

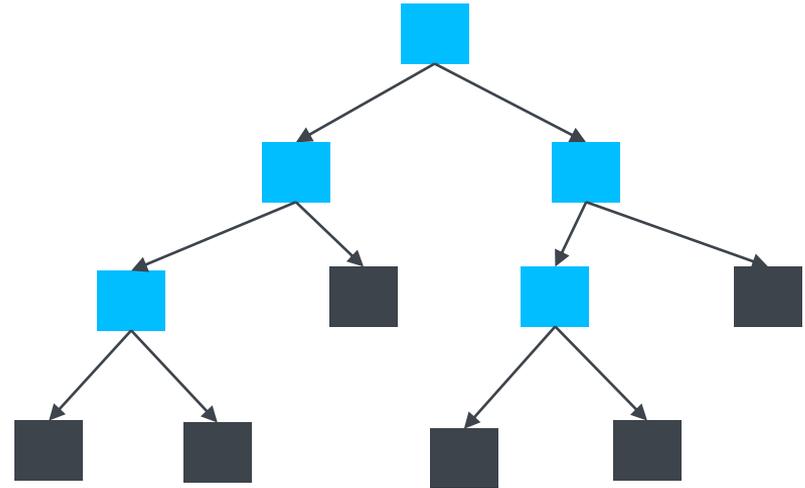


# Training von Klassifikationsbäumen

... und Overfitting

## Wie baut man einen Entscheidungsbaum?

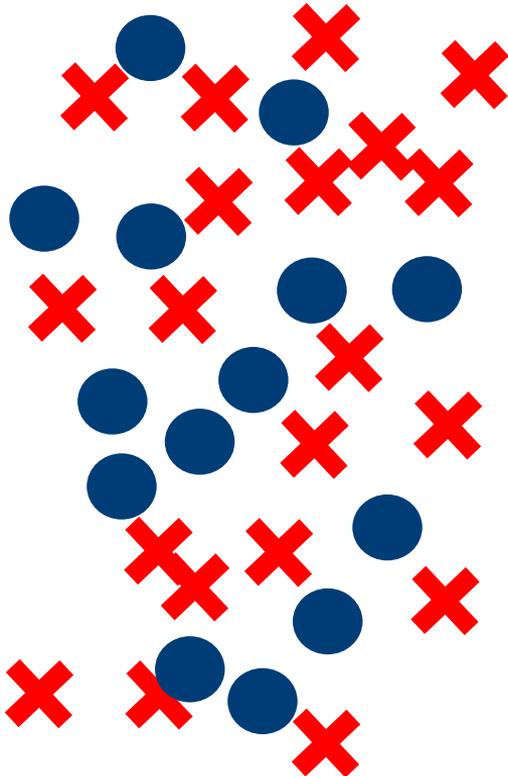
- Zwei Teilprobleme:
  - Wie baut man Zweige?
  - Wie baut man Blätter?
- Zweige = verzweigende Knoten
- Blätter = nicht verzweigende Knoten, Terminalknoten
- Start immer oben, also zuerst: Zweige



## Wie baut man Zweige?

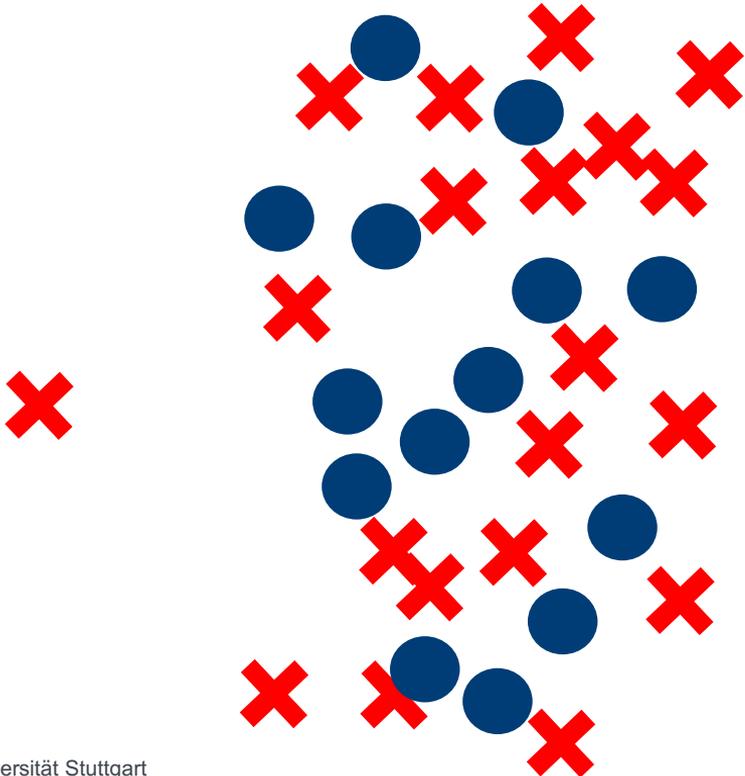
- Gegeben: Datenpunkte
- Gesucht: Kriterium für Aufteilung: ein Feature und ein Schwellwert  
z.B. Temperatur  $\leq 16$  Grad
- Gehe alle Features und alle möglichen Schwellwerte durch
  - Wie würden die Daten in zwei Mengen aufgeteilt?
  - Welche Entropien hätten die Verteilungen der Klassen in beiden Mengen jeweils?
  - Welche Entropie ergibt das insgesamt (gewichtet nach Häufigkeit)?

