

# Landmålingens fejlteori

## Lektion 6

### Den generelle fejlforplantningslov

Rasmus Waagepetersen - [rw@math.aau.dk](mailto:rw@math.aau.dk)

Institut for Matematiske Fag  
Aalborg Universitet

# Simple fejlforplantningslov

Antag  $X_1, X_2, \dots, X_n$  er  $n$  *uafhængige* stokastiske variable, hvor  $\text{Var}(X_1) = \sigma_1^2, \dots, \text{Var}(X_n) = \sigma_n^2$ .

Lad  $Y = g(X_1, X_2, \dots, X_n)$ , hvor  $g$  er en differentiabel funktion.

Et tilnærmet udtryk for variansen for  $\text{Var}(Y) = \sigma_Y^2$  er

$$\sigma_Y^2 \approx \left( \frac{\partial g}{\partial X_1} \right)^2 \sigma_1^2 + \dots + \left( \frac{\partial g}{\partial X_n} \right)^2 \sigma_n^2$$

# Planlægning af måleserier

I eksempel 27 i noterne kom vi frem til følgende estimat af variansen på det estimerede trekant-areal:

$$\begin{aligned}\sigma_T^2 &\approx 75.66^2 \cdot 0.01^2 + 57.44^2 \cdot 0.01^2 + (927.1\pi/200)^2 \cdot 0.002^2 \\ &\approx 75.66^2 \cdot 0.01^2 + 57.44^2 \cdot 0.01^2 + (14.56)^2 \cdot 0.002^2\end{aligned}$$

Leddene svarer til bidrag fra målingerne af side  $a$ , side  $b$  og vinkel  $C$  med spredningerne 0.01, 0.01 og 0.002.

Hvis vi ønsker at reducere variansen ved at foretage yderligere målinger - hvad er da den bedste fremgangsmåde ?

# Kovarians og korrelation

Kovarians:

$$\text{Cov}(X_1, X_2) = \mathbb{E}[(X_1 - \mu_1)(X_2 - \mu_2)]$$

Korrelation:

$$\rho = \text{Corr}(X_1, X_2) = \frac{\text{Cov}(X_1, X_2)}{\sqrt{\text{Var}X_1 \text{Var}X_2}} = \frac{\text{Cov}(X_1, X_2)}{\sigma_1 \sigma_2}$$

$\rho$  mellem -1 og 1

$\rho$  positiv/negativ  $\Leftrightarrow$  positiv/negativ sammenhæng mellem  $X_1$  og  $X_2$ .

**Eks.:**  $X_1$  har spredning 0.1 og er uafhængig af  $\nu$  som har spredning 0.05.  
Hvad er kovariansen og korrelationen mellem  $X_1$  og  $X_2 = X_1 + \nu$  ?

# Variansen af afhængige variable

## Varians for linearkombination af afhængige SV

Antag  $X_1, X_2, \dots, X_n$  er stokastiske variable, med varianser  $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$ . Antag desuden, at kovariansen mellem  $X_i$  og  $X_j$  er  $\text{Cov}(X_i, X_j) = \sigma_{ij}$ .

Variansen for linearkombinationen er

$$\begin{aligned}\text{Var}(a_0 + a_1X_1 + \dots + a_nX_n) &= a_1^2\sigma_1^2 + \dots + a_n^2\sigma_n^2 + 2 \sum_{i < j} a_i a_j \sigma_{ij} \\ &= \sum_{i=1}^n a_i^2 \sigma_i^2 + 2 \sum_{i < j} a_i a_j \sigma_{ij}\end{aligned}$$

# Fejlforplantning med afhængige variable

Lad  $Y = g(X_1, \dots, X_n)$  hvor  $\sigma_{ij} = \text{Cov}(X_i, X_j)$  kan være forskellig fra nul. Da gælder

$$\sigma_Y^2 \approx \left( \frac{\partial g}{\partial X_1} \right)^2 \sigma_1^2 + \dots + \left( \frac{\partial g}{\partial X_n} \right)^2 \sigma_n^2 + 2 \sum_{i < j} \frac{\partial g}{\partial X_i} \frac{\partial g}{\partial X_j} \sigma_{ij}$$

Dvs. vi skal nu også inkludere en sum over alle par  $X_i, X_j, i \neq j$ .

