

## Anlage zum AK-Bericht Nr. 2

### Zusammenstellung der im Bericht verwendeten mathematischen Formalismen

#### 1. Korrelationskoeffizient (Bartsch s. 573)

Zusammenhang zwischen der Testreaktion x und anderen Zustandsparametern y

$$r_{xy} = \frac{m(xy) - m(x)m(y)}{\sqrt{(m(x^2) - m(x)^2)(m(y^2) - m(y)^2)}} \quad (1)$$

dabei ist  $m(x)$  = Mittelwert von  $x_i$ ,  $m(y)$  = Mittelwert von  $y_i$  und  
 $m(xy)$  = Mittelwert von  $x_i y_i$ , also

$$m(x) = \frac{1}{n} \sum x_i; \quad m(x^2) = \frac{1}{n} \sum x_i^2; \quad m(y) = \frac{1}{n} \sum y_i; \quad m(y^2) = \frac{1}{n} \sum y_i^2 \quad \text{und} \\ m(xy) = \frac{1}{n} \sum x_i y_i \quad (2)$$

#### 2. Regression über die $y_i$ -Werte, ausgehend vom Punkthaufen $x_i, y_i$ mit der Anzahl n.

Es wird nur die lineare Regression mit  $y = a_0 + a_1 x$  betrachtet. (3)

(siehe Brauch, Dreyer, Hacke s. 665)

Minimierung über die  $y_i$ -Werte mit der Quadratsumme

$$Q = \sum_{i=1}^{i=n} (y_i - a_0 - a_1 x_i)^2 = \sum v^2 \quad (4)$$

Bestimmung von  $a_0$  und  $a_1$  mit den 2 Gleichungen für das Q-Minimum

$$\frac{\partial Q}{\partial a_0} = -2 \sum (y_i - a_0 - a_1 x_i) = 0 \quad \text{mit } 0 = -2n(m(y) - a_0 - a_1 m(x)) \quad (5a)$$

$$\frac{\partial Q}{\partial a_1} = -2 \sum (y_i - a_0 - a_1 x_i) x_i = 0 \quad \text{mit } 0 = -2n(m(xy) - a_0 m(x) - a_1 m(x^2)) \quad (5b)$$

Aus (5a)  $a_0 = m(y) - a_1 m(x)$  eingesetzt in (5b), dann wird

$$a_1 = \frac{m(xy) - m(x)m(y)}{m(x^2) - m^2(x)} \quad (6a)$$

$$a_0 = \frac{m(y)m(x^2) - m(x)m(xy)}{m(x^2) - m^2(x)} \quad (6b)$$

Wird die Testreaktion  $x$  gesetzt mit Wertebereich 0 bis 1, dann kann die Regressionsgerade (3) mit  $x=0$  und  $y(0)=a_0$

$$x=1 \text{ und } y(1)=a_0+a_1 \quad (7)$$

gut gezeichnet werden.

### 3. Krümmung von Q im Minimum

Ausgehend von (4) wird

$$\begin{aligned} Q &= \sum [(y_i - a_0) - a_1 x_i]^2 = \sum [(y_i - a_0)^2 - 2a_1(y_i - a_0)x_i + a_1^2 x_i^2] \\ &= \sum [y_i^2 - 2a_0 y_i + a_0^2 - 2a_1 x_i y_i + 2a_0 a_1 x_i - a_1^2 x_i^2] \\ &= n [m(y^2) - 2a_0 m(y) + a_0^2 - 2a_1 m(xy) + 2a_0 a_1 m(x) + a_1^2 m(x^2)] \end{aligned} \quad (8)$$

