

# Sandsynlighedsregning

## 5. forelæsning

Bo Friis Nielsen



Matematik og Computer Science  
Danmarks Tekniske Universitet  
2800 Kgs. Lyngby – Danmark  
Email: bfn@dtu.dk

### Poisson-fordelingen

En binomialfordelingen med mange forsøg, hvert med lille sandsynlighed.



$n$  stor  
 $p$  lille  
 $np$  moderat.



### Dagens emner afsnit 3.5 og 4.1

Poissonfordelingen



$$P(X = x) = \frac{\mu^x}{x!} e^{-\mu}, \quad E(X) = \mu, \quad \text{Var}(X) = \mu$$

- Kontinuerte stokastiske variable
  - ◇ Tæthed (density):  $f(x) \geq 0$ ,  $\int f(x)dx = 1$ ,  
 $P(X \in dx) = f(x)dx$ ,  $P(a < X \leq b) = \int_a^b f(x)dx$
  - ◇ Middelværdi, varians (momenter):  $E(X) = \int x f(x)dx$   
 $E(g(X)) = \int g(x) f(x)dx$ ,  $E(X^k) = \int x^k f(x)dx$ ,
- Normalfordelingen:  $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}(\frac{x-\mu}{\sigma})^2}$   $Z = \frac{X-\mu}{\sigma}$ 
  - ◇ Den centrale grænseværdisætning
- Standardisering  $Z = \frac{X-E(X)}{SD(X)}$ ,  $E(Z) = 0$ ,  $SD(Z) = 1$

### Eksempler på Poissonfordelte variable (?)



- Antal børn født i et kalenderår i Danmark med en given sjælden sygdom.
- Antal radioaktive henfald i en prøve indenfor et bestemt tidsrum.
- Antal komponenter i en batch der er defekte.

## Sandsynlighedsfordelingen for $X \sim \text{Pois}(\mu)$



$$P(X = x) = \frac{\mu^x}{x!} e^{-\mu}$$

kan findes som grænsen af  $\text{Bin}(n, \mu/n)$  for  $n \rightarrow \infty$

## Momenter i Poisson-fordelingen

Vi får middelværdi:


$$E(X) = \mu \quad \text{og varians:}$$

$$\text{Var}(X) = E(X^2) - E(X)^2 = E(X^2) - \mu^2 = \mu$$

Eller

$$\text{Var}(X) = E(X(X-1)) + E(X) - \mu^2 = \mu$$

## Poisson punktprocessen (scatter)



## Antagelser (p. 229)



Antagelse 1: Ikke multiple forekomster, hvert punkt eller forekomst har særskilt placering

Antagelse 2: Tilfældighed. Alle disjunkte delområder med samme areal bliver "ramt" med samme sandsynlighed og uafhængigt af hinanden.

"Poisson Scatter Theorem" (p. 230):

Punktprocessen har en intensitet (tæthed)  $\lambda$  så:

Antallet af forekomster i et område  $B$  er  $\sim \text{Pois}(\lambda|B|)$

Antallet af forekomster i disjunkte områder er uafhængige.

## Overvejning



Hvis to Poisson-punktprocesser overlejres, er resultatet en ny Poisson punktprocess. Intensiteten i den nye process er summen af intensiteterne i de to komponenter.

## Udtynding

Hvis hvert punkt fjernes fra en Poisson-punktproces med sandsynlighed  $1 - p$  (bibeholdes med sandsynlighed  $p$ ), er resultatet en ny Poisson-punktproces med intensitet  $p \cdot \lambda$ .

## Middelværdi for Poissonfordeling



$$E(X) = \sum_x x f(x) = \sum_x x P(X = x) = \sum_{x=0}^{\infty} x \frac{\mu^x}{x!} e^{-\mu}$$

- Lidt manipulation med summen giver

$$\begin{aligned} \sum_{x=0}^{\infty} x \frac{\mu^x}{x!} e^{-\mu} &= \sum_{x=1}^{\infty} \frac{\mu^x}{(x-1)!} e^{-\mu} = \mu e^{-\mu} \sum_{x=1}^{\infty} \frac{\mu^{x-1}}{(x-1)!} \\ &= \mu e^{-\mu} \sum_{y=0}^{\infty} \frac{\mu^y}{y!} = \mu e^{-\mu} e^{\mu} = \mu \end{aligned}$$

Samme fremgangsmåde for  $E(X(X-1))$  giver os  $\text{Var}(X) = \mu$

## Beregning i ligefordelingen



Spm: For  $a < x < y < b$  find  $P(x < X < y)$

Svar:

$$P(x < X < y) = \frac{y-x}{b-a} = c(y-x) = \int_x^y f(u) du$$

Sandsynligheden er altså den del af intervallet fra  $a$  til  $b$ , der udgøres af intervallet fra  $x$  til  $y$ .


