der Allgegenwart zufälliger Variation zu entdecken



# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

	<b>Deterministische Modelle</b>	<b>Stochastische Modelle</b>
<b>Strukturorientiert</b>		
Global: Annahmen über Funktionstyp	Standardmodelle (linear, Polynome, Exponentialfunktion etc.)	lineare Regression nichtlineare Regression
Lokal: Annahmen über lokales Änderungsverhalten	Differenzgleichungen Differentialgleichungen	Autoregressive Zeitreihen, Markov-Prozesse, Stochastische Differentialgleichungen
<b>Datenorientiert</b>	Polynominterpolation, Splines	Gleitende Mittelwerte, Kernschätzer, Lokal-lineare Schätzer

# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

---

- Unterschiedliche epistemologische Positionen
  - Empirie (David Hume, John Locke)
  - „Reines“ Denken (Rene Descartes)
  - „Gedanken ohne Inhalt sind leer, Anschauungen ohne Begriffe sind blind“ (Immanuel Kant)
- Implikation für Verhältnis Modellieren in der Mathematik?
  - *Datenerhebung ohne Theorie ist blind, Theorie ohne Daten ist leer*
- Umgang mit Abweichungen zwischen Modell und Daten
  - Ignorieren?
  - Als Zufallsprozess modellieren?



# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

---

## Zusammenfassung: Veränderte Fragestellungen

Nicht nur: Bestimme passenden Parameter, sondern

- Was ist der geeignete Funktionstyp?
- Welche Rolle und Bedeutung nehmen Parameter ein?
- Prüfen und Verbessern von Modellen mittels Residuen
- Standardfunktionen als Bausteine
- Rolle der Abweichungen von Daten und Modell




# Wie kommt man zu einer Funktion, die Zusammenhänge der Umwelt beschreibt?

---

## Anregungen für Schule

- Engel, J. (2016). Funktionen, Daten und Modelle: Vernetzende Zugänge zu zentralen Themen der (Schul-) Mathematik. *JMD*, 37, 107-139.  
<https://doi.org/10.1007/s13138-016-0094-4>
- Engel, J (2018). *Anwendungsorientierte Mathematik: Von Daten zur Funktion*. Eine Einführung in die mathematische Modellbildung für Lehramtsstudierende. 2. Aufl., Springer
- Mohr, M., Hofer, L. , Ufer, S. (2025). Introducing Data-Based Modeling with Functions in a Student Laboratory: Design and Implementation for Enhancing Statistical Literacy among Upper Secondary School Students. *Themenheft Data Literacy mathematica didactica* 48,
- *Weitere Beispiele z.B. in Mathematiklehren, PM Mathematik in der Schule*



# 4. Big Data und Algorithmen

---

- Große, z.T. riesige Datenmengen
- Viele Variable, unterschiedlichen Typus
- Rechenpower
- Mächtige Algorithmen

Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984).  
*Classification and regression trees*, Taylor and Francis,



# 4. Big Data und Algorithmen

---

## Ein Paradigmenwechsel


Breiman (2001) zwei Kulturen:

- Suche nach einem passenden Modell, das Erklärungen für das beobachtete Phänomen liefert
- Suche nach effizienten Algorithmen, um auf der Basis von Big Data möglichst gute Vorhersagen zu machen

Breiman, L. (2001). Statistical modeling: The two cultures. *Statistical Science*, 16(3), 199–231.

# 4. Big Data und Algorithmen: CART-Classification

- $y_i = f(x_{i,1}, x_{i,2}, \dots, x_{i,k}) + \varepsilon_i, i = 1, \dots, n$
- Classification: Zielvariable  $y$  kategorial
- Regression: Zielvariable  $y$  numerisch
  - Prädiktoren  $x_1, \dots, x_n$  metrisch, kategorial, ...
  - $\varepsilon_1, \dots, \varepsilon_n$ . Residuen
- Gegeben Daten  $(x_i, y_i)$ , rekonstruiere  $f$
- Im Fall Classification: Entscheidungsproblem
- Im Fall Regression: Hochdimensionale Funktionsschätzung



