

Datenanalyse in der Physik

Vorlesung 5

Mehrdimensionale Gauß-Verteilung und Transformation von Wahrscheinlichkeitsdichten

Prof. Dr. J. Mnich

DESY und Universität Hamburg



Datenanalyse in der Physik Vorlesung 5 – p. 1

Hauptachsentransformation

Erinnerung aus der Linearen Algebra

- Man findet zu jeder symmetrischen $n \times n$ Matrix A eine orthogonale Transformation U , d.h. $U^T = U^{-1}$, so dass $A' = UAU^T$ diagonal ist

\implies Diagonalisierung

Bemerkung: für komplexe Matrizen entspricht das einer unitären Transformation mit $U^\dagger \equiv (U^T)^* = U^{-1}$

- Das Problem entspricht der Transformation eines Vektors $\vec{y} = U\vec{x}$, so dass die quadratische Form $\vec{y}^T A' \vec{y}$ nur noch quadratische Terme enthält:
 $\sum_i A'_{ii} y_i^2$

Hauptachsentransformation (z.B. einer Ellipse in zwei Dimensionen)
Drehung eines n -dimensionalen Vektors

Beweis:

Aus $\vec{y} = U\vec{x}$ folgt $\vec{x} = U^T\vec{y}$ und $\vec{x}^T = \vec{y}^T U$

$$\vec{x}^T A \vec{x} = \vec{y}^T U A U^T \vec{y} = \vec{y}^T A' \vec{y} = \sum_i A'_{ii} y_i^2$$



Datenanalyse in der Physik Vorlesung 5 – p. 2

Hauptachsentransformation

➊ Daraus folgt für mehrdimensionale Zufallsvariablen:

Es ist immer möglich eine orthogonale Transformation $\vec{y} = U\vec{x}$ zu finden, so dass die Zufallsvariablen y_i unkorreliert sind

d.h. man erhält eine diagonale Kovarianzmatrix und die Korrelationsmatrix wird zur Einheitsmatrix

Beweis:

Wegen $E[\lambda h(x)] = \lambda E[h(x)]$ und $E[h(x) + j(x)] = E[h(x)] + E[j(x)]$ können lineare Transformation auch auf Erwartungswerte angewendet werden

Es gilt für die Kovarianzmatrix der Zufallsvariablen \vec{x}

$$V = V(\vec{x}) = E[(\vec{x} - \vec{\mu}_x)(\vec{x} - \vec{\mu}_x)^T]$$

Wir wenden darauf eine orthogonale Transformation U an, so dass

$V' = UV(\vec{x})U^T$ diagonal ist:

$$\begin{aligned} V' &= UV(\vec{x})U^T = UE[(\vec{x} - \vec{\mu}_x)(\vec{x} - \vec{\mu}_x)^T]U^T \\ &= E[U(\vec{x} - \vec{\mu}_x)(\vec{x} - \vec{\mu}_x)^T U^T] = E[(\vec{y} - \vec{\mu}_y)(\vec{y} - \vec{\mu}_y)^T] \end{aligned}$$

mit $\vec{y} = U\vec{x}$ und $\vec{\mu}_y = U\vec{\mu}_x$



Mehrdimensionale Gauß-Verteilung

Die mehrdimensionale Gauß-Verteilung des Zufallsvektors \vec{x} enthält als Parameter den Vektor der Mittelwerte $\vec{\mu}_x = \vec{x}$ und die Kovarianzmatrix V

$$f(\vec{x}) = \frac{1}{(2\pi)^{\frac{n}{2}} |V|^{\frac{1}{2}}} e^{-\frac{1}{2}(\vec{x} - \vec{\mu}_x)^T V^{-1} (\vec{x} - \vec{\mu}_x)}$$

- ➊ Darin ist $|V| = \det V$ die Determinante der Kovarianzmatrix
- ➋ und V^{-1} die inverse Kovarianzmatrix ($VV^{-1} = 1$)
- ➌ Die Zahl der Parameter der mehrdimensionalen Gauß-Verteilung ist:
 - ➍ n Mittelwerte und
 - ➎ $(n^2 + n)/2$ Elemente der symmetrischen Kovarianzmatrix

Das ist das einfachste und wichtigste Beispiel einer mehrdimensionalen Wahrscheinlichkeitsdichteverteilung

Wegen der großen Bedeutung wollen wir hier die mehrdimensionale Gauß-Verteilung explizit zeigen



