

Algorithmen für geographische Informationssysteme

Least Squares Adjustment

Carl Friedrich Gauß

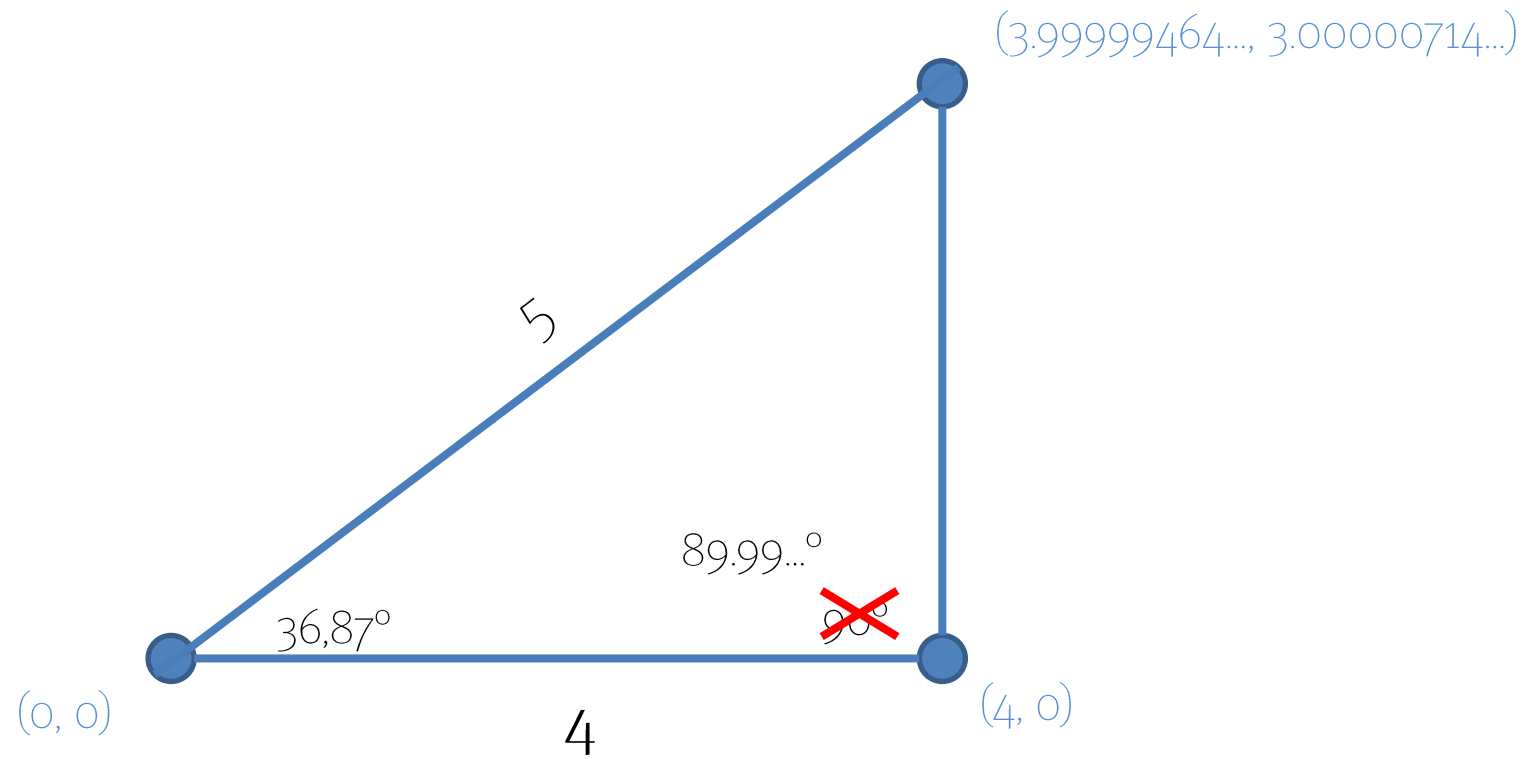
(1777 Braunschweig – 1855 Göttingen)



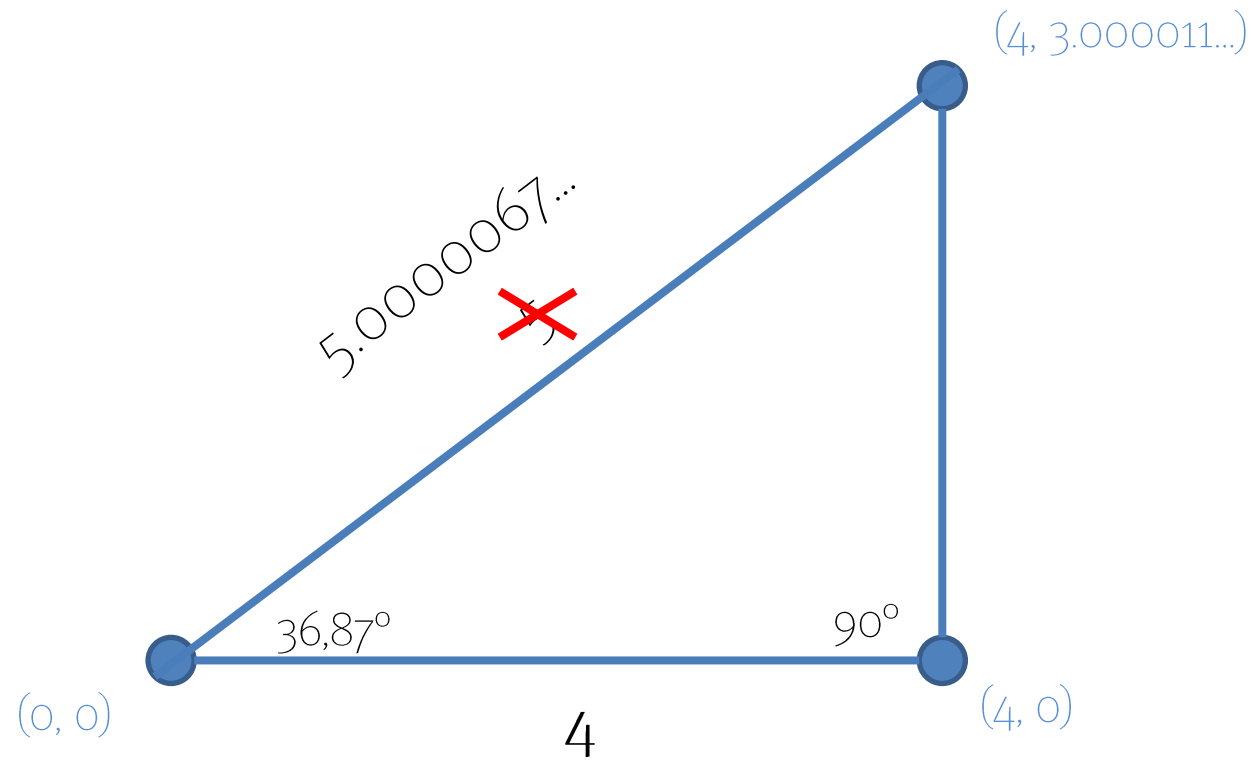
Ausgleichsrechnung




Ausgleichsrechnung



Ausgleichsrechnung





Ausgleichsrechnung



Ausgleichsrechnung



Gaußsche Gradmessung, 1821-1823



Ablesegenauigkeit: 4 Bogensekunden

Ausgleichsrechnung

Gaußsche Gradmessung, 1821-1823





Ablesegenauigkeit: 4 Bogensekunden

Grundidee: Redundante Messung zur Steigerung der Genauigkeit

Ausgleichsrechnung

Gaußsche Gradmessung, 1821-1823



Ablesegenauigkeit: 4 Bogensekunden

Grundidee: Redundante Messung zur Steigerung der Genauigkeit

Genauigkeit nach Ausgleichung: 0.5 Bogensekunden

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten)

