

Die AGM-Schranke besagt, dass die Ungleichung $(***)$ sogar für jede Abbildung $x: [1, m] \rightarrow \mathbb{Q}_{\geq 0}$, die $(**)$ erfüllt, gilt.

Notation: $\mathbb{Q}_{\geq 0}$ bezeichnet die Menge aller nicht-negativen rationalen Zahlen.

Präzise Formulierung der AGM-Schranke:

Definition 2.8 (Faktionale Kantenüberdeckung)

Sei G ein beliebiger Hypergraph mit Knotenmenge V und Hyperkantenmenge E .

Eine faktionale Kantenüberdeckung (kurz: fKü, engl.: fractional edge cover) von G ist eine

Abbildung $x: E \rightarrow \mathbb{Q}_{\geq 0}$, so dass für jeden

Knoten $v \in V$ gilt:
$$\sum_{\substack{e \in E: \\ v \in e}} x(e) \geq 1.$$

Notation:

Wenn wir Join-Anfragen Q betrachten, sprechen wir von "faktionalen Kantenüberdeckungen von Q " und meinen damit faktionale Kantenüberdeckungen des Anfrage-Hypergraphen G_Q . Statt " $x(R_i(\bar{x}_i))$ " schreiben wir auch kurz: " $x(i)$ ".

Satz 2.9 (Die AGM-Schranke)

Sei Q eine Join-Anfrage der Form

$$Q(\bar{X}_0) \leftarrow R_1(\bar{X}_1), \dots, R_m(\bar{X}_m).$$

Für jede fraktionale Kantenüberdeckung x von Q und jede Datenbank D gilt:

$$|Q(D)| \leq \prod_{i=1}^m N_i^{x(i)},$$


wobei $N_i := |R_i^D|$ für alle $i \in [1, m]$ ist.

Bevor wir die AGM-Schranke beweisen, schauen wir uns zunächst einige Beispiele an

Beispiel 2.10

(a) Betrachte die Anfrage $Q'_\Delta(A, B, C) \leftarrow E_1(A, B), E_2(B, C), E_3(C, A)$

Skizze von $G_{Q'_\Delta}$:



Die Abbildung x mit $x(1) = x(2) = x(3) = \frac{1}{2}$ ist eine f.kü von Q'_Δ .

Laut AGM-Schranke gilt: $|Q'_\Delta(D)| \leq \prod_{i=1}^3 N_i^{1/2} = \sqrt{N_1} \cdot \sqrt{N_2} \cdot \sqrt{N_3}$
f.a. DBen D und $N_i := |E_i^D|$ für $i \in \{1, 2, 3\}$.

Dies liefert auch eine leicht verbesserte Variante von Satz Δ :

Für die Anfrage $Q_{\Delta}(A,B,C) \leftarrow E(A,B), E(B,C), E(C,A)$ und jede $\{E\}$ -DB D gilt:

$$|Q_{\Delta}(D)| \leq (N^D)^{3/2},$$

wobei $N^D := |E^D|$ ist

Beweis:

Sei D eine $\{E\}$ -DB und sei D' die $\{E_1, E_2, E_3\}$ -DB mit $E_i^{D'} := E^D$ f.a. $i \in [1,3]$. Dann gilt:


$$Q_{\Delta}(D) = Q'_{\Delta}(D'). \quad \text{Gemäß AGM-Schranke folgt:}$$

$$|Q_{\Delta}(D)| = |Q'_{\Delta}(D')| \leq \sqrt{N^{D'}} \cdot \sqrt{N^{D'}} \cdot \sqrt{N^{D'}} = (N^D)^{3/2}.$$

(b) Betrachte die Anfrage $Q_{(b)}$ aus Beispiel 2.5:

$$Q_{(b)}(A,B,C,D,E) \leftarrow R_1(A,B,C), R_2(C,D), R_3(D,E).$$

$G_{Q_{(b)}}$:




Für jede f.kü x von $Q_{(b)}$ gilt: $x(1) \geq 1$ und $x(3) \geq 1$, da der Knoten A (bzw. E) nur in einer einzigen Hyperkante, nämlich $R_1(A,B,C)$ (bzw. $R_3(D,E)$) vorkommt.

