

Landmålingens fejlteori Lektion 1 Det matematiske fundament Kontinuerte stokastiske variable

Rasmus Waagepetersen - rw@math.aau.dk

Institut for Matematiske Fag
Aalborg Universitet

1/41

Formål

- introduktion til basal sandsynlighedsberegning
- introduktion til basal statistik/fejlteori
- hvordan kvantificeres usikkerhed på en måling eller et gennemsnit af målinger ?
- hvorledes kvantificeres usikkerhed på en størrelse beregnet ud fra målinger som er behæftet med fejl ?

NB: jeg afviger af og til lidt fra noternes fremstilling, når det er hensigtsmæssigt.

3/41

Landmålingens fejlteori - lidt om kurset

Kursusholder

Rasmus Waagepetersen
Institut for Matematiske Fag
rw@math.aau.dk

Litteratur

Kasper Klitgaard Berthelsen, Poul Winding & Jens Møller Pedersen,
Noter i Fejlteori.

Kursusform


Seks kursusgange, hver med vekslen mellem forelæsninger og opgaver.

Eksamen

Mundtlig og fælles med *Det matematiske grundlag for kortprojektioner.*
Tager udgangspunkt i seks opgaver - tre fra hvert af de to kurser.

2/41

Formål




1

Arealet af ovenstående trekant kan bestemmes vha:
$$\text{areal} = \frac{1}{2} s_b \cdot s_c \cdot \sin \alpha.$$


Hvordan kvantificerer vi usikkerheden på målinger/skøn af α , s_b og s_c ?
Hvordan kvantificerer vi den resulterende usikkerhed på det beregnede areal ?

4/41

Formål



Antag vi har følgende 25 målinger af α :
 129.188, 129.203, 129.211, ..., 129.196, 129.205, 129.193.
 Histogram over målingerne:



Hvad er et godt skøn/estimat for α ? Gennemsnittet? Hvad kan vi sige om usikkerheden på vores estimat?

5/41

Kender vi usikkerheden på skønnene/estimerne af α , s_b og s_c giver Fejlforplantningsloven (clou'et i dette kursus) et skøn over usikkerheden på det beregnede areal.

6/41

Sandsynlighed

Udgangspunkt: Vi udfører et eksperiment/måling og observerer om en given hændelse H indtræffer.

Antag vi gentager eksperimentet n gange under identiske forhold og lader m angive antal gange, hvor H indtraf.

Hvis n går mod uendelig vil andelen m/n gå mod en fast størrelse - sandsynligheden for at H indtræffer.

Sandsynligheden noteres $P(H)$ (' P ' for 'probability')

2

7/41

Eksempel: Kast med en fair mønt

Eksperiment: Kast en *fair* mønt

Mulige udfald: *Plat* og *Krone*

H : kast giver krone.

Mønten er fair, dvs. i det lange løb forventer vi lige store andele plat og krone. Med andre ord gælder $P(H) = 0,5$.

8/41

Stokastiske variable noteres ofte med store bogstaver, mens konkrete udfald noteres med tilsvarende små bogstaver.

F.eks. kan X angive en fremtidig (endnu ikke foretaget måling) mens x angiver det konkrete resultat, når målingen er foretaget - f.eks. $x = 2$.

Vi kan da tale om sandsynligheden for hændelser $X = x$, $X \leq x$, $X > 4$, dvs. $P(X = x)$, $P(X \leq x)$, $P(X > 4)$...

Vi har nu brug for en bekvem måde at specificere sandsynlighederne for X !

Undtagelse: for en trekant følger vi traditionen og lader A, B, C og a, b, c betegne henholdsvis vinkler og sidelængder.

Sandsynligheder for kontinuerte stokastiske variable

For en kontinuert variabel tillægger vi kun positive sandsynligheder til intervaller, f.eks. $P(1 < X \leq 2)$.

For et enkelt x har vi altid $P(X = x) = 0$ for alle x .

Sandsynligheder for en kontinuert stokastisk variabel specificeres vha. tæthedsfunktion eller fordelingsfunktion.