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)

normalerweise: $n > n_{\text{ötig}}$


- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten)

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten)

Problemdefinition


- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert.



Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert.

Beispiel:



$$\begin{pmatrix} d_1 \\ d_2 \\ d_3 \end{pmatrix} = \Phi(x, y) = \begin{pmatrix} \sqrt{(x - x_1)^2 + (y - y_1)^2} \\ \sqrt{(x - x_2)^2 + (y - y_2)^2} \\ \sqrt{(x - x_3)^2 + (y - y_3)^2} \end{pmatrix}$$

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten)

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten) und
- Vektor $\hat{\mathbf{L}} = \mathbf{L} + \mathbf{v}$ von ausgeglichenen Beobachtungen


Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten) und
- Vektor $\hat{\mathbf{L}} = \mathbf{L} + \mathbf{v}$ von ausgeglichenen Beobachtungen
- so dass
 - $\hat{\mathbf{L}} = \Phi(\hat{\mathbf{X}})$ gilt und
 - $\mathbf{v}^T \mathbf{v}$ minimal ist.

Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten) und
- Vektor $\hat{\mathbf{L}} = \mathbf{L} + \mathbf{v}$ von ausgeglichenen Beobachtungen
- so dass
 - $\hat{\mathbf{L}} = \Phi(\hat{\mathbf{X}})$ gilt und
 - $\mathbf{v}^T \mathbf{v}$ minimal ist.

**Methode der
kleinsten Quadrate**



Problemdefinition

- Gegeben
 - ein Vektor \mathbf{L} von n Beobachtungen (Strecken, Winkel,...)
 - eine Funktion $\Phi: \mathbb{R}^u \rightarrow \mathbb{R}^n$, die für wahre Unbekannte $\tilde{\mathbf{X}}$ die wahren Beobachtungen durch $\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}})$ liefert
- finde Vektor $\hat{\mathbf{X}}$ von u Unbekannten (Koordinaten) und
- Vektor $\hat{\mathbf{L}} = \mathbf{L} + \mathbf{v}$ von ausgeglichenen Beobachtungen
- so dass
 - $\hat{\mathbf{L}} = \Phi(\hat{\mathbf{X}})$ gilt und
 - $\mathbf{v}^T \mathbf{P} \mathbf{v}$ minimal ist.

**Methode der
kleinsten Quadrate**

**Spezialfall:
Ausgleichung bei linearem
funktionalen Modell**

**(= linearer Zusammenhang zwischen
Beobachtungen & Unbekannten)**

$$\tilde{L} = \Phi(\tilde{X}) = A\tilde{X}$$

Ausgleichung bei linearem funktionalem Modell

$$\tilde{L} = \Phi(\tilde{X}) = A\tilde{X}$$

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$L = \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} \text{ mit } L_i = i\text{-te Messung der Strecke}$$

Gesucht: Ausgegliche Strecke \hat{X} , Verbesserungen v

Bedingung:

$$\hat{L} =$$

Ausgleichung bei linearem funktionalem Modell

Lösung...

$$A\hat{X} = \hat{L} = L + v \Rightarrow v = A\hat{X} - L$$

Minimiere $v^T v$...

$$\begin{aligned}\Rightarrow v^T v &= (A\hat{X} - L)^T (A\hat{X} - L) \\ &= \hat{X}^T A^T A \hat{X} - 2\hat{X}^T A^T L + L^T L\end{aligned}$$

notwendige Bedingung für Optimum:

Gradient der Zielfunktion = Nullvektor

Ausgleichung bei linearem funktionalem Modell

Lösung...

$$F(\hat{\mathbf{X}}) = \hat{\mathbf{X}}^T \mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} - 2\hat{\mathbf{X}}^T \mathbf{A}^T \mathbf{L} + \mathbf{L}^T \mathbf{L}$$

$$\text{grad } F(\hat{\mathbf{X}}) = \begin{pmatrix} \frac{\partial F}{\partial \hat{X}_1} \\ \vdots \\ \frac{\partial F}{\partial \hat{X}_u} \end{pmatrix} = 2\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} - 2\mathbf{A}^T \mathbf{L}$$

notwendige Bedingung für Optimum:

Gradient der Zielfunktion = Nullvektor

Ausgleichung bei linearem funktionalem Modell

Lösung...

$$F(\hat{\mathbf{X}}) = \hat{\mathbf{X}}^T \mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} - 2\hat{\mathbf{X}}^T \mathbf{A}^T \mathbf{L} + \mathbf{L}^T \mathbf{L}$$

$$\text{grad } F(\hat{\mathbf{X}}) = \begin{pmatrix} \frac{\partial F}{\partial \hat{X}_1} \\ \vdots \\ \frac{\partial F}{\partial \hat{X}_u} \end{pmatrix} = 2\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} - 2\mathbf{A}^T \mathbf{L} \stackrel{!}{=} \mathbf{0}$$

notwendige Bedingung für Optimum:

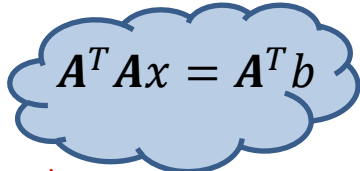
Gradient der Zielfunktion = Nullvektor

Ausgleichung bei linearem funktionalem Modell

Lösung...

$$F(\hat{X}) = \hat{X}^T A^T A \hat{X} - 2\hat{X}^T A^T L + L^T L$$

$$\text{grad } F(\hat{X}) = \begin{pmatrix} \frac{\partial F}{\partial \hat{X}_1} \\ \vdots \\ \frac{\partial F}{\partial \hat{X}_u} \end{pmatrix} = 2A^T A \hat{X} - 2A^T L \stackrel{!}{=} \mathbf{0}$$


$$A^T A x = A^T b$$

Gauß-Normalgleichung

$$\Leftrightarrow \boxed{A^T A \hat{X} = A^T L}$$

Lösung durch Gaußsches Eliminationsverfahren

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$\mathbf{L} = \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix}$ mit $L_i = i$ -te Messung der Strecke

