

# Permanents and the power of entropy

Stefan Haan

2023-01-09

## Definition (Entropie)

Sei  $X$  eine Zufallsvariable mit Support  $\{x_1, x_2, \dots, x_n\}$  und Wahrscheinlichkeiten  $p_i = \text{Prob}(X = x_i)$ . Die Entropie von  $X$  ist definiert als

$$H(X) := \sum_i p_i \log_2 \frac{1}{p_i} = - \sum_i p_i \log_2 p_i.$$

## Definition (Entropie)

Sei  $X$  eine Zufallsvariable mit Support  $\{x_1, x_2, \dots, x_n\}$  und Wahrscheinlichkeiten  $p_i = \text{Prob}(X = x_i)$ . Die Entropie von  $X$  ist definiert als

$$H(X) := \sum_i p_i \log_2 \frac{1}{p_i} = - \sum_i p_i \log_2 p_i.$$

- ▶ Erwartungswert der "Überraschung", dass  $X$  den Wert  $x_i$  annimmt  $h(x_i) := \log_2 \frac{1}{p_i}$ .
- ▶ Maß für die Unsicherheit welchen Wert  $X$  annimmt.

## Definition (Entropie)

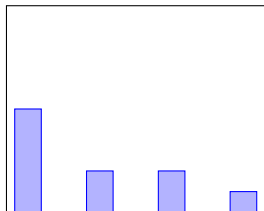
Sei  $X$  eine Zufallsvariable mit Support  $\{x_1, x_2, \dots, x_n\}$  und Wahrscheinlichkeiten  $p_i = \text{Prob}(X = x_i)$ . Die Entropie von  $X$  ist definiert als

$$H(X) := \sum_i p_i \log_2 \frac{1}{p_i} = - \sum_i p_i \log_2 p_i.$$

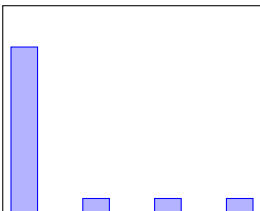
- ▶ Erwartungswert der "Überraschung", dass  $X$  den Wert  $x_i$  annimmt  $h(x_i) := \log_2 \frac{1}{p_i}$ .
- ▶ Maß für die Unsicherheit welchen Wert  $X$  annimmt.
- ▶ Nur von der Verteilung abhängig.

Bei welcher Zufallsvariable gibt es am meisten Unsicherheit über den Ausgang?

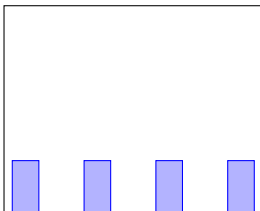
X



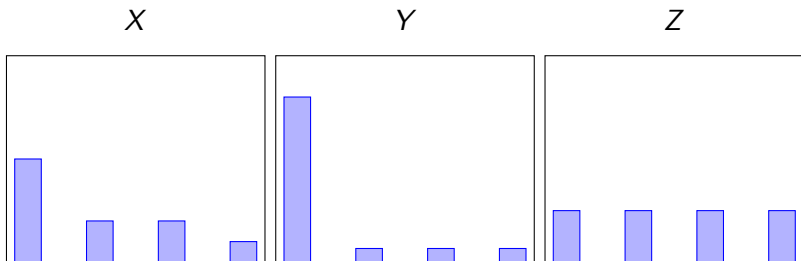
Y



Z



Bei welcher Zufallsvariable gibt es am meisten Unsicherheit über den Ausgang?



- ▶ Antwort: Z.
- ▶  $H(X) \approx 1.76$ ,  $H(Y) \approx 1.04$ ,  $H(Z) = 2$ .
- ▶ Vermutung: Die Entropie ist maximal bei Gleichverteilung.

## Lemma (Entropie maximal bei Gleichverteilung)

*Es gilt  $H(X) \leq \log_2 |\text{supp } X|$ . Die Schranke wird genau dann angenommen, wenn  $X$  gleichverteilt ist.*

Beweis " $\Leftarrow$ ".

