



Egenskaber ved normalfordelingen

Claus Ekstrøm


E-mail: ekstrom@life.ku.dk




Hvorfor skal vi lære om normalfordelingen (nu)?

Har set tre typer af data/eksperimenter med kontinuerte data:

Ensidet ANOVA



Lineær regression



En stikprøve:

Blood pressure								
96	119	119	108	126	128	110	105	94

Vi skal bruge normalfordelingen for alle tre forsøgstyper/datatyper!



Program

- Repetition fra i mandags
- Er data normalfordelt?
- Egenskaber ved normalfordelingen (jf. opgave 4.3 fra mandag)
- Standard normalfordelingen
- Diverse normalfordelingssandsynligheder

Afsnit 4.3.2 om transformation: læs selv ifm. case.



Hvorfor netop normalfordelingen?

Normalfordelingen er vigtig af flere grunde

- Passer ofte godt til (biologiske) data
- Pæne matematiske egenskaber — får pæne resultater for estimerer, statistiske test mm.
- Centrale grænseværdisætning (CLT): gennemsnit af næsten hvad som helst er approksimativt normalfordelt?

Kaldes også den Gaussiske fordeling.

Opkaldt efter Carl Friedrich Gauss — tysk matematiker og fysiker, 1777–1855.





Gauss



Er data normalfordelt?

Vægt af 162 krabber: y_1, \dots, y_{162} . Tidligere: $\bar{y} = 12.76$ og $s = 2.25$.




- Histogram sammen med tæthed for $N(\bar{y}, s^2)$
- QQ-plot: quantile-quantile plot. **Sammenlign med ret linie med skæring \bar{y} og hældning σ .** R: `qqnorm(wgt); qqline(wgt)/abline`

Tæthed og sandsynligheder

Tæthed for normalfordelingen med middelværdi μ og spredning σ :

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



$Y \sim N(\mu, \sigma^2)$ hvis
sandsynligheden for at Y havner
mellem a og b er lig areal fra a til
 b under tætheden

$$P(a < Y < b) = \int_a^b f(y) dy$$



Egenskaber ved normalfordelingen — simulation

- Histogrammer og QQ-plots
- $Y \sim N(\mu, \sigma^2)$: middelværdi $EY = \mu$, spredning $sd(Y) = \sigma$
- $Y_1 \sim N(\mu_1, \sigma_1^2)$ og $Y_2 \sim N(\mu_2, \sigma_2^2) \Rightarrow Y_1 + Y_2 \sim$
Specielt $sd(Y_1 + Y_2) =$
- $Y \sim N(\mu, \sigma^2) \Rightarrow a + b \cdot Y \sim$
Specielt $sd(a + b \cdot Y) =$
- $Z = \frac{Y-\mu}{\sigma} \sim$
- $P(\mu - \sigma < Y < \mu + \sigma) =$
 $P(\mu - 2\sigma < Y < \mu + 2\sigma) =$





Egenskaber ved normalfordelingen — simulation

	Normal?	\bar{y}	s	s^2
y1				
y2				
$z=y1+y2$				
$v=4+2*y1$				
$u=(y2-8)/2$				



Slide 9— Statistisk Dataanalyse 1 (Uge 2-2 2010) — Normalfordelingen

Standard normalfordelingen



- 95%-fraktilen er **1.6449**: $\Phi(1.6449) = P(Z \leq 1.6449) = 0.95$
 $P(-1.6449 \leq Z \leq 1.6449) =$
- 97.5%-fraktilen er **1.960**: $\Phi(1.960) = P(Z \leq 1.960) = 0.975$
 $P(-1.96 \leq Z \leq 1.96) =$



Slide 11— Statistisk Dataanalyse 1 (Uge 2-2 2010) — Normalfordelingen

Standard normalfordelingen

Hvis $Y \sim N(\mu, \sigma^2)$, så er $Z = \frac{Y-\mu}{\sigma} \sim N(0, 1)$ — **standard N-fordelingen**.

Sandsynligheder om $N(\mu, \sigma^2)$ kan omskrives til sandsynligheder om $N(0, 1)$. For eksempel

$$P(Y \leq a) = P\left(\frac{Y-\mu}{\sigma} \leq \frac{a-\mu}{\sigma}\right) = P\left(Z \leq \frac{a-\mu}{\sigma}\right) = \Phi\left(\frac{a-\mu}{\sigma}\right)$$

Tæthed for $N(0, 1)$:

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

Fordelingsfunktion — “areal til venstre for z ”:

$$\Phi(z) = P(Z \leq z) = \int_{-\infty}^z \phi(x) dx$$



Slide 10— Statistisk Dataanalyse 1 (Uge 2-2 2010) — Normalfordelingen

Standard normalfordelingen

Intet eksplisit udtryk for Φ , men Φ er tabelleret i statistiske tabeller.

I R:

- fordelingsfunktion: **pnorm**, fx.
 $> pnorm(1.6449)$
 $[1] 0.9500048$
- Fraktiler: **qnorm**, fx.
 $> qnorm(0.975)$
 $[1] 1.959964$

Tabel: Appendix C2, p. 400 i bogen.



Slide 12— Statistisk Dataanalyse 1 (Uge 2-2 2010) — Normalfordelingen

N-sandsynligheder

Krabbedata: antag at krabbeveigt $Y \sim N(12.76, 2.25^2)$

Beregn sandsynligheden for at

- en tilfældigt udtaget krabbe vejer højst 14 gram?
- en tilfældigt udtaget krabbe vejer mindst 10 gram?
- en tilfældigt udtaget krabbe vejer mellem 10 og 14 gram?
- summen af to tilfældigt udvalgte krabber vejer mindst 26 gram?

```
> pnorm(1.227)          > pnorm(0.5511)
[1] 0.8900887           [1] 0.7092174
> pnorm(-1.227)         > pnorm(-0.5511)
[1] 0.1099113            [1] 0.2907826
```




Dagens hovedpunkter

- Er data normalfordelt?
 - Sammenlign histogram med tæthed for $N(\bar{y}, s^2)$.
 - Sammenlign QQ-plot med ret line
- Summer af normalfordelte variable er normalfordelt
- Lineær transformation af normalfordelt variabel er normalfordelt
- Standard normalfordelingen, $N(0,1)$
 - $Z = \frac{Y-\mu}{\sigma} \sim N(0,1)$
 - Fraktiler og sandsynligheder for $N(0,1)$
 - Alle N -sandsynligheder kan beregnes vha. $N(0,1)$
- Sandsynligheder for $\mu \pm \sigma$, $\mu \pm 2 \cdot \sigma$, osv.



Sandsynligheder for $\mu \pm k \cdot \sigma$



$$P(\mu - \sigma < Y < \mu + \sigma)$$

$$= P\left(\frac{\mu - \sigma - \mu}{\sigma} < Z < \frac{\mu + \sigma - \mu}{\sigma}\right)$$

$$= P(-1 < Z < 1)$$

$$= 0.68$$

- 68% mest centrale obs. ligger i intervallet $\mu \pm \sigma$
- 95% mest centrale obs. ligger i intervallet $\mu \pm 2 \cdot \sigma$

Dette gælder for alle normalfordelinger!



Ordliste

Engelsk

Central limit theorem (CLT)
cumulative distribution function (cdf)
density
drawn at random
Gaussian distribution
mean
quantile
sample
standard deviation

Dansk

centrale grænseværdisætning
fordelingsfunktion
tæthed
tilvældigt udvalgt
normalfordelingen
gennemsnit el. middelværdi
fraktil
stikprøve
spredning

