

Matematisk Statistik 2015

ANTECKNINGAR: ANTON ÄLGMYR

FÖRELÄSARE OCH EXAMINATOR: OLLE NERMAN

Innehållsförteckning

1 Föreläsning 1	1
1.1 Utfall och händelser	1
Exempel	1
1.2 DeMorgans lagar	2
1.3 Lag kring komplement	2
1.4 Likformiga sannolikheter	2
1.4.1 Tärningsexempel	3
1.5 Icke-likformiga sannolikheter	3
Falsk tärning	3
Generellt	3
1.6 Disjunkta mängder	3
1.6.1 Generellt	3
1.7 Räknelagar	4
2 Föreläsning 2	5
2.1 Mer om klassisk sannolikhetsdef.	5
2.2 Multiplikationsprincipen	5
Exempel	5
Exempel	5
Exempel	5
2.3 Case study — Poker	6
2.3.1 “Färg (flush)”	6
2.3.2 “Två par”	6
2.4 Betingade sannolikheter	7
2.4.1 Kast av en blå och en röd tärning	7
3 Föreläsning 3	9
3.1 Betingade sannolikheter vid disjunkta händelser	9
3.1.1 Två händelser	9
Exempel	9
Exempel	9
3.1.2 Tre händelser	10
3.1.3 Generellt	10
3.2 Stokastiska variabler	10
Exempel	10
Exempel	11
3.2.1 Bernoullifördelning	11
Exempel	11
3.2.2 Binomialfördelning	11
3.3 Kontinuerlig stokastisk fördelning	12
3.4 (Kumulerad) fördelningsfunktion	12
3.5 Oberoende försöksupprepningar	13
3.5.1 Geometrisk fördelning	13
3.5.2 Negativ binomialfördelning	13
4 Föreläsning 4	14
4.1 Endimensionella diskreta SV	14

Exempel	14
Repetition	15
Exempel – plocka utan återläggning	15
Binomialfördelning	15
Användning för ovanstående slutsats?	16
4.2 Reella SV	16
4.2.1 Likformig fördelning	16
4.2.2 Exponentiell fördelning	17
Γ -fördelning(α, λ)	17
5 Föreläsning 5	18
5.1 Normalfördelning(μ, σ^2) = $N(\mu, \sigma^2)$	18
$N(0,1)$:	18
5.1.1 p -fraktile — även quantile, fractile och percentiler	18
5.1.2 Generell normalfördelning från $N(0, 1)$	19
Not kring kontinuerliga och diskreta fördelningar	19
5.2 Två och n -dimensionella SV	19
Definition	20
5.2.1 (X, Y) tvådimensionell kontinuerlig SV	20
Exempel	20
Matematiken bakom	20
6 Föreläsning 6	21
6.1 Tvådimensionell SV	21
6.1.1 Oberoende	21
6.1.2 Fördelning för $X + Y$?	21
Exempel	22
För heltal	22
Rekursiv intuition	22
6.2 Teoretisk median	23
6.2.1 Väntevärdet $\mu = E[X]$	23
Exempel	23
Exempel	24
Sats	24
Exempel	24
Markovs olikhet	25
6.2.2 Varians	25
6.2.3 Standardavvikelse	25
Not	25
7 Föreläsning 7	26
7.1 Mått för stokastiska variabler?	26
7.1.1 Väntevärden och varians	26
Sats	26
Sats	26
Följdsats – Summa för SV	26
“Steiners sats”	26
Från förra gången	26
Sats	27
Bevis	27
Följdsats	27
Bevis	27