Jensensche Ungleichung für die konkave Funktion  $\log_2$  liefert

$$H(X) = \sum_i p_i \log_2 \left( \frac{1}{p_i} \right) \leq \log_2 \left( \sum_i p_i \frac{1}{p_i} \right) = \log_2 n.$$

Bei Gleichverteilung ist  $p_1 = p_2 = \dots = \frac{1}{n}$  und es gilt Gleichheit. □

## Eine andere Sichtweise...

- ▶ Jemand versteckt vor uns den Ausgang der Zufallsvariable  $X$ .
- ▶ Sie beantwortet nur Ja/Nein Fragen über das Ergebnis.



## Eine andere Sichtweise...

- ▶ Jemand versteckt vor uns den Ausgang der Zufallsvariable  $X$ .
- ▶ Sie beantwortet nur Ja/Nein Fragen über das Ergebnis.
- ▶ Wieviele Ja/Nein Fragen müssen wir durchschnittlich stellen, um das Ergebnis mit Sicherheit zu kennen?
- ▶ Interpretation: *Informationsgehalt* in Bits.

Informationsgehalt von  $X \longleftrightarrow$  Unsicherheit über  $X$

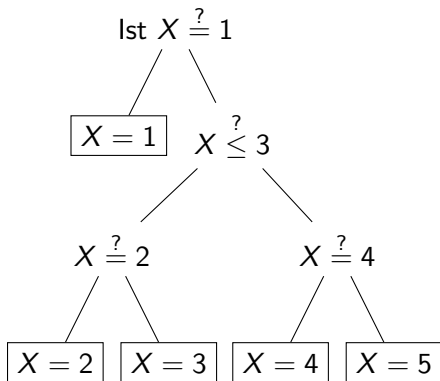
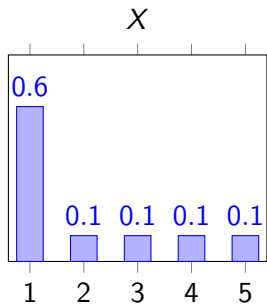
## Eine andere Sichtweise...

- ▶ Jemand versteckt vor uns den Ausgang der Zufallsvariable  $X$ .
- ▶ Sie beantwortet nur Ja/Nein Fragen über das Ergebnis.
- ▶ Wieviele Ja/Nein Fragen müssen wir durchschnittlich stellen, um das Ergebnis mit Sicherheit zu kennen?
- ▶ Interpretation: *Informationsgehalt* in Bits.

Informationsgehalt von  $X \longleftrightarrow$  Unsicherheit über  $X$

### Zusammenhang

Die Entropie ist eine untere Schranke für die durchschnittliche Anzahl Fragen, die wir stellen müssen!



$$1.77 \approx H(X) \leq \mathbb{E}[\#\text{Fragen}] = \frac{6}{10} \cdot 1 + \frac{4}{10} \cdot 3 = 1.8$$

## Definition (Bedingte Entropie)

Seien  $X, Y$  Zufallsvariablen die die Werte  $\{x_1, x_2, \dots, x_m\}$  bzw.  $\{y_1, y_2, \dots, y_n\}$  annehmen. Die Entropie von  $Y$ , falls  $X = x_i$  bekannt ist, ist definiert als

$$H(Y | x_i) := - \sum_j p(y_j | x_i) \log_2 p(y_j | x_i).$$

## Definition (Bedingte Entropie)

Seien  $X, Y$  Zufallsvariablen die die Werte  $\{x_1, x_2, \dots, x_m\}$  bzw.  $\{y_1, y_2, \dots, y_n\}$  annehmen. Die Entropie von  $Y$ , falls  $X = x_i$  bekannt ist, ist definiert als

$$H(Y | x_i) := - \sum_j p(y_j | x_i) \log_2 p(y_j | x_i).$$

Über alle Werte von  $X$  erhalten wir die *bedingte Entropie von  $Y$  unter  $X$* :

$$H(Y | X) := \sum_i p(x_i) H(Y | x_i).$$

## Definition (Bedingte Entropie)

Seien  $X, Y$  Zufallsvariablen die die Werte  $\{x_1, x_2, \dots, x_m\}$  bzw.  $\{y_1, y_2, \dots, y_n\}$  annehmen. Die Entropie von  $Y$ , falls  $X = x_i$  bekannt ist, ist definiert als

$$H(Y | x_i) := - \sum_j p(y_j | x_i) \log_2 p(y_j | x_i).$$

Über alle Werte von  $X$  erhalten wir die *bedingte Entropie von  $Y$  unter  $X$* :

$$H(Y | X) := \sum_i p(x_i) H(Y | x_i).$$

- ▶  $H(Y | X) = 0$ , wenn der Ausgang von  $Y$  keine Überraschung mehr ist, sobald  $X$  bekannt ist.
- ▶ Wenn  $X$  und  $Y$  unabhängig:  $H(Y | X) = H(Y)$ .