Beweis der mehrdimensionalen Gauß-Verteilung

Zur Vereinfachung führen wir zunächst folgende Abkürzungen ein

$$f(\vec{x}) = N e^{g(\vec{x})} \quad \text{mit} \quad g(\vec{x}) = -\frac{1}{2} (\vec{x} - \vec{\mu}_x)^T G (\vec{x} - \vec{\mu}_x)$$

Wir berechnen den Normierungsfaktor N und zeigen, dass die Matrix G die inverse Kovarianzmatrix ist

Normierung: Es soll gelten

$$1 = \int \dots \int N e^{g(\vec{x})} dx_1 \dots dx_n$$

Wir führen eine orthogonale Transformation aus $\vec{x} = U\vec{y}$, so dass die Matrix $G' = U^T G U$ diagonal wird

$$g(\vec{x}) = -\frac{1}{2} (\vec{y} - \vec{\mu}_y)^T U^T G U (\vec{y} - \vec{\mu}_y) = -\frac{1}{2} (\vec{y} - \vec{\mu}_y)^T G' (\vec{y} - \vec{\mu}_y) = -\frac{1}{2} \sum_i G'_{ii} (y_i - \mu_{y_i})^2$$

Bei Wechseln der Integrationsvariablen von $dx_1 \dots dx_n$ nach $dy_1 \dots dy_n$ tritt die Funktionaldeterminante auf:

$$\vec{y} = U^T \vec{x} \quad \implies \quad \frac{\partial y_i}{\partial x_j} = \frac{\partial}{\partial x_j} \sum_k U_{ki} x_k = \sum_k U_{ki} \frac{\partial}{\partial x_j} x_k = U_{ji}$$

Für orthogonale Transformationen gilt aber $\det U = \det U^T = 1$. Damit ist die Normierung

$$1 = \int \dots \int N e^{g(\vec{y})} dy_1 \dots dy_n = \int \dots \int N e^{-\frac{1}{2} \sum_i G'_{ii} (y_i - \mu_{y_i})^2} dy_1 \dots dy_n$$



Beweis der mehrdimensionalen Gauß-Verteilung

Umwandeln der Summe im Exponenten in ein Produkt

$$1 = \int \dots \int N \prod_i e^{-\frac{1}{2} G'_{ii} (y_i - \mu_{y_i})^2} dy_1 \dots dy_n$$

Das Mehrfachintegral zerfällt in ein Produkt von Integralen und mit der Normierung der eindimensionalen Gauß-Verteilung ergibt sich

$$1 = N \prod_i \underbrace{\int e^{-\frac{1}{2} G'_{ii} (y_i - \mu_{y_i})^2} dy_i}_{= \sqrt{\frac{2\pi}{G'_{ii}}}} = N \prod_{i=1}^n \sqrt{\frac{2\pi}{G'_{ii}}} = N \frac{(2\pi)^{\frac{n}{2}}}{\sqrt{\prod_{i=1}^n G'_{ii}}}$$

Das Produkt $\prod_{i=1}^n G'_{ii}$ ist nun aber genau die Determinante der diagonalen Matrix G' und weil eine orthogonale Transformation die Determinante nicht ändert

$$\det G' = \det(U^T G U) = (\det U^T)(\det G)(\det U) = \det G$$

folgt

$$N = \frac{\sqrt{\prod_{i=1}^n G'_{ii}}}{(2\pi)^{\frac{n}{2}}} = \frac{\sqrt{\det G}}{(2\pi)^{\frac{n}{2}}} = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{\det(G^{-1})}}$$



Beweis der mehrdimensionalen Gauß-Verteilung

Wir zeigen nun noch, dass gilt $G = V^{-1}$. Für alle Mittelwerte μ_{x_i} soll gelten $E[x_i] = \mu_{x_i}$ oder

$$0 = E[x_i - \mu_{x_i}] = \int \dots \int (x_i - \mu_{x_i}) Ne^{g(\vec{x})} dx_1 \dots dx_n$$

Ableiten dieser Gleichung nach dem Parameter μ_{x_l} ergibt

$$\begin{aligned} 0 &= \frac{\partial}{\partial \mu_{x_l}} \int \dots \int (x_i - \mu_{x_i}) Ne^{g(\vec{x})} dx_1 \dots dx_n \\ &= -\delta_{il} \int \dots \int Ne^{g(\vec{x})} dx_1 \dots dx_n + \int \dots \int (x_i - \mu_{x_i}) Ne^{g(\vec{x})} \frac{\partial g(\vec{x})}{\partial \mu_{x_l}} dx_1 \dots dx_n \end{aligned}$$

worin $\delta_{il} = \begin{cases} 1 & i = l \\ 0 & i \neq l \end{cases}$ und das erste Integral die Normierung ist.