Nach Bronstein S.205 ist mit (5a) und dem daraus folgenden

$$\frac{\partial^2 Q}{\partial a_0^2} = 2n$$

der Krümmungsradius im Minimum in  $a_0$ -Richtung

$$R_{a_0} = \frac{\left[ 1 + \left( \frac{\partial Q}{\partial a_0} \right)^2 \right]^{3/2}}{\frac{\partial^2 Q}{\partial a_0^2}} = \frac{1}{2n} \quad (9a)$$

und mit (5b) und dem daraud folgenden

$$\frac{\partial^2 Q}{\partial a_1^2} = 2nm(x^2)$$

der Krümmungsradius im Minimum in  $a_1$ -Richtung

$$R_{a_1} = \frac{\left[1 + \left(\frac{\partial Q}{\partial a_1}\right)^2\right]^{3/2}}{\frac{\partial^2 Q}{\partial a_1^2}} = \frac{1}{2nm(x^2)} \quad (9b)$$

Beide Krümmungsradien sind von der y-Streuung unabhängig, sind aber um so kleiner, je größer die Messzahl n ist. Sie zeigen, wie nah das Q dem Nullwert liegt. Q=0 würde ja größte Korrelation der x<sub>i</sub>- und der y<sub>i</sub>-Werte bedeuten.

#### 4. Die Größe Q und der Zusammenhang mit der Korrelation r<sub>xy</sub>.

(siehe auch Bartsch S.573).

Man geht von der entwickelten Gleichung (8) aus und ersetzt dort zunächst a<sub>0</sub> aus (5a) mit  $a_0 = m(y) - a_1 m(x)$  und bekommt

$$\frac{Q}{n} = (m(y^2) - m^2(y)) - a_1^2 (m(x^2) - m^2(x)) \quad (10a)$$

Nun wird mit dem Zähler von (6a) der Zähler von (1) kombiniert, so dass

$$a_1 = r_{xy} \sqrt{\frac{m(y^2) - m^2(y)}{m(x^2) - m^2(x)}} \quad (10b)$$

wird, das man wiederum in (10a) einsetzt und damit

$$\frac{Q}{n} = (1 - r_{xy}^2) (m(y^2) - m^2(y)) \quad (10c)$$

bekommt. Wählt man noch den rechten Klammerausdruck zu z, dann hat

$$\text{man das sogenannte Unabhängigkeitsmaß } M = \frac{Q}{nz} = 1 - r_{xy}^2 \quad (11)$$

eine noch schärfere Größe als der Korrelationskoeffizient r<sub>xy</sub>.

Ist die Korrelation  $r_{xy}=1$  (also 100%), dann wird  $M=Q=0$ .

Ist dagegen  $r_{xy}=0$ , also kein Zusammenhang, dann ist  $M=Q/nz = 1$ .

$M=Q/nz$  liegt immer zwischen 0 und 1 wie  $r_{xy}$  auch, nur entgegengesetzt.

Für Korrelation  $r_{xy}=0$  wird auch  $a_1=0$  (siehe Gl.10b), d.h. die Regressionsgerade liegt horizontal und das quadratische Mittel  $Q$  ist

$$Q_{\min} = n[m(y^2) - m^2(y)]$$

Es mittelt also die  $y_i$ -Werte auf den Mittelwert von  $y_i$ , also  $m(y)$ , die horizontale Gerade.  $a_0$  ist dabei (siehe 5a)  $a_0 = m(y)$ .

#### 5. Die Zuverlässigkeit der Werte $a_0$ und $a_1$ (siehe auch Brauch,Dreger,...S.665)

Die  $a_0$  und  $a_1$  aus der Regression sind Schätzwerte. Für sie lassen sich mittlere Fehler angeben, die von der gewünschten Aussagesicherheit abhängen, nämlich dem t-Faktor der Studentverteilung.

Die mittleren Fehler sind

$$\Delta a_0 = tS_y \sqrt{\frac{\sum x_i^2}{n \sum x_i^2 - (\sum x_i)^2}} \quad (12a)$$

$$\Delta a_1 = tS_y \sqrt{\frac{n}{n \sum x_i^2 - (\sum x_i)^2}} \quad (12b)$$

Dabei ist 
$$S_y^2 = \frac{\sum v_i^2}{n - (m + 1)} = \frac{Q_{\min}}{n - 2} \quad (12c)$$

wobei nach (4) ja  $Q_{\min} = \sum v_i^2$ ,  $n$  die Zahl der Messungen und  $m$  der Grad des Ausgleichspolynoms ist. Wenn mit  $y = a_0 + a_1 x$  ein lineares Polynom genommen wird, ist ja  $m = 1$ .

