



# Pólya-Verteilung 1930

Eine Urne enthalte  $s$  schwarze und  $w$  weiße Kugeln. Es wird zufällig eine Kugel entnommen, anschließend werden diese sowie  $c$  weitere Kugeln derselben Farbe in die Urne gelegt. Dieser Vorgang wird noch  $n - 1$  mal wiederholt. Das Ziehen einer schwarzen Kugel wird als Treffer bezeichnet. Die Anzahl  $X$  der Treffer nach  $n$  Ziehungen besitzt dann eine Pólya-Verteilung.




Wir betrachten zunächst eine Urne mit zwei schwarzen und einer weißen Kugel, zweimaliges Ziehen und  $c = 1$ : Wie groß ist die Wahrscheinlichkeit, aus der dann vier Kugeln enthaltenen Urne eine schwarze Kugel zu ziehen?



Bemerkenswerterweise hat sich die Wahrscheinlichkeit  $P_{2. \text{Zug}}$  für das Ziehen einer schwarzen Kugel gegenüber dem ersten Ziehen mit  $P_{1. \text{Zug}} = 2/3$  nicht geändert.

Was passiert, wenn wir nach dem 1. Zug zusätzlich  $c$  weitere Kugeln derselben Farbe in die Urne legen?



$$P(\text{Treffer im 2. Zug}) = \frac{1}{3(3+c)} \cdot [2(2+c) + 2] = \frac{2}{3}$$


Die im 2. Zug gezogene Kugel ist entweder eine ursprünglich vorhandene, die mit Wahrscheinlichkeit  $p = 2/3$  schwarz ist, oder eine der zusätzlich zurückgelegten Kugeln, deren schwarz/weiß-Verhältnis auch 2:1 beträgt.

Aus entsteht zusätzlich jeweils  $c$ -fach.

Auch eine zusätzlich zurückgelegte Kugel ist mit Wahrscheinlichkeit  $p = 2/3$  schwarz. Für  $c = 0$  (Ziehen mit Zurücklegen) entsteht eine Binomialverteilung, für  $c = -1$  (Ziehen ohne Zurücklegen) eine hypergeometrische Verteilung. Der Urneninhalt muss groß genug sein, damit  $n$ -maliges Ziehen für  $c < 0$  möglich ist.


$n = 3$

Es ist ratsam, vor den Wahrscheinlichkeiten die Urneninhalte im Diagramm zu notieren.



$$P(\text{Treffer im 3. Zug}) = \dots = \frac{2}{3}$$

Allgemeiner: Eine Urne enthalte  $s$  schwarze und  $w$  weiße Kugeln,  $n = 2$ .




$$P(\text{Treffer im 2. Zug}) = \dots = p = \frac{s}{s+w} \text{ und dann auch in jedem weiteren Zug.}$$

Es ist einsichtig, dass das schwarz/weiß-Verhältnis  $s : w$  nach jedem Zug erhalten bleibt.

Aus  $\bullet\bullet\circ$  jeweils  $k$ -fach entsteht  $\bullet\bullet\circ$  jeweils  $(k+c)$ -fach,  $c < 0$  eingeschlossen.

Dann folgt wegen der Additivität der Erwartungswertbildung:

$$E(X) = P(\text{Treffer im 1. Zug}) + P(\text{Treffer im 2. Zug}) + \dots + P(\text{Treffer im } n\text{-ten Zug}) = np$$



Pfade mit gleicher Trefferanzahl (hier  $n = 5$ ,  $k = 3$ ) haben (wie in der Binomialverteilung) dieselbe Wahrscheinlichkeit.

$$\begin{aligned}
 P(swsws) &= \frac{s}{s+w} \cdot \frac{w}{s+w+c} \cdot \frac{s+c}{s+w+2c} \cdot \frac{w+c}{s+w+3c} \cdot \frac{s+2c}{s+w+4c} \\
 &= \frac{s}{s+w} \cdot \frac{s+c}{s+w+c} \cdot \frac{s+2c}{s+w+2c} \cdot \frac{w}{s+w+3c} \cdot \frac{w+c}{s+w+4c}
 \end{aligned}$$

$$\begin{aligned}
 P(wsssw) &= \frac{w}{s+w} \cdot \frac{s}{s+w+c} \cdot \frac{s+c}{s+w+2c} \cdot \frac{s+2c}{s+w+3c} \cdot \frac{w+c}{s+w+4c} \\
 &= \frac{s}{s+w} \cdot \frac{s+c}{s+w+c} \cdot \frac{s+2c}{s+w+2c} \cdot \frac{w}{s+w+3c} \cdot \frac{w+c}{s+w+4c}
 \end{aligned}$$

Die Urnen enthalten schlussendlich jeweils gleichviele schwarze und weiße Kugeln. Die Gleichheit der Faktoren im Zähler wird durch Umordnen offensichtlich.