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

Gesucht: Ausgegliche Strecke $\hat{\mathbf{X}}$, Verbesserungen \mathbf{v}

Bedingung:

$$\hat{\mathbf{L}} = \mathbf{L} + \mathbf{v} = \mathbf{A} \hat{\mathbf{X}} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \hat{\mathbf{X}} \quad \text{und} \quad \mathbf{v}^T \mathbf{v} \rightarrow \text{Min}$$

Ausgleichung bei linearem funktionalen Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} =$$

Ausgleichung bei linearem funktionalen Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} =$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \sum_{i=1}^n L_i$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \sum_{i=1}^n L_i$$

$$\mathbf{A}^T \mathbf{A} \hat{X} = \mathbf{A}^T \mathbf{L} \quad \Rightarrow$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \sum_{i=1}^n L_i$$

$$\mathbf{A}^T \mathbf{A} \hat{X} = \mathbf{A}^T \mathbf{L} \quad \Rightarrow \quad n \hat{X} = \sum_{i=1}^n L_i$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \sum_{i=1}^n L_i$$

$$\mathbf{A}^T \mathbf{A} \hat{X} = \mathbf{A}^T \mathbf{L} \quad \Rightarrow \quad n \hat{X} = \sum_{i=1}^n L_i \quad \Leftrightarrow \quad \hat{X} = \frac{\sum_{i=1}^n L_i}{n}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 1: Mehrfache Beobachtung einer Strecke

$$\mathbf{A}^T \mathbf{A} = (1, \dots, 1) \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

$$\mathbf{A}^T \mathbf{L} = (1, \dots, 1) \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \sum_{i=1}^n L_i$$

$$\mathbf{A}^T \mathbf{A} \hat{X} = \mathbf{A}^T \mathbf{L} \quad \Rightarrow \quad n \hat{X} = \sum_{i=1}^n L_i \quad \Leftrightarrow$$

**Ausgleichung
entspricht hier
Berechnung des
Mittelwerts!**

$$\hat{X} = \frac{\sum_{i=1}^n L_i}{n}$$

Ausgleichung bei linearem funktionalen Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Zielfunktion $v^T v$

$$= F(\hat{X}) = \hat{X}^T A^T A \hat{X} - 2\hat{X}^T A^T L + L^T L$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Beispiel: $f(x) = x^2 + 6x - 7$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Beispiel:

$$\begin{aligned} f(x) &= x^2 + 6x - 7 \\ &= x^2 + 6x + 9 - 16 \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Beispiel:

$$\begin{aligned} f(x) &= x^2 + 6x - 7 \\ &= x^2 + 6x + 9 - 16 \\ &= (x + 3)^2 - 16 \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Beispiel:

$$\begin{aligned} f(x) &= x^2 + 6x - 7 \\ &= x^2 + 6x + 9 - 16 \\ &= (x + 3)^2 - 16 \\ &= \xi^2 - 16 \quad \text{mit} \quad \xi = x + 3 \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

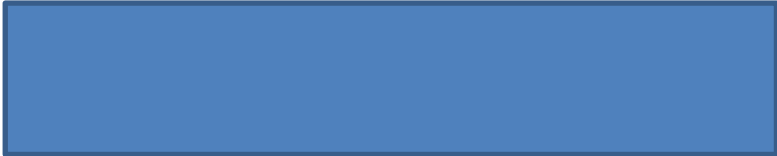
Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Beispiel: $f(x) = ax^2 + bx + c$



Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Da $F(\hat{X}) = v^T v$ gilt $F(\hat{X}) \geq 0$. Also hat F die Normalform

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_u \xi_u^2 + \gamma \quad \text{mit} \quad \alpha_1, \dots, \alpha_u, \gamma \geq 0.$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Funktion F hat immer eine Minimalstelle.

Jede quadratische Funktion in den Variablen X_1, \dots, X_u lässt sich durch **Drehung** und **Verschiebung** des Koordinatensystems in die **Normalform**

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_r \xi_r^2 + \alpha_{r+1} \xi_{r+1} + \dots + \alpha_u \xi_u + \gamma$$

bringen (d.h. keine gemischten Terme, jede Variable nur einmal).

Da $F(\hat{X}) = v^T v$ gilt $F(\hat{X}) \geq 0$. Also hat F die Normalform

$$f(\xi_1, \dots, \xi_u) = \alpha_1 \xi_1^2 + \dots + \alpha_u \xi_u^2 + \gamma \quad \text{mit} \quad \alpha_1, \dots, \alpha_u, \gamma \geq 0.$$

Damit ist der Punkt $\xi_1 = \dots = \xi_u = 0$ eine Minimalstelle.

Der Funktionswert an dieser Stelle ist γ .



Ausgleichung bei linearem funktionalen Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

D.h. für jede Lösung $\hat{\mathbf{X}}$ der Gauß-Normalgleichung ist $\mathbf{v}^T \mathbf{v}$ global minimal.

Ausgleichung bei linearem funktionalen Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$F(\mathbf{X}) = (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L})$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.

Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{AX} - \mathbf{L})^T (\mathbf{AX} - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) \\ &\quad + 2(\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX}_0 - \mathbf{L}) \\ &\quad + (\mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{AX} - \mathbf{L})^T (\mathbf{AX} - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) \\ &\quad + 2(\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX}_0 - \mathbf{L}) \\ &\quad + (\mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) \\ &\quad + 2(\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X}_0 - \mathbf{L}) = 0 \\ &\quad + (\mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) \\ &\quad + (\mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X}_0 - \mathbf{L}) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{A}\mathbf{X} - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 + \mathbf{A}\mathbf{X}_0 - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) \\ &\quad + (\mathbf{A}\mathbf{X}_0 - \mathbf{L})^T (\mathbf{A}\mathbf{X}_0 - \mathbf{L}) \\ &= (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) + F(\mathbf{X}_0) \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist hinreichend.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt

$$\begin{aligned} F(\mathbf{X}) &= (\mathbf{AX} - \mathbf{L})^T (\mathbf{AX} - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX} - \mathbf{AX}_0 + \mathbf{AX}_0 - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) \\ &\quad + (\mathbf{AX}_0 - \mathbf{L})^T (\mathbf{AX}_0 - \mathbf{L}) \\ &= (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) + F(\mathbf{X}_0) \geq F(\mathbf{X}_0) \end{aligned}$$

□

Ausgleichung bei linearem funktionalen Modell

Satz: Die Gauß-Normalgleichung ist eindeutig lösbar,
wenn $\text{rang}(A) = u$.

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist eindeutig lösbar, wenn $\text{rang}(A) = u$.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.

Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt:

$$F(\mathbf{X}) = (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) + F(\mathbf{X}_0) \geq F(\mathbf{X}_0)$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist eindeutig lösbar, wenn $\text{rang}(A) = u$.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt:

$$F(\mathbf{X}) = (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) + F(\mathbf{X}_0) \geq F(\mathbf{X}_0)$$

Wenn $F(\mathbf{X}) = F(\mathbf{X}_0)$, dann:

$$\begin{aligned} & (\mathbf{AX} - \mathbf{AX}_0)^T (\mathbf{AX} - \mathbf{AX}_0) = 0 \\ \Leftrightarrow & \mathbf{AX} - \mathbf{AX}_0 = \mathbf{A}(\mathbf{X} - \mathbf{X}_0) = \mathbf{0} \end{aligned}$$

Ausgleichung bei linearem funktionalem Modell

Satz: Die Gauß-Normalgleichung ist eindeutig lösbar, wenn $\text{rang}(A) = u$.

Sei $\mathbf{X}_0 \in \mathbb{R}^u$ eine Lösung der Gauß-Normalgleichung.
Für jedes $\mathbf{X} \in \mathbb{R}^u$ gilt:

$$F(\mathbf{X}) = (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) + F(\mathbf{X}_0) \geq F(\mathbf{X}_0)$$

Wenn $F(\mathbf{X}) = F(\mathbf{X}_0)$, dann:


$$(\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0)^T (\mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0) = 0$$

$$\Leftrightarrow \mathbf{A}\mathbf{X} - \mathbf{A}\mathbf{X}_0 = \mathbf{A}(\mathbf{X} - \mathbf{X}_0) = \mathbf{0}$$

mit $\text{rang}(A) = u \Rightarrow \mathbf{X} = \mathbf{X}_0 \quad \square$


Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen



Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen




Gesucht: h_2, h_3, h_4

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{L} = \begin{pmatrix} \Delta h_{1,2} \\ \Delta h_{2,3} \\ \Delta h_{3,4} \\ \Delta h_{4,1} \\ \Delta h_{4,2} \end{pmatrix} = \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$



Gesucht: h_2, h_3, h_4


Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{L} = \begin{pmatrix} \Delta h_{1,2} \\ \Delta h_{2,3} \\ \Delta h_{3,4} \\ \Delta h_{4,1} \\ \Delta h_{4,2} \end{pmatrix} = \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$

$$\hat{\mathbf{X}} = \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix}$$

$$\Phi(\hat{\mathbf{X}}) = \hat{\mathbf{L}}$$



Gesucht: h_2, h_3, h_4

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{L} = \begin{pmatrix} \Delta h_{1,2} \\ \Delta h_{2,3} \\ \Delta h_{3,4} \\ \Delta h_{4,1} \\ \Delta h_{4,2} \end{pmatrix} = \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$

$$\hat{\mathbf{X}} = \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix}$$

$$\Phi(\hat{\mathbf{X}}) = \hat{\mathbf{L}} = \begin{pmatrix} h_2 \\ h_3 - h_2 \\ h_4 - h_3 \\ -h_4 \\ h_2 - h_4 \end{pmatrix}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{L} = \begin{pmatrix} \Delta h_{1,2} \\ \Delta h_{2,3} \\ \Delta h_{3,4} \\ \Delta h_{4,1} \\ \Delta h_{4,2} \end{pmatrix} = \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$

$$\hat{\mathbf{X}} = \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix}$$

$$\Phi(\hat{\mathbf{X}}) = \hat{\mathbf{L}} = \begin{pmatrix} h_2 \\ h_3 - h_2 \\ h_4 - h_3 \\ -h_4 \\ h_2 - h_4 \end{pmatrix} = \begin{matrix} \mathbf{A} \\ \left(\begin{array}{ccc} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{array} \right) \cdot \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix} \end{matrix}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{L} = \begin{pmatrix} \Delta h_{1,2} \\ \Delta h_{2,3} \\ \Delta h_{3,4} \\ \Delta h_{4,1} \\ \Delta h_{4,2} \end{pmatrix} = \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\hat{\mathbf{X}} = \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix}$$

$$\Phi(\hat{\mathbf{X}}) = \hat{\mathbf{L}} = \begin{pmatrix} h_2 \\ h_3 - h_2 \\ h_4 - h_3 \\ -h_4 \\ h_2 - h_4 \end{pmatrix} = \overbrace{\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix}}^{\mathbf{A}} \cdot \begin{pmatrix} h_2 \\ h_3 \\ h_4 \end{pmatrix}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 1 & -1 & 0 & 0 & 1 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 & -1 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix}$$

\mathbf{A}^T $\mathbf{A}^T \mathbf{A}$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 1 & -1 & 0 & 0 & 1 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 & -1 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 3 \end{pmatrix}$$

\mathbf{A}^T $\mathbf{A}^T \mathbf{A}$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 1 & -1 & 0 & 0 & 1 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 & -1 \end{pmatrix} \begin{pmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 3 \end{pmatrix}$$

\mathbf{A}^T $\mathbf{A}^T \mathbf{A}$

$$\mathbf{L} \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix}_m$$
$$\begin{pmatrix} \\ \\ \\ \\ \end{pmatrix}_m$$

$\mathbf{A}^T \mathbf{L}$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 1 & -1 & 0 & 0 & 1 \\ 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 & -1 \end{pmatrix} \begin{pmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 3 \end{pmatrix}$$

\mathbf{A}^T $\mathbf{A}^T \mathbf{A}$

$$\mathbf{L} \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m}$$
$$\begin{pmatrix} 16.5 \\ -8.1 \\ -5.5 \end{pmatrix} \text{ m}$$

$\mathbf{A}^T \mathbf{L}$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Gauß-Normalgleichung:


$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 3 \end{pmatrix} \cdot \hat{\mathbf{X}} = \begin{pmatrix} 16.5 \\ -8.1 \\ -5.5 \end{pmatrix} \text{ m}$$

$\mathbf{A}^T \mathbf{A}$ $\mathbf{A}^T \mathbf{L}$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen



Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{L}$$

$$\begin{pmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 3 \end{pmatrix} \cdot \hat{\mathbf{X}} = \begin{pmatrix} 16.5 \\ -8.1 \\ -5.5 \end{pmatrix} \text{ m} \Rightarrow \hat{\mathbf{X}} = \underline{\underline{\begin{pmatrix} 4.2 \\ -2.6 \\ -1.3 \end{pmatrix} \text{ m}}}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Ausgegliche Beobachtungen:

$$\hat{\mathbf{L}} = \mathbf{A}\hat{\mathbf{X}}$$
$$\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} \hat{\mathbf{X}} \\ 4.2 \\ -2.6 \\ -1.3 \end{pmatrix}_m$$
$$\begin{matrix} \mathbf{A} & \hat{\mathbf{L}} \end{matrix}$$

Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Ausgegliche Beobachtungen:

$$\hat{\mathbf{L}} = \mathbf{A}\hat{\mathbf{X}}$$
$$\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} 4.2 \\ -2.6 \\ -1.3 \end{pmatrix}_m$$
$$\begin{pmatrix} 4.2 \\ -6.8 \\ 1.3 \\ 1.3 \\ 5.5 \end{pmatrix}_m$$
$$\mathbf{A} \quad \hat{\mathbf{L}}$$