Vi kan udtrykke dette som integralet af en normeringskonstant over et delinterval.

## Ligefordelingen (uniform) side 264-265



- Vi ankommer til et busstoppested et øde sted. Vi ved, at der er en time mellem busserne, men kender ikke køreplanen og ved ikke, hvad klokken er.
- Vi vil gerne vide, hvad risikoen er for, at vi skal vente mindst tre kvarter.
- Hvordan kunne vi gribe det an?

## Tætheden $f(x)$ af en kontinuert S.V.



Sandsynligheder findes som arealet under kurven (s. 260)

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

NB! Sammenfatning s. 262-263

En funktion  $f(t)$  er en tæthed hvis

- $f(t) \geq 0$  for alle  $t$
- $f$  er normeret, d.v.s.

$$P(-\infty < X < +\infty) = \int_{-\infty}^{\infty} f(t) dt = 1$$

## Ligefordelingen



$$f(x) = \begin{cases} c & \text{hvis } a < x < b \\ 0 & \text{ellers} \end{cases}$$

Hvad er så  $c$ ?

$$\begin{aligned} 1 &= \int_{-\infty}^{\infty} f(x) dx \\ &= \int_{-\infty}^a f(x) dx + \int_a^b f(x) dx + \int_b^{\infty} f(x) dx = 0 + (b-a) \cdot c + 0 \\ c &= \frac{1}{b-a} \end{aligned}$$

Antag at  $X$  er en stokastisk variabel med tæthed

$$f(x) = \begin{cases} c & \text{hvis } a < x < b \\ 0 & \text{ellers} \end{cases}.$$

### Spørgsmål 1

Lad  $U = (X - a)/(b - a)$ . Værdimængden for  $U$  er


- 1  (0; 1)
- 2  (0;  $b/(b-a)$ )
- 3   $(-\infty; \infty)$
- 4   $(a/(b-a); b/(b-a))$
- 5  Oplysningerne i teksten er ikke tilstrækkelige
- 6  Ved ikke

## Tætheder fortolket som sandsynligheder



For en kontinuert stokastisk variabel er alle punktsandsynligheder 0.

Sandsynligheden for at observere en observation i en omegn  $h$  af  $x$  findes som  $hf(x)$ .



## Middelværdi og varians (side 261)



Generelt erstattes beregninger af summer (for diskrete variable) med integraler (for kontinuerte variable)

Eksempelvis

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx \quad E(X^2) = \int_{-\infty}^{\infty} x^2 \cdot f(x) dx$$

Vi har stadig den meget vigtige beregningsformel

$$\text{Var}(X) = E(X^2) - (E(X))^2$$

## Normalisering/standardisering



$$U = \frac{X - a}{b - a} \Leftrightarrow X = a + (b - a)U$$

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} xf(x)dx = \int_a^b xf(x)dx \\ &= \frac{1}{2} \left[ \frac{x^2}{b-a} \right]_a^b = \frac{a+b}{2} \end{aligned}$$

Alternativt

$$E(X) = E(a + (b - a)U) = E(a) + (b - a)E(U) = a + (b - a)\frac{1}{2}$$

Antag at  $X$  er en stokastisk variabel med tæthed  $f(x) = cx(1 + x)$  for  $-1 < x < 0$ , og 0 ellers.

### Spørgsmål 2

Værdien af  $c$  er

- 1  -6
- 2  1
- 3  2
- 4  6
- 5   $f(x)$  kan ikke være en tæthed
- 6  Ved ikke

## Variansberegning



$$\text{Var}(X) = \text{Var}(a + (b - a)U) = (b - a)^2 \text{Var}(U)$$

$$\text{Var}(X) = (b - a)^2 (E(U^2) - (E(U))^2)$$

$$E(U^2) = \int_0^1 u^2 du = \frac{1}{3}$$

$$\text{Var}(X) = (b - a)^2 \left( \frac{1}{3} - \left( \frac{1}{2} \right)^2 \right) = \frac{(b - a)^2}{12}$$

## Opgave 4.1.3 (modificeret)



Lad  $X$  være en stokastisk variabel med tæthed  $f(x) = cx(1 + x)$  for  $-1 < x < 0$ , og 0 ellers.