Generalisering	27
7.1.2 Kovarians	27
Specialfall	27
7.2 Mått för specifika fördelningar	27
En likformig fördelning	27
Väntevärde	28
Varians	28
Standardavvikelse	28
7.2.1 Normalfördelning	28
Väntevärde	28
Varians	28
Standardavvikelse	28
7.2.2 Exponentialfördelning	29
Väntevärde	29
Varians	29
Standardavvikelse	29
7.2.3 Γ -fördelning	29
Väntevärde	29
Varians	29
Standardavvikelse	29
Medelvärden	29
7.2.4 Poissonfördelning	29
Väntevärde	30
Varians	30
Standardavvikelser	30
7.2.5 Binomialfördelning	30
Väntevärde	30
Varians	30
7.2.6 Multinomialfördelning	30
Kovarians	30
8 Föreläsning 8	31
8.1 Repetition	31
8.2 Momentgenererande funktioner	31
Exempel	32
Sats	32
Sista minutens svammel TM	33
8.3 Stora talens lag	33
8.3.1 Repetition	33
8.3.2 Stora talens lag	33
Sats	33
Bevis	33
Specialfall	34
8.3.3 Centrala gränsvärdessatsen	34
Sats	34
Handviftande bevis	34
9 Föreläsning 9	36
9.1 Repetition	36
9.1.1 Halvtalskorrektion	36
9.2 Poissonprocesser	37
9.2.1 Beteckningskrock	37

9.2.2	Not	37
9.3	Simuleringar	38
9.3.1	Monte Carlo – simuleringar	39
10	Föreläsning 10	40
10.1	χ^2 -fördelning	40
10.2	Student's t -fördelning	40
	Påstående	40
	Bevis	40
10.3	Skattade standardfel	41
10.4	Momentmetoden	42
	Exempel	42
11	Föreläsning 11	43
11.1	ML-skattningar av μ och σ^2 i normalfördelade stickprov	43
	Exempel	43
11.2	Filosofidags	44
11.2.1	Enstickprovsmodeller	44
	Ordnat stickprov	44
	Om vi känt till fördelningen	44
	Empirisk fördelning	45
11.3	Bayesk statistik	45
	Tvåsidigt konfidensintervall	46
12	Föreläsning 12	47
12.1	Repetition för konfidensintervall	47
	Exempel	47
	Exempel	48
	Exempel	48
	Exempel	48
	Exempel	49
12.2	Hypotestester	50
12.2.1	Exempel	50
12.3	Tvästickprov	51
13	Föreläsning 13	52
13.1	Enstickprov	52
	Exempel	52
	Exempel – Test av medianer	52
13.2	Tvästickprov	53
13.3	Tvästickprovs t -test (samma modell)	54
	Exempel (tvåsidig mothypotes)	54
	Exempel	55
14	Föreläsning 14	56
14.1	Linjär regression	56
	Sats	57
14.2	Pivoter för konfidensintervall	58
	Exempel	58
14.3	Tvådimensionell normalfördelning	59
15	Föreläsning 15	60
15.1	Tentan från 27 Augusti 2014	60

15.1.1	1.	60
15.1.2	2.	60
15.1.3	3.	60
15.1.4	4.	61
15.1.5	5.	61
15.1.6	6.	62
15.1.7	7.	62
15.1.8	8.	62
15.1.9	9.	62

1 Föreläsning 1

23 mars 2015

1.1 Utfall och händelser

Kastar en tärning.

Utfallsrum: $\Omega = \{1, 2, 3, 4, 5, 6\}$
mängd av alla möjliga utfall

Likformig (klassisk) sannolikhetsfördelning: ändligt många utfall med samma sannolikhet.

En händelse $A \subseteq \Omega$. Var noga med beteckningar i extremfall.

Exempel $A =$ utfallet udda poäng $= \{1, 3, 5\}$


$B =$ poängtal mindre än $3 = \{1, 2\}$
 <3

$C =$ poängtal högst $3 = \{1, 2, 3\}$
 ≤ 3

Våra språkliga uttryck kan (ibland tvetydigt) översättas


$$\begin{aligned} A \text{ och } B &\iff A \cap B \\ A \text{ eller } B &\iff A \cup B \\ A \text{ eller } B \text{ } \rightarrow \text{ } A \text{ och eller } B, \text{ men inte båda} &\iff A \Delta B \end{aligned}$$

$$A \Delta B = (A \setminus B) \cup (B \setminus A)$$



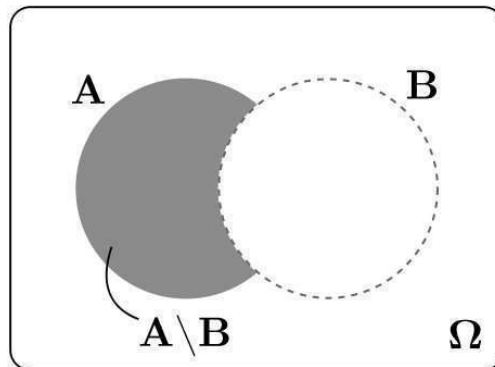
Figur. Venn-diagram illustrerande A, B, C och Ω .