Ausgleichung bei linearem funktionalem Modell


Beispiel 2: Ausgleichung von Höhendifferenzen

Ausgeglichene Beobachtungen:

$$\hat{L} = A\hat{X}$$

$$\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} 4.2 \\ -2.6 \\ -1.3 \end{pmatrix} \text{ m}$$

A \hat{L}



Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Ausgegliche Beobachtungen:

$$\hat{L} = A\hat{X}$$


$$\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} 4.2 \\ -2.6 \\ -1.3 \end{pmatrix} \text{ m}$$

\hat{X}

$$\begin{pmatrix} 4.2 \\ -6.8 \\ 1.3 \\ 1.3 \\ 5.5 \end{pmatrix} \text{ m}$$

\hat{L}

A



Ausgleichung bei linearem funktionalem Modell

Beispiel 2: Ausgleichung von Höhendifferenzen

Ausgegliche Beobachtungen:

$$\hat{L} = A\hat{X}$$


$$\begin{pmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \\ 0 & 0 & -1 \\ 1 & 0 & -1 \end{pmatrix} \begin{pmatrix} 4.2 \\ -2.6 \\ -1.3 \end{pmatrix} \text{ m}$$

\hat{X}

$$\begin{pmatrix} 4.2 \\ -6.8 \\ 1.3 \\ 1.3 \\ 5.5 \end{pmatrix} \text{ m}$$

\hat{L}

A



Ausgleichung bei linearem funktionalem Modell (1)

Wenn

$$\tilde{\mathbf{L}} = \Phi(\tilde{\mathbf{X}}) = \mathbf{A}\tilde{\mathbf{X}}$$

dann erfüllt Optimum

$$(\mathbf{A}^T \mathbf{A}) \hat{\mathbf{X}} = \mathbf{A}^T \hat{\mathbf{L}}$$

Genauigkeit



Quelle: wikipedia

Genauigkeit

Jede **Beobachtung** ist die Realisierung einer **Zufallsvariablen X** .



Quelle: wikipedia

Gelegentlich ist eine **a-priori-Genauigkeit** der Beobachtung bekannt,

gegeben als Varianz $\sigma^2 := \mathbf{E} \left((X - \mathbf{E}(X))^2 \right)$.

Bei **mehreren Beobachtungen** (Vektor \mathbf{L}):

Kovarianzmatrix $\Sigma_{\mathbf{LL}} := \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$.

Genauigkeit

Bei *mehreren Beobachtungen* (Vektor \mathbf{L}):

$$\text{Kovarianzmatrix } \Sigma_{LL} := \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right).$$

Bei *zwei Beobachtungen*:

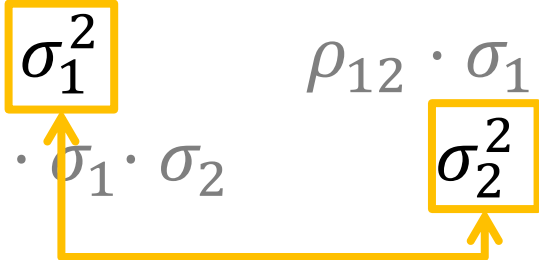
$$\text{Kovarianzmatrix } \Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & \rho_{12} \cdot \sigma_1 \cdot \sigma_2 \\ \rho_{12} \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{pmatrix}.$$

Genauigkeit

Bei *mehreren Beobachtungen* (Vektor \mathbf{L}):

$$\text{Kovarianzmatrix } \Sigma_{LL} := \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right).$$

Bei *zwei Beobachtungen*:

$$\text{Kovarianzmatrix } \Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & \rho_{12} \cdot \sigma_1 \cdot \sigma_2 \\ \rho_{12} \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{pmatrix}.$$


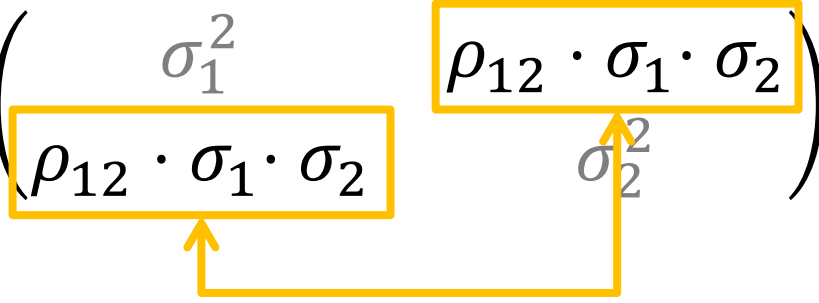
Varianzen

Genauigkeit

Bei *mehreren Beobachtungen* (Vektor \mathbf{L}):

$$\text{Kovarianzmatrix } \Sigma_{LL} := \mathbb{E} \left((\mathbf{L} - \mathbb{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbb{E}(\mathbf{L}))^T \right).$$

Bei *zwei Beobachtungen*:

$$\text{Kovarianzmatrix } \Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & \rho_{12} \cdot \sigma_1 \cdot \sigma_2 \\ \rho_{12} \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{pmatrix}.$$


Kovarianzen

Genauigkeit

Bei *mehreren Beobachtungen* (Vektor \mathbf{L}):

$$\text{Kovarianzmatrix } \Sigma_{LL} := \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right).$$

Bei *zwei Beobachtungen*:

$$\text{Kovarianzmatrix } \Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & \rho_{12} \cdot \sigma_1 \cdot \sigma_2 \\ \rho_{12} \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{pmatrix}.$$

Korrelationskoeffizienten

$$-1 \leq \rho_{12} \leq 1$$

Maß für stochastische Abhängigkeit

Genauigkeit

Bei *mehreren Beobachtungen* (Vektor \mathbf{L}):

$$\text{Kovarianzmatrix } \Sigma_{LL} := \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right).$$

Bei *zwei Beobachtungen*:

$$\text{Kovarianzmatrix } \Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & \rho_{12} \cdot \sigma_1 \cdot \sigma_2 \\ \rho_{12} \cdot \sigma_1 \cdot \sigma_2 & \sigma_2^2 \end{pmatrix}.$$

In der Regel:

$$\Sigma_{LL} = \begin{pmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{pmatrix}.$$

Genauigkeit

Σ_{LL} oft schwer *a priori* abzuschätzen,
aber Genauigkeits*relationen* bekannt:

$$\Sigma_{LL} = \sigma_0^2 \cdot Q_{LL}$$

Varianz der
Gewichtseinheit
(unbekannte
Konstante)

Kofaktormatrix
(lässt sich gut
abschätzen)

Genauigkeit

Ausgleichungsziel:

$$\mathbf{v}^T \mathbf{v} \rightarrow \text{Min}$$

Genauigkeit

Ausgleichungsziel:

$$\cancel{v^T v \rightarrow \text{Min}}$$

$$v^T P v \rightarrow \text{Min}$$

mit $P = Q^{-1}$



Quelle: wikipedia

Verbesserungen *genauer Beobachtungen* werden besonders bestraft.

