









Gutes Äffchen – böses Äffchen

Überleben im Zoo
dank Entscheidungsbäumen



Beißt




Beißt nicht




Haben Sie gelernt, wer beißt?




beißt




beißt




beißt nicht




beißt nicht






beißt







beißt nicht (?)



Beißt




Beißt nicht







beißt nicht




beißt




beißt nicht




beißt nicht




beißt



beißt




beißt nicht




beißt nicht




beißt nicht




beißt nicht




beißt nicht



beißt



beißt nicht



Was soll ich am Wochenende unternehmen? Entwerfen Sie einen Entscheidungsbaum!

| Weekend | Weather | Parents | Money | Decision |
|----------------|----------------|----------------|--------------|-----------------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

Welches Attribut steht im Wurzelknoten Ihres Baums? Warum?

Welches Attribut ist am „hilfreichsten“ für die Entscheidungsfindung?

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

Ein Attribut sollte möglichst weit oben im Baum stehen, wenn seine verschiedenen Attributwerte zu möglichst klaren Entscheidungen führen.

- Bsp.: *Money* als Wurzel. Argument: Wenn Money=Rich, geht man auf jeden Fall ins Kino
- Bsp.: *Parents* als Wurzel. Argument: Wenn Parents=Yes, geht man auf jeden Fall ins Kino

Der Gini-Koeffizient

- Der *Gini-Koeffizient* ist eine Zahl zwischen 0 und 1
- misst, wie *heterogen* („unordentlich“) die Daten sind, d.h. wie ungleichmäßig die Werte des Ziel-Features verteilt sind
- Gini = 0: Alle Daten haben beim Ziel-Feature denselben Wert → perfekte Ordnung
- Bsp. *Weather=Windy* → Werte bei *Decision*: [Cinema, Cinema, Shopping, Cinema]
→ ziemlich einheitlich → niedriger Gini-Koeffizient
- Bsp. *Parents=No* → [Tennis, Stay-In, Cinema, Shopping, Tennis]
→ eher uneinheitlich → hoher Gini-Koeffizient

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

Der Gini-Koeffizient (die Gini-Unreinheit)

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

- D: (Ausgewählte) Datensätze
- K: Anzahl möglicher Werte für das Ziel-Feature
 - hier: K=4 (4 Entscheidungen möglich)
- p_i : relative Häufigkeit des i-ten Werts in D
 - Bsp: In der Gesamtliste ist $p_{cinema} = \frac{6}{10}$ (an 6 von 10 Wochenenden gehe ich ins Kino)

$$Gini(D) = 1 - \sum_{i=1}^K (p_i)^2$$

Maximalwert 1, aber in der Regel deutlich niedriger

- Bei 2 möglichen Werten: Maximalwert Gini = 0,5
- Bei n möglichen Werten: Maximalwert Gini = $1 - \frac{1}{n}$ (näher sich 1)

- $Gini(\text{Gesamt}) = 1 - \left(\left(\frac{6}{10}\right)^2 + \left(\frac{2}{10}\right)^2 + \left(\frac{1}{10}\right)^2 + \left(\frac{1}{10}\right)^2 \right) = 0,58$

Trennschärfe bestimmen


- Wir wollen herausfinden, wie gut wir das *Zielmerkmal* (hier: *Decision*) anhand der Werte eines anderen Merkmals vorhersagen können
- Bsp.: Es wäre ideal, wenn wir bei *Parents=no* immer Tennis spielen und bei *Parents=yes* immer ins Kino gehen würden
- Dann wäre *Parents* der perfekte Wurzelknoten für unseren Entscheidungsbaum, weil es ausreicht, für einen unbekanntem Datensatz dessen Wert bei *Parent* zu betrachten, um eine Entscheidung zu treffen

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

Wie schätzt du die Trennschärfe von *Parents* ein?

Aufteilungen bewerten: Der *gewichtete* Gini-Koeffizient

Warum ist die Gewichtung notwendig?
Stell dir vor, es gäbe 9 Datensätze mit *Parents=yes* und nur 1 mit *Parents=no*



$$Gini(F) = \sum_{v \in V_F} p_v \cdot Gini(F = v)$$

- F : ein Feature (Bsp. *Parents*)
- V_F : mögliche Werte dieses Features (Bsp. $\{yes, no\}$)
- v : ein bestimmter Wert (Bsp. *no*)
- p_v : **relative Häufigkeit** von $F=v$ in den Daten (Bsp. $p_{no} = \frac{5}{10}$)

Gini(parents=no)