Breiman, L., Friedman, J.,  
Olshen, R., & Stone, C. (1984).  
*Classification and regression  
trees*, Wadsworth

# 4. Big Data und Algorithmen: CART

---

## Entscheidungsalgorithmen in komplexen Situationen:

- Medizinische Diagnose und Intervention
- Finanzielle Investitionen: Wer bekommt einen Kredite
- Gesichtserkennung/ Personenerkennung
- Google, Amazon Empfehlungen etc.
- Bankkredite
- Automatische Übersetzungen (GoogleTranslate, DeepL, ..)
- Pattern Recognition



# 4. Big Data und Algorithmen: CART Classification

---

## Entscheidungsalgorithmen:

Wie trifft der Computer Entscheidungen?

- **Trainingsstichprobe** (Lernstichprobe): verwendet um eine Entscheidungsregel zu lernen (d.h. aufzubauen) (hier “lernt” der Algorithmus)
- **Teststichprobe**: verwendet, um die Qualität einer Entscheidungsregel zu evaluieren (Hier muss der Algorithmus zeigen, ob er etwas taugt)



# 4. Big Data und Algorithmen: CART Classification



## Entscheidungsbäume und Rekursive Partitionen

Einfaches Szenario :

Zwei Prädiktoren  $X_1$  und  $X_2$  mit Werten in  $[0 ; 1]$

Zielvariable  $Y$ : kategorisch (nominal): Blau oder Rot

Binäre Bäume sind äquivalent zu einem **rekursiven Partitions Schema** (recursive partitioning scheme)





# 4. Big Data und Algorithmen: CART Classification

## Entscheidungsbäume und Rekursive Partitionen

$$y_i = f(x_{i,1}, x_{i,2}, \dots, x_{i,k}) + \varepsilon_i, \quad i = 1, \dots, n$$

1. Unterteile Stichprobenraum der Prädiktoren rekursiv in Teilmengen, so dass die Teilmengen bezüglich der Zielvariable möglichst homogen sind
2. Höre irgendwann mit der rekursiven Unterteilung auf
3. Klassifiziere neue Daten nach Mehrheitswahl, d.h. ordne ihnen diejenige Kategorie zu, die in der nach 1) erhaltenen Teilmenge die Mehrheit hat




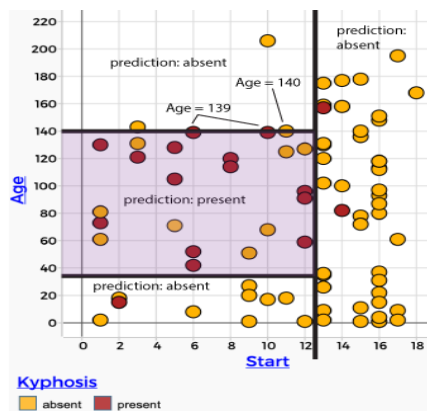
# 4. Big Data und Algorithmen: CART Classification

## Beispiel: Kyphose nach Wirbelsäulenoperation:

Stichprobe 81 „Fälle“= Kinder, die nach einer Wirbelsäulenoperation eine postoperative Kyphose (eine Art Schiefstellung der Wirbelsäule) haben/ nicht haben

Prädiktoren: Age, Start; Zielvariable: Kyphose

- Age: Alter des Kindes in Monaten
- Start: oberster operierter Wirbels
- Kyphose: Vorliegen oder Abwesenheit von Kyphose

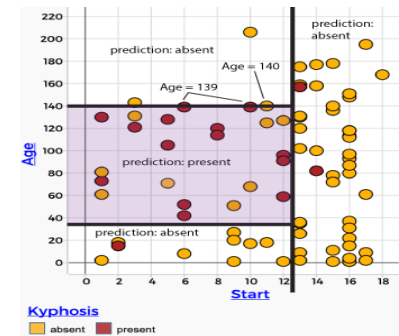


# 4. Big Data und Algorithmen: CART Classification


## Was macht einen Baum zu einem guten Baum?

Drei zentrale Fragen:

- Wie und wo wird eine Partition weiter geteilt?
  - Wann soll das Wachstum des Baumes gestoppt werden?
  - Wie kann man jedem Terminalknoten eine Kategorie zuordnen?
- 
- Finde den Split, der die einzelnen Regionen möglichst homogen bezüglich Y macht
  - Das ist schwieriger als gedacht: dazu gleich mehr
  - Klassifizierung: Mehrheitswahl; ordne den Wert von Y zu, der in diesem terminalen Knoten die meisten Repräsentanten hat




# 4. Big Data und Algorithmen: CART Classification



Zu kleine Bäume: Underfit

Zu große Bäume: Overfit



# 4. Big Data und Algorithmen: CART Classification

---

## Geeignet für die Schule?

- Hand-On: Karten Sortieren
- Codap Plug-in Arbor: Computer als Hilfsmittel, nicht als Entscheider
- Algorithmen, Software rpart, tree (R) oder sklearn (Python)
  
- Biehler, R., Fleischer, Y. (2021). Introducing students to machine learning with decision trees using CODAP and Jupyter Notebooks. *Teaching Statistics*
- Erickson, T., Engel, J. (2021). What goes before the CART? Introducing classification trees with Arbor and CODAP. *Teaching Statistics*
- Fleischer, Y., Biehler, R. (2025). Exploring students' constructions of data-based decision trees after an introductory teaching unit on machine learning. *ZDM*
- Podworny, S., Biehler, R., Fleischer, Y. (2025). Young students' engagement with data to create decision trees. *ZDM*



## 4. Big Data und Algorithmen: CART Regression

---

- $y_i = f(x_{i,1}, x_{i,2}, \dots, x_{i,k}) + \varepsilon_i, i = 1, \dots, n$
- Classification: Zielvariable  $y$  kategorial
- Regression: Zielvariable  $y$  numerisch
  - Prädiktoren  $x_1, \dots, x_n$  metrisch, kategorial, ...
  - $\varepsilon_1, \dots, \varepsilon_n$ . Residuen
- Gegeben Daten  $(x_i, y_i)$ , rekonstruiere  $f$
- Im Fall Classification: Entscheidungsproblem
- Im Fall Regression: Hochdimensionale Funktionsschätzung





# 4. Big Data und Algorithmen: CART Regression

## Entscheidungsbäume und Rekursive Partitionen

$$y_i = f(x_{i,1}, x_{i,2}, \dots, x_{i,k}) + \varepsilon_i, \quad i = 1, \dots, n$$

1. Unterteile Stichprobenraum der Prädiktoren rekursiv in Teilmengen, so dass die Teilmengen bezüglich der Zielvariable möglichst homogen sind
2. Höre irgendwann mit der rekursiven Unterteilung auf
3. Berechne in allen nach 1) erhaltenen Teilmengen das arithmetische Mittel als Funktionswert der zu dieser Teilmenge gehörenden Prädiktoren