Genauigkeit

Ausgleichungsziel:

$$\cancel{\mathbf{v}^T \mathbf{v} \rightarrow \text{Min}}$$

$$\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$$

mit $\mathbf{P} = \mathbf{Q}^{-1}$

Gauß-Normalgleichung:

$$\mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{P} \mathbf{L}$$

Genauigkeit

Wie genau sind Größen,
die aus Beobachtungen abgeleitet wurden?

→ *Kovarianzfortpflanzungsgesetz*

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} Σ_{LL}

Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

Gesucht:

Kovarianzmatrix des Vektors \mathbf{f} Σ_{ff}

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} Σ_{LL}

Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{F}\mathbf{L}$

Gesucht:

Kovarianzmatrix des Vektors \mathbf{f} Σ_{ff}

Beispiel:



$$f = l_1 + l_2 = \begin{pmatrix} 1 & 1 \end{pmatrix} \begin{pmatrix} L_1 \\ L_2 \end{pmatrix} \quad \Sigma_{LL} = \begin{pmatrix} 3 & 0 \\ 0 & 4 \end{pmatrix} [\text{cm}^2]$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\boldsymbol{\Sigma}_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\boldsymbol{\Sigma}_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

$$\boldsymbol{\Sigma}_{ff} =$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\boldsymbol{\Sigma}_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

$$\boldsymbol{\Sigma}_{ff} = \mathbf{E} \left((\mathbf{FL} - \mathbf{E}(\mathbf{FL})) \cdot (\mathbf{FL} - \mathbf{E}(\mathbf{FL}))^T \right)$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\boldsymbol{\Sigma}_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

$$\begin{aligned} \boldsymbol{\Sigma}_{ff} &= \mathbf{E} \left((\mathbf{FL} - \mathbf{E}(\mathbf{FL})) \cdot (\mathbf{FL} - \mathbf{E}(\mathbf{FL}))^T \right) \\ &= \mathbf{E} \left((\mathbf{FL} - \mathbf{FE}(\mathbf{L})) \cdot (\mathbf{FL} - \mathbf{FE}(\mathbf{L}))^T \right) \end{aligned} \begin{array}{l} \text{Linearität des} \\ \text{Erwartungswerts!} \end{array}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\boldsymbol{\Sigma}_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{F}\mathbf{L}$

$$\begin{aligned} \boldsymbol{\Sigma}_{ff} &= \mathbf{E} \left((\mathbf{F}\mathbf{L} - \mathbf{E}(\mathbf{F}\mathbf{L})) \cdot (\mathbf{F}\mathbf{L} - \mathbf{E}(\mathbf{F}\mathbf{L}))^T \right) \\ &= \mathbf{E} \left((\mathbf{F}\mathbf{L} - \mathbf{F}\mathbf{E}(\mathbf{L})) \cdot (\mathbf{F}\mathbf{L} - \mathbf{F}\mathbf{E}(\mathbf{L}))^T \right) \\ &= \mathbf{E} \left(\mathbf{F} \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \cdot \mathbf{F}^T \right) \end{aligned}$$

Linearität des Erwartungswerts!

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\Sigma_{LL} = E \left((\mathbf{L} - E(\mathbf{L})) \cdot (\mathbf{L} - E(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{F}\mathbf{L}$

$$\begin{aligned} \Sigma_{ff} &= E \left((\mathbf{F}\mathbf{L} - E(\mathbf{F}\mathbf{L})) \cdot (\mathbf{F}\mathbf{L} - E(\mathbf{F}\mathbf{L}))^T \right) \\ &= E \left((\mathbf{F}\mathbf{L} - \mathbf{F}E(\mathbf{L})) \cdot (\mathbf{F}\mathbf{L} - \mathbf{F}E(\mathbf{L}))^T \right) \\ &= E \left(\mathbf{F} \cdot (\mathbf{L} - E(\mathbf{L})) \cdot (\mathbf{L} - E(\mathbf{L}))^T \cdot \mathbf{F}^T \right) \\ &= \mathbf{F} \cdot E \left((\mathbf{L} - E(\mathbf{L})) \cdot (\mathbf{L} - E(\mathbf{L}))^T \right) \cdot \mathbf{F}^T \end{aligned}$$

Linearität des Erwartungswerts!

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\Sigma_{LL} = E\left(\left(\mathbf{L} - E(\mathbf{L})\right) \cdot \left(\mathbf{L} - E(\mathbf{L})\right)^T\right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{F}\mathbf{L}$

$$\begin{aligned}\Sigma_{ff} &= E\left(\left(\mathbf{F}\mathbf{L} - E(\mathbf{F}\mathbf{L})\right) \cdot \left(\mathbf{F}\mathbf{L} - E(\mathbf{F}\mathbf{L})\right)^T\right) \\ &= E\left(\left(\mathbf{F}\mathbf{L} - \mathbf{F}E(\mathbf{L})\right) \cdot \left(\mathbf{F}\mathbf{L} - \mathbf{F}E(\mathbf{L})\right)^T\right) \\ &= E\left(\mathbf{F} \cdot \left(\mathbf{L} - E(\mathbf{L})\right) \cdot \left(\mathbf{L} - E(\mathbf{L})\right)^T \cdot \mathbf{F}^T\right) \\ &= \mathbf{F} \cdot E\left(\left(\mathbf{L} - E(\mathbf{L})\right) \cdot \left(\mathbf{L} - E(\mathbf{L})\right)^T\right) \cdot \mathbf{F}^T \\ &= \underline{\underline{\mathbf{F}\Sigma_{LL}\mathbf{F}^T}}\end{aligned}$$

Linearität des Erwartungswerts!

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\Sigma_{LL} = E \left((\mathbf{L} - E(\mathbf{L})) \cdot (\mathbf{L} - E(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{FL}$

$$\underline{\underline{\Sigma_{ff} = \mathbf{F}\Sigma_{LL}\mathbf{F}^T}}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Gegeben:

Kovarianzmatrix des Vektors \mathbf{L} $\Sigma_{LL} = \mathbf{E} \left((\mathbf{L} - \mathbf{E}(\mathbf{L})) \cdot (\mathbf{L} - \mathbf{E}(\mathbf{L}))^T \right)$
Vektor \mathbf{f} als lin. Funktion von \mathbf{L} $\mathbf{f} = \mathbf{F}\mathbf{L}$

$$\underline{\underline{\Sigma_{ff} = \mathbf{F}\Sigma_{LL}\mathbf{F}^T}}$$

Beispiel: $f = L_1 + L_2 = (1 \quad 1) \begin{pmatrix} L_1 \\ L_2 \end{pmatrix} \quad \Sigma_{LL} = \begin{pmatrix} 3 & 0 \\ 0 & 4 \end{pmatrix} [\text{cm}^2]$

$$\Sigma_{ff} = (1 \quad 1) \begin{pmatrix} 3 \text{ cm}^2 & 0 \\ 0 & 4 \text{ cm}^2 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = (7 \text{ cm}^2)$$