Hvorfor nok at give sandsynligheder til intervaller ?

Målinger er i praksis altid afrundede størrelser.

Måling 201,43 med to decimaler repræsenterer i realiteten et interval $[201,425, 201,435[$ - vi kender ikke den nøjagtige værdi.

Dvs. i realiteten opererer vi altid med (små) intervaller omkring de målte størrelser.

Kontinuert og diskret stokastisk variabel

Diskrete stokastiske variable er variable hvor $P(X = x) > 0$ for en mængde af diskrete udfald - f.eks. $x = 0, 1, 2, 3, \dots$ (terningkast, tælldata, ...).

Sandsynligheder for diskrete stokastiske variable specificeres vha. sandsynlighedsfunktion $p(x) = P(X = x)$ for de diskrete udfald x .

Kontinuerte stokastiske variable kan som udgangspunkt antage alle reelle værdier.

Målinger af vinkler og længder betragtes mest relevant som kontinuerte variable.


Tæthedsfunktion

Definition: Tæthedsfunktion

En tæthedsfunktion $f(x)$ er en reel funktion, der opfylder

1. $f(x) \geq 0$ for alle $x \in R$.
2. $\int_{-\infty}^{\infty} f(x) dx = 1$.

Eksempel på en tæthedsfunktion:



Hvordan skal tæthedsfunktionen fortolkes?

Tæthedsfunktion: Fortolkning

Hvis X er en SV med tæthedsfunktion $f(x)$, så er sandsynligheden for at X ligger mellem a og b ($a \leq b$) givet ved


$$P(a \leq X \leq b) = \int_a^b f(x)dx$$

Sandsynligheden for at X ligger mellem a og b er således arealet under $f(x)$ fra a til b .

$$P(1 \leq X \leq 2) = \int_1^2 f(x)dx = \text{Areal}(\square)$$


$$P(4 \leq X \leq 5) = \int_4^5 f(x)dx = \text{Areal}(\blacksquare)$$

Dvs. $P(1 \leq X \leq 2) > P(4 \leq X \leq 5)$.



17/41

Fordelingsfunktionen: Egenskaber



Fordelingsfunktionen $F(x)$ har følgende egenskaber:

- $F(x)$ er en ikke-aftagende funktion
- $\lim_{x \rightarrow -\infty} F(x) = 0$
- $\lim_{x \rightarrow \infty} F(x) = 1$
- $F'(x) = f(x)$

Bemærk: entydig sammenhæng mellem f og F !

5

19/41


Fordelingsfunktionen

Definition: Fordelingsfunktion

Lad X være en stokastisk variabel med tæthedsfunktion $f(x)$. Da er fordelingsfunktionen $F(x)$ givet ved

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(t)dt.$$

Eksempel på tæthedsfunktion og tilhørende fordelingsfunktion:




18/41

Fordelingsfunktionen: Egenskaber

For en SV med fordelingsfunktion $F(x)$ har vi

$$P(a \leq X \leq b) = F(b) - F(a).$$



Sandsynligheden for at X tager værdien a er nul:

$$P(X = a) = P(a \leq X \leq a) = F(a) - F(a) = 0$$

“Mindre end” og “Mindre end eller lig” er derfor det samme:

$$P(a < X < b) = P(a < X \leq b) = P(a \leq X < b) = P(a \leq X \leq b)$$

20/41

Middelværdi - frekventiel definition

Fortolkning: Lad X_1, X_2, \dots repræsentere gentagne målinger af samme størrelse under ens betingelser.

Så svarer den fælles middelværdi $\mu = \mathbb{E}X_1 = \mathbb{E}X_2 = \dots$ til grænseværdien af det empiriske gennemsnit:

$$\frac{1}{n}(x_1 + x_2 + \dots + x_n) \rightarrow \mu \quad \text{når } n \rightarrow \infty$$

hvor x_1, x_2, \dots er udfald af X_1, X_2, \dots

Middelværdi og transformation af SV

Sætning: Middelværdi af generel transformation

Antag X er en SV med tæthedsfunktion $f(x)$. Lad $Y = h(X)$. Da er Y er SV med middelværdi

$$\mathbb{E}[Y] = \mathbb{E}[h(X)] = \int_{-\infty}^{\infty} h(x)f(x)dx$$

Typisk er integralet svært at udregne på nær når $h(x)$ er en lineær funktion af x .

