

Die Hypergeometrische Verteilung

Timm Grams, Fulda, 31. Juli 2010 (rev. 02.08.10)

Formel für die Wahrscheinlichkeiten

Die Grundmenge der Größe N möge M Merkmalsträger enthalten. Es ist $M \leq N$. Aus dieser Grundmenge werden n Elemente rein zufällig ausgewählt. Die Wahrscheinlichkeit p_k , dass sich in dieser Auswahl genau k Merkmalsträger befinden, ist gleich

$$p_k = \frac{\binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}}.$$

Dass es sich hier tatsächlich um eine Verteilung handelt, wird dadurch nachgewiesen, dass die Summe der p_k gleich 1 ist. Das ist genau dann der Fall, wenn die Formel

$$\sum_{k=0}^n \binom{M}{k} \cdot \binom{N-M}{n-k} = \binom{N}{n}$$

gilt. Ich beweise sie mittels vollständiger Induktion über N . (Ich reite auf der Sache mehr als nötig herum, weil wir die Formel in den folgenden Herleitungen wiederholt benötigen werden.)

Induktionsanfang: Weil 0 über 0 gleich 1 ist, gilt die Formel für $N = 0$.

Induktionsschluss: Wie man leicht einsieht, gilt die Formel für $M=0$ grundsätzlich. Wir können für den Induktionsschluss also davon ausgehen, dass M eine natürliche Zahl ist, dass also $0 < M$ gilt. Nun nehmen wir an, dass die Formel für $N-1$ bereits bewiesen worden ist. Daraus folgt

$$\begin{aligned} \sum_{k=0}^n \binom{M}{k} \cdot \binom{N-M}{n-k} &= \binom{N-M}{n} + \sum_{k=1}^n \binom{M}{k} \cdot \binom{N-M}{n-k} \\ &= \binom{N-M}{n} + \sum_{k=1}^n \left(\binom{M-1}{k-1} + \binom{M-1}{k} \right) \cdot \binom{N-M}{n-k} \\ &= \sum_{k=1}^n \binom{M-1}{k-1} \cdot \binom{N-M}{n-k} + \sum_{k=0}^n \binom{M-1}{k} \cdot \binom{N-M}{n-k} \\ &= \sum_{k=1}^n \binom{M-1}{k-1} \cdot \binom{N-M}{n-k} + \sum_{k=0}^n \binom{M-1}{k} \cdot \binom{N-M}{n-k} \\ &= \sum_{k=1}^n \binom{M-1}{k-1} \cdot \binom{N-1-(M-1)}{n-1-(k-1)} + \sum_{k=0}^n \binom{M-1}{k} \cdot \binom{N-1-(M-1)}{n-k} \\ &= \sum_{k=0}^{n-1} \binom{M-1}{k} \cdot \binom{N-1-(M-1)}{n-1-k} + \sum_{k=0}^n \binom{M-1}{k} \cdot \binom{N-1-(M-1)}{n-k} \\ &= \binom{N-1}{n-1} + \binom{N-1}{n} = \binom{N}{n}, \end{aligned}$$

also die Gültigkeit der Formel für N .

Der Erwartungswert

Der Erwartungswert μ ist in diesem Fall gegeben durch $\mu = \sum_{k=0}^n k \cdot p_k$. Wegen

$$\begin{aligned} \mu &= \sum_{k=0}^n x_k p_k = \sum_{k=0}^n k \cdot \binom{M}{k} \cdot \binom{N-M}{n-k} / \binom{N}{n} = \sum_{k=1}^n k \cdot \binom{M}{k} \cdot \binom{N-M}{n-k} / \binom{N}{n} \\ &= \sum_{k=1}^n M \cdot \binom{M-1}{k-1} \cdot \binom{N-M}{n-k} / \binom{N}{n} \\ &= \sum_{k=1}^n M \cdot \binom{M-1}{k-1} \cdot \binom{N-1-(M-1)}{n-1-(k-1)} / \binom{N}{n} \\ &= \sum_{k=0}^{n-1} M \cdot \binom{M-1}{k} \cdot \binom{N-1-(M-1)}{n-1-k} / \binom{N}{n} \\ &= M \cdot \sum_{k=0}^{n-1} \binom{M-1}{k} \cdot \binom{N-1-(M-1)}{n-1-k} / \binom{N}{n} \\ &= M \cdot \binom{N-1}{n-1} / \binom{N}{n} = n \frac{M}{N}. \end{aligned}$$