## Lemma

Für die Entropie der gemeinsamen Verteilung von  $X$  und  $Y$  gilt

$$H(X, Y) = H(X) + H(Y | X).$$

- ▶ Beweis: Definition und  $p(y, x) = p(x) p(y | x)$ .
- ▶ Iterierte Anwendung des Lemmas liefert  $H(X_1, \dots, X_n) = H(X_1) + H(X_2 | X_1) + \dots + H(X_n | X_1, \dots, X_{n-1})$ .

- ▶ Wenn  $X$  bekannt ist, wieviele Werte kann  $Y$  noch annehmen?
- ▶ Partitioniere  $\text{supp } X = \{x_1, \dots, x_n\}$  je nach Anzahl in  $E_1, \dots, E_d$ :

$$x \in E_j \iff |\text{supp}(Y \mid x)| = j.$$



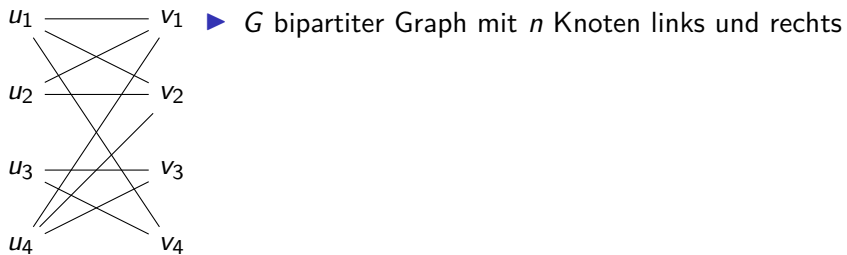
- ▶ Wenn  $X$  bekannt ist, wieviele Werte kann  $Y$  noch annehmen?
- ▶ Partitioniere  $\text{supp } X = \{x_1, \dots, x_n\}$  je nach Anzahl in  $E_1, \dots, E_d$ :

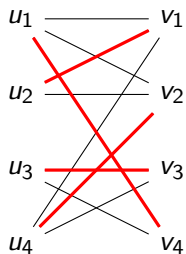
$$x \in E_j \iff |\text{supp}(Y | x)| = j.$$

- ▶ Da Entropie  $\leq \log_2 |\text{supp}(\dots)|$  ist, gilt

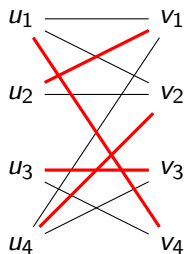
$$\begin{aligned} H(Y | X) &= \sum_{x \in \text{supp } X} p(x) H(Y | x) \\ &= \sum_{j=1}^d \sum_{x \in E_j} p(x) \underbrace{H(Y | x)}_{\leq \log_2 j} \\ &\leq \sum_{j=1}^d \text{Prob}(X \in E_j) \log_2 j. \end{aligned}$$

And now for something completely different. . .





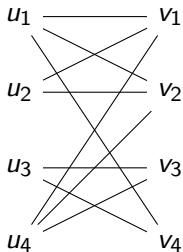
- ▶  $G$  bipartiter Graph mit  $n$  Knoten links und rechts
- ▶ Matching: Menge von Kanten ohne gemeinsame Knoten
- ▶ ... perfekt, wenn alle Knoten gematcht werden
- ▶ perfektes Matching weist jedem  $u_i$  genau ein  $v_{\sigma(i)}$  zu.