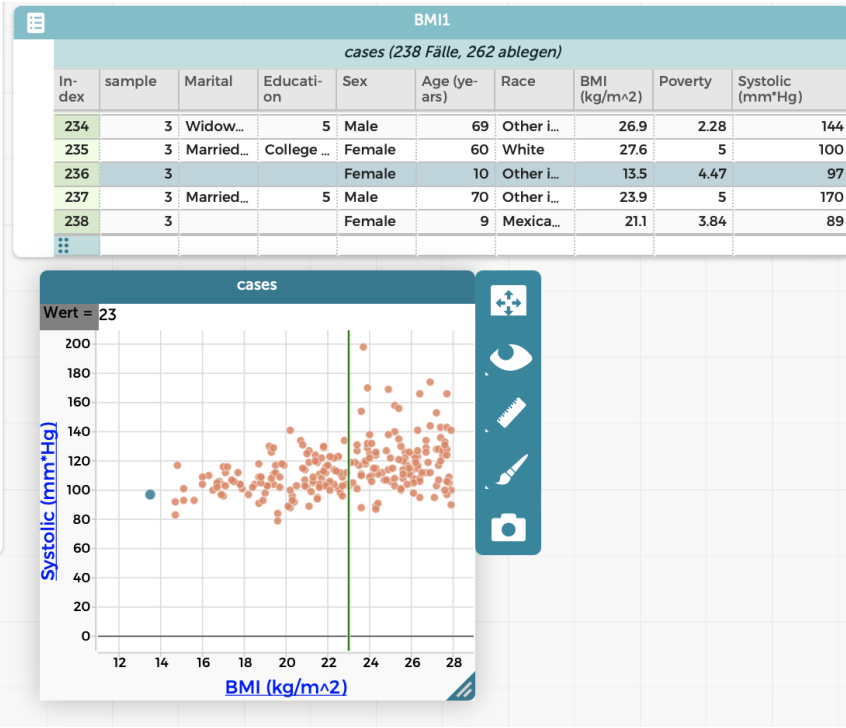
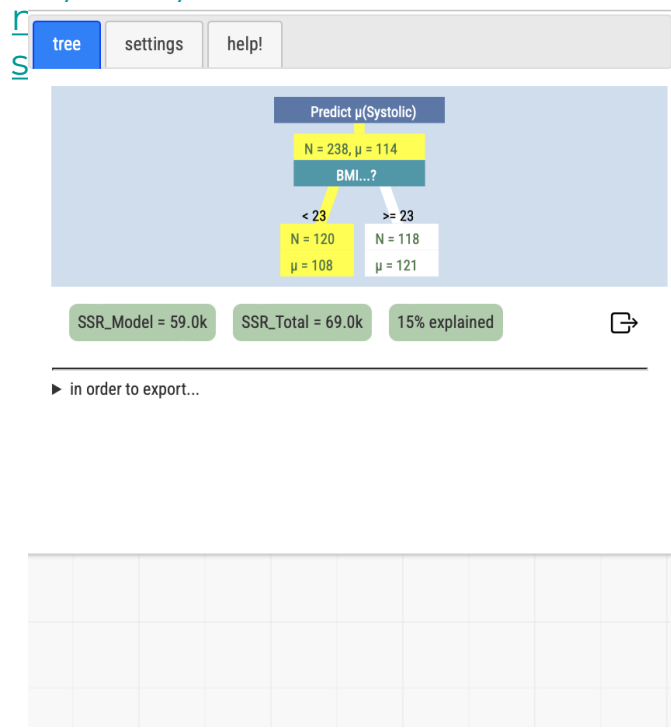


# 4. Big Data und Algorithmen: CART Regression

## Zwischenschritt: Arbor-Plug-In von Codap: Triff selbst die Entscheidungen

Beispiel: Systolischer Blutdruckwert von Patienten in Abhängigkeit von BMI, Geschlecht, Bildung, Ethnie u.a.

- 500 Daten von NHANES 2017
- <https://codap.concord.org/app/static/dg/de/cert/index.html?di=https://codap.xyz/plugi>



# 4. Big Data und Algorithmen: CART Regression

## Zwischenschritt: Arbor-Plug-In von Codap: Triff selbst die Entscheidungen

- systolischer Blutdruckwert von Patienten in Abhängigkeit von BMI, Geschlecht, Bildung, Ethnie u.a.
- 500 Daten von NHANES 2017



Erickson, T., Engel, J. (2021). What goes before the CART? Introducing classification trees with Arbor and CODAP. *Teaching Statistics*

# 4. Big Data und Algorithmen: CART Regression



R Paket rpart

```
# -1) Train/test split ---  
set.seed(2026)  
split <- initial_split(df, prop = 0.80, strata = Systolic)  
train <- training(split)  
test <- testing(split)
```

```
# --- 2) Fit a simple regression tree ---  
tree_fit <- rpart(  
  Systolic ~ Marital + Education + Sex + Race + Age + BMI + Poverty,  
  data = train,  
  method = "anova",  
  control = rpart.control(  
    cp = 0.02, # complexity parameter (bigger = smaller tree)  
    minsplit = 20, # minimum obs to try a split  
    minbucket = 7, # minimum obs in a terminal node  
    maxdepth = 6 # cap tree depth for simplicity) )
```

```
# 3Plot tree  
rpart.plot(tree_fit, type = 2, extra = 101, fallen.leaves = TRUE)
```