Wir berechnen nun $\frac{\partial g(\vec{x})}{\partial \mu_{x_l}}$. In Komponenten geschrieben

$$g(\vec{x}) = -\frac{1}{2} (\vec{x} - \vec{\mu}_x)^T G (\vec{x} - \vec{\mu}_x) = -\frac{1}{2} \sum_i \sum_j (x_i - \mu_{x_i}) G_{ij} (x_j - \mu_{x_j})$$

$$\begin{aligned} \frac{\partial g(\vec{x})}{\partial \mu_{x_l}} &= -\frac{1}{2} \sum_i \sum_j \frac{\partial}{\partial \mu_{x_l}} [(x_i - \mu_{x_i}) G_{ij} (x_j - \mu_{x_j})] \\ &= -\frac{1}{2} \sum_i \sum_j [\delta_{il}(-1) G_{ij} (x_j - \mu_{x_j}) + \delta_{jl}(-1)(x_i - \mu_{x_i}) G_{ij}] \end{aligned}$$



Beweis der mehrdimensionalen Gauß-Verteilung

$$\frac{\partial g(\vec{x})}{\partial \mu_{x_l}} = +\frac{1}{2} \left\{ \sum_j G_{lj} (x_j - \mu_{x_j}) + \sum_i G_{il} (x_i - \mu_{x_i}) \right\}$$

Da G symmetrisch ist, $G_{il} = G_{li}$, sind beide Summen identisch

$$\frac{\partial g(\vec{x})}{\partial \mu_{x_l}} = \sum_j G_{lj} (x_j - \mu_{x_j})$$

Eingesetzt in $\frac{\partial}{\partial \mu_{x_l}} E[x_i - \mu_{x_i}]$ folgt

$$0 = -\delta_{il} + \int \dots \int (x_i - \mu_{x_i}) Ne^{g(\vec{x})} \sum_j G_{lj} (x_j - \mu_{x_j}) dx_1 \dots dx_n$$

oder

$$\delta_{il} = \sum_j G_{lj} \underbrace{\int \dots \int (x_i - \mu_{x_i}) f(\vec{x}) (x_j - \mu_{x_j}) dx_1 \dots dx_n}_{= \text{cov}(x_i, x_j) = V_{ij} = V_{ji}}$$

$$\delta_{il} = \sum_j G_{lj} V_{ji}$$

In Matrixschreibweise lautet die letzte Gleichung $1 = G \cdot V$ also $G = V^{-1}$



Transformation von Wahrscheinlichkeitsdichten

Häufige Problemstellung in der Physik:

Messung einer oder mehrerer Größen mit zugehöriger Unsicherheit (Fehler) aus denen physikalische Parameter, inklusive deren Unsicherheiten, bestimmt werden sollen

⇒ Schätzung von Parametern

Beispiel: Messung der Periodendauer T und Länge l eines Fadenpendels zur Bestimmung der Erdbeschleunigung g

$$\omega = \frac{2\pi}{T} = \sqrt{\frac{g}{l}} \quad \Rightarrow \quad g = \left(\frac{2\pi}{T}\right)^2 l$$

Mögliche Vorgehensweise: Messe Periodendauer T mehrfach und erhalte pdf (z.B. Gauß-Verteilung), deren Standardabweichung σ der Messfehler in T abgeschätzt wird, und schätze Fehler in l ab.

Wie groß ist die Standardabweichung in g ?