(c) Betrachte die Anfrage

$$Q_4(A, B, C, D) \leftarrow E_1(A, B), E_2(B, C), E_3(C, D), E_4(D, A)$$

g_{Q4}:



Einige fkt. von Q₄:

	1	2	3	4
$x^{(1)}$	1	0	1	0
$x^{(2)}$	0	1	0	1
$x^{(3)}$	$1/2$	$1/2$	$1/2$	$1/2$
$x^{(4)}$	$1/3$	$2/3$	$1/3$	$2/3$

(d) Sei $k \in \mathbb{N}$ mit $k \geq 2$. Betrachte die Coomis-Whitney Join-Anfrage LW_k mit

$$LW_k(x_1, \dots, x_k) \leftarrow R_1(x_2, \dots, x_k), R_2(x_1, x_3, \dots, x_k), \dots, R_k(x_1, \dots, x_{k-1})$$

dh: für jedes $i \in [1, k]$ ein Atom der Form $R_i(x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_k)$

Eine fkt. von LW_k ist die Abbildung $x: [1, k] \rightarrow \mathbb{Q}_{\geq 0}$ mit $x(i) := 1/(k-1)$ f.a. $i \in [1, k]$.

Die AGM-Schranke liefert: $|LW_k(D)| \leq \prod_{i=1}^k \sqrt[k-1]{N_i}$,

wobei $N_i := |R_i^D|$ f.a. $i \in [1, k]$ ist
 Insbesondere: Falls $N_1 = \dots = N_k = N$, so ist $|LW_k(D)| \leq N^{k/(k-1)} = N \cdot \sqrt[k-1]{N}$.

Betrachten wir nun folgendes Szenario:

Gegeben sei eine Join-Anfrage

$$Q(\bar{X}_0) \leftarrow R_1(\bar{X}_1), \dots, R_m(\bar{X}_m)$$

mit $\text{vars}(Q) = \{A_1, \dots, A_n\}$.

Anßerdem seien Zahlen N_1, \dots, N_m bekannt, von denen wir wissen, dass die Datenbank D , auf der Q ausgewertet wird in der Relation R_i genau N_i Tupel enthält (d.h. $N_i = |R_i^D|$), f.a. $i \in [1, m]$

Die AGM-Schranke besagt, dass für jede fkt x von Q gilt:

$$|Q(D)| \leq \prod_{i=1}^m N_i^{x(i)}$$

Frage: Wie können wir eine fkt x finden, für die $\prod_{i=1}^m N_i^{x(i)}$ möglichst klein ist?

Dazu lösen wir folgendes Optimierungsproblem:

Statt $x(i)$ schreibe x_i für $i \in [1, m]$ und setze $x := \begin{pmatrix} x_1 \\ \vdots \\ x_m \end{pmatrix}$.

Ziel: minimiere $\prod_{i=1}^m N_i^{x_i}$
 unter der Bedingung, dass Folgendes gilt:

(1) f.a. $j \in [1, m]$ ist $\sum_{\substack{i \in [1, m]: \\ A_j \in \bar{X}_i}} x_i \geq 1$
 und
 (2) f.a. $i \in [1, m]$ ist $x_i \geq 0$, $x_i \in \mathbb{Q}$

Beachte: $\prod_{i=1}^m N_i^{x_i}$ ist minimal

(\Rightarrow) $\log\left(\prod_{i=1}^m N_i^{x_i}\right)$ ist minimal

$$= \sum_{i=1}^m \log(N_i^{x_i}) = \sum_{i=1}^m x_i \cdot \log N_i = \sum_{i=1}^m x_i \cdot c_i$$

mit $c_i := \log N_i$ f.a. $i \in [1, m]$.