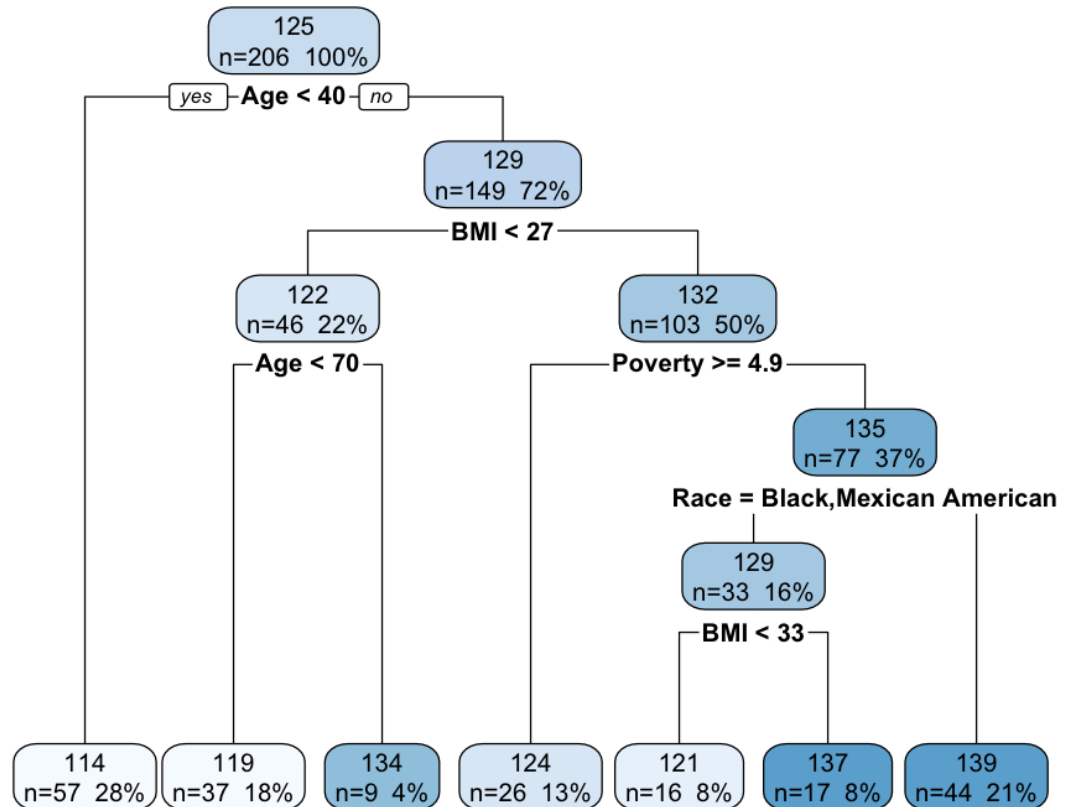
```
#4 Predict and evaluate  
pred <- predict(tree_fit, newdata = test)  
results <- test |> mutate(.pred = pred)  
metrics <- metric_set(rmse, mae, rsq)  
metrics(results, truth = Systolic, estimate = .pred)
```



# 4. Big Data und Algorithmen: CART Regression



Metrik	
RMSE	21
MAE	16,3
RSQ	0,0427



# 4. Big Data und Algorithmen: Bäume a la CART

---

Klassifikationsbäume und Regressionsbäume sind eine explorative Methode um Struktur in unübersichtlichen Daten zu finden

- Transparent
- Leicht zu interpretieren
- Klare Entscheidungsregeln,
- Visualisierung
- Basieren auf rechenintensiven Algorithmen
- Sind ein Einstieg in Methoden des Machine Learning

Aber:


- Nur mäßig gute Vorhersagequalität
- Empfindlich gegenüber kleinen Veränderungen der Trainingsstichprobe,



# 4. Big Data und Algorithmen: Random Forests

## Idee:

- Lass viele Bäume wachsen und entscheide dann auf Mehrheitsbasis der Bäume
- **Aber:** CART ist ein deterministischer Algorithmus, d.h. wiederholtes Durchrechnen führt zu identischen Bäumen.