## Beispiel aus dem Jupyter-Notebook



- Eis-Beispieldaten: 20 Fälle von „geschlossen“, 14 Fälle von „offen“
- Aufteilung nach Temperatur
- Niedrigster möglicher Schwellwert: -0.5 Grad
- Ergibt Aufteilung in zwei Untermengen:
  - Untermenge  $\leq -0.5$ : 1 mal geschlossen
  - Untermenge  $> -0.5$ : 19 mal geschlossen, 14 mal offen

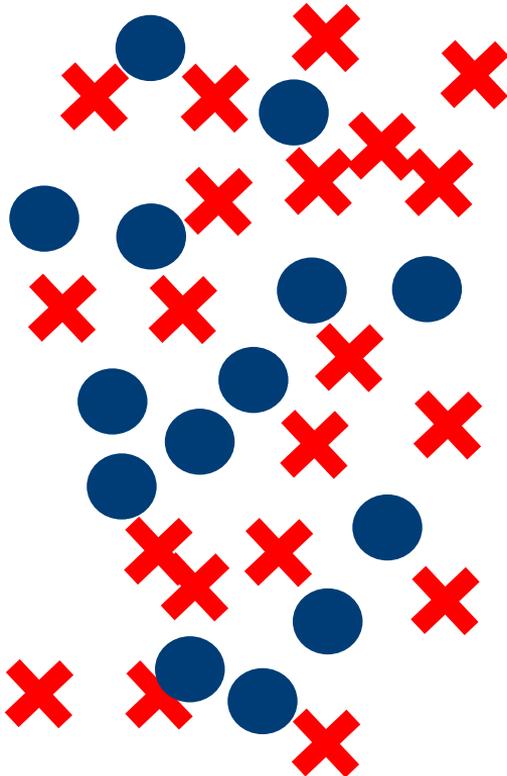
## Beispiel aus dem Jupyter-Notebook



- Entropie für Untermenge 1:
  - 0
- Entropie für Untermenge 2:
  - Verteilung 19:14
  - Insgesamt 33 Datenpunkte
  - $19/33 * -\log_2(19/33) + 14/33 * -\log_2(14/33)$
- Gewichtete Entropie:
  - $1/34 * 0 + 33/34 * 0.98 = 0.954$