Als Zielfunktion für unser Minimierungsproblem können wir statt $\prod_{i=1}^m N_i^{x_i}$ also auch $c^T x$ verwenden.

• Die Bedingung (1) lässt sich darstellen als

" $Ax \geq b$ " für die Matrix $A_{\mathbb{Q}} := A := (a_{ji})_{\substack{j \in [1, m], \\ i \in [1, m]}}$ mit

$$a_{ji} := \begin{cases} 1 & \text{falls } A_j \in \{X_i\} \\ 0 & \text{sonst} \end{cases}$$

und den Vektor $b = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$

Unser Ziel ist also:

minimiere $c^T x$ (mit $c_i = \log N_i$ f.a. $i \in [1, m]$)

unter der Bedingung, dass

$$Ax \geq b, \quad (\text{mit } A = (a_{ji}) \text{ und } a_{ji} := \begin{cases} 1 & \text{falls } A_j \in \{X_i\} \\ 0 & \text{sonst} \end{cases})$$

$$x \geq 0, \quad x \in \mathbb{R}^m$$

Dies ist ein lineares Optimierungsproblem, für das wir eine rationale Lösung suchen.

Dazu stehen verschiedene Lösungsverfahren zur Verfügung:

- der Simplex-Algorithmus (exponentiell im worst-case, aber in der Praxis i.d.R. effizient)
- das Innere-Punkte-Verfahren (Karmarkar-Verfahren (1984) - läuft in Polynomialzeit)
- die Ellipsoid-Methode (Khachiyan (1979) - läuft in Polynomialzeit)

Beachte:

gemäß AHT-Schranke

Ist x eine Lösung des Optimierungsproblems OPT, so gilt für jede DB D mit $N_i = |\mathbb{R}_i^D|$ f.a. $i \in \{1, \dots, m\}$, dass $|Q(D)| \leq 2^{c^T x}$ ist.

Denn:

$$2^{c^T x} = 2^{\sum_{i=1}^m c_i x_i} = 2^{\sum_{i=1}^m x_i \cdot \log N_i} = 2^{\sum_{i=1}^m \log(N_i^{x_i})}$$

$$= 2^{\log\left(\prod_{i=1}^m N_i^{x_i}\right)} = \prod_{i=1}^m N_i^{x_i}$$

Beweis der AGM-Schranke

Zum Beweis benötigen wir einige Grundlagen aus der Wahrscheinlichkeitsrechnung und der Informationstheorie, die wir hier zunächst bereitstellen.

Wahrscheinlichkeitsräume

Definition: Ein endlicher Wahrscheinlichkeitsraum (Ω, P) besteht aus einer endlichen, nicht-leeren Menge Ω von Ergebnissen bzw. Elementarereignissen, denen Wahrscheinlichkeiten $P(\omega) = p_\omega \in \mathbb{R}$ für jedes $\omega \in \Omega$ zugeordnet sind, so dass gilt:

$$0 \leq p_\omega \leq 1, \text{ für jedes } \omega \in \Omega, \text{ und } \sum_{\omega \in \Omega} p_\omega = 1.$$

Ereignisse

Definition: Ein Ereignis ist eine Menge von Ergebnissen, d.h. eine Teilmenge von Ω . Die Wahrscheinlichkeit eines Ereignisses $A \subseteq \Omega$ ist definiert als

$$P(A) := \sum_{\omega \in A} P(\omega).$$

Wir schreiben \bar{A} um das Komplement von A zu bezeichnen, d.h. $\bar{A} = \Omega \setminus A$

Regeln zum Rechnen mit Wahrscheinlichkeiten:

Für jeden endlichen Wahrscheinlichkeitsraum (Ω, \mathcal{P}) und für alle Ereignisse A und B gilt:

- $P(\bar{A}) = 1 - P(A)$
- $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

Für $s \in \mathbb{N}_{\geq 1}$ und beliebige Ereignisse $A_1, \dots, A_s \in \mathcal{P}$

gilt: $P(A_1 \cup \dots \cup A_s) \leq \sum_{i=1}^s P(A_i)$

Falls $A_i \cap A_j = \emptyset$ für alle $i, j \in [1, s]$ mit $i \neq j$, so gilt

sogar: $P(A_1 \cup \dots \cup A_s) = \sum_{i=1}^s P(A_i)$.