Tally: Six 1s and Three 0s  
Prediction: 1

Daher gehe wie folgt vor:

1. Verändere mittels Zufallsmechanismus die Trainingsstichprobe („Bootstrapping: Ziehe aus der vorhandenen Trainingsstichprobe durch Ziehen mit Zurücklegen eine neue Stichprobe gleichen Umfangs“)
2. Wähle per Zufallsverfahren nur einen Teil der vorhandenen Prädiktoren aus und lass a la CART ein Entscheidungsbaum aus der Bootstrapstichprobe auf der Basis dieser Prädiktoren entstehen
3. Wiederhole 1. und 2. sehr oft: so entsteht ein ganzer Zufallswald
4. Zur Klassifizierung von neuen Daten, lass die Bäume demokratisch abstimmen: die Kategorie mit den meisten Stimmen (für die die Mehrheit der Bäume im Wald sich entschieden hat), gewinnt.

# 4. Big Data und Algorithmen: Random Forests

---

- Random Forests beruhen auf einer einfachen Idee: der "**Weisheit der Masse**". Die Summe der Ergebnisse mehrerer Prädiktoren ergibt eine bessere Vorhersage als der beste Einzelprädiktor.
- Zuerst haben wir Klassifizierungs- und Regressionsbäume verwendet um Vorhersagen zu treffen. Um unsere Technik zu verbessern, können wir eine Gruppe von **CART Bäumen** trainieren, jeder auf einer anderen zufälligen Teilmenge der Trainingsmenge. Um eine Vorhersage zu treffen, werden einfach die Vorhersagen aller einzelnen Bäume ermittelt.
- Bei Klassifizierung wird dann die Klasse vorhergesagt, die die meisten Stimmen erhält, bei Regression wird das arithmetische Mittel der Werte der einzelnen Bäume als Vorhersage genommen



# 4. Big Data und Algorithmen: CART und Random Forests


---

## World Happiness Report: Was macht Menschen glücklich?

Stichprobe: ca 1000 Befragte in 140 Ländern

Variable:

- Life Ladder (Lebensglück)
- Land
- Gesunde Lebenserwartung
- BSP pro Einwohner
- Soziale Unterstützung
- Freiheit
- Großzügigkeit
- Wahrnehmung von Korruption
- Positive Affekte
- Negative Affekte



<https://www.worldhappiness.report/ed/2025/>

# 4. Big Data und Algorithmen: CART und Random Forests


## World Happiness Report: Was macht Menschen glücklich?

Stichprobe: ca 1000 Befragte in 140 Ländern

Variable:

- Life Ladder (Glück)
- Land
- Gesunde Lebenserwartung
- BSP pro Einwohner
- Soziale Unterstützung
- Freizeitmöglichkeiten
- Großzügigkeit
- Wahrnehmung von Korruption
- Positive Affekte
- Negative Affekte

Wie hängt das Lebensglück (Zielvariable) von den anderen Variablen (Prädiktoren) ab?




<https://www.worldhappiness.report/ed/2025/>

# 4. Big Data und Algorithmen: CART

## Wie hängt das Lebensglück (Zielvariable) von den anderen Variablen (Prädiktoren) ab?

- 1) root 1677 2177. 5.47
- 2)  $\text{gdp\_pc} < 9.66$  952 653 4.78
- 4)  $\text{lif\_exp} < 60.31$  490 213 4.34
- 5)  $\text{lif\_exp} \geq 60.31$  462 245 5.24
- 3)  $\text{gdp\_pc} \geq 9.66$  725 473 6.38
- 6)  $\text{gdp\_pc} < 10.51$  390 169. 5.88
- 7)  $\text{gdp\_pc} \geq 10.51$  335 95 6.96

U..s.W.