# Eksempel

Lad  $X_1$  og  $X_2$  være stokastiske variable med middelværdi og spredninger  $\mu_1, \mu_2$  og  $\sigma_1, \sigma_2$  hvor  $\text{Corr}(X_1, X_2) = \rho \neq 0$ .

Vi ønsker at bestemme variansen af  $Y = \frac{X_1}{X_2}$ . Dvs vi skal bestemme de partielt afledte af  $Y$  mht.  $X_1$  og  $X_2$ ,

$$\frac{\partial Y}{\partial X_1} = \frac{1}{X_2} \qquad \frac{\partial Y}{\partial X_2} = -\frac{X_1}{X_2^2}$$

Indsættes udtrykkene nu i formelen for  $\sigma_Y^2$  får vi

$$\begin{aligned}\sigma_Y^2 &\approx \left(\frac{1}{\mu_2}\right)^2 \sigma_1^2 + \left(-\frac{\mu_1}{\mu_2^2}\right)^2 \sigma_2^2 + 2\left(\frac{1}{\mu_2}\right)\left(-\frac{\mu_1}{\mu_2^2}\right)\sigma_{12} \\ &= \left(\frac{\sigma_1}{\mu_2}\right)^2 + \left(\frac{\mu_1}{\mu_2^2}\right)^2 \sigma_2^2 - 2\frac{\mu_1}{\mu_2^3}\sigma_1\sigma_2\rho\end{aligned}$$

Godt eller skidt at have positiv korrelation?

# Motiverende eksempel: Polære koordinater

I landmåling forekommer **polære målinger** hvor de **rektangulære målinger** fremkommer ved følgende sammenhænge,

$$X = S \cos \theta \quad Y = S \sin \theta$$

- Vi ser at både  $X$  og  $Y$  er transformationer af de samme stokastiske variable  $S$  og  $\theta$ .
- Det medfører at de *ikke* er indbyrdes uafhængige og derfor har vi typisk  $\text{Cov}(X, Y) \neq 0$ . Vi siger også at  $X$  og  $Y$  er korrelerede.
- Målet er nu at finde et (tilnærmet) udtryk for kovariansen mellem  $X$  og  $Y$ .
- først får vi brug for lidt vektor og matrix-regning.

# Stokastiske vektorer

Antag  $X_1, X_2, \dots, X_n$  er SV. Vi kan da forme en *stokastisk vektor*

$$\mathbf{X} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}$$

Antag  $X_i$  har middelværdi  $\mu_i$ , da kan vi definere en middelværdi-vektor:

$$\boldsymbol{\mu}_{\mathbf{X}} = \mathbb{E}[\mathbf{X}] = \begin{bmatrix} E[X_1] \\ E[X_2] \\ \vdots \\ E[X_n] \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{bmatrix}.$$

# Kovariansmatricen

Antag  $X_i$  har varians  $\sigma_i^2$  og kovariansen mellem  $X_i$  og  $X_j$  er  $\text{Cov}(X_i, X_j) = \sigma_{ij}$ .

Alle varianser og kovarianser kan samles i en *kovarians-matrix*

$$K_{\mathbf{X}} = \text{Var}[\mathbf{X}] = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_2^2 & & \sigma_{2n} \\ \vdots & & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_n^2 \end{bmatrix}$$

Kovariansmatricen  $K_{\mathbf{X}}$  er en kvadratisk og symmetrisk  $n \times n$  matrix, da  $\text{Cov}(X_i, X_j) = \text{Cov}(X_j, X_i)$ .

# Kovariansmatricen $K_{\mathbf{X}}$

I tilfældet, hvor  $X_i$ 'erne er indbyrdes uafhængige, er  $\sigma_{ij} = 0$  for alle  $i$  og  $j$  og  $K_{\mathbf{X}}$  bliver således en diagonal matrix:

$$K_{\mathbf{X}} = \begin{bmatrix} \sigma_1^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & 0 & \dots & 0 \\ 0 & 0 & \sigma_3^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \sigma_n^2 \end{bmatrix}$$

# Regneregler

Antag at  $\mathbf{X}$  er en  $n \times 1$  søjle-vektor (som før).