Genauigkeit

*Kovarianzfortpflanzungsgesetz
für $\hat{\mathbf{X}}$?*

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

Genauigkeit

*Kovarianzfortpflanzungsgesetz
für $\hat{\mathbf{X}}$?*

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} = \mathbf{A}^T \mathbf{P} \mathbf{L}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} =$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{\mathbf{L}\mathbf{L}} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{\mathbf{LL}} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$
 $= \sigma_0^2 \mathbf{F} \mathbf{Q}_{\mathbf{LL}} \mathbf{F}^T$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{\mathbf{L}\mathbf{L}} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$
 $= \sigma_0^2 \mathbf{F} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{\mathbf{L}\mathbf{L}} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$

$$\begin{aligned} &= \sigma_0^2 \mathbf{F} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{F}^T \end{aligned}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{LL} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$

$$\begin{aligned} &= \sigma_0^2 \mathbf{F} \mathbf{Q}_{LL} \mathbf{F}^T = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{Q}_{LL} \mathbf{F}^T \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{F}^T \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{A} (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \end{aligned}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

$$\begin{aligned} \mathbf{A}^T \mathbf{P} \mathbf{A} \hat{\mathbf{X}} &= \mathbf{A}^T \mathbf{P} \mathbf{L} \\ \Leftrightarrow \hat{\mathbf{X}} &= (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{L} \end{aligned}$$

Also: $\Sigma_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \mathbf{F} \Sigma_{\mathbf{L}\mathbf{L}} \mathbf{F}^T$ mit $\mathbf{F} = (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P}$

$$\begin{aligned} &= \sigma_0^2 \mathbf{F} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{Q}_{\mathbf{L}\mathbf{L}} \mathbf{F}^T \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{F}^T \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{P} \mathbf{A} (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \\ &= \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \end{aligned}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

Genauigkeit der ausgeglichenen Unbekannten:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

Genauigkeit der ausgeglichenen Unbekannten:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1}$$

Genauigkeit der ausgeglichenen Beobachtungen:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{L}}\hat{\mathbf{L}}} = \quad \text{wegen } \hat{\mathbf{L}} = \mathbf{A}\hat{\mathbf{X}}$$

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

Genauigkeit der ausgeglichenen Unbekannten:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1}$$

Genauigkeit der ausgeglichenen Beobachtungen:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{L}}\hat{\mathbf{L}}} = \mathbf{A} \boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} \mathbf{A}^T \quad \text{wegen } \hat{\mathbf{L}} = \mathbf{A} \hat{\mathbf{X}}$$

Genauigkeit

Problem:

Berechnung von $\Sigma_{\hat{X}\hat{X}} = \sigma_0^2 (A^T P A)^{-1}$
erfordert Kenntnis von σ_0^2 .

Lösung:

Schätze σ_0^2 durch Ausgleichung (Kenntnis von Genauigkeitsrelationen Q_{LL} vorausgesetzt)

Genauigkeit

σ_0^2 lässt sich mittels \mathbf{v} abschätzen.

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

ist ein *erwartungstreuer Schätzer* für σ_0^2 .

(ohne Beweis)

Genauigkeit

σ_0^2 lässt sich mittels \mathbf{v} abschätzen.

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

ist ein *erwartungstreuer Schätzer* für σ_0^2 .
(ohne Beweis)

Beispiel 1:

$$\mathbf{v} = \mathbf{A}\hat{\mathbf{X}} - \mathbf{L} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \hat{X} - \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \begin{pmatrix} \hat{X} - L_1 \\ \vdots \\ \hat{X} - L_n \end{pmatrix}$$

Genauigkeit

σ_0^2 lässt sich mittels \mathbf{v} abschätzen.

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

ist ein *erwartungstreuer Schätzer* für σ_0^2 .
(ohne Beweis)

Beispiel 1:

$$\mathbf{v} = \mathbf{A}\hat{\mathbf{X}} - \mathbf{L} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \hat{X} - \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \begin{pmatrix} \hat{X} - L_1 \\ \vdots \\ \hat{X} - L_n \end{pmatrix}$$

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

Genauigkeit

σ_0^2 lässt sich mittels \mathbf{v} abschätzen.

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

ist ein *erwartungstreuer Schätzer* für σ_0^2 .
(ohne Beweis)

Beispiel 1:

$$\mathbf{v} = \mathbf{A}\hat{\mathbf{X}} - \mathbf{L} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \hat{\mathbf{X}} - \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \begin{pmatrix} \hat{\mathbf{X}} - L_1 \\ \vdots \\ \hat{\mathbf{X}} - L_n \end{pmatrix}$$

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u} = \frac{\mathbf{v}^T \mathbf{v}}{n - 1}$$

Genauigkeit

σ_0^2 lässt sich mittels \mathbf{v} abschätzen.

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u}$$

ist ein *erwartungstreuer Schätzer* für σ_0^2 .
(ohne Beweis)

Beispiel 1:

$$\mathbf{v} = \mathbf{A} \hat{\mathbf{X}} - \mathbf{L} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \hat{\mathbf{X}} - \begin{pmatrix} L_1 \\ \vdots \\ L_n \end{pmatrix} = \begin{pmatrix} \hat{X} - L_1 \\ \vdots \\ \hat{X} - L_n \end{pmatrix}$$

Stichprobenvarianz

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u} = \frac{\mathbf{v}^T \mathbf{v}}{n - 1} = \frac{\sum_{i=1}^n (\hat{X} - L_i)^2}{n - 1}$$

Genauigkeit

Beweis für Spezialfall Mittelwert

$$E(\hat{\sigma}_0^2) = E\left(\frac{\sum_{i=1}^n (\hat{X} - L_i)^2}{n-1}\right)$$

Genauigkeit

Beweis für Spezialfall Mittelwert

$$\begin{aligned} E(\hat{\sigma}_0^2) &= E\left(\frac{\sum_{i=1}^n (\hat{X} - L_i)^2}{n-1}\right) \quad \mu = E(\hat{X}) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (\hat{X} - \mu + \mu - L_i)^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n \left((\hat{X} - \mu)^2 - 2(\hat{X} - \mu)(L_i - \mu) + (L_i - \mu)^2\right)\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (\hat{X} - \mu)^2 - 2\sum_{i=1}^n (\hat{X} - \mu)(L_i - \mu) + \sum_{i=1}^n (L_i - \mu)^2\right) \\ &= \frac{1}{n-1} E\left(n(\hat{X} - \mu)^2 - 2n(\hat{X} - \mu)(\hat{X} - \mu) + \sum_{i=1}^n (L_i - \mu)^2\right) \\ &= \frac{1}{n-1} E\left(\sum_{i=1}^n (L_i - \mu)^2 - n(\hat{X} - \mu)^2\right) \\ &= \frac{1}{n-1} \left(\sum_{i=1}^n E(L_i - \mu)^2 - nE\left((\hat{X} - \mu)^2\right)\right) \\ &= \frac{1}{n-1} (n\sigma_0^2 - n\sigma_{\hat{X}}^2) \\ &= \frac{1}{n-1} \left(n\sigma_0^2 - n\frac{\sigma_0^2}{n}\right) = \underline{\sigma_0^2} \end{aligned}$$