Middelværdi - definition ud fra tæthed

Definition: Middelværdi

Lad X være en kontinuert stokastisk variabel med tæthedsfunktion f . **Middelværdien** af X defineres som

$$\mu = \mathbb{E}(X) = \int_{-\infty}^{\infty} xf(x)dx < \infty$$

- også kaldet forventet værdi (UK: \mathbb{E} xpectation).

Bemærk: $f(x)dx \approx P(x \leq X \leq x + dx)$.

Integralet kan opfattes som et vægtet gennemsnit af X 's udfald x med vægte $f(x)$ givet ved X 's tæthedsfunktion.

$$\int_{-\infty}^{\infty} xf(x)dx \approx \sum_{i=1}^k x_i f(x_i) \Delta \approx \sum_{i=1}^k x_i P(X \in]x_i, x_i + \Delta])$$

Middelværdi af lineær transformation

Sætning: Middelværdi af lineær transformation

Antag X er en SV med tæthedsfunktion $f(x)$ og middelværdi μ . Lad $Y = aX + b$. Da er Y en SV med middelværdi

$$\mathbb{E}[Y] = \mathbb{E}[aX + b] = a\mathbb{E}[X] + b = a\mu + b$$

Bevis:

$$\begin{aligned} \mathbb{E}[aX + b] &= \int_{-\infty}^{\infty} (ax + b)f(x)dx \\ &= a \int_{-\infty}^{\infty} xf(x)dx + b \int_{-\infty}^{\infty} f(x)dx \\ &= a\mathbb{E}[X] + b = a\mu + b. \end{aligned}$$

6

Eksempel: Telefonabonnement

Den månedlige samtale tid for en tilfældig abonnent hos TeleFlunk er i middel 83,2 minutter. Prisen pr. måned er 99kr/md + 0,10 kr/min.

Hvad er den månedlige udgift i middel?

Lad

- Lad X være den (tilfældige) månedlige samtale tid målt i minutter.
- Lad Y være den månedlige udgift, dvs. $Y = 99 + 0,1X$.

Middel-udgiften er

$$\begin{aligned} \mathbb{E}(Y) &= \mathbb{E}(99 + 0,1X) \\ &= 99 + 0,1\mathbb{E}(X) \\ &= 99 + 0,1 \cdot 83,2 \\ &= 107,32. \end{aligned}$$

Middel-udgiften er altså 107,32 kr.

Varians af en lineær transformation

Sætning: Varians af lineær transformation

Antag X er en SV med tæthedsfunktion $f(x)$, middelværdi μ og varians σ^2 . Lad $Y = aX + b$. Da er Y en SV med varians

$$\text{Var}[Y] = \text{Var}[aX + b] = a^2 \text{Var}[X] = a^2 \sigma^2.$$

Bevis:

$$\begin{aligned} \text{Var}[Y] &= \mathbb{E}[(Y - \mathbb{E}[Y])^2] \\ &= \mathbb{E}[(aX + b - (a\mu + b))^2] \\ &= \mathbb{E}[(a(X - \mu))^2] \\ &= a^2 \mathbb{E}[(X - \mu)^2] = a^2 \text{Var}[X] = a^2 \sigma^2 \end{aligned}$$

Bemærk at b ikke indgår.

Varians og spredning

Definition: Varians

Lad X være en kontinuert stokastisk variabel med tæthedsfunktion f . **Variansen** af X defineres som

$$\sigma^2 = \text{Var}(X) = \mathbb{E}[(X - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx < \infty,$$

hvor σ kaldes **spredningen** (eller **standardafvigelsen**) - mål for forventet variabilitet i X .

Variansen er den *forventede værdi af kvadratet på afvigelsen fra middelværdi* - dvs. hvis X ofte langt fra μ så er σ^2 stor !