Antag  $\mathbf{A}$  er en  $m \times n$  matrix og  $\mathbf{b}$  er en  $m \times 1$  søjle-vektor og lad

$$\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{b}.$$

Da er  $\mathbf{Y}$  en  $m \times 1$  søjle-vektor med middelværdi-vektor

$$\mathbb{E}[\mathbf{Y}] = \mathbb{E}[\mathbf{A}\mathbf{X} + \mathbf{b}] = \mathbf{A}\mathbb{E}[\mathbf{X}] + \mathbf{b}.$$

og kovariansmatrix

$$\mathbb{V}\text{ar}[\mathbf{Y}] = \mathbb{V}\text{ar}[\mathbf{A}\mathbf{X} + \mathbf{b}] = \mathbf{A}\mathbb{V}\text{ar}(\mathbf{X})\mathbf{A}^T = \mathbf{A}\mathbf{K}_{\mathbf{X}}\mathbf{A}^T$$

# Vilkårlige transformationer

Antag nu  $Y_1, \dots, Y_m$  er transformationer af  $X_1, \dots, X_n$ .

Dvs.

$$Y_1 = g_1(X_1, \dots, X_n)$$

$$Y_2 = g_2(X_1, \dots, X_n)$$

$$\vdots$$

$$Y_m = g_m(X_1, \dots, X_n)$$

hvor  $g_1, \dots, g_m$  er  $m$  differentiable funktioner

# Linearisering af $Y$ — matrixform

Som tidligere laver vi en lineær approximation af  $Y_k$  omkring middelværdierne af  $X$ 'erne,

$$Y_k \approx g_k(\mu_1, \dots, \mu_n) + \frac{\partial g_k}{\partial X_1}(X_1 - \mu_1) + \dots + \frac{\partial g_k}{\partial X_n}(X_n - \mu_n)$$

Omskrevet til matrix-form:

$$\begin{aligned} Y_k &\approx g_k(\dots) + \begin{bmatrix} \frac{\partial g_k}{\partial X_1} & \frac{\partial g_k}{\partial X_2} & \dots & \frac{\partial g_k}{\partial X_n} \end{bmatrix} \begin{bmatrix} X_1 - \mu_1 \\ X_2 - \mu_2 \\ \vdots \\ X_n - \mu_n \end{bmatrix} \\ &= g_k(\dots) - \begin{bmatrix} \frac{\partial g_k}{\partial X_1} & \frac{\partial g_k}{\partial X_2} & \dots & \frac{\partial g_k}{\partial X_n} \end{bmatrix} \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{bmatrix} + \begin{bmatrix} \frac{\partial g_k}{\partial X_1} & \frac{\partial g_k}{\partial X_2} & \dots & \frac{\partial g_k}{\partial X_n} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \\ &= g_k(\dots) - \mathbf{G}_k \boldsymbol{\mu}_X + \mathbf{G}_k \mathbf{X}. \end{aligned}$$

# Tilnærmet udtryk for variansen af $Y_k$

Lineariseringen af  $Y_k$  kan (altså) skrives som

$$Y_k \approx g_k(\cdots) - \mathbf{G}_k \boldsymbol{\mu}_{\mathbf{X}} + \mathbf{G}_k \mathbf{X},$$

hvor  $\mathbf{G}_k = \begin{bmatrix} \frac{\partial g_k}{\partial X_1} & \frac{\partial g_k}{\partial X_2} & \cdots & \frac{\partial g_k}{\partial X_n} \end{bmatrix}$ .