⇒ Transformation von Wahrscheinlichkeitsdichten



Transformation von Wahrscheinlichkeitsdichten

● Einzelne Zufallsvariable

Gegeben sei die Wahrscheinlichkeitsdichteverteilung $f(x)$ der Zufallsvariablen x
Suche die Wahrscheinlichkeitsdichteverteilung $g(y)$ in der Zufallsvariablen $y = y(x)$

Die Wahrscheinlichkeit, die Variable x im Intervall $(x, x + dx)$ zu finden, soll gleich der Wahrscheinlichkeit sein, die Variable y im Intervall $(y, y + dy)$ zu finden

$$f(x) dx = g(y) dy \quad \Rightarrow \quad g(y) = f(x(y)) \left| \frac{dx}{dy} \right| = \frac{f(x(y))}{\left| \frac{dy}{dx} \right|}$$

Dabei ist $x = x(y)$ die Umkehrfunktion zu $y = y(x)$

Falls die Transformation nicht eineindeutig ist, muß über alle Zweige summiert werden

$$g(y) = \sum_{\text{Zweige}} \frac{f(x(y))}{\left| \frac{dy}{dx} \right|}$$

Beispiel: die Transformation $y = x^2$ ist für $(-\infty < x < +\infty)$ nicht eineindeutig

$$g(y) = \frac{1}{2|x|} (f(x) + f(-x)) = \frac{1}{2\sqrt{y}} (f(+\sqrt{y}) + f(-\sqrt{y}))$$



Transformation des Mittelwertes und der Varianz

- Für lineare Transformation $y = ax + b$ gilt exakt:

$$\begin{aligned}\langle y \rangle &= E[y] = E[ax + b] = a \langle x \rangle + b \\ \sigma_y^2 &= E[(y - \langle y \rangle)^2] = E[(ax + b - a \langle x \rangle - b)^2] = a^2 E[(x - \langle x \rangle)^2] \\ &= a^2 \sigma_x^2\end{aligned}$$

- Näherung für nichtlineare Transformationen:

Man entwickle die Funktion $y = y(x)$ um den Mittelwert $x = \langle x \rangle$

$$\begin{aligned}y(x) &= y(\langle x \rangle) + (x - \langle x \rangle) \left. \frac{dy}{dx} \right|_{x=\langle x \rangle} + \frac{1}{2} (x - \langle x \rangle)^2 \left. \frac{d^2y}{dx^2} \right|_{x=\langle x \rangle} + \dots \\ \Rightarrow E[y] &= y(\langle x \rangle) + \underbrace{E[x - \langle x \rangle]}_{=0} \left. \frac{dy}{dx} \right|_{x=\langle x \rangle} + \frac{1}{2} \underbrace{E[(x - \langle x \rangle)^2]}_{=\sigma_x^2} \left. \frac{d^2y}{dx^2} \right|_{x=\langle x \rangle} + \dots \\ \Rightarrow \langle y \rangle &\approx y(\langle x \rangle) + \frac{1}{2} \sigma_x^2 \left. \frac{d^2y}{dx^2} \right|_{x=\langle x \rangle}\end{aligned}$$

Oft lässt man auch noch den Term $\propto \sigma_x^2$ weg, da ja bereits $\langle x \rangle$ in einer Einzelmessung eine Unsicherheit von σ_x hat



Transformation des Mittelwertes und der Varianz

- Näherung für die Varianz von y :

Entwicklung von $y(x)$ bis zum linearen Glied

$$y(x) \approx y(\langle x \rangle) + (x - \langle x \rangle) \left. \frac{dy}{dx} \right|_{x=\langle x \rangle}$$

und für $\langle y \rangle \approx y(\langle x \rangle)$ folgt

$$\begin{aligned}(y - \langle y \rangle)^2 &\approx \left((x - \langle x \rangle) \left. \frac{dy}{dx} \right|_{x=\langle x \rangle} \right)^2 \\ \Rightarrow \sigma_y^2 &= E[(y - \langle y \rangle)^2] \approx \left(\left. \frac{dy}{dx} \right|_{x=\langle x \rangle} \right)^2 E[(x - \langle x \rangle)^2] = \left(\left. \frac{dy}{dx} \right|_{x=\langle x \rangle} \right)^2 \sigma_x^2\end{aligned}$$

Das ist das Gesetz der Fehlerfortpflanzung für eine Zufallsvariable:

$$\sigma_y^2 = \left(\frac{dy}{dx} \right)^2 \sigma_x^2$$



Beispiel Fehlerfortpflanzung

Häufig hat man es mit Transformationen der Form $y = a x^n$ zu tun

$$\implies \frac{dy}{dx} = n a x^{n-1} = n \frac{y}{x}$$

Eingesetzt in das Fehlerfortpflanzungsgesetz folgt

$$\sigma_y^2 = \left(\frac{dy}{dx} \right)^2 \sigma_x^2 = \left(n \frac{y}{x} \right)^2 \sigma_x^2$$