Hier zur  
Basis 2 wie  
in sklearn

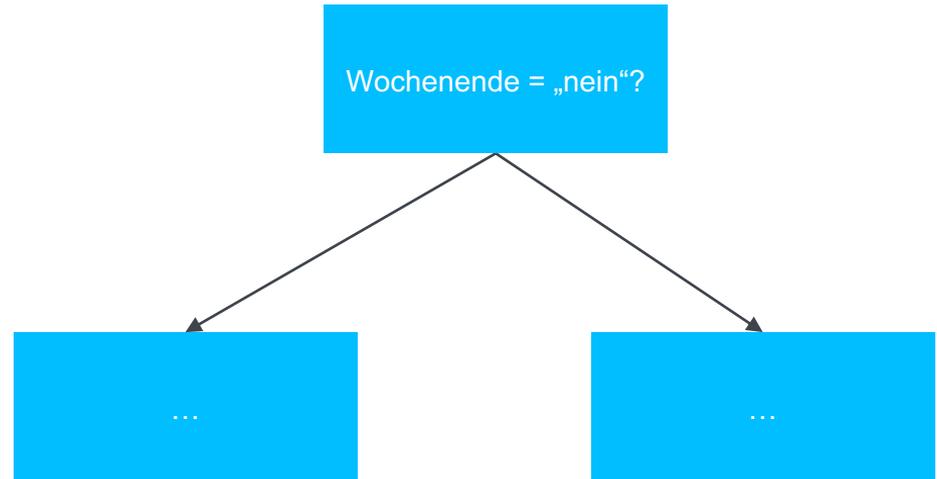
## Beispiel aus dem Jupyter-Notebook



- Beste Aufteilung für Temperatur: 16.5 Grad
- Untermenge 1: 19 Fälle geschlossen, Entropie 0
- Untermenge 2: 1 Fall geschlossen, 14 Fälle offen
  - Insgesamt 15 Datenpunkte
  - $1/15 * -\log_2(1/15) + 14/15 * -\log_2(14/15) = 0.353$
- Gewichtete Entropie:  $19/34 * 0 + 15/34 * 0.353 = 0.156$

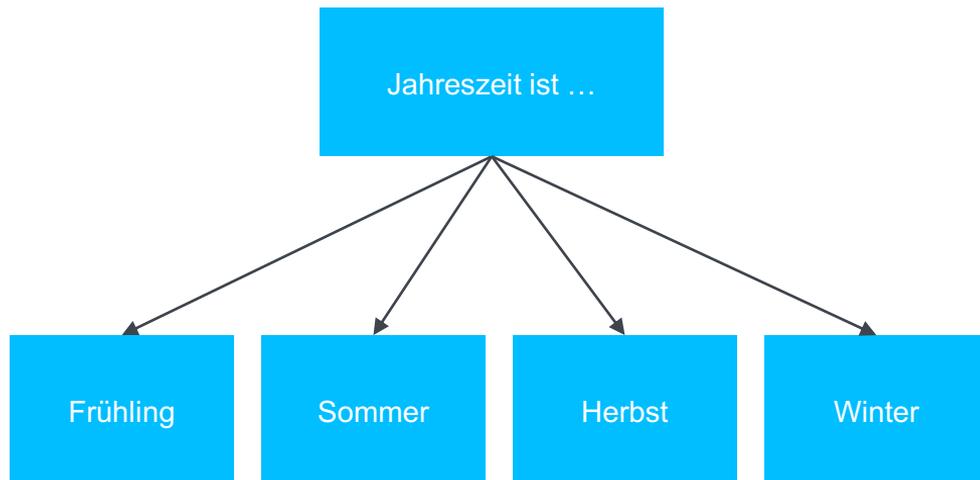
## Kategoriale Features

- Was macht man, wenn die Features keine kontinuierlichen Werte aufweisen?
- Zum Beispiel: Wochenende nein/ja
  - Kodierung als 0 und 1
  - Oder Verzweigungen wie Wochenende = "nein"



## Kategoriale Features mit mehreren Klassen

- Was macht man, wenn die Features mehrere Klassen haben?
- Zum Beispiel: Jahreszeit
  - Dummy-Kodierung als 0 und 1, alles wie bisher
  - Oder Mehrfachverzweigungen erlauben
- Achtung: sklearn erlaubt nur binäre Verzweigungen und nur kontinuierliche Werte



## Wie baut man Zweige?

- Gegeben: Datenpunkte
- Gesucht: Kriterium für Aufteilung: ein Feature und ein Schwellwert
- Gehe alle Features und alle möglichen Schwellwerte durch
  - Wie würden die Daten in zwei Mengen aufgeteilt?
  - Welche Entropien hätten die Verteilungen der Klassen in beiden Mengen jeweils?
  - Welche Entropie ergibt das insgesamt für den aktuellen Knoten (gewichtet nach Häufigkeit)?
- Wähle das Feature und den Schwellwert mit der niedrigsten (also „besten“) Gesamt-Entropie
- Füge einen Knoten ein sowie einen linken Zweig und einen rechten Zweig
- Teile die Daten gemäß Feature und Schwellwert auf diese beiden Zweige auf

## Wie baut man ein Blatt?

- Füge einen Knoten ein
- Weise ihm die Klasse zu, die in den Daten am häufigsten vorkommt