*Spm:* Find værdien af  $c$ .


*Svar:* Vi kræver

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$

... og finder

$$\int_{-1}^0 cx(1 + x) dx = -\frac{c}{6}$$


altså  $c = -6$ .




Spm: Bestem værdien af  $P(X \leq -\frac{1}{2})$

Svar: Da fordelingen er symmetrisk om  $-\frac{1}{2}$  får vi

$$P\left(X \leq -\frac{1}{2}\right) = \frac{1}{2}$$



Spm: Bestem værdien af  $P(X \leq -\frac{2}{3})$



Svar:

Vi benytter sammenhængen mellem tæthed og sandsynlighed side 260 eller side 263

$$P\left(X \leq -\frac{2}{3}\right) = \int_{-1}^{-\frac{2}{3}} cx(1+x)dx = c \left[ \frac{1}{2}x^2 + \frac{1}{3}x^3 \right]_{x=-1}^{x=-\frac{2}{3}}$$


Med  $c = -6$  får vi

$$P\left(X \leq -\frac{2}{3}\right) = \frac{7}{27}$$

Spm: Hvad er  $P(-\frac{2}{3} \leq X \leq -\frac{1}{2})$

Svar:

$$P\left(-\frac{2}{3} \leq X \leq -\frac{1}{2}\right) = \frac{1}{2} - \frac{7}{27} = \frac{13}{54}$$



Spm: Hvad er middelværdi og varians af  $X$ ?



Svar: Middelværdien er  $-\frac{1}{2}$  ud fra symmetrien.

Vi finder  $E(X^2)$

$$E(X^2) = -6 \int_{-1}^0 x^2 \cdot x(1+x) dx = \frac{6}{20}$$

...og dermed

$$\text{Var}(X) = \frac{6}{20} - \frac{1}{4} = \frac{1}{20}$$

## Den centrale grænseværdisætning side 268, (196)



- I naturen/teknikken observeres ofte en "klokkeformet" fordeling
- Dette understøttes teoretisk netop af CGS
- En sum af mange bidrag er (tilnærmelsesvist) normal fordelt når intet enkeltbidrag "dominerer" summen
- Formen (formlen!) for normalfordelingen fremkommer netop gennem udledningen - beviset - for CGS

## En række generiske modeller



- Forskellige ingeniørtekniske problemstillinger:
  - ◊ Hvor mange ulykker sker der i et vejkryds
  - ◊ Tidsafstanden mellem to pakker i et kommunikationsnetværk
  - ◊ Vægt/mængde angivelse af et kemisk produkt
  - ◊ Antal positive respondenter i en markedsanalyse
- og varianter heraf

## Normalfordeling - udtryk og egenskaber side 266-267, 477, 484-485



Hvis  $X \sim N(\mu, \sigma^2)$ , så:


$X$  har tætheden

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

$$\text{Middelværdi} \quad E(X) = \mu$$

$$\text{Varians} \quad \text{Var}(X) = \sigma^2$$

$$\text{Spredning} \quad SD(X) = \sigma$$



For  $\mu = 0$  og  $\sigma^2 = 1$  bruger vi  $f(x) = \phi(x)$

## Den standardiserede normalfordeling



$$X \sim N(\mu, \sigma^2) : P(a < X < b) = \int_a^b \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} dx$$

De normalfordelte variable bevarer under affine transformationer:

$$c_1X + c_2 \sim N(c_1\mu + c_2, c_1^2\sigma^2)$$

Vi kan *standardisere*  $X$ :

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

$$P(Z \leq z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt = \Phi(z)$$

## Opgave 4.1.8



Vægtmålinger af en metalklump formodes at være uafhængige og identisk fordelte (I.I.D.), med middelværdien af 12 gram og standardafvigelse 1.1 gram.

*Spørgsmål:*

Hvad er sandsynligheden for at en enkelt måling er mellem 11.8 og 12.2 gram under antagelse af, at de enkelte målinger kan beskrives ved en normalfordeling?

Vi betragter en stokastisk variabel  $X$ , der er standard normal fordelt.



### Spørgsmål 3

Sandsynligheden  $P(0 < X < 0.001)$  findes (eventuelt approksimativt) til

- 1  0.001
- 2   $\Phi(0.01) - \frac{1}{2}$
- 3   $\frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}0.001^2}$
- 4   $\Phi(0)$
- 5   $\frac{0.001}{\sqrt{2\pi}}$
- 6  Ved ikke

Hvor  $\Phi$  som sædvanlig betegner fordelingsfunktionen for en standardiseret normalfordelt variabel.