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

- $p_{Tennis} = \frac{2}{5}$

- $p_{Stay-In} = \frac{1}{5}$

- $p_{Shopping} = \frac{1}{5}$

- $p_{Cinema} = \frac{1}{5}$

- Gini(Parents=No) =


$$1 - \left(\left(\frac{2}{5} \right)^2 + \left(\frac{1}{5} \right)^2 + \left(\frac{1}{5} \right)^2 + \left(\frac{1}{5} \right)^2 \right)$$
$$= 0,72$$

Gini(parents=yes)

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

- $p_{Cinema} = \frac{5}{5}$
- $p_{Tennis} = \frac{0}{5}$
- $p_{Stay-In} = \frac{0}{5}$
- $p_{Shopping} = \frac{0}{5}$
- $Gini(Parents=Yes) =$
 $1 - \left(\left(\frac{5}{5} \right)^2 + \left(\frac{0}{5} \right)^2 + \left(\frac{0}{5} \right)^2 + \left(\frac{0}{5} \right)^2 \right)$
 $= 1 - 1 = 0$

Aufteilungen bewerten: Der *gewichtete* Gini-Koeffizient



$$Gini(F) = \sum_{v \in V_F} p_v \cdot Gini(F = v)$$

$$Gini(Parents) = \frac{5}{10} \cdot 0 + \frac{5}{10} \cdot 0,72 = 0,36$$

Formelsammlung TGI

6.2 Gini-Unreinheit

Für eine (ausgewählte) Menge von Datensätzen D und einem Ziel-Feature mit k möglichen Ausprägungen ist die **Gini-Unreinheit** (auch: Gini-Koeffizient, Gini-Index, Gini Impurity) wie folgt definiert:

$$Gini(D) = 1 - \sum_{i=1}^k (p_i)^2$$

wobei p_i die relative Häufigkeit der i -ten Ausprägung des Ziel-Merkmals ist.

Mit $Gini(F = v)$ bezeichnen wir die Gini-Unreinheit der Auswahl von Datensätzen, bei denen das Merkmal/Feature F den Wert v hat.

Ein Feature F kann verschiedene Werte $v \in V_f$ annehmen. Tritt ein bestimmter Wert v mit der relativen Häufigkeit p_v auf, dann berechnet sich die **gewichtete Gini-Unreinheit** für das Feature F folgendermaßen:

$$Gini(F) = \sum_{v \in V_F} p_v \cdot Gini(F = v)$$

Aufgabe

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

- Berechne die gewichteten Gini-Koeffizienten für die Features
 - Money und
 - Weather


Lösung

| Weekend | Weather | Parents | Money | Decision |
|---------|---------|---------|-------|----------|
| W1 | Sunny | Yes | Rich | Cinema |
| W2 | Sunny | No | Rich | Tennis |
| W3 | Windy | Yes | Rich | Cinema |
| W4 | Rainy | Yes | Poor | Cinema |
| W5 | Rainy | No | Rich | Stay In |
| W6 | Rainy | Yes | Poor | Cinema |
| W7 | Windy | No | Poor | Cinema |
| W8 | Windy | No | Rich | Shopping |
| W9 | Windy | Yes | Rich | Cinema |
| W10 | Sunny | No | Rich | Tennis |

- $Gini(Money) = \frac{3}{10} \cdot 0 + \frac{7}{10} \cdot 0,694 = 0,486$
- $Gini(Weather) = \frac{3}{10} \cdot 0,444 + \frac{3}{10} \cdot 0,444 + \frac{4}{10} \cdot 0,375 = 0,416$
- $Gini(Parents) = \frac{5}{10} \cdot 0 + \frac{5}{10} \cdot 0,72 = 0,36$

Parents hat den niedrigsten Gini-Wert, d.h. sorgt für am meisten Ordnung
→ bester Wurzelknoten des Entscheidungsbaums


So sieht unser Entscheidungsbaum jetzt aus



Wie geht es jetzt weiter?

- Wir ergänzen jeden Teilbaum nach derselben Methode wie eben
 - gewichtete Gini-Koeffizienten für alle Features (außer *Parents*) berechnen. Feature mit bestem (= niedrigsten) Wert auswählen
- Rekursion!

So sieht unser Entscheidungsbaum jetzt aus



Wichtig: In jedem Teilbaum nur noch diejenigen Datensätze verwenden, die zu den getroffenen Entscheidung passen!

- Bsp.: Im Ast *Parents=Yes* müssen alle Daten beim Feature *Parents* den Wert *Yes* haben.

Entscheidungsbaum der Tiefe 2