Wenn man nun den relativen Fehler, d.h. die auf den Mittelwert bezogene Standardabweichung $\frac{\sigma_x}{\langle x \rangle}$ bzw. $\frac{\sigma_y}{\langle y \rangle}$ betrachtet, folgt:

$$\frac{\sigma_y}{\langle y \rangle} = n \frac{\sigma_x}{\langle x \rangle}$$

Das bedeutet z.B. wenn man den Radius einer Kugel auf $\frac{\sigma_r}{\langle r \rangle} = 1\%$ kennt, so kennt man ihr Volumen nur auf $\frac{\sigma_V}{\langle V \rangle} = 3\%$



Lineare mehrdimensionale Transformationen

Wie behandeln jetzt die Transformation von n Zufallsvariablen auf m Zufallsvariablen, d.h. von einem n -dim. Vektor \vec{x} auf einen m -dim. Vektor \vec{y}

Achtung: n und m können i.a. verschieden sein

siehe das Beispiel des Fadenpendels:

$n = 2 : x_1 = T, x_2 = l$ und $m = 1 : y_1 = g$

- **Lineare Transformationen** (\rightarrow exakte Berechnung möglich)

$$\vec{y} = B \vec{x} \quad B \text{ ist } m \times n \text{ Matrix}$$

- **Mittelwerte**

$$\vec{\mu}_y = E[\vec{y}] = E[B \vec{x}] = B E[\vec{x}] = B \vec{\mu}_x$$

- **Kovarianzmatrix**

$$\begin{aligned} V'(\vec{y}) &= E[(\vec{y} - \vec{\mu}_y)(\vec{y} - \vec{\mu}_y)^T] = E[B(\vec{x} - \vec{\mu}_x)(\vec{x} - \vec{\mu}_x)^T B^T] \\ &= B E[(\vec{x} - \vec{\mu}_x)(\vec{x} - \vec{\mu}_x)^T] B^T = B V(\vec{x}) B^T \end{aligned}$$



Lineare mehrdimensionale Transformationen

Lineare Transformationen

Man beachte, dass hier für die Ableitungen gilt:

$$\frac{\partial y_i}{\partial x_j} = \frac{\partial}{\partial x_j} \sum_k B_{ik} x_k = B_{ij}$$

- Für den Spezialfall $m = n$, d.h. B ist quadratisch, kann die transformierte Wahrscheinlichkeitsdichteverteilung berechnet werden:

$$\begin{aligned} \int_{\Delta x} \dots \int f(\vec{x}) dx_1 \dots dx_n &= \int_{\Delta y} \dots \int g(\vec{y}(\vec{x})) dy_1 \dots dy_n \\ &= \int_{\Delta x} \dots \int g(\vec{y}(\vec{x})) |\det J| dx_1 \dots dx_n \end{aligned}$$

wobei beim Variablenwechsel die Funktional- oder Jacobi-Determinante $\det J$ auftritt: $J_{ij} = \frac{\partial y_i}{\partial x_j}$, die im Falle der linearen Transformation die Transformationsmatrix B ist

$$g(\vec{y}) = f(\vec{x}) \left| \frac{1}{\det B} \right|$$



Allgemeine mehrdimensionale Transformationen

- Transformation ist gegeben durch m Gleichungen

$$y_i = y_i(x_1, \dots, x_n) = y_i(\vec{x}) \quad i = 1, \dots, m$$

- Im Sonderfall $n = m$ kann wieder die pdf berechnet werden

$$g(\vec{y}) = f(\vec{x}) \left| \frac{1}{\det B} \right| \quad \text{mit} \quad B = \begin{pmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} & \dots & \frac{\partial y_1}{\partial x_n} \\ \frac{\partial y_2}{\partial x_1} & \frac{\partial y_2}{\partial x_2} & \dots & \frac{\partial y_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial y_n}{\partial x_1} & \frac{\partial y_n}{\partial x_2} & \dots & \frac{\partial y_n}{\partial x_n} \end{pmatrix}$$

- Mittelwerte aus der Entwicklung $\vec{y}(\vec{x})$ um die Mittelwerte $\vec{\mu}_x$ (beliebige m, n)

$$\begin{aligned} y_i(\vec{x}) &= y_i(\vec{\mu}_x) + \sum_k (x_k - \mu_{x_k}) \frac{\partial y_i}{\partial x_k} \Big|_{x_k = \mu_{x_k}} + \dots \\ \Rightarrow \langle y_i(\vec{x}) \rangle &\approx y_i(\vec{\mu}_x) \quad \text{oder} \quad \vec{\mu}_y = \vec{y}(\vec{\mu}_x) \end{aligned}$$