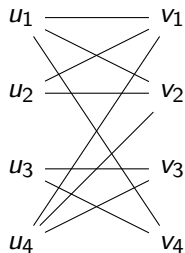


$$\sigma = 4132$$

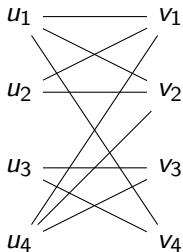
- ▶  $G$  bipartiter Graph mit  $n$  Knoten links und rechts
- ▶ Matching: Menge von Kanten ohne gemeinsame Knoten
- ▶ ... perfekt, wenn alle Knoten gematcht werden
- ▶ perfektes Matching weist jedem  $u_i$  genau ein  $v_{\sigma(i)}$  zu.
- ▶ entspricht einer Permutation!

- ▶ Permutationen  $\rightarrow$  perfekte Matchings?
- ▶  $\sigma = 3142$  liefert kein Matching, da keine Kante zwischen  $u_1$  und  $v_3$ .





- ▶ Permutationen  $\rightarrow$  perfekte Matchings?
- ▶  $\sigma = 3142$  liefert kein Matching, da keine Kante zwischen  $u_1$  und  $v_3$ .
- ▶ Sei  $M_G$  die 0/1-Matrix mit  $m_{ij} = 1 \iff (u_i, v_j) \in E$ .
- ▶ Zeilensumme  $d_i = \sum_j m_{ij}$  ist Knotengrad von  $u_i$ .



- ▶ Permutationen  $\rightarrow$  perfekte Matchings?
- ▶  $\sigma = 3142$  liefert kein Matching, da keine Kante zwischen  $u_1$  und  $v_3$ .
- ▶ Sei  $M_G$  die 0/1-Matrix mit  $m_{ij} = 1 \iff (u_i, v_j) \in E$ .
- ▶ Zeilensumme  $d_i = \sum_j m_{ij}$  ist Knotengrad von  $u_i$ .

### Definition (Permanente)

$$\text{per } M := \sum_{\sigma \in S_n} m_{1\sigma(1)} m_{2\sigma(2)} \cdots m_{n\sigma(n)}$$

Produkt ist 1  $\iff$  alle für  $\sigma$  benötigten Kanten in  $G$ .  
 Daher:  $\text{per } M_G = \text{Anzahl perfekte Matchings in } G$ .



$$\text{per } M = \sum_{\sigma \in S_n} m_{1\sigma(1)} m_{2\sigma(2)} \cdots m_{n\sigma(n)}$$

### Theorem (Brégman 1973)

Sei  $M$  eine  $n \times n$  Matrix mit Einträgen aus  $\{0, 1\}$ . Es gilt

$$\text{per } M \leq \prod_{i=1}^n (d_i!)^{(1/d_i)}$$

wobei  $d_i$  die Zeilensumme  $d_i = \sum_j m_{ij}$  ist.

$$\text{per } M = \sum_{\sigma \in S_n} m_{1\sigma(1)} m_{2\sigma(2)} \cdots m_{n\sigma(n)}$$

## Theorem (Brégman 1973)

Sei  $M$  eine  $n \times n$  Matrix mit Einträgen aus  $\{0, 1\}$ . Es gilt

$$\text{per } M \leq \prod_{i=1}^n (d_i!)^{(1/d_i)}$$

wobei  $d_i$  die Zeilensumme  $d_i = \sum_j m_{ij}$  ist.

- ▶  $\text{per } M$  (=Anzahl perfekter Matchings) für große 0/1-Matrizen sehr schwer zu bestimmen.
- ▶ Theorem liefert uns eine einfach zu bestimmende Abschätzung!

Wir wollen zeigen:

$$\text{per } M \leq \prod_{i=1}^n (d_i!)^{(1/d_i)}$$

- ▶  $\text{per } M$  ist die Anzahl perfekter Matchings in  $G_M$ .
- ▶ Sei  $\sigma$  eine gleichverteilte Zufallsvariable über den perfekten Matchings, dann gilt

$$H(\sigma(1), \dots, \sigma(n)) = \log_2(\text{per } M).$$

- ▶ ... umformuliert ist also zu zeigen, dass

$$H(\sigma(1), \dots, \sigma(n)) \leq \sum_{i=1}^n \frac{1}{d_i} \log_2(d_i!).$$

- Aus  $H(X, Y) = H(X) + H(Y | X)$  erhalten wir

$$H(\sigma(1), \dots, \sigma(n)) = \sum_{i=1}^n H(\sigma(i) | \sigma(1), \dots, \sigma(i-1)).$$