Zufallsvariablen

Definition:

Sei (Ω, \mathcal{P}) ein endlicher Wahrscheinlichkeitsraum.

Eine Zufallsvariable ist eine Funktion $Y: \Omega \rightarrow M$,

für eine beliebige nicht-leere Menge M .

Für jedes $a \in M$ definieren wir die Wahrscheinlichkeit dafür, dass die Zufallsvariable Y den Wert a annimmt, durch

$P(Y=a) := P(A)$ für das Ereignis $A := \{\omega \in \Omega : Y(\omega) = a\}$.

Beispiel 2.11

Betrachte eine Join-Anfrage Q der Form

$$Q(\bar{X}_0) \leftarrow R_1(\bar{X}_1), \dots, R_m(\bar{X}_m)$$

mit $\bar{X}_0 = A_1, \dots, A_m$.

Sei D eine Datenbank vom Schema $\{R_1, \dots, R_m\}$.

Wir betrachten das "Zufallsexperiment", bei dem wir zufällig, gleichverteilt ein beliebiges Tupel aus dem Anfrageergebnis $Q(D)$ ziehen.

Dies entspricht dem endlichen Wahrscheinlichkeitsraum

$$(\Omega, \mathcal{P}) \text{ mit } \Omega := Q(D) \text{ und } P(\omega) := \frac{1}{|Q(D)|}$$

f.a. $\omega \in Q(D)$.

Sei $M := \text{atom}(D)$.

Für jedes $j \in [1, m]$ sei $Y_j: \Omega \rightarrow M$ die

Zufallsvariable, die jedem Tupel $t = (t_1, \dots, t_m) \in Q(D)$

den Wert t_j zuordnet — d.h. $Y_j(t) = \pi_j(t)$ f.a. $t \in Q(D)$.

Für jedes feste Element $a \in \text{atom}(D)$ ist dann

$P(Y_j = a)$ die Wahrscheinlichkeit dafür, dass ein zufällig, gleichverteilt aus $Q(D)$ gewähltes Tupel in der j -ten Spalte den Eintrag a hat. D.h.

$$P(Y_j = a) = \frac{|\{t \in Q(D) : \pi_j(t) = a\}|}{|Q(D)|}.$$

Informationsgehalt und Entropie

Definition:

Sei (Ω, P) ein endlicher Wahrscheinlichkeitsraum

Der Informationsgehalt eines Elementarereignisses

$w \in \Omega$ ist definiert als

$$\log\left(\frac{1}{P_w}\right) \quad (= -\log(P_w))$$

Die Entropie von (Ω, P) ist definiert als

$$H((\Omega, P)) := \sum_{w \in \Omega} P_w \cdot \log\left(\frac{1}{P_w}\right) \quad (= -\sum_{w \in \Omega} P_w \cdot \log(P_w))$$

Konvention für den Fall, dass $P_w = 0$ ist:

$$0 \cdot \log\left(\frac{1}{0}\right) := -0 \cdot \log(0) := 0$$

Bemerkung:

Man kann beweisen, dass Folgendes gilt:

$$H((\Omega, P)) \leq \left[\begin{array}{l} \text{durchschnittliche Länge des Bitstrings,} \\ \text{der ein gemäß } P \text{ zufällig aus } \Omega \\ \text{gewähltes Elementarereignis kodiert} \\ \text{(bei optimaler Kodierung)} \end{array} \right] \leq H((\Omega, P)) + 1$$