Et tilnærmet udtryk for variansen for  $Y_k$  er

$$\begin{aligned} \text{Var}(Y_k) &\approx \text{Var}(g_k(\cdots) - \mathbf{G}_k \boldsymbol{\mu}_{\mathbf{X}} + \mathbf{G}_k \mathbf{X}) \\ &= \underbrace{\mathbf{G}_k}_{1 \times n} \underbrace{\text{Var}(\mathbf{X})}_{n \times n} \underbrace{\mathbf{G}_k^T}_{n \times 1} = \mathbf{G}_k \mathbf{K}_{\mathbf{X}} \mathbf{G}_k^T = \\ &= \left( \frac{\partial g_k}{\partial X_1} \right)^2 \sigma_1^2 + \cdots + \left( \frac{\partial g_k}{\partial X_n} \right)^2 \sigma_n^2 + 2 \sum_{i < j} \frac{\partial g_k}{\partial X_i} \frac{\partial g_k}{\partial X_j} \sigma_{ij}. \end{aligned}$$

Resultatet matcher de tidligere beregninger **Ex**: varians for  $Y = X_1/X_2$  vha. matrixberegning.

# Linearisering af $\mathbf{Y}$ på matrixform

Lineariseringen for  $Y_1, \dots, Y_m$  kan skrives samlet som

$$\begin{aligned}\mathbf{Y} &\approx \mathbf{g} + \mathbf{G}(\mathbf{X} - \boldsymbol{\mu}_{\mathbf{X}}) \\ &= \mathbf{g} - \mathbf{G}\boldsymbol{\mu}_{\mathbf{X}} + \mathbf{G}\mathbf{X},\end{aligned}$$

hvor

$$\mathbf{g} = \begin{bmatrix} g_1(\mu_1, \dots, \mu_n) \\ g_2(\mu_1, \dots, \mu_n) \\ \vdots \\ g_m(\mu_1, \dots, \mu_n) \end{bmatrix} \quad \text{og} \quad \mathbf{G} = \begin{bmatrix} \mathbf{G}_1 \\ \mathbf{G}_2 \\ \vdots \\ \mathbf{G}_m \end{bmatrix} = \begin{bmatrix} \frac{\partial g_1}{\partial X_1} & \frac{\partial g_1}{\partial X_2} & \cdots & \frac{\partial g_1}{\partial X_n} \\ \frac{\partial g_2}{\partial X_1} & \frac{\partial g_2}{\partial X_2} & & \frac{\partial g_2}{\partial X_n} \\ \vdots & & \ddots & \vdots \\ \frac{\partial g_m}{\partial X_1} & \frac{\partial g_m}{\partial X_2} & \cdots & \frac{\partial g_m}{\partial X_n} \end{bmatrix}$$

Matricen  $\mathbf{G}$  kaldes *Jacobi-matricen*.

# Den generelle fejlforplantningslov

Et tilnærmet udtryk for kovariansmatricen for  $\mathbf{Y}$  er

$$\begin{aligned}\text{Var}(\mathbf{Y}) &\approx \text{Var}(\mathbf{g} - \mathbf{G}\boldsymbol{\mu}_{\mathbf{X}} + \mathbf{G}\mathbf{X}) \\ &= \mathbf{G}\text{Var}(\mathbf{X})\mathbf{G}^T = \mathbf{G}K_{\mathbf{X}}\mathbf{G}^T\end{aligned}$$

Dette resultat kan opsummeres i den generelle fejlforplantningslov:

## Den Generelle Fejlforplantningslov

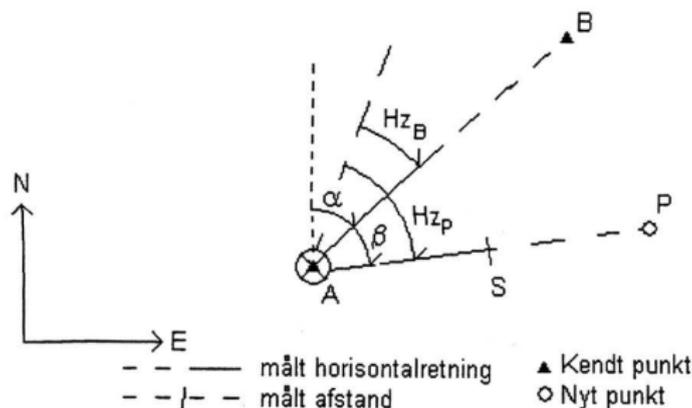
Antag  $X_1, X_2, \dots, X_n$  er SV med kovariansmatrix  $K_{\mathbf{X}}$ . Antag for  $i = 1, \dots, m$ , at  $Y_i = g_i(X_1, \dots, X_n)$ , hvor  $g_i$  er en differentiabel funktion. Da er et tilnærmet udtryk for kovariansmatricen for  $\mathbf{Y}$  givet ved