Weiter werden die Gln.(12) mit  $\sum x_i = nm(x)$  und

$$\begin{aligned} \sum x_i^2 &= \sum [x_i - m(x) + m(x)]^2 \\ &= \sum [(x_i - m(x))^2 + 2(x_i - m(x))m(x) + m^2(x)] \\ &= \sum (x_i - m(x))^2 + nm^2(x) = (n-1)S_x^2 + nm^2(x) \end{aligned}$$

weil die Streuung  $S_x^2 = \frac{1}{n-1} \sum (x_i - m(x))^2 = \frac{n}{n-1} [m(x^2) - m^2(x)]$  ist.

Damit wird dann endgültig aus (12)

$$\Delta a_0 = tS_y \sqrt{\frac{(n-1)S_x^2 + nm^2(x)}{n(n-1)S_x^2 + n^2m^2(x) - n^2m^2(x)}} = \frac{tS_y}{\sqrt{n}} \sqrt{1 + \frac{n}{n-1} \frac{m^2(x)}{S_x^2}} \quad (13a)$$

$$\Delta a_1 = tS_y \sqrt{\frac{n}{n(n-1)S_x^2 + n^2m^2(x) - n^2m^2(x)}} = \frac{tS_y}{\sqrt{n-1}S_x} \quad (13b)$$

Die mittleren Fehler werden um so kleiner, je größer die Zahl der Messungen ist. Für die Unsicherheit der Regressionsgeraden nach unten oder oben ist das  $\Delta a_0$  zuständig und damit in erster Linie die Schwankung von  $y_i$ , also  $S_y$ .

Werden die Messungen bei großem  $x_i$  und einer kleinen Schwankung  $S_x$  durchgeführt, dann wird

$$\Delta a_0 \approx \frac{tS_y}{\sqrt{n-1}} \frac{m(x)}{S_x}$$

also unverständlich groß. Dies rührt daher, dass große Bereiche von  $x_i$  nicht mit Messungen abgedeckt sind, sie hier berücksichtigt werden sollten.

Im Fall von Messungen großer  $x_i$ -Werte in einem kleinen Bereich, auf den man sich beschränken will oder muß, ist es zweckmäßig, die x-Koordinatenachse um  $m(x)$  zu verschieben. Dann liegt nämlich der Nullpunkt der neuen x-Koordinatenachse im alten  $m(x)$  und das neue  $m(x)$  verschwindet. Dann wird aus (13a)

$$\Delta a_0 \approx \frac{tS_y}{\sqrt{n}} \quad (13c)$$

wie es auch sofort verständlich ist.

T ist der Studentparameter und wird Tabellen (z.B. Brauch...) entnommen, z.B. für 95%-ige Sicherheit. Der Nenner in (12c) ist der Freiheitsgrad  $f = n - 2$  (Zahl der überschießenden Gleichungen bei der Bestimmung von  $a_0$  und  $a_1$ ).

Es folgen dazu 3 Beispiele, die in den Bilder des anderen Anhangs dargestellt sind.

#### A) Diagramm Luftdruck/Testreaktion

$$a_0 = 766,28135 \quad a_1 = 6,32315113$$

$t = 2,306$  bei  $f = 8$  und 95%-ige Sicherheit,  $n=10$

$$S_x = \sqrt{\frac{10}{9}(0,336 - 0,2116)} = 0,37, S_y = \sqrt{\frac{Q_{\min}}{8}} = \sqrt{\frac{149,31109}{8}} = 4,32$$

$$\Delta a_0 = \frac{2,306 \times 4,32}{\sqrt{10}} = 3,1525 ; \quad \Delta a_1 = \frac{2,306 \times 4,32}{\sqrt{9 \times 0,37}} = 8,909$$

Das Ergebnis ist in das zuständige Diagramm gestrichelt eingezeichnet. Die Verschiebung der Regressionsgeraden um  $\Delta a_0$  umfasst praktisch die Streupunkte. Die Verteilerung der Geraden um  $\Delta a_1$  liegt sehr einleuchtend in der Punkteschar.