Allgemeine mehrdimensionale Transformationen

Lineare Näherung für die Kovarianzmatrix

Aus Entwicklung von $y_i(\vec{x})$ folgt

$$y_i(\vec{x}) - \mu_{y_i} \approx \sum_k (x_k - \mu_{x_k}) \frac{\partial y_i}{\partial x_k}$$

Das Element il der transformierten Kovarianzmatrix $V'(\vec{y})$ ist dann

$$\begin{aligned} V'_{il} &= E[(y_i - \mu_{y_i})(y_l - \mu_{y_l})] \\ &\approx E \left[\left(\sum_k (x_k - \mu_{x_k}) \frac{\partial y_i}{\partial x_k} \right) \left(\sum_j (x_j - \mu_{x_j}) \frac{\partial y_l}{\partial x_j} \right) \right] \\ &= E \left[\sum_k \sum_j \underbrace{\frac{\partial y_i}{\partial x_k}}_{=B_{ik}} \underbrace{(x_k - \mu_{x_k})(x_j - \mu_{x_j})}_{\text{cov}(x_k, x_j)} \underbrace{\frac{\partial y_l}{\partial x_j}}_{=B_{lj}} \right] \end{aligned}$$

⇒ Allgemeines Gesetz der Fehlerfortpflanzung

$$V'(\vec{y}) = B V(\vec{x}) B^T$$



Beispiel Fehlerfortpflanzung

Auf einem Messtisch werden kartesische Koordinaten x_1, x_2 mit den Standardabweichungen (Fehlern) $\sigma_{x_1}, \sigma_{x_2}$ gemessen. Die beiden Messungen sollen unabhängig sein.

Wie groß ist der Messfehler in Polarkoordinaten r, φ ?

$$\begin{aligned} x_1 &= r \cos \varphi & \Rightarrow & & y_1 &= r = \sqrt{x_1^2 + x_2^2} \\ x_2 &= r \sin \varphi & & & y_2 &= \varphi = \arctan \frac{x_2}{x_1} \end{aligned}$$

$$B = \begin{pmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} \\ \frac{\partial y_2}{\partial x_1} & \frac{\partial y_2}{\partial x_2} \end{pmatrix} = \begin{pmatrix} \frac{x_1}{r} & \frac{x_2}{r} \\ -\frac{x_2}{r^2} & \frac{x_1}{r^2} \end{pmatrix}$$

$$\begin{aligned} V'(r, \varphi) &= B V(x_1, x_2) B^T = \begin{pmatrix} \frac{x_1}{r} & \frac{x_2}{r} \\ -\frac{x_2}{r^2} & \frac{x_1}{r^2} \end{pmatrix} \begin{pmatrix} \sigma_{x_1}^2 & 0 \\ 0 & \sigma_{x_2}^2 \end{pmatrix} \begin{pmatrix} \frac{x_1}{r} & -\frac{x_2}{r^2} \\ \frac{x_2}{r} & \frac{x_1}{r^2} \end{pmatrix} \\ &= \begin{pmatrix} \frac{1}{r^2} (x_1^2 \sigma_{x_1}^2 + x_2^2 \sigma_{x_2}^2) & \frac{x_1 x_2}{r^3} (\sigma_{x_2}^2 - \sigma_{x_1}^2) \\ \frac{x_1 x_2}{r^3} (\sigma_{x_2}^2 - \sigma_{x_1}^2) & \frac{1}{r^4} (x_2^2 \sigma_{x_1}^2 + x_1^2 \sigma_{x_2}^2) \end{pmatrix} \\ &= \begin{pmatrix} \sigma_r^2 & \text{cov}(r, \varphi) \\ \text{cov}(r, \varphi) & \sigma_\varphi^2 \end{pmatrix} \end{aligned}$$



Beispiel Fehlerfortpflanzung

Was passiert wenn $m \neq n$ ist?