Wegen $H((\Omega, P)) \stackrel{\text{Def}}{=} \sum_{w \in \Omega} P_w \cdot \log\left(\frac{1}{P_w}\right)$ gilt daher:

$$\left[\begin{array}{l} \text{Informationsgehalt} \\ \text{von } w \in \Omega \end{array} \right] \stackrel{\text{Def}}{=} \log\left(\frac{1}{P_w}\right) \approx \left[\begin{array}{l} \text{Länge des Bitstrings,} \\ \text{der } w \text{ kodiert} \\ \text{(bei optimaler Kodierung)} \end{array} \right]$$

Definition (Entropie einer Zufallsvariablen)

Sei (Ω, P) ein endlicher Wahrscheinlichkeitsraum,
Sei M eine beliebige nicht-leere Menge und
Sei $Y: \Omega \rightarrow M$ eine Zufallsvariable.

Die Entropie von Y ist definiert als

$$H(Y) := \sum_{a \in M} P(Y=a) \cdot \log\left(\frac{1}{P(Y=a)}\right).$$

Bemerkung:

Wir können uns $H(Y)$ vorstellen als ein Maß für die
"Unsicherheit" bzw. "Unbestimmtheit" von Y .

Falls es ein $b \in M$ gibt, so das $P(Y=b) = 1$,
so wissen wir, dass die Zufallsvariable, unabhängig
vom Ausgang des Zufallsexperiments, stets den
Wert b annimmt — die "Unsicherheit" bzw.
"Unbestimmtheit" von Y ist also 0.

Die spiegelt sich in der Entropie wider, da

$$\begin{aligned} H(Y) &\stackrel{\text{Def}}{=} \sum_{a \in M} P(Y=a) \cdot \log\left(\frac{1}{P(Y=a)}\right) = P(Y=b) \cdot \log\left(\frac{1}{P(Y=b)}\right) \\ &= 1 \cdot \log\left(\frac{1}{1}\right) = 0 \end{aligned}$$

ist.

Falls jedoch für jedes $b \in M$ gilt, dass $P(Y=b) = \frac{1}{|M|}$,
so ist die "Unsicherheit / Unbestimmtheit" von Y größtmöglich,
und es gilt: $H(Y) = \sum_{a \in M} \frac{1}{|M|} \cdot \log(|M|) = \log(|M|)$

Wichtige Eigenschaften der Entropie:

Sei (Ω, P) ein endlicher Wahrscheinlichkeitsraum

(1) Für jede Zufallsvariable $Y: \Omega \rightarrow M$ mit endlichem M gilt:

$$0 \leq H(Y) \leq \log(|M|)$$

Anßerdem gilt:

- $H(Y) = 0 \iff \exists b \in M \text{ s.d. } P(Y=b) = 1$

- $H(Y) = \log(|M|) \iff \forall a, b \in M \text{ ist } P(Y=b) = \frac{1}{|M|}$

(2) Seien $Y_1: \Omega \rightarrow M_1$ und $Y_2: \Omega \rightarrow M_2$ zwei Zufallsvariablen.

Die zusammengesetzte Zufallsvariable (Y_1, Y_2) ist die Zufallsvariable $Y: \Omega \rightarrow M_1 \times M_2$ mit

$$Y(\omega) := (Y_1(\omega), Y_2(\omega)) \quad \forall \omega \in \Omega.$$

• Die gemeinsame Entropie von Y_1 und Y_2 ist die Entropie von (Y_1, Y_2) . D.h.:

$$H(Y_1, Y_2) = \sum_{\substack{a_1 \in M_1 \\ a_2 \in M_2}} P(Y_1=a_1, Y_2=a_2) \cdot \log\left(\frac{1}{P(Y_1=a_1, Y_2=a_2)}\right)$$

↑
Komma $\hat{=}$ "und"

• Für $a_1 \in M_1$ mit $P(Y_1=a_1) \neq 0$ ist die bedingte Entropie von Y_2 unter der Voraussetzung, dass $Y_1=a_1$ ist,

$$H(Y_2 | Y_1=a_1) := \sum_{a_2 \in M_2} P(Y_2=a_2 | Y_1=a_1) \cdot \log\left(\frac{1}{P(Y_2=a_2 | Y_1=a_1)}\right)$$