ist also

$$\boxed{\mu = n \frac{M}{N}}$$

Die Streuung

Die Streuung σ^2 ist in diesem Fall gegeben durch $\sigma^2 = \sum_{k=0}^n (k - \mu)^2 p_k = \left(\sum_{k=1}^n k^2 p_k \right) - \mu^2$. Es

ist

$$\begin{aligned} \sum_{k=1}^n k^2 p_k &= \sum_{k=1}^n \frac{k^2 \cdot \binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}} \\ &= \sum_{k=1}^n \frac{k(k-1) \cdot \binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}} + \sum_{k=1}^n \frac{k \cdot \binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}} \\ &= \sum_{k=2}^n \frac{k(k-1) \cdot \binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}} + n \frac{M}{N} \\ &= \sum_{k=2}^n \frac{M(M-1) \cdot \binom{M-2}{k-2} \cdot \binom{N-M}{n-k}}{\binom{N}{n}} + n \frac{M}{N} \end{aligned}$$

$$\begin{aligned}
 &= \sum_{k=2}^n \frac{M(M-1) \cdot \binom{M-2}{k-2} \cdot \binom{N-2-(M-2)}{n-2-(k-2)}}{\binom{N}{n}} + n \frac{M}{N} \\
 &= M(M-1) \cdot \sum_{k=0}^{n-2} \frac{\binom{M-2}{k} \cdot \binom{N-2-(M-2)}{n-2-k}}{\binom{N}{n}} + n \frac{M}{N} \\
 &= \frac{M(M-1)}{\binom{N}{n}} \cdot \sum_{k=0}^{n-2} \binom{M-2}{k} \cdot \binom{N-2-(M-2)}{n-2-k} + n \frac{M}{N} \\
 &= \frac{M(M-1)}{\binom{N}{n}} \cdot \binom{N-2}{n-2} + n \frac{M}{N} \\
 &= \frac{M(M-1)n(n-1)}{N(N-1)} + n \frac{M}{N}.
 \end{aligned}$$

Für die Streuung ergibt sich damit

$$\begin{aligned}
 \sigma^2 &= \frac{M(M-1)n(n-1)}{N(N-1)} + n \frac{M}{N} - \left(n \frac{M}{N} \right)^2 \\
 &= \frac{M(M-1)n(n-1)}{N(N-1)} + n \frac{M}{N} - \left(n \frac{M}{N} \right)^2 \\
 &= \frac{MN(M-1)n(n-1) + MN(N-1)n - M^2(N-1)n^2}{N^2(N-1)} \\
 &= \frac{MN(M-1)n(n-1) + MN(N-1)n - M^2(N-1)n^2}{N^2(N-1)} \\
 &= \frac{M^2Nn^2 - M^2Nn - MNn^2 + MNn + MN^2n - MNn - M^2Nn^2 + M^2n^2}{N^2(N-1)} \\
 &= \frac{-M^2Nn - MNn^2 + MN^2n + M^2n^2}{N^2(N-1)} \\
 &= \frac{MN(N-M)n - M(N-M)n^2}{N^2(N-1)} \\
 &= \frac{nM(N-M)(N-n)}{N^2(N-1)}.
 \end{aligned}$$

In Kürze:

$$\boxed{\sigma^2 = \frac{nM(N-M)(N-n)}{N^2(N-1)}}$$