*Svar:*



Lad  $W$  betegne vægten på en måling.  $W \in normal(12, 1.1^2)$

Spørgsmålet kan nu formuleres: Bestem  $P(11.8 < W < 12.2)$ .

Transformér til standardiseret normalfordeling:

$$\begin{aligned} P(11.8 < W < 12.2) &= P(11.8 - 12 < W - 12 < 12.2 - 12) \\ &= P\left(\frac{11.8 - 12}{1.1} < \frac{W - 12}{1.1} < \frac{12.2 - 12}{1.1}\right) \\ &= \Phi(0.1818) - \Phi(-0.1818) = 2 \cdot 0.0714 = 0.1428 \end{aligned}$$



Spørgsmål:



Beregn sandsynligheden for at gennemsnittet af 100 målinger ligger i intervallet [11.8 gram;12.2 gram]

(er normalfordelingsantagelsen nødvendig her?)

Svar:

Lad  $W_i$  betegne resultatet af den  $i$ 'te måling.

Lad  $\bar{W}$  være gennemsnittet  $\bar{W} = \frac{\sum_{i=1}^{100} W_i}{100}$

Spørgsmålet er altså:

$$P(11.8 < \bar{W} < 12.2)$$

Ifølge C.G.S. (s. 196) er  $\bar{W}$  approksimativt normalfordelt

Sum $S = \sum_{i=1}^n W_i$ : $S \sim N(n\mu, n\sigma^2)$	Gennemsnit $\bar{W} = S/n$ : $\bar{W} \sim N\left(\mu, \frac{1}{n}\sigma^2\right)$
---	---

Standardisér: Indfør



$$Z = \frac{\bar{W} - \mu}{\frac{\sigma}{\sqrt{n}}} = \sqrt{n} \frac{\bar{W} - \mu}{\sigma} \sim N(0, 1)$$

Omformulér spørgsmålet til at gælde  $Z$ :

$$P(a < \bar{W} < b) = P\left(\sqrt{n} \frac{a - \mu}{\sigma} < \sqrt{n} \frac{\bar{W} - \mu}{\sigma} < \sqrt{n} \frac{b - \mu}{\sigma}\right)$$

$$= P\left(\sqrt{n} \frac{a - \mu}{\sigma} < Z < \sqrt{n} \frac{b - \mu}{\sigma}\right) = \Phi\left(\sqrt{n} \frac{b - \mu}{\sigma}\right) - \Phi\left(\sqrt{n} \frac{a - \mu}{\sigma}\right)$$

Vi finder

$$P(11.8 < \bar{W} < 12.2) = P(-1.818 < Z < 1.818) = 0.9312$$



### Afsnit 3.5 og 4.1

#### Poissonfordelingen



$$P(X = x) = \frac{\mu^x}{x!} e^{-\mu}, \quad E(X) = \mu, \quad \text{Var}(X) = \mu$$

- Kontinuerte stokastiske variable
  - ◊ Tæthed (density):  $f(x) \geq 0, \int f(x)dx = 1, P(X \in dx) = f(x)dx, P(a < X \leq b) = \int_a^b f(x)dx$
  - ◊ Middelværdi, varians (momenter):  $E(X) = \int x f(x)dx, E(g(X)) = \int g(x) f(x)dx, E(X^k) = \int x^k f(x)dx,$
- Normalfordelingen:  $f(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} \quad Z = \frac{X-\mu}{\sigma}$ 
  - ◊ Den centrale grænseværdisætning
- Standardisering  $Z = \frac{X-E(X)}{SD(X)}, E(Z) = 0, SD(Z) = 1$

## Fra binomialfordelingen til Poissonfordelingen

$$\begin{aligned} X &\sim \text{Bin}(n, p), \quad P(X = x) = \binom{n}{x} p^x (1-p)^{n-x} \\ &= \frac{(np)^x}{x!} \frac{n!}{n^x (n-x)!} (1-p)^n (1-p)^{-x} \\ &= \frac{(np)^x}{x!} (1-p)^n (1-p)^{-x} \prod_{k=0}^{x-1} \frac{n-k}{n} \\ &= \frac{(np)^x}{x!} \left(1 - \frac{np}{n}\right)^n (1-p)^{-x} \prod_{k=0}^{x-1} \left(1 - \frac{k}{n}\right) \rightarrow \frac{\mu^x}{x!} e^{-\mu}, \quad \mu = np \end{aligned}$$