$$\text{Var}(\mathbf{Y}) \approx \mathbf{G} K_{\mathbf{X}} \mathbf{G}^T,$$

hvor  $\mathbf{G}$  er jacobimatricen.

# Anvendelse: Polære målinger

Afsnit 11.3 i Karsten Jensens noter:



Koordinaterne til punkt  $P = (E, N)$ . Vinklerne er målt in gon.

$$\begin{pmatrix} E \\ N \end{pmatrix} = \begin{pmatrix} E_A + S \cos(100 - [\alpha + \beta]) \\ N_A + S \sin(100 - [\alpha + \beta]) \end{pmatrix} = \begin{pmatrix} E_A + S \sin(\alpha + \beta) \\ N_A + S \cos(\alpha + \beta) \end{pmatrix},$$

idet  $\sin(100 - \theta) = \cos(\theta)$  og  $\cos(100 - \theta) = \sin(\theta)$ .

## Nøjagtighed af punktet $P$

Vi antager at koordinaterne for opstillingspunkterne  $A$  og  $B$  er fejlfrie, dvs  $\sigma_{E_A}^2 \approx 0$ ,  $\sigma_{N_A}^2 \approx 0$ ,  $\sigma_{E_B}^2 \approx 0$ ,  $\sigma_{N_B}^2 \approx 0$ , og dermed  $\sigma_\alpha \approx 0$ .

Vi antager også, at målingerne af  $S$  og  $\beta$  er uafhængige. Kovariansmatricen for  $[S, \beta]^T$  er derfor

$$K_b = \begin{bmatrix} \sigma_S^2 & 0 \\ 0 & \sigma_\beta^2 \end{bmatrix}$$

Ifølge den generelle fejlforplantningslov er et tilnærmet udtryk for kovariansmatricen for  $(E, N)$  givet ved

$$\text{Var} \left( \begin{bmatrix} E \\ N \end{bmatrix} \right) = K_{EN} = GK_bG^T = \begin{bmatrix} \sigma_E^2 & \sigma_{EN} \\ \sigma_{NE} & \sigma_N^2 \end{bmatrix}$$

hvor  $G$  er Jakobimatricen:

$$G = \begin{bmatrix} \frac{\partial E}{\partial S} & \frac{\partial E}{\partial \beta} \\ \frac{\partial N}{\partial S} & \frac{\partial N}{\partial \beta} \end{bmatrix} = \begin{bmatrix} \sin(\alpha + \beta) & S \cos(\alpha + \beta) \frac{1}{\omega} \\ \cos(\alpha + \beta) & -S \sin(\alpha + \beta) \frac{1}{\omega} \end{bmatrix} \quad \omega = \frac{200\text{gon}}{\pi}$$