Wir betrachten unser Beispiel des Fadenpendels mit unkorrelierten Messungen von T und l :

$$\begin{aligned} x_1 &= T \\ x_2 &= l \end{aligned} \quad \Rightarrow \quad y_1 = g = \left(\frac{2\pi}{T}\right)^2 l$$

Die Matrix der partiellen Ableitungen B ist eine 1×2 Matrix

$$B = \begin{pmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} \end{pmatrix} = \begin{pmatrix} -2 \frac{g}{T} & \frac{g}{l} \end{pmatrix}$$

und die neue Kovarianzmatrix ist eine 1×1 Matrix:

$$V(y_1) = \begin{pmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_1}{\partial x_2} \end{pmatrix} \begin{pmatrix} \sigma_{x_1}^2 & 0 \\ 0 & \sigma_{x_2}^2 \end{pmatrix} \begin{pmatrix} \frac{\partial y_1}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} \end{pmatrix} = \left(\frac{\partial y_1}{\partial x_1}\right)^2 \sigma_{x_1}^2 + \left(\frac{\partial y_1}{\partial x_2}\right)^2 \sigma_{x_2}^2$$

Die Beiträge der einzelnen Varianzen addieren sich, gewichtet mit den Quadraten der partiellen Ableitungen

Für unser Fadenpendel findet man also:

$$V(g) = \sigma_g^2 = \left(-2 \frac{g}{T}\right)^2 \sigma_T^2 + \left(\frac{g}{l}\right)^2 \sigma_l^2$$



Weiteres Beispiel zur Fehlerfortpflanzung

Die Verallgemeinerung des obigen Beispiels ist das häufige Problem, dass n unabhängige Messungen x_1, \dots, x_n in die Bestimmung eines Parameter y eingehen ($m = 1$)

Anwendung des allgemeinen Gesetzes führt zu:

$$\begin{aligned} \sigma_y^2 = V(y) &= \begin{pmatrix} \frac{\partial y}{\partial x_1} & \dots & \frac{\partial y}{\partial x_n} \end{pmatrix} \begin{pmatrix} \sigma_1^2 & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \sigma_n^2 \end{pmatrix} \begin{pmatrix} \frac{\partial y}{\partial x_1} \\ \vdots \\ \frac{\partial y}{\partial x_n} \end{pmatrix} \\ &= \sum_{i=1}^n \left(\frac{\partial y}{\partial x_i}\right)^2 \sigma_i^2 \end{aligned}$$

Beiträge zum Fehler addieren sich quadratisch, gewichtet mit Ableitungen

Falls gilt $y = c x_i^{k_i}$ für alle i :

$$\frac{\partial y}{\partial x_i} = c k_i x_i^{k_i-1} = k_i \frac{y}{x_i} \quad \Rightarrow \quad \sigma_y^2 = \sum_{i=1}^n k_i^2 y^2 \frac{\sigma_i^2}{x_i^2}$$

oder für den relativen Fehler

$$\frac{\sigma_y}{y} = \sqrt{\sum_{i=1}^n k_i^2 \frac{\sigma_i^2}{x_i^2}}$$

Relative Fehler addieren sich quadratisch, gewichtet mit Potenzen k_i



Übersicht Transformationsformeln

Eindimensionale Transformationen $x \rightarrow y$	
linear	allgemein
$y = ax + b$	$y = y(x)$
$\langle y \rangle = a \langle x \rangle + b$	$\langle y \rangle \approx y(\langle x \rangle)$
$\sigma_y^2 = a^2 \sigma_x^2$	$\sigma_y^2 \approx \left(\frac{dy}{dx}\right)^2 \sigma_x^2$
$g(y) = \frac{1}{a} f(x)$	$g(y) = f(x) \frac{1}{\left \frac{dy}{dx}\right }$

Mehrdimensionale Transformationen $x_1, \dots, x_n \rightarrow y_1, \dots, y_m$	
linear	allgemein
$y_i = \sum_j B_{ij} x_j$	$y_i = y_i(x_1, \dots, x_n)$
$\langle y_i \rangle = \sum_j B_{ij} \langle x_j \rangle$	$\langle y_i \rangle \approx y_i(\langle x_1 \rangle, \dots, \langle x_n \rangle)$
$V'(\vec{y}) = B V(\vec{x}) B^T$	$V'(\vec{y}) \approx B V(\vec{x}) B^T \quad \left(B_{ij} = \frac{\partial y_i}{\partial x_j}\right)$
$g(\vec{y}) = f(\vec{x}) \frac{1}{ \det B } \quad (n = m)$	$g(\vec{y}) = f(\vec{x}) \frac{1}{ \det B } \quad (n = m)$