- B) Um das Verfahren mit einer 100%-igen Korrelation zu prüfen, wird die Testreaktion mit sich selber korreliert.

$$\text{Dabei ist } S_y = \sqrt{\frac{Q_{\min}}{8}} = 0$$

Und damit auch  $\Delta a_0 = \Delta a_1 = 0$

- C) Zur Überprüfung der Wetterdaten von den offiziellen Stationen und den eigenen Messungen wurde auch hier eine Regression vorgenommen. Es ergibt sich aus den Daten  
-Luftdruck off./Luftdruck eig.-folgende Sicht:

$$a_0 = -37,9173168$$

$$a_1 = 1,28722073$$

$$S_y = \sqrt{\frac{Q_{\min}^o}{8}} = \sqrt{\frac{9,7883034}{8}} = 1,11$$

$$S_x = \sqrt{\frac{Q_{\min}^e}{8}} = \sqrt{\frac{149,311}{8}} = 4,32$$

Hier ist angebracht,  $\Delta a_0 \approx \frac{t S_y}{\sqrt{n}}$ , also Gl.(13c) zu benutzen.

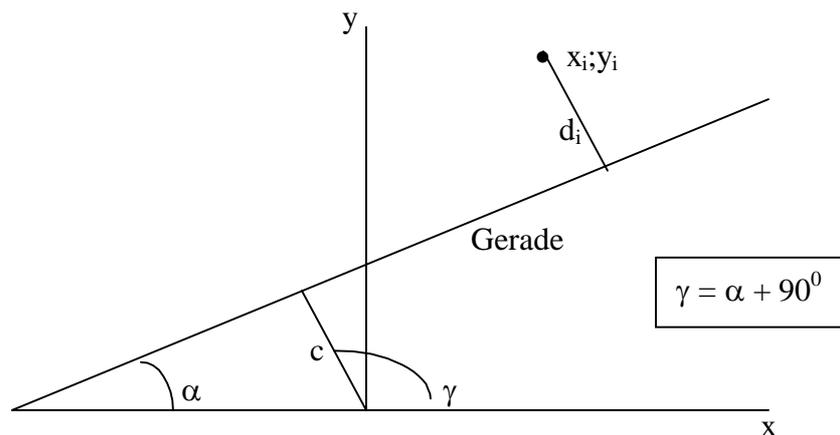
Dann ergibt sich

$$\Delta a_0 = \frac{2,306 \times 1,11}{\sqrt{10}} = 0,81$$

$$\Delta a_1 = \frac{2,306 \times 1,11}{\sqrt{9 \times 4,32}} = 0,197$$

Die Unsicherheit für die Regressionsgeraden liegt sowohl für Ihre Lage als auch ihre Richtung in einem sehr kleinen Intervall, d.h. die Übereinstimmung der beiden Luftdruckmessungen ist recht gut.

## 6. Regression über die Abstandsminimierung der Messpunkte



Man geht aus von der Hesse'schen Normalform einer Geraden

$$x \cos\gamma + y \sin\gamma - c = 0$$

oder  $-x \sin\alpha + y \cos\alpha - c = 0$  (14)

Für den Punktabstand  $d_i$  von der Geraden gilt dann

$$d_i = -x_i \sin\alpha + y_i \cos\alpha - c$$

Die Abstände  $d_i$  sind zu minimieren mit

$$Q = \sum (y_i \cos \alpha - x_i \sin \alpha - c)^2 \Rightarrow \text{Minimum zu}$$