Hierbei ist $P(Y_2=a_2 | Y_1=a_1)$ die bedingte Wahrscheinlichkeit dafür, dass Y_2 den Wert a_2 annimmt unter der Voraussetzung, dass Y_1 den Wert a_1 angenommen hat.

$$\text{D.h.: } P(Y_2=a_2 | Y_1=a_1) := \frac{P(Y_2=a_2, Y_1=a_1)}{P(Y_1=a_1)}$$

• Die bedingte Entropie von Y_2 bei gegebenem Y_1 ist

$$\begin{aligned} H(Y_2 | Y_1) &:= \sum_{a_1 \in M_1} P(Y_1=a_1) \cdot H(Y_2 | Y_1=a_1) \\ &= \sum_{a_1 \in M_1} \left(P(Y_1=a_1) \cdot \sum_{a_2 \in M_2} P(Y_2=a_2 | Y_1=a_1) \cdot \log \left(\frac{1}{P(Y_2=a_2 | Y_1=a_1)} \right) \right) \end{aligned}$$

• Es gilt:
$$H(Y_1, Y_2) = H(Y_1) + H(Y_2 | Y_1) \quad \textcircled{1}$$

Beweis:

$$\begin{aligned} H(Y_1, Y_2) &\stackrel{\text{Def}}{=} \sum_{\substack{a_1 \in M_1 \\ a_2 \in M_2}} \overbrace{P(Y_1=a_1, Y_2=a_2)}^{= P(Y_1=a_1) \cdot P(Y_2=a_2 | Y_1=a_1)} \cdot \log \left(\frac{1}{P(Y_1=a_1, Y_2=a_2)} \right) \\ &= \sum_{a_1 \in M_1} \left(P(Y_1=a_1) \cdot \sum_{a_2 \in M_2} P(Y_2=a_2 | Y_1=a_1) \cdot \left(\log \left(\frac{1}{P(Y_1=a_1)} \right) + \log \left(\frac{1}{P(Y_2=a_2 | Y_1=a_1)} \right) \right) \right) \\ &= \sum_{a_1 \in M_1} P(Y_1=a_1) \cdot \log \left(\frac{1}{P(Y_1=a_1)} \right) \cdot \left(\sum_{a_2 \in M_2} P(Y_2=a_2 | Y_1=a_1) \right) + \sum_{a_1 \in M_1} P(Y_1=a_1) \cdot \left(\sum_{a_2 \in M_2} P(Y_2=a_2 | Y_1=a_1) \cdot \log \left(\frac{1}{P(Y_2=a_2 | Y_1=a_1)} \right) \right) \\ &= H(Y_1) + H(Y_2 | Y_1) \quad \square \end{aligned}$$

• Es gilt:

$$H(Y_2 | Y_1) \leq H(Y_2) \quad (2)$$

Intuition dazu: Die "Unsicherheit von Y_2 " kann durch die zusätzliche Information hinsichtlich Y_1 höchstens abnehmen, aber nicht größer werden.

Beweis von (2): Übung!

Hinweis: Verwende die so genannte Jensensche Ungleichung, die Folgendes besagt:

Für jede konkave Funktion f und für Zahlen $\lambda_1, \dots, \lambda_n \in \mathbb{R}_{\geq 0}$ mit $\sum_{i=1}^n \lambda_i = 1$ gilt

$$f\left(\sum_{i=1}^n \lambda_i x_i\right) \geq \sum_{i=1}^n \lambda_i f(x_i) \quad \text{für alle } x_1, \dots, x_n \in \mathbb{R}$$

Eine Funktion $f: \mathbb{R} \rightarrow \mathbb{R}$ heißt konkav, wenn für alle $x, y \in \mathbb{R}$ und alle $\lambda \in \mathbb{R}$ mit $0 \leq \lambda \leq 1$ gilt:

$$f(\lambda x + (1-\lambda)y) \geq \lambda f(x) + (1-\lambda)f(y)$$

Insbesondere ist die Funktion $f(x) := \log x$ konkav

(3) Die Begriffe aus (2) können für zusammengesetzte Zufallsvariablen (Y_1, \dots, Y_n) verallgemeinert werden: Sei $n \geq 2$. Für jedes $j \in \{n\}$ sei $Y_j: \Omega \rightarrow M_j$ eine Zufallsvariable.

