

## Zur Abhängigkeit der Varianz von einem Einzelwert<sup>1</sup>

Man habe die Daten  $a, b, x$ . Der Mittelwert  $\frac{x}{3} + \frac{a+b}{3}$  hängt linear von  $x$  ab, die Varianz quadratisch, so dass kein monotoner Zusammenhang zu erwarten ist. Sehen wir uns das an: Die Varianz

$$V(a, b, x) = \frac{\left(x - \frac{a+b+x}{3}\right)^2 + \left(a - \frac{a+b+x}{3}\right)^2 + \left(b - \frac{a+b+x}{3}\right)^2}{3} = \frac{2}{9} \cdot \left( \left(x - \frac{a+b}{2}\right)^2 + \frac{3}{4} \cdot (a-b)^2 \right)$$

beschreibt in Abhängigkeit von  $x$  eine nach oben geöffnete Parabel und nimmt den kleinsten Wert für  $x = \frac{a+b}{2}$  an; dieser beträgt  $\frac{1}{6} \cdot (a-b)^2$  und ist *kleiner* als die Varianz

$$V(a, b) = \frac{\left(a - \frac{a+b}{2}\right)^2 + \left(b - \frac{a+b}{2}\right)^2}{2} = \frac{(a-b)^2}{4} \text{ zu } a \text{ und } b.$$

Für  $x = \frac{a+b}{2} \pm \frac{\sqrt{6}}{4} \cdot (a-b)$  ist  $V(a, b, x) = V(a, b)$ .

Allgemeiner habe man die Daten  $a_1, a_2, \dots, a_n$  und  $x$ , und es sei  $S := \sum_{i=1}^n a_i$  und  $Q := \sum_{i=1}^n a_i^2$ . Der

Mittelwert  $\frac{S}{n+1} + \frac{x}{n+1}$  hängt wieder linear von  $x$  ab.

Mit  $b_j := (n+1) \cdot a_j - S$  ist wegen  $\sum_{j=1}^n b_j = (n+1) \cdot S - n \cdot S = S$  und wegen

$$\sum_{j=1}^n b_j^2 = (n+1)^2 \cdot Q - 2 \cdot S^2 \cdot (n+1) + n \cdot S^2 = (n+1)^2 \cdot Q - S^2 \cdot (n+2)$$

ist die Varianz gegeben durch

---

<sup>1</sup> Zu diesen Ausführungen wurde ich angeregt von Hans Humenberger: How does the change of a single data point affect the variance, and why? In: Teaching Statistics 2020; 42: 87-90. Eine deutsche Übersetzung erscheint demnächst in Stochastik in der Schule.

$$\begin{aligned}
V(a_1, \dots, a_n, x) &= \frac{\left(x - \frac{S}{n+1} - \frac{x}{n+1}\right)^2 + \sum_{j=1}^n \left(a_j - \frac{S}{n+1} - \frac{x}{n+1}\right)^2}{n+1} \\
&= \frac{(n \cdot x - S)^2 + \sum_{j=1}^n ((n+1) \cdot a_j - S - x)^2}{(n+1)^3} \\
&= \frac{(n \cdot x - S)^2 + \sum_{j=1}^n (b_j - x)^2}{(n+1)^3} \\
&= \frac{x^2 \cdot (n^2 + n) - 2 \cdot x \cdot \left(n \cdot S + \sum_{j=1}^n b_j\right) + S^2 + \sum_{j=1}^n b_j^2}{(n+1)^3} \\
&= \frac{x^2 \cdot (n^2 + n) - 2 \cdot x \cdot (n \cdot S + S) + S^2 + (n+1)^2 \cdot Q - S^2 \cdot (n+2)}{(n+1)^3} \\
&= \frac{x^2 \cdot n \cdot (n+1) - 2 \cdot x \cdot S \cdot (n+1) - S^2 \cdot (n+1) + (n+1)^2 \cdot Q}{(n+1)^3} \\
&= \frac{x^2 \cdot n - 2 \cdot x \cdot S - S^2 + (n+1) \cdot Q}{(n+1)^2}
\end{aligned}$$

Dieser Term beschreibt wieder eine nach oben geöffnete Parabel. Für  $x = \frac{S}{n} = \frac{\sum_{i=1}^n a_i}{n}$  wird (analog zum Fall  $n=2$ ) der kleinste Wert angenommen. Insbesondere steigt die Varianz, wenn sich  $x$  von  $\frac{\sum_{i=1}^n a_i}{n}$  entfernt. Der kleinste Wert beträgt

$$V_{\min} = \frac{\frac{S^2}{n} - 2 \cdot \frac{S}{n} \cdot S - S^2 + (n+1) \cdot Q}{(n+1)^2} = \frac{-S^2 \cdot \frac{n+1}{n} + (n+1) \cdot Q}{(n+1)^2} = \frac{n \cdot Q - S^2}{n \cdot (n+1)}$$

und ist (wie im Fall  $n=2$ ) kleiner als die Varianz  $V(a_1, \dots, a_n) = \frac{\sum_{j=1}^n \left(a_j - \frac{S}{n}\right)^2}{n} = \frac{n \cdot Q - S^2}{n^2}$  für  $n$  Daten.

Es gibt also wieder zwei  $x$ -Werte, für die  $V(a_1, \dots, a_n, x) = V(a_1, \dots, a_n)$  ist.