(1)

$$\begin{aligned} \frac{\partial Q}{\partial \alpha} &= \sum (y_i \cos \alpha - x_i \sin \alpha - c)(-y_i \sin \alpha - x_i \cos \alpha) = 0 \\ m(y^2) \sin \alpha \cos \alpha - m(xy) \cos^2 \alpha + m(xy) \sin^2 \alpha + m(x^2) \sin \alpha \cos \alpha + \\ cm(y) \sin \alpha + cm(x) \cos \alpha &= 0 \\ -m(xy) \cos 2\alpha + \frac{1}{2} \sin 2\alpha (m(x^2) - m(y^2)) + c(m(y) \sin \alpha + m(x) \cos \alpha) &= 0 \end{aligned}$$

(2)

$$\begin{aligned} \frac{\partial Q}{\partial c} &= m(y) \cos \alpha - m(x) \sin \alpha - c = 0 \\ c &= m(y) \cos \alpha - m(x) \sin \alpha \end{aligned}$$

Aus (1) und (2) ergibt sich

$$\begin{aligned} m(xy) \cos 2\alpha - \frac{1}{2} (m(x^2) - m(y^2)) \sin 2\alpha = \\ (m(y) \cos \alpha - m(x) \sin \alpha)(m(y) \sin \alpha + m(x) \cos \alpha) = \frac{1}{2} (m^2(y) - m^2(x)) \sin 2\alpha + \\ m(x)m(y) \cos 2\alpha \end{aligned}$$

Zusammengefasst wird daraus

$$\begin{aligned} \tan 2\alpha &= 2 \frac{m(xy) - m(x)m(y)}{[m(x^2) - m^2(x)] - [m(y^2) - m^2(y)]} \\ c &= m(y) \cos \alpha - m(x) \sin \alpha \end{aligned} \quad (15)$$

Die Gleichung der Regressionsgeraden ist nach (14)

$$y = \frac{c}{\cos \alpha} + x \tan \alpha \quad (16)$$

Wird die Testreaktion wieder  $x$  gesetzt mit Wertebereich 0 bis 1, dann kann die Regressionsgerade (16) mit

$$x = 0 \text{ und } y(0) = c/\cos\alpha$$

$$x = 1 \text{ und } y(1) = c/\cos\alpha + x \tan\alpha \quad \text{gezeichnet werden.}$$

## 7. Eine Bemerkung zur $\tan 2\alpha$ -Formel

Ist volle Korrelation mit  $r_{xy} = 1$  gegeben, dann wird nach (4)

$$m(xy) - m(x)m(y) = \sqrt{[m(x^2) - m^2(x)][m(y^2) - m^2(y)]}$$

und damit (14a)  $\tan 2\alpha = 2 \frac{ab}{a^2 - b^2}$  mit  $a^2 = m(x^2) - m^2(x)$   
 $b^2 = m(y^2) - m^2(y)$

bzw. dann auch  $\tan\alpha = \frac{b}{a} = a_1$  (siehe Gl.(10a)), wie es auch nach der

anderen Art der Fall ist.

Ist aber keine Korrelation  $r_{xy}=0$  gegeben, dann wird  $m(xy) - m(x)m(y) = 0$

und  $\tan 2\alpha = 2 \frac{0}{[m(x^2) - m^2(x)] - [m(y^2) - m^2(y)]} = 0$

$2\alpha$  ist demnach  $0^\circ$  oder  $180^\circ$ , also  $\alpha=0^\circ$  oder  $90^\circ$ .

Bei  $\alpha=0^\circ$  ist die Punktwolke horizontal gestreckt, bei  $\alpha=90^\circ$  dagegen vertikal.

Ist dazu auch noch  $a=b$ , also in  $x$ -Richtung und  $y$ -Richtung kein Unterschied in der Punkteverteilung (runde Punktwolke). Dann wird

$$\tan 2\alpha = 0/0 = 0 \text{ also unbestimmt}$$

und  $\alpha$  kann jede Richtung gleichberechtigt annehmen.