Die zusammengesetzte Zufallsvariable (Y_1, \dots, Y_n) ist die Zufallsvariable $Y: \Omega \rightarrow M_1 \times \dots \times M_n$ mit

$$Y(\omega) := (Y_1(\omega), \dots, Y_n(\omega)) \quad \text{f.a. } \omega \in \Omega.$$

• Die gemeinsame Entropie von Y_1, \dots, Y_n ist

$$H(Y_1, \dots, Y_n) := \sum_{(a_1, \dots, a_n) \in M_1 \times \dots \times M_n} P\left(\bigwedge_{j=1}^n Y_j = a_j\right) \cdot \log\left(\frac{1}{P\left(\bigwedge_{j=1}^n Y_j = a_j\right)}\right)$$

• Analog zu (1) gilt

$$H(Y_1, \dots, Y_n) = H(Y_1) + H(Y_2 | Y_1) + H(Y_3 | Y_1, Y_2) + \dots + H(Y_n | Y_1, \dots, Y_{n-1}) \quad (1)$$

• Analog zu (2) gilt f.a. $J \subseteq J' \subseteq [n]$ und f.a. $k \in [n]$:

$$H(Y_k | (Y_{j'})_{j' \in J'}) \leq H(Y_k | (Y_j)_{j \in J}) \quad (2)$$

Das zentrale Werkzeug, das wir zum Beweis der AAM-Schranke verwenden werden, ist

Shearer's Lemma: Sei (Ω, P) ein endlicher Wahrscheinlichkeitsraum

Sei $n \in \mathbb{N}_{\geq 1}$ und sei $I := \{1, \dots, n\}$. Für jedes $j \in I$ sei $Y_j: \Omega \rightarrow M_j$ eine Zufallsvariable.

Für jedes $J \subseteq I$ sei $Y_J = (Y_j)_{j \in J}$.

Sei $\ell \in \mathbb{N}_{\geq 1}$, und seien J_1, \dots, J_ℓ Teilmengen von I , so dass für eine Zahl $q \in \mathbb{N}$ gilt: jedes $j \in I$ kommt in mindestens q der Mengen J_k vor.

Dann gilt: $H(Y_1, \dots, Y_n) \leq \frac{1}{q} \cdot \sum_{k=1}^{\ell} H(Y_{J_k})$

Beweis:

Gemäß (1) gilt für jedes $J \subseteq I$, dass

$$H(Y_J) = \sum_{j \in J} H(Y_j | (Y_i)_{i \in J \text{ mit } i < j}) \quad *$$

Somit gilt:

$$\sum_{k=1}^{\ell} H(Y_{J_k})$$

$$\stackrel{=}{=} \sum_{k=1}^{\ell} \sum_{j \in J_k} H(Y_j | (Y_i)_{i \in J_k \text{ mit } i < j}) \quad *$$

$$\stackrel{\geq}{\geq} \sum_{k=1}^{\ell} \sum_{j \in J_k} H(Y_j | (Y_i)_{i \in I \text{ mit } i < j}) \quad (2)$$

$$\stackrel{\geq}{\geq} q \cdot \sum_{j \in I} H(Y_j | (Y_i)_{i \in I \text{ mit } i < j}) \quad \stackrel{=}{=} q \cdot H(\underbrace{Y_I}_m) = (Y_1, \dots, Y_m)$$

den laut Voraussetzung gilt:
jedes $j \in I$ kommt in
mindestens q der Mengen J_1, \dots, J_k vor.

□