## Wie baut man einen Baum?

- Falls alle Datenpunkte dieselbe Klasse haben, erstelle ein Blatt
- Andernfalls:
  - Erstelle einen Zweig
  - Baue einen Baum für den linken Zweig
  - Baue einen Baum für den rechten Zweig



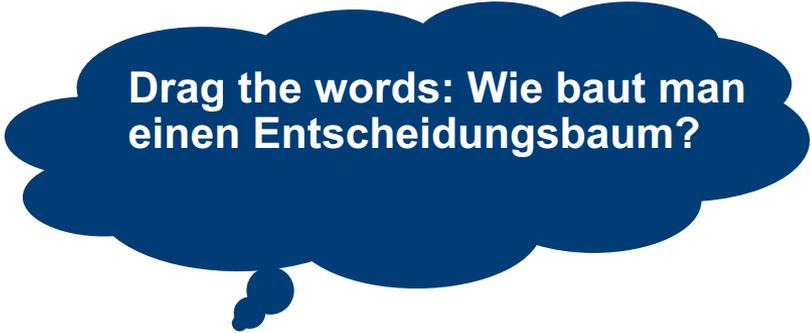
Training?



Rekursion

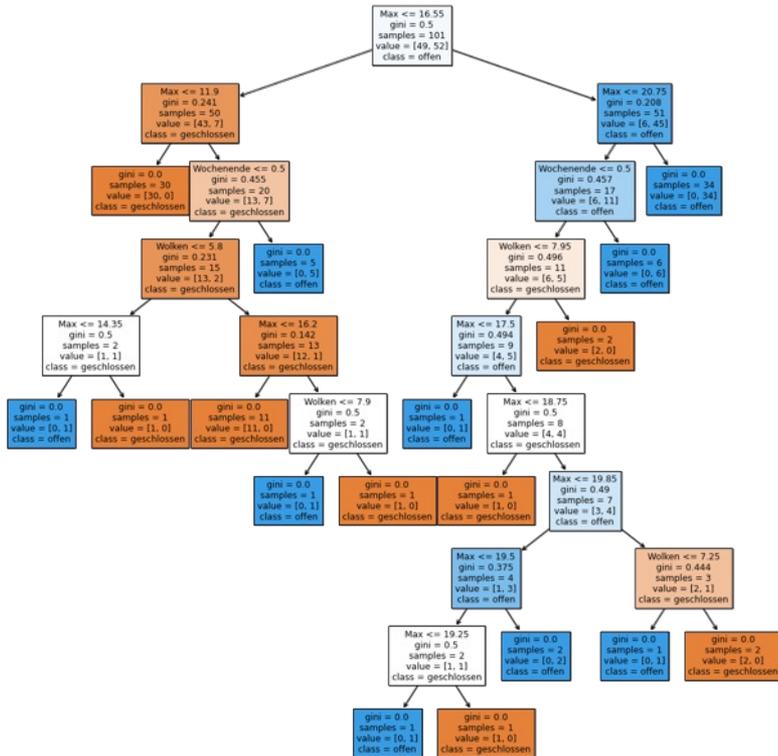
Eigentlich bedeutet Training: immer und immer wieder üben, um bessere Ergebnisse zu erzielen...