Das ergibt die Pólya-Verteilung mit den Parametern  $n$ ,  $s$ ,  $w$  und  $c$ .



$$P(X = k) = \binom{n}{k} \cdot \frac{\prod_{i=1}^k (s + (i-1)c) \cdot \prod_{i=1}^{n-k} (w + (i-1)c)}{\prod_{i=1}^n (s + w + (i-1)c)}, \quad k = 0, 1, \dots, n, \quad \prod_{i=1}^0 = 1$$

alternative Produktschreibweise

$$P(X = k) = \binom{n}{k} \cdot \frac{\prod_{i=0}^{k-1} (s + ic) \cdot \prod_{i=0}^{n-k-1} (w + ic)}{\prod_{i=0}^{n-1} (s + w + ic)}, \quad k = 0, 1, \dots, n, \quad \prod_{i=0}^{-1} = \prod_{i=0}^0 = 1$$

# Diagramme der Pólya-Verteilung





## Erwartungswert

$$P_{n,s,w}(X = k) = \binom{n}{k} \cdot \frac{\prod_{i=0}^{k-1} (s + ic) \cdot \prod_{i=0}^{n-k-1} (w + ic)}{\prod_{i=0}^{n-1} (s + w + ic)}, \quad k = 0, 1, \dots, n, \quad \prod_{i=0}^{-1} = \prod_{i=0}^0 = 1$$

$$E(X) = \sum_{k=0}^n k \cdot P_{n,s,w}(X = k) = \sum_{k=0}^n k \cdot \binom{n}{k} \cdot \frac{\prod_{i=0}^{k-1} (s + ic) \cdot \prod_{i=0}^{n-k-1} (w + ic)}{\prod_{i=0}^{n-1} (s + w + ic)} \quad | k \cdot \binom{n}{k} = n \cdot \binom{n-1}{k-1}$$

$$= np \sum_{k=1}^n \binom{n-1}{k-1} \cdot \frac{\prod_{i=1}^{k-1} (s + ic) \cdot \prod_{i=0}^{n-k-1} (w + ic)}{\prod_{i=1}^{n-1} (s + w + ic)} \quad | \text{achte auf die Indices, } p = \frac{s}{s+w}$$

$$= np \underbrace{\sum_{k=1}^n P_{n-1,s+c,w}(X = k-1)}_1 = np \quad | \text{siehe *}$$

1 Verteilung für  $n-1$

$$\begin{aligned} * P_{n-1,s+c,w}(X = k-1) &= \binom{n-1}{k-1} \cdot \frac{\prod_{i=0}^{(k-1)-1} (s + (i+1)c) \cdot \prod_{i=0}^{(n-1)-(k-1)-1} (w + ic)}{\prod_{i=0}^{(n-1)-1} (s + w + (i+1)c)} \\ &= \binom{n-1}{k-1} \cdot \frac{\prod_{i=1}^{k-1} (s + ic) \cdot \prod_{i=0}^{n-k-1} (w + ic)}{\prod_{i=1}^{n-1} (s + w + ic)} \end{aligned}$$

## Varianz

Benötigt wird

$$k(k-1) \cdot \binom{n}{k} = n(n-1) \cdot \binom{n-2}{k-2}, \quad k \geq 2$$

$$\begin{aligned} V(X) &= E(X^2) - (E(X))^2 \\ &= E(X^2 - X) + E(X) - (E(X))^2 \end{aligned}$$

$$\begin{aligned} E(X^2 - X) &= \sum_{k=2}^n k(k-1) \cdot \binom{n}{k} \cdot \frac{\prod_{i=0}^{k-1} (s+ic) \cdot \prod_{i=0}^{n-k-1} (w+ic)}{\prod_{i=0}^{n-1} (s+w+ic)} \\ &= n(n-1) \frac{s(s+c)}{(s+w)(s+w+c)} \sum_{k=2}^n \binom{n-2}{k-2} \cdot \frac{\prod_{i=2}^{k-1} (s+ic) \cdot \prod_{i=0}^{n-k-1} (w+ic)}{\prod_{i=2}^{n-1} (s+w+ic)} \\ &= n(n-1) \frac{s(s+c)}{(s+w)(s+w+c)} \underbrace{\sum_{k=2}^n P_{n-2, s+2c, w}(X = k-2)}_{1 \text{ Verteilung für } n-2} = n(n-1) \frac{s(s+c)}{(s+w)(s+w+c)} \quad | \text{ siehe } * \end{aligned}$$

$$\begin{aligned} V(X) &= E(X^2 - X) + E(X) - (E(X))^2 \\ &= n(n-1) \frac{p(s+c)}{s+w+c} + np - n^2 p^2 \quad | p = \frac{s}{s+w} \\ &= np(1-p) \left[ 1 + \frac{(n-1)c}{s+w+c} \right] \end{aligned}$$

Die Äquivalenz der Terme (siehe nächste Seite) für  $V(X)$  kann verifiziert werden.