Spredning/standardafvigelse:

$$\sigma = \sqrt{\text{Var}(X)}$$

Nyttig omskrivning af definition for varians:

$$\sigma^2 = \mathbb{E}(X^2) - \mu^2$$

Eksempel: Telefonabonnement

Standardafvigelsen for den månedlige samtale tid for en tilfældig abonnent hos TeleFlunk er 17,2 minutter.

Hvad er variansen for den månedlige udgift?

$$\begin{aligned} \text{Var}(Y) &= \text{Var}(99 + 0,1X) \\ &= 0,1^2 \text{Var}(X) \\ &= 0,1^2 \cdot 17,2^2 \\ &= 2,96. \end{aligned}$$

Variansen er altså 2,96 kr².

Standardafvigelsen for udgiften er $\sqrt{2,96 \text{ kr}^2} = 1,72 \text{ kr}$.


Varians vs. standardafvigelse

Fordele ved standardafvigelse: samme enhed for den stokastiske variabel og dens standardafvigelse (jf. foregående eksempel).

Standardafvigelse bekvemt mål for usikkerhed - f.eks. kan $\pm 2\sigma$ fortolkes som et 95% interval for en stokastisk variabel (vender tilbage til dette senere).

29/41

Normalfordelingen: Tre eksempler



31/41

Normalfordelingen

Definition: Normalfordelingen


En stokastisk variabel X med **tæthedsfunktion**

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right), \quad x \in \mathbb{R},$$

siges at være **normalfordelt** med middelværdi μ og varians σ^2 , hvor μ og σ er reelle tal og $\sigma > 0$.

Notation: $X \sim \mathcal{N}(\mu, \sigma^2)$.

Klokkeformet symmetrisk tæthedsfunktion.



30/41

Fordelingsfunktion for normalfordelingen

Der findes ikke et simpelt 'lukket' udtryk for fordelingsfunktionen.

Sandsynligheder udregnes vha. 'standardisering' og tabelopslag eller vha. `matlab` (senere).

32/41

Transformationer

Sætning: Lineær transformation

Antag $X \sim \mathcal{N}(\mu, \sigma^2)$, og $a, b \in \mathbb{R}$ og $a \neq 0$. Lad Y være en lineær transformation af X :

$$Y = aX + b.$$

Da gælder

$$Y \sim \mathcal{N}(a\mu + b, a^2\sigma^2).$$

Dvs. en lineær transformation af en normalfordelt SV er stadig normalfordelt.

Middelværdi og varians for Y følger af de generelle regler:

$$Y \text{ har middelværdi: } \mathbb{E}(Y) = \mathbb{E}(aX + b) = a\mathbb{E}(X) + b = a\mu + b$$

$$\text{og varians: } \text{Var}(Y) = \text{Var}(aX + b) = a^2\text{Var}(X) = a^2\sigma^2.$$

33/41

Standard-normalfordelingen

Definition: Standard-normalfordelingen

Fordelingen $\mathcal{N}(0,1)$ kaldes **standard-normalfordelingen**. Typisk noteres standard-normalfordelte variable Z .

Tæthedsfunktionen for $\mathcal{N}(0,1)$ er givet ved:

$$f(z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}z^2\right)$$

Den tilhørende fordelingsfunktion betegnes $\Phi(z)$:

$$\text{Dvs } F(z) = \Phi(z) \text{ når } \mu = 0 \text{ og } \sigma = 1.$$

Der findes ikke et 'lukket' udtryk for fordelingsfunktionen $\Phi(z)$.

35/41

Tilfældig fejl

Definition: Tilfældig fejl

Antag vi vil måle en længde. Den sande længde betegnes μ . Lad X være en SV, der repræsenterer målingen af længden μ . Vi har

$$X = \mu + \epsilon,$$

hvor ϵ er en *tilfældig fejl*.

Dvs. målingen er den sande længde plus en tilfældig fejl.

Vi antager ofte

$$\epsilon \sim \mathcal{N}(0, \sigma^2).$$

Dvs. den tilfældige fejl er normalfordelt og i middel er fejlen nul.