- ▶ Aus  $H(X, Y) = H(X) + H(Y | X)$  erhalten wir

$$H(\sigma(1), \dots, \sigma(n)) = \sum_{i=1}^n H(\sigma(i) | \sigma(1), \dots, \sigma(i-1)).$$

- ▶ Wir müssen  $\sigma(i)$  aber nicht in der Reihenfolge  $1, \dots, n$  aufdecken!
- ▶ Sei  $\tau \in S_n$  eine andere Reihenfolge und  $k_i := \tau^{-1}(i)$  der neue Index von  $i$  unter  $\tau$ , dann

$$H(\sigma(1), \dots, \sigma(n)) = \sum_{i=1}^n H(\sigma(i) | \sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))).$$

- ▶ Aus  $H(X, Y) = H(X) + H(Y | X)$  erhalten wir

$$H(\sigma(1), \dots, \sigma(n)) = \sum_{i=1}^n H(\sigma(i) | \sigma(1), \dots, \sigma(i-1)).$$

- ▶ Wir müssen  $\sigma(i)$  aber nicht in der Reihenfolge  $1, \dots, n$  aufdecken!
- ▶ Sei  $\tau \in S_n$  eine andere Reihenfolge und  $k_i := \tau^{-1}(i)$  der neue Index von  $i$  unter  $\tau$ , dann

$$H(\sigma(1), \dots, \sigma(n)) = \sum_{i=1}^n H(\sigma(i) | \sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))).$$

- ▶ Da dies für alle  $n!$  Reihenfolgen  $\tau$  gilt,

$$\dots = \frac{1}{n!} \sum_{\tau \in S_n} \sum_{i=1}^n H(\sigma(i) | \sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))).$$

- ▶ Wir wollen  $H(\sigma(i) \mid \overbrace{\sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))}^{=: X})$  abschätzen.
- ▶ Partitioniere  $\text{supp } X$  in Mengen  $E_{i,j}^{(\tau)}$ :

$x \in E_{i,j}^{(\tau)} : \iff$  genau  $j$  Nachbarn von  $u_i$  sind noch frei unter  $x$ ,

wobei ein Nachbar  $v_\ell$  von  $u_i$  noch frei ist, wenn er noch nicht von  $u_{\tau(1)}, \dots, u_{\tau(k_i-1)}$  gematcht wurde.

- ▶ Wir wollen  $H(\sigma(i) \mid \overbrace{\sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))}^{=: X})$  abschätzen.
- ▶ Partitioniere  $\text{supp } X$  in Mengen  $E_{i,j}^{(\tau)}$ :

$x \in E_{i,j}^{(\tau)} : \iff$  genau  $j$  Nachbarn von  $u_i$  sind noch frei unter  $x$ ,

wobei ein Nachbar  $v_\ell$  von  $u_i$  noch frei ist, wenn er noch nicht von  $u_{\tau(1)}, \dots, u_{\tau(k_i-1)}$  gematcht wurde.

- ▶ Da  $\sigma$  einmal ein perfektes Matching sein will, muss mindestens ein Nachbar von  $u_i$  noch frei geblieben sein, also  $1 \leq j \leq d_i$ .



- ▶ Wir wollen  $H(\sigma(i) \mid \overbrace{\sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))}^{=: X})$  abschätzen.
- ▶ Partitioniere  $\text{supp } X$  in Mengen  $E_{i,j}^{(\tau)}$ :

$x \in E_{i,j}^{(\tau)} \iff$  genau  $j$  Nachbarn von  $u_i$  sind noch frei unter  $x$ ,

wobei ein Nachbar  $v_\ell$  von  $u_i$  noch frei ist, wenn er noch nicht von  $u_{\tau(1)}, \dots, u_{\tau(k_i-1)}$  gematcht wurde.