Das Gleichsetzen von  $V(X)$  mit  $np(1-p) \left[ 1 + \frac{ac}{s+w+c} \right]$  ist naheliegend, da wir für  $c = 0$  die Varianz der Binomialverteilung erhalten. Gleichheit liegt dann für  $a = n - 1$  vor.

$$\begin{aligned} * P_{n-2, s+2c, w}(X = k-2) &= \binom{n-2}{k-2} \cdot \frac{\prod_{i=0}^{(k-2)-1} (s+(i+2)c) \cdot \prod_{i=0}^{(n-2)-(k-2)-1} (w+ic)}{\prod_{i=0}^{(n-2)-1} (s+w+(i+2)c)} \\ &= \binom{n-2}{k-2} \cdot \frac{\prod_{i=2}^{k-1} (s+ic) \cdot \prod_{i=0}^{n-k-1} (w+ic)}{\prod_{i=2}^{n-1} (s+w+ic)} \end{aligned}$$


## Äquivalenz der Terme

$$\begin{aligned}n(n-1) \frac{p(s+c)}{s+w+c} + np - n^2 p^2 &\stackrel{!}{=} np(1-p) \left[1 + \frac{(n-1)c}{s+w+c}\right] && | : np \\(n-1) \frac{s+c}{s+w+c} + 1 - np &= (1-p) + \frac{(1-p)(n-1)c}{s+w+c} && | 1 \text{ fällt heraus.} \\(n-1) \frac{s+c}{s+w+c} - p(n-1) &= \frac{(1-p)(n-1)c}{s+w+c} \\ \frac{s+c}{s+w+c} - p &= \frac{(1-p)c}{s+w+c} && | \cdot (s+w+c) \\s+c - p(s+w+c) &= (1-p)c && | c \text{ fällt heraus.} \\s - p(s+w+c) &= -pc && | : p, -c \text{ fällt heraus.} \\ \frac{s}{p} - s - w &= 0 && | p = \frac{s}{s+w} \\0 &= 0\end{aligned}$$

## Varianz einer Indikatorsumme

Sei  $A$  ein Ereignis in  $\Omega$ .

Wir betrachten die Funktion, die jedem Element aus  $A$  den Wert 1 und jedem Element aus  $\bar{A}$  den Wert 0 zuordnet. Sie heißt Indikator von  $A$  und wird mit  $I_A$  bezeichnet.



Indikatoren und Ereignisse entsprechen einander eindeutig.

Es gilt:  $E(I_A) = 1 \cdot P(A) + 0 \cdot P(\bar{A}) = P(A)$

Der Erwartungswert eines Indikators ist gleich der Wahrscheinlichkeit des Ereignisses, das er anzeigt.

Offensichtlich aber wichtig ist die Eigenschaft:  $I_A^2 = I_A$

Grundlegende Beziehungen zwischen Mengen- und Indikator-Operationen sind:

$$I_{\bar{A}} = 1 - I_A$$

$$I_{A_1 \cap A_2 \cap \dots \cap A_n} = I_{A_1} \cdot I_{A_2} \cdot \dots \cdot I_{A_n} = \min\{I_{A_1}, I_{A_2}, \dots, I_{A_n}\}$$

$$I_{A_1 \cup A_2 \cup \dots \cup A_n} = 1 - (1 - I_{A_1})(1 - I_{A_2}) \dots (1 - I_{A_n}) = \max\{I_{A_1}, I_{A_2}, \dots, I_{A_n}\}$$

Insbesondere ist:

$$I_{A \cup B} = 1 - (1 - I_A)(1 - I_B)$$

$$= I_A + I_B - I_A I_B$$

$$= I_A + I_B - I_{A \cap B} \implies \text{(Erwartungswert auf beiden Seiten)}$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Es seien  $A_1, \dots, A_n \subseteq \Omega$  Ereignisse.

Die Zufallsvariable  $X = \sum_{i=1}^n I_{A_i}$  heißt Indikatorsumme oder Zählvariable.