# Kovariansmatricen $K_{EN}$

Vi anvender udtrykket for  $K_{EN}$  og indsætter de kendte matricer,

$$\begin{aligned}
 K_{EN} &= \begin{bmatrix} \sin(\theta) & S \cos(\theta) \frac{1}{\omega} \\ \cos(\theta) & -S \sin(\theta) \frac{1}{\omega} \end{bmatrix} \begin{bmatrix} \sigma_S^2 & 0 \\ 0 & \sigma_\beta^2 \end{bmatrix} \begin{bmatrix} \sin(\theta) & \cos(\theta) \\ S \cos(\theta) \frac{1}{\omega} & -S \sin(\theta) \frac{1}{\omega} \end{bmatrix} \\
 &= \begin{bmatrix} \sigma_S^2 \sin(\theta) & \sigma_\beta^2 S \cos(\theta) \frac{1}{\omega} \\ \sigma_S^2 \cos(\theta) & -\sigma_\beta^2 S \sin(\theta) \frac{1}{\omega} \end{bmatrix} \begin{bmatrix} \sin(\theta) & \cos(\theta) \\ S \cos(\theta) \frac{1}{\omega} & -S \sin(\theta) \frac{1}{\omega} \end{bmatrix} \\
 &= \begin{bmatrix} \sigma_S^2 \sin^2(\theta) + \sigma_\beta^2 S^2 \cos^2(\theta) \frac{1}{\omega^2} & (\sigma_S^2 - \sigma_\beta^2 S^2 \frac{1}{\omega^2}) \cos(\theta) \sin(\theta) \\ (\sigma_S^2 - \sigma_\beta^2 S^2 \frac{1}{\omega^2}) \sin(\theta) \cos(\theta) & \sigma_S^2 \cos^2(\theta) + \sigma_\beta^2 S^2 \sin^2(\theta) \frac{1}{\omega^2} \end{bmatrix}
 \end{aligned}$$

hvor  $\theta = \alpha + \beta$ . Idet der gælder  $\sin(2\theta) = 2 \sin(\theta) \cos(\theta)$  forkortes

$$= \begin{bmatrix} \sigma_S^2 \sin^2(\alpha + \beta) + \sigma_\beta^2 \frac{S^2}{\omega^2} \cos^2(\alpha + \beta) & \frac{1}{2} (\sigma_S^2 - \sigma_\beta^2 \frac{S^2}{\omega^2}) \sin(2[\alpha + \beta]) \\ \frac{1}{2} (\sigma_S^2 - \sigma_\beta^2 \frac{S^2}{\omega^2}) \sin(2[\alpha + \beta]) & \sigma_S^2 \cos^2(\alpha + \beta) + \sigma_\beta^2 \frac{S^2}{\omega^2} \sin^2(\alpha + \beta) \end{bmatrix}$$

*Næsten* som (11.2) i Karstens noter (der mangler nogle  $\omega$ 'er i noterne).

# Implementation i matlab

(se polar\_fejlforplantning.m script på hjemmesiden)

```
sigmaS=0.01
```

```
sigmabeta=0.1
```

```
theta=60*pi/200 (theta=alpha+beta)
```

```
S=254
```

```
omega=200/pi
```

```
Kb=[power(sigmaS,2) 0 ; 0 power(sigmabeta,2)]
```

```
G=[sin(theta) S*cos(theta)/omega; cos(theta) -S*sin(theta)/omega]
```

```
KEN=G*Kb*transpose(G)
```

```
corr=-0.0757/sqrt(0.0551*0.1042)
```

# Trekant-areal-beregningerne fra lektion 5

$$a=115.5434$$

$$b=152.1584$$

$$c=181.1240$$

$$A=43.7495\pi/200$$

$$B=62.9515\pi/200$$

$$C=93.2910\pi/200$$

$$T1=0.5*a*b*\sin(C)$$

$$T2=0.5*a*c*\sin(B)$$

$$T3=0.5*b*c*\sin(A)$$

$$\text{sigmaside2}=\text{power}(0.01,2)$$

$$\text{sigmaangle2}=\text{power}(0.002,2)$$

$$K=\text{diag}([\text{sigmaside2}/8 \text{ sigmaside2}/3 \text{ sigmaside2}/5 \text{ sigmaangle2}/2 \text{ sig}$$

$$G=[T1/a \ T1/b \ 0 \ 0 \ 0 \ T1/(\tan(C)*\omega); T2/a \ 0 \ T2/c \ 0 \ T2/(\tan(B)*\omega)$$

$$0 \ T3/b \ T3/c \ T3/(\tan(A)*\omega) \ 0 \ 0]$$

$$\text{VarT}=G*K*\text{transpose}(G)$$

# Varians af vægtet gennemsnit

Vi kan skrive vægtet gennemsnit som matrix produkt

$$\bar{x}^* = \mathbf{w}\mathbf{T}^T$$

hvor

$$\mathbf{w} = [p_1, p_2, p_3]/(p_+) \quad \mathbf{T} = [T_1, T_2, T_3]$$

Dvs.