**Das Erstellen eines  
Entscheidungsbaumes wird oft als  
„Training“ bezeichnet.**



**Drag the words: Wie baut man  
einen Entscheidungsbaum?**

# Overfitting

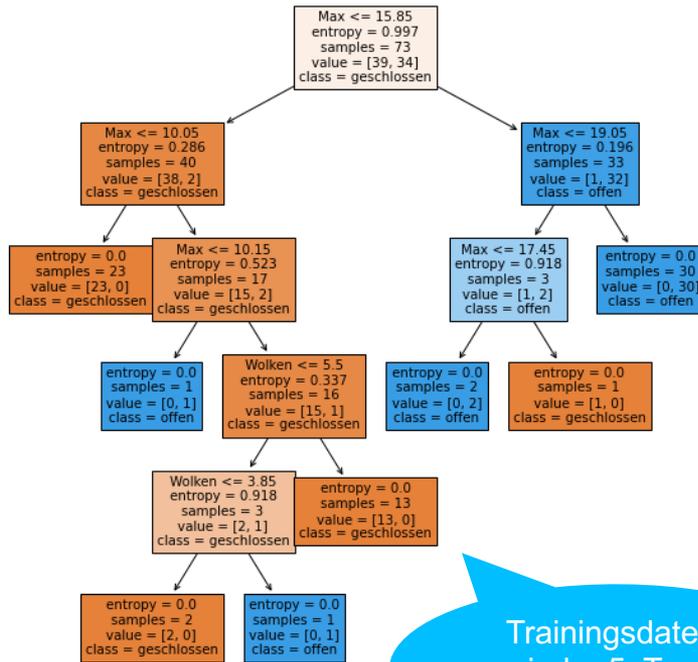


- 101 Datenpunkte für Eisverkäufe, 33 Knoten
- Verdächtig: nicht alle Knoten erscheinen sinnvoll
- Eisverkäufe unterliegen auch dem Zufall
- Dieser Baum versucht trotzdem, die Daten (zu) perfekt zu modellieren
- Es ist unwahrscheinlich, dass dieser Baum auch für Daten von anderen Tagen perfekt ist

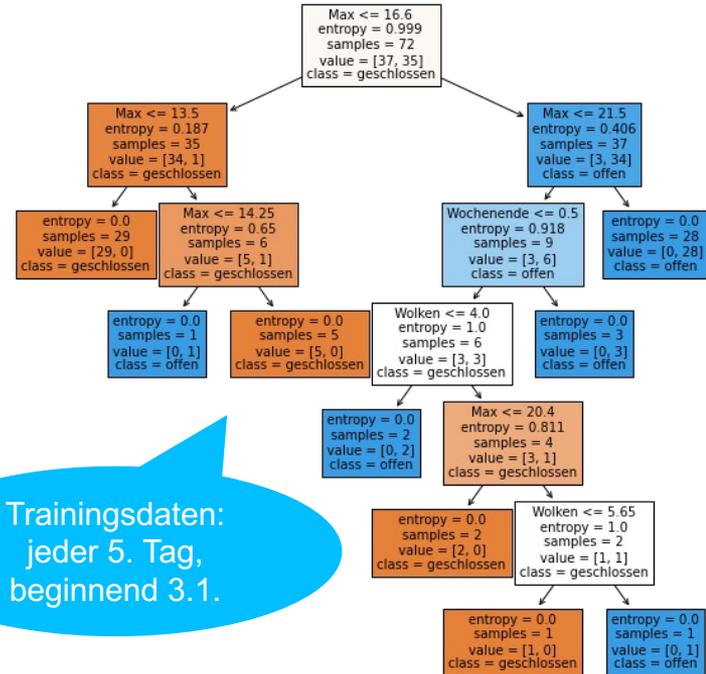
Overfitting

Schlechte Generalisierung

# Beispiel für schlechte Generalisierung



Trainingsdaten:  
jeder 5. Tag,  
beginnend 1.1.



Trainingsdaten:  
jeder 5. Tag,  
beginnend 3.1.

**Overfitting bezeichnet die zu starke Anpassung eines KI-Modells auf die Trainingsdaten.**

**Overfitting ist nicht wünschenswert, weil solche Modelle nicht gut generalisieren: sie erzielen in der Regel auf neuen Datenpunkten deutlich schlechtere Ergebnisse.**

## Overfitting verhindern

- Erkennen von Overfitting: siehe spätere Kursabschnitte
  - Verhindern von Overfitting bei Entscheidungsbäumen
    - Blätter auch dann einfügen, wenn nicht ganz perfekt
- ⇒ Neue Kriterien zum Verzweigen bzw. zum Erstellen von Blättern!

## Wie baut man einen Baum mit weniger Overfitting?

- Falls alle Datenpunkte dieselbe Klasse haben, erstelle ein Blatt

- Andernfalls:

- Erstelle einen Zweig
- Baue einen Baum für den linken Zweig
- Baue einen Baum für den rechten Zweig

Falls der Baum schon sehr tief ist, erstelle ein Blatt

Falls nicht mehr viele Datenpunkte vorhanden sind, erstelle ein Blatt

Wenn es noch nicht zu viele Blätter gibt, erstelle ein Blatt

... aber nur, wenn für beide Zweige genügend Datenpunkte vorhanden sind

**Beim Bau von  
Entscheidungsbäumen gibt es eine  
Reihe von Parametern, die  
Overfitting reduzieren können.**

## Maßnahmen gegen Overfitting, die Zweite

- Fertig erstellte Bäume können nachträglich vereinfacht werden
- Dies bezeichnet man als Pruning
- Engl. „Pruning“ = Zurechtstutzen/Beschneiden von Bäumen
- Dabei werden z.B. Unterbäume durch Blätter ersetzt