$X$  gibt an, wie viele der  $A_i$  eintreten.  $\{X = 0\} = \bar{A}_1 \cap \bar{A}_2 \cap \dots \cap \bar{A}_n$ ,  $\{X = n\} = A_1 \cap A_2 \cap \dots \cap A_n$

$$V(X) = \sum_{i=1}^n P(A_i)(1 - P(A_i)) + 2 \sum_{1 \leq i < j \leq n} (P(A_i \cap A_j) - P(A_i)P(A_j))$$

Beweis

$$V(X) = E(X^2) - (E(X))^2$$

$$X^2 = \left( \sum_{i=1}^n I_{A_i} \right)^2 = \sum_{i=1}^n \sum_{j=1}^n I_{A_i} I_{A_j} = \sum_{i=1}^n \sum_{j=1}^n I_{A_i \cap A_j} = \sum_{i=1}^n I_{A_i} + 2 \sum_{1 \leq i < j \leq n} I_{A_i \cap A_j}$$

## Varianz der Pólya-Verteilung alternativ

$$\implies E(X^2) = \sum_{i=1}^n P(A_i) + 2 \sum_{1 \leq i < j \leq n} P(A_i \cap A_j)$$

$$(E(X))^2 = \left( \sum_{i=1}^n P(A_i) \right)^2 = \sum_{i=1}^n \sum_{j=1}^n P(A_i)P(A_j) = \sum_{i=1}^n (P(A_i))^2 + 2 \sum_{1 \leq i < j \leq n} P(A_i)P(A_j)$$

$$\implies V(X) = \sum_{i=1}^n P(A_i)(1 - P(A_i)) + 2 \sum_{1 \leq i < j \leq n} (P(A_i \cap A_j) - P(A_i)P(A_j)) \quad | P(A_i) \text{ ausgeklammert}$$

Insbesondere für  $P(A_i) = P(A_1)$ ,  $P(A_i \cap A_j) = P(A_1 \cap A_2)$ ,  $i \neq j \implies$

$$V(X) = n \cdot [P(A_1)(1 - P(A_1)) + (n - 1)(P(A_1 \cap A_2) - (P(A_1))^2)] \quad | 2 \binom{n}{2} = n(n - 1)$$

angewandt auf die Pólya-Verteilung

$$V(X) = np(1 - p) + n(n - 1)(P(A_1 \cap A_2) - p^2) \quad | p = P(A_i) = \frac{s}{s + w}$$

Mit  $P(A_1 \cap A_2) = p \cdot \frac{s + c}{s + w + c}$

(1. und 2. Kugel schwarz, nur die Anzahl ist relevant, nicht die Stellung im Pfad)

ergibt das:  $V(X) = np(1 - p)\left(1 + \frac{(n - 1)c}{s + w + c}\right)$

Nachdem durch  $np$  dividiert wurde, ist zu verifizieren:

$$(1 - p) + (n - 1) \underbrace{\left( \frac{s + c}{s + w + c} - p \right)}_{\frac{wc}{(s + w + c)(s + w)}} \stackrel{!}{=} (1 - p) \left( 1 + \frac{(n - 1)c}{s + w + c} \right)$$

$$\frac{wc}{(s + w + c)(s + w)} = \frac{(1 - p)c}{s + w + c} \quad | p = \frac{s}{s + w}, \text{ vereinfachen, } 1 - p = \frac{w}{s + w}$$

# Hypergeometrische Verteilung

In einer Lieferung von 1000 Glühlampen sind 20 defekt. Für eine Stichprobe vom Umfang  $n = 100$  interessieren wir uns für die Wahrscheinlichkeiten, dass  $k = 0, 1, 2, \dots$ , defekte Glühlampen in der Stichprobe sind.

Ziehen ohne Zurücklegen:

$X$  ist hypergeometrisch verteilt.

$$P(X = k) = \frac{\binom{r}{k} \cdot \binom{N-r}{n-k}}{\binom{N}{n}}$$

$N$	Grundgesamtheit	im Beispiel 1000
$n$	Stichprobenumfang	100
$r$	Anzahl aller Merkmalsträger	20
$k$	Anzahl der Merkmalsträger in der Stichprobe	

Varianz der hypergeometrischen Verteilung

$$V(X) = n \frac{r}{N} \left(1 - \frac{r}{N}\right) \frac{N-n}{N-1} \quad | \quad p = \frac{r}{N}$$


$$= np(1-p) \frac{N-n}{N-1}$$

Die Varianz der Pólya-Verteilung

$$V(X) = np(1-p) \left[1 + \frac{(n-1)c}{s+w+c}\right] \quad | \quad p = \frac{s}{s+w}$$

geht mit  $c = -1$ ,  $s+w \hat{=} N$ ,  $s \hat{=} r$ ,  $n \hat{=} n$  in die Varianz der hypergeometrischen Verteilung über.

$c$  variiert



Startseite

Pólya-Verteilung GeoGebra