$$\text{Var}\bar{X}^* = \mathbf{w}\text{Var}\mathbf{T}\mathbf{w}^T$$

I matlab:

```
p=[1 1.4399 0.8553]
```

```
w=p/sum(p)
```

```
w*VarT*transpose(w)
```

Svar=0.1021 dvs. del mindre end de separate varianser for  $T_1$ ,  $T_2$  og  $T_3$ .

# Optimal estimation baseret på afhængige observationer

Antag  $X_1, X_2, \dots, X_n$  er stokastiske variable, alle med samme middelværdi  $\mu$  og kovariansmatrix  $K_X$ .

Lad  $\mathbf{X} = [X_1 X_2 \cdots X_n]$ . Da er det optimale vægtede gennemsnit af  $X_1, \dots, X_n$  givet ved

$$\bar{X}^* = \mathbf{w}\mathbf{X}^\top$$

hvor  $\mathbf{w}$  er  $1 \times n$  matricen (rækkevektoren)

$$\mathbf{w} = (\mathbf{1}K_X^{-1}\mathbf{1}^\top)^{-1}\mathbf{1}K_X^{-1}$$

hvor  $\mathbf{1} = [11 \cdots 1]$  er  $1 \times n$  matricen med 1 i alle indgange.

Variansen for  $\bar{X}^*$  er

$$(\mathbf{1}^\top K_X^{-1} \mathbf{1})^{-1}$$

# Optimal estimation - tilbage til trekanten

Ser vi på trekant-areal beregningerne er bedste estimat for arealet baseret på  $T_1, T_2, T_3$  givet ved

$$(\mathbf{1}^\top K_T^{-1} \mathbf{1})^{-1} \mathbf{1}^\top K_T^{-1} \mathbf{T} = 8741.5$$

med varians

$$(\mathbf{1}^\top K_T^{-1} \mathbf{1})^{-1} = 0.0979$$

## Fordeling af slutfejl i trekant - generelle varianser

Lad  $X_\alpha$ ,  $X_\beta$  og  $X_\gamma$  være uafhængige målinger af vinklerne  $\alpha$ ,  $\beta$  og  $\gamma$  med varianser  $\sigma_\alpha^2$ ,  $\sigma_\beta^2$  og  $\sigma_\gamma^2$ .

Vi kan da estimere  $\alpha$  ved et vægtet gennemsnit af  $X_\alpha$  og  $Y_\alpha = 200 - X_\beta - X_\gamma$  med vægte 1 og  $\sigma_\alpha^2/\sigma_{Y_\alpha}^2$  hvor  $\sigma_{Y_\alpha}^2 = \sigma_\beta^2 + \sigma_\gamma^2$  er variansen af  $Y_\alpha$ .

Lad  $\sigma_+^2 = \sigma_\alpha^2 + \sigma_\beta^2 + \sigma_\gamma^2$  være summen af alle varianserne.

Det vægtede gennemsnit er da

$$\bar{X}^* = \frac{1}{1 + \frac{\sigma_\alpha^2}{\sigma_{Y_\alpha}^2}} X_\alpha + \frac{\frac{\sigma_\alpha^2}{\sigma_{Y_\alpha}^2}}{1 + \frac{\sigma_\alpha^2}{\sigma_{Y_\alpha}^2}} Y_\alpha = \frac{1}{\frac{\sigma_+^2}{\sigma_\alpha^2}} X_\alpha + \frac{\frac{\sigma_\alpha^2}{\sigma_{Y_\alpha}^2}}{\frac{\sigma_+^2}{\sigma_\alpha^2}} (r + X_\alpha) = X_\alpha + \frac{\sigma_\alpha^2}{\sigma_+^2} r$$

Estimatet af  $\alpha$  tildeles den andel af slutfejlen  $r$  som svarer til  $X_\alpha$ 's andel af den samlede varians.