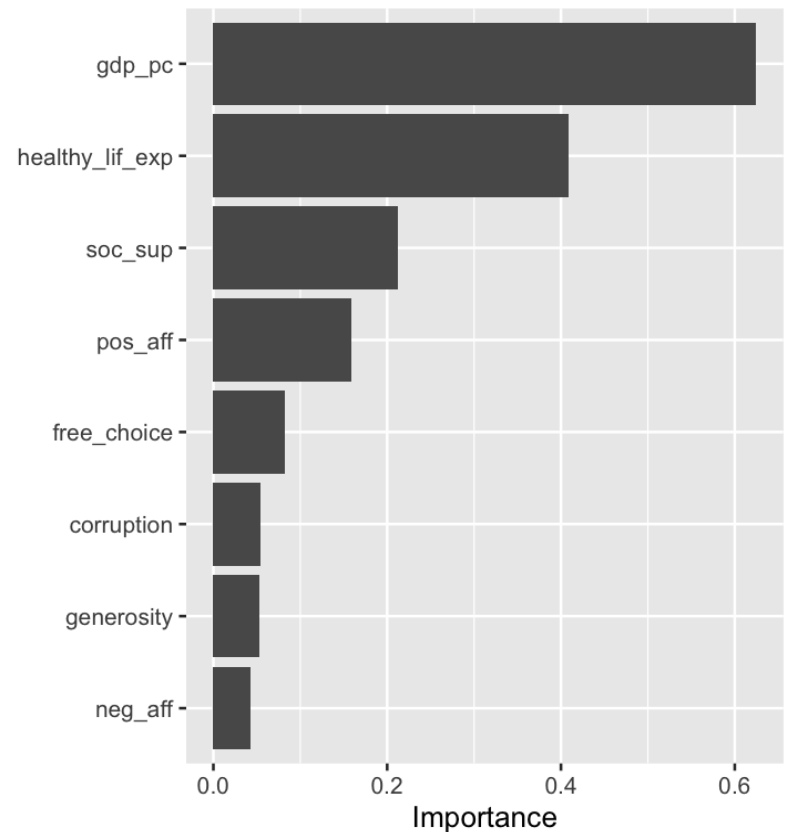


# 4. Big Data und Algorithmen: CART und Random Forests

## Wie hängt das Lebensglück (Zielvariable) von den anderen Variablen (Prädiktoren) ab?

	MAE	RMSE	RSQ
CART	0,401	0,530	0,783
Random Forest	0,302	0,403	0,874

Variable Importance Random Forests



# 4. Big Data und Algorithmen: CART und Random Forests

---

## CART

- + transparent
- + Leicht zu interpretieren
- + Visualisierung
  
- Mäßige Vorhersagequalität
- Empfindliche gegenüber Outliers und kleinen Änderungen in den Daten
- Neigung zum Overfitting

## Random Forests

- + Gute Vorhersagequalität
- + Robust bei Outliers und kleinen Änderungen in den Daten
- + Durchschnittsbildung verhindert Overfitting
  
- Intransparent
- Keine Visualisierung
- Black Box



# 4. Big Data und Algorithmen: CART und Random Forests

---

Eignung als Thema für die Schule?

- Rolle von Maschinellem Lernen und KI in Gesellschaft der Zukunft
- Grundwissen über Vorgehenswissen und Beschränkungen jenseits von mathematisch-technischem Know-How
  - Rolle von Teststichprobe: Bias
  - Mächtige Werkzeuge per Konstruktion als Black Box

Konsequenzen bezüglich Nutzung von KI und verantwortlichen Entscheidungen



---

# Fragen, Kommentare, Kritik, Anmerkungen?

Joachim Engel

Pädagogische Hochschule Ludwigsburg




## Kontakt:

[engel@ph-ludwigsburg.de](mailto:engel@ph-ludwigsburg.de)

[www.joachimengel.eu](http://www.joachimengel.eu)

# Statistik: Signale in verrauschten Daten erkennen

What we observe can be divided into:



ÜBERBLICK  
INFORMATION