- ▶ Da  $\sigma$  einmal ein perfektes Matching sein will, muss mindestens ein Nachbar von  $u_i$  noch frei geblieben sein, also  $1 \leq j \leq d_i$ .
- ▶ Gleichzeitig muss  $\sigma(i)$  einer der  $j$  noch freien Nachbarn werden, also  $\text{supp}(\sigma(i) \mid x) \leq j$ .

$$\implies H(\sigma(i) \mid x) \leq \log_2 j$$

$$\implies H(\sigma(i) \mid X) \leq \sum_{j=1}^{d_i} \text{Prob}(X \in E_{i,j}^{(\tau)}) \log_2 j.$$

## Zusammenfassend

$$\begin{aligned} H(\sigma(1), \dots, \sigma(n)) &= \frac{1}{n!} \sum_{\tau \in S_n} \sum_{i=1}^n H(\sigma(i) \mid \overbrace{\sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))}^{=: X}) \\ &\leq \frac{1}{n!} \sum_{\tau \in S_n} \sum_{i=1}^n \sum_{j=1}^{d_i} \text{Prob}(X \in E_{i,j}^{(\tau)}) \log_2 j \\ &= \frac{1}{n!} \sum_{i=1}^n \sum_{j=1}^{d_i} \log_2 j \sum_{\tau \in S_n} \text{Prob}(X \in E_{i,j}^{(\tau)}). \end{aligned}$$

## Zusammenfassend

$$\begin{aligned} H(\sigma(1), \dots, \sigma(n)) &= \frac{1}{n!} \sum_{\tau \in S_n} \sum_{i=1}^n H(\sigma(i) \mid \overbrace{\sigma(\tau(1)), \dots, \sigma(\tau(k_i - 1))}^{=: X}) \\ &\leq \frac{1}{n!} \sum_{\tau \in S_n} \sum_{i=1}^n \sum_{j=1}^{d_i} \text{Prob}(X \in E_{i,j}^{(\tau)}) \log_2 j \\ &= \frac{1}{n!} \sum_{i=1}^n \sum_{j=1}^{d_i} \log_2 j \sum_{\tau \in S_n} \text{Prob}(X \in E_{i,j}^{(\tau)}). \end{aligned}$$

Gelingt es uns zu zeigen, dass die innerste Summe  $\frac{n!}{d_i}$  ist, so vereinfacht sich der Ausdruck zu

$$\dots = \sum_{i=1}^n \frac{1}{d_i} \underbrace{\sum_{j=1}^{d_i} \log_2 j}_{\log_2 d_i!}$$

und wir sind fertig!

- ▶ Betrachte, in Reihenfolge  $\tau$ , die Liste von Knoten, die mit den Nachbarn von  $u_i$  gematcht werden.
- ▶ Diese Liste enthält auch  $u_i$  selbst. Aber an welcher Stelle?

- ▶ Betrachte, in Reihenfolge  $\tau$ , die Liste von Knoten, die mit den Nachbarn von  $u_i$  gematcht werden.
- ▶ Diese Liste enthält auch  $u_i$  selbst. Aber an welcher Stelle?
- ▶ Finden wir  $u_i$  an erster Stelle, so sind noch alle  $d_i$  Nachbarn von  $u_i$  frei geblieben, bis wir in  $\tau$  zu  $i$  gekommen sind.
- ▶ ... an zweiter Stelle,  $d_i - 1$  Nachbarn frei geblieben usw.

- ▶ Betrachte, in Reihenfolge  $\tau$ , die Liste von Knoten, die mit den Nachbarn von  $u_i$  gematcht werden.
- ▶ Diese Liste enthält auch  $u_i$  selbst. Aber an welcher Stelle?
- ▶ Finden wir  $u_i$  an erster Stelle, so sind noch alle  $d_i$  Nachbarn von  $u_i$  frei geblieben, bis wir in  $\tau$  zu  $i$  gekommen sind.
- ▶ ... an zweiter Stelle,  $d_i - 1$  Nachbarn frei geblieben usw.
- ▶ Über alle Reihenfolgen  $\tau$  tritt  $u_i$  aber an allen  $d_i$  Stellen mit gleicher Wahrscheinlichkeit auf!
- ▶ Da  $x \in E_{i,j}^{(\tau)} : \iff$  genau  $j$  Nachbarn sind noch frei geblieben, haben wir deshalb

$$\frac{1}{n!} \sum_{\tau \in S_n} \text{Prob}(X \in E_{i,j}^{(\tau)}) = \frac{1}{d_i}.$$