Det følger, at

$$X \sim \mathcal{N}(\mu, \sigma^2).$$

34/41

Standardisering

Vi kan **standardisere** en hvilken som helst normalfordelt SV X til at være standard-normalfordelt:

Sætning: Standardisering

Hvis $X \sim \mathcal{N}(\mu, \sigma^2)$, så gælder

$$Z = \frac{X - \mu}{\sigma} \sim \mathcal{N}(0, 1).$$

Middelværdi og varians beregnes vha. foregående sætninger:

$$\mathbb{E}\left(\frac{X - \mu}{\sigma}\right) = \mathbb{E}\left(\frac{X}{\sigma} - \frac{\mu}{\sigma}\right) = \frac{\mathbb{E}(X)}{\sigma} - \frac{\mu}{\sigma} = \frac{\mu - \mu}{\sigma} = 0$$

$$\text{Var}\left(\frac{X - \mu}{\sigma}\right) = \text{Var}\left(\frac{X}{\sigma} - \frac{\mu}{\sigma}\right) = \frac{\text{Var}(X)}{\sigma^2} = \frac{\sigma^2}{\sigma^2} = 1$$

9

36/41

Hvis $X \sim \mathcal{N}(\mu, \sigma^2)$ gælder

$$P(X \leq x) = P\left(\frac{X - \mu}{\sigma} \leq \frac{x - \mu}{\sigma}\right) = P\left(Z \leq \frac{x - \mu}{\sigma}\right) = \Phi\left(\frac{x - \mu}{\sigma}\right).$$

Dvs. for X med vilkårlig middelværdi og varians kan vi finde sandsynligheder vha. tabel for standardnormalfordelingen.

Nu om dage benyttes dog typisk i praksis et computer program - f.eks. `matlab`.

37/41

Inverse fordelingsfunktion

Den inverse fordelingsfunktion Φ^{-1} går den "modsatte vej" af Φ . Dvs. hvis $\Phi(1.4) = 0.8849303$, så er $\Phi^{-1}(0.8849303) = 1.4$.

1.4 er 0.8849303 *fraktilen* for standardnormalfordelingen.

Inverse fordelingsfunktion $\Phi^{-1}(p)$ i `matlab`:

```
>> norminv(0.8849303)
ans =
    1.4
```

Eksempel:

Antag $Z \sim \mathcal{N}(0,1)$. Find konstant z , så $P(Z \leq z) = 0,8$.

Løsning:

$$P(Z \leq z) = \Phi(z) = 0,8 \Leftrightarrow z = \Phi^{-1}(0,8) = 0.8416$$

```
>> norminv(0.8)
ans =
    0.8416212
```

39/41

Eksempel

Lad $X \sim \mathcal{N}(3,4)$, så er

$$Z = \frac{X - 3}{\sqrt{4}} \sim \mathcal{N}(0, 1).$$

Udregning af $P(X \leq 5)$ i `Matlab`:

```
>> normcdf(5,3,sqrt(4))
ans =
    0.8413
```

38/41

Opsummering: sandsynligheder og fraktiler for normalfordeling

Antag $X \sim \mathcal{N}(\mu, \sigma^2)$.

$p = P(X \leq x) = F(x)$ kan udregnes enten vha. omformning til standardnormalfordeling og tabel eller direkte vha. f.eks. `matlab` (eller Excel eller...).

For et givet $0 \leq p \leq 1$ kaldes

$$x_p = F^{-1}(p)$$

for p -*fraktilen*. Dvs. x_p opfylder $P(X \leq x_p) = p$.

Kan også udregnes vha. standardnormalfordeling (og baglæns opslag i tabel) eller `matlab`.

10

40/41

Eksempel $X \sim N(-2,3)$.

Beregn $P(X \leq -2.908288)$ samt $x_{0.3}$:

```
>> normcdf(-2.908288,-2,sqrt(3))
ans =
    0.3
>> norminv(0.3,-2,sqrt(3))
ans =
   -2.908288
```