Genauigkeit


Beispiel 2: Ausgleichung von Höhendifferenzen

$$\mathbf{v} = \hat{\mathbf{L}} - \mathbf{L}$$

$$= \begin{pmatrix} 4.2 \\ -6.8 \\ 1.3 \\ 1.3 \\ 5.5 \end{pmatrix} \text{ m} - \begin{pmatrix} 4.1 \\ -7.0 \\ 1.1 \\ 1.2 \\ 5.4 \end{pmatrix} \text{ m} = \begin{pmatrix} 0.1 \\ 0.2 \\ 0.2 \\ 0.1 \\ 0.1 \end{pmatrix} \text{ m}$$

$$\hat{\sigma}_0^2 = \frac{\mathbf{v}^T \mathbf{P} \mathbf{v}}{n - u} = \frac{0.11 \text{ m}^2}{5 - 3} = 0.055 \text{ m}^2$$

$$\underline{\underline{\hat{\sigma}_0 = 0.23 \text{ m}}}$$



Genauigkeit

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\Sigma_{\hat{X}\hat{X}} = \sigma_0^2 \cdot (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1}$$

Genauigkeit

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\begin{aligned}\Sigma_{\hat{X}\hat{X}} &= \sigma_0^2 \cdot (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \\ &= 0.055 \text{ m}^2 \cdot \begin{pmatrix} 0.625 & 0.500 & 0.375 \\ 0.500 & 1.000 & 0.500 \\ 0.375 & 0.500 & 0.625 \end{pmatrix}\end{aligned}$$

Genauigkeit

Beispiel 2: Ausgleichung von Höhendifferenzen

$$\begin{aligned}\Sigma_{\hat{X}\hat{X}} &= \sigma_0^2 \cdot (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \\ &= 0.055 \text{ m}^2 \cdot \begin{pmatrix} 0.625 & 0.500 & 0.375 \\ 0.500 & 1.000 & 0.500 \\ 0.375 & 0.500 & 0.625 \end{pmatrix} \\ &= \begin{pmatrix} 0.0344 & 0.0275 & 0.0206 \\ 0.0275 & 0.0550 & 0.0275 \\ 0.0206 & 0.0275 & 0.0344 \end{pmatrix} \text{ m}^2\end{aligned}$$

Genauigkeit

Beispiel 2: Ausgleichung von Höhendifferenzen


$$\begin{aligned}\Sigma_{\hat{X}\hat{X}} &= \sigma_0^2 \cdot (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1} \\ &= 0.055 \text{ m}^2 \cdot \begin{pmatrix} 0.625 & 0.500 & 0.375 \\ 0.500 & 1.000 & 0.500 \\ 0.375 & 0.500 & 0.625 \end{pmatrix} \\ &= \begin{pmatrix} 0.0344 & 0.0275 & 0.0206 \\ 0.0275 & 0.0550 & 0.0275 \\ 0.0206 & 0.0275 & 0.0344 \end{pmatrix} \text{ m}^2\end{aligned}$$

$$\sigma_{h_2} = \sigma_{h_4} = \sqrt{0.0344 \text{ m}^2} = \underline{\underline{0.185 \text{ m}}}$$

$$\sigma_{h_3} = \sqrt{0.0550 \text{ m}^2} = \underline{\underline{0.235 \text{ m}}}$$

Genauigkeit

Beispiel 2: Ausgleichung von Höhendifferenzen



$$\sigma_{h_2} = \sigma_{h_4} = \sqrt{0.0344 \text{ m}^2} = \underline{\underline{0.185 \text{ m}}}$$

$$\sigma_{h_3} = \sqrt{0.0550 \text{ m}^2} = \underline{\underline{0.235 \text{ m}}}$$

Genauigkeit

$$\Sigma_{\widehat{LL}} =$$

Genauigkeit

$$\Sigma_{\hat{L}\hat{L}} = A\Sigma_{\hat{X}\hat{X}}A^T$$

Genauigkeit

$$\Sigma_{\hat{L}\hat{L}} = A\Sigma_{\hat{X}\hat{X}}A^T$$
$$= \begin{pmatrix} 0.0344 & -0.0069 & -0.0069 & -0.0206 & 0.0138 \\ -0.0069 & 0.0344 & -0.0206 & -0.0069 & -0.0138 \\ -0.0069 & -0.0206 & 0.0344 & -0.0069 & -0.0138 \\ -0.0206 & -0.0069 & -0.0069 & 0.0344 & 0.0138 \\ 0.0138 & -0.0138 & -0.0138 & 0.0138 & 0.0275 \end{pmatrix} \text{m}^2$$

Genauigkeit

$$\Sigma_{\hat{L}\hat{L}} = A\Sigma_{\hat{X}\hat{X}}A^T$$

$$= \begin{pmatrix} 0.0344 & -0.0069 & -0.0069 & -0.0206 & 0.0138 \\ -0.0069 & 0.0344 & -0.0206 & -0.0069 & -0.0138 \\ -0.0069 & -0.0206 & 0.0344 & -0.0069 & -0.0138 \\ -0.0206 & -0.0069 & -0.0069 & 0.0344 & 0.0138 \\ 0.0138 & -0.0138 & -0.0138 & 0.0138 & 0.0275 \end{pmatrix} \text{ m}^2$$

$$\sigma_{\Delta h_{1,2}} = \sigma_{\Delta h_{2,3}} = \sigma_{\Delta h_{3,4}} = \sigma_{\Delta h_{4,1}} = \sqrt{0.0344 \text{ m}^2} = \underline{\underline{0.185 \text{ m}}}$$

$$\sigma_{\Delta h_{4,2}} = \sqrt{0.0275 \text{ m}^2} = \underline{\underline{0.166 \text{ m}}}$$

Vergleich: $\hat{\sigma}_0 = 0.23 \text{ m}$ → Genauigkeitsgewinn durch Ausgleich

Genauigkeit

Kovarianzfortpflanzungsgesetz

Ausgleichung mit Ziel $\mathbf{v}^T \mathbf{P} \mathbf{v} \rightarrow \text{Min}$:

Genauigkeit der ausgeglichenen Unbekannten:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} = \sigma_0^2 (\mathbf{A}^T \mathbf{P} \mathbf{A})^{-1}$$

Genauigkeit der ausgeglichenen Beobachtungen:

$$\boldsymbol{\Sigma}_{\hat{\mathbf{L}}\hat{\mathbf{L}}} = \mathbf{A} \boldsymbol{\Sigma}_{\hat{\mathbf{X}}\hat{\mathbf{X}}} \mathbf{A}^T \quad \text{wegen } \hat{\mathbf{L}} = \mathbf{A} \hat{\mathbf{X}}$$