**Das nachträgliche Vereinfachen von  
Entscheidungsbäumen bezeichnet  
man als Pruning.**

**Pruning ist eine weitere Möglichkeit,  
Overfitting zu reduzieren.**

**Die Verhinderung zu komplexer  
Bäume schon beim Bauen durch  
Parameter, die die Anzahl der  
Verzweigungen oder der Blätter  
begrenzen, bezeichnet man als  
Pre-Pruning.**

## Nochmal: wie baut man Zweige?

- Gehe alle Features und alle möglichen Schwellwerte durch
  - Wie würden die Daten in zwei Mengen aufgeteilt?
  - Welche Entropien hätten die Verteilungen der Klassen in beiden Mengen jeweils?
  - Welche Entropie ergibt das insgesamt für den aktuellen Knoten (gewichtet nach Häufigkeit)?

Wähle das Feature und den Schwellwert mit der niedrigsten (also „besten“) Gesamt-Entropie

- Füge einen Knoten ein sowie einen linken Zweig und einen rechten Zweig.
- Teile die Daten gemäß Feature und Schwellwert auf diese beiden Zweige auf

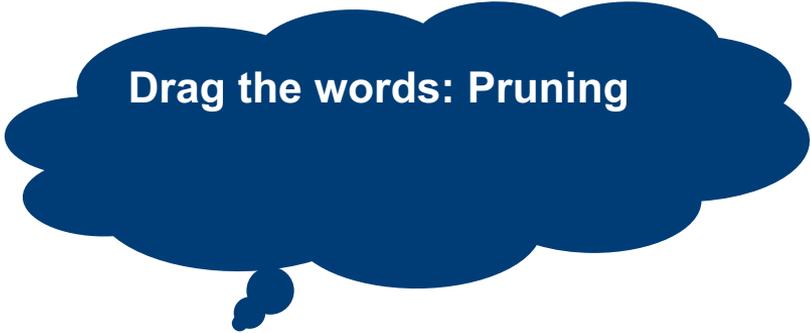
Greedy-Algorithmus:  
das in diesem Moment  
„lokal“ beste

## Problem mit der Greedy-Strategie

- Garantiert nicht den insgesamt (global) optimalen Baum
- Möglicherweise ergäben sich durch Wahl eines anderen Features/Schwellwerts später andere Verzweigungen
- Evtl. also ein besserer oder auch weniger komplexer Baum

**Im Maschinellen Lernen werden häufig „Greedy“-Algorithmen angewandt.**

**Diese entscheiden sich für die lokal optimale Wahl, garantieren aber nicht, dass das Resultat auch insgesamt (global) optimal ist.**



**Drag the words: Pruning**

## Dr. Antje Schweitzer

Universität Stuttgart  
Institut für Maschinelle Sprachverarbeitung



**Universität Stuttgart**

Institut für Maschinelle Sprachverarbeitung  
Institut für Software Engineering



**IHK** Industrie- und Handelskammer  
Reutlingen

Reutlingen | Tübingen | Zollernalb



**IHK** Region Stuttgart



**IHK** Industrie- und Handelskammer  
Karlsruhe



# Lizenzbestimmungen

“Training von Klassifikationsbäumen” von Antje Schweitzer, KI B<sup>3</sup> / Uni Stuttgart

Das Werk - mit Ausnahme der folgenden Elemente:

- Logos der Verbundpartner und des Förderprogramms
- im Quellenverzeichnis aufgeführte Medien

ist lizenziert unter:

 [CC BY 4.0 \(https://creativecommons.org/licenses/by/4.0/deed.de\)](https://creativecommons.org/licenses/by/4.0/deed.de)

(Namensnennung 4.0 International)

## Quellenverzeichnis

Titelfoto: [Randy Fath \(https://unsplash.com/@randyfath\)](https://unsplash.com/@randyfath), „Amish barn-raising near my home“, auf [Unsplash \(https://unsplash.com/photos/ymf4\\_9Y9S\\_A\)](https://unsplash.com/photos/ymf4_9Y9S_A), ist lizenziert unter [Unsplash-Lizenz \(https://unsplash.com/license\)](https://unsplash.com/license).

Bildausschnitt verändert.