$$\text{Inte } A \rightarrow \Omega \text{ men inte } A \iff A^c = \Omega \setminus A.$$



Figur. Venn-diagram för komplement.

$$A \text{ men inte } B \iff A \setminus B$$

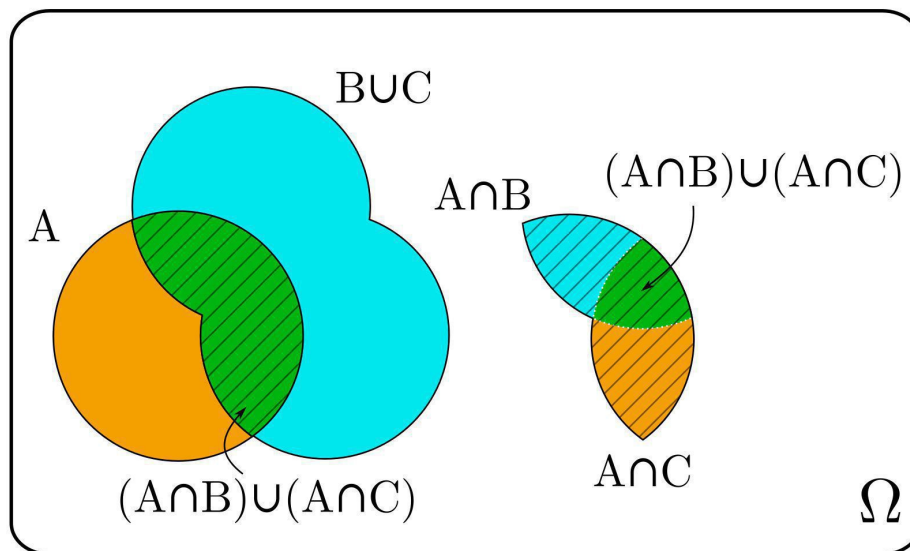


Figur. Venn diagram för inte, relativt komplement.

1.2 DeMorgans lagar

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$



Figur. Venn-diagram med tre skärande mängder som "bevis" för en av deMorgans lagar.

1.3 Lag kring komplement

$$(A \cup B)^c = A^c \cap B^c$$

1.4 Likformiga sannolikheter

$$\Omega = \{u_1, \dots, u_n\}$$

Samma sannolikhet för varje utfall

$$A \subseteq \Omega \quad P(A) = \frac{n(A)}{n(\Omega)} = \frac{n(A)}{n}$$

där n är antalet möjliga utfall, $n(A)$ är utfall $\in A$, så antalet "gynnsamma" fall.

1.4.1 Tärningsexempel

$$\begin{aligned} P(A) &= P(\text{udda poäng}) = \frac{n(A)}{n} = \frac{3}{6} = \frac{1}{2} \\ P(B) &= P(\{1, 2\}) = \frac{n(\{1, 2\})}{n} = \frac{2}{6} = \frac{1}{3} \\ P(A \cup B) &= \frac{n(A \cup B)}{6} = \frac{n(\{1, 2, 3, 5\})}{6} = \frac{4}{6} = \frac{2}{3} \\ &= P(A) + P(B) - P(A \cap B) \end{aligned}$$

[Venn-diagram 2 mängder som visar att skärningen räknas två gånger]

[Venn-diagram 3 mängder som visar $P(A \cap (B \cup C))$, räknar antal för första och andra termen]

$$P(A \cap (B \cup C)) = P(A \cap B) + P(A \cap C) - P(A \cap B \cap C)$$

1.5 Icke-likformiga sannolikheter

$$\Omega = \{u_1, \dots, u_n\}$$

$$P(u_i) \geq 0, \quad P(u_1) + \dots + P(u_n) = 1$$

Falsk tärning $P(\text{udda}) = P(u_1) + P(u_3) + P(u_5)$

Generellt $D \subseteq \Omega \quad P(D) = \sum_{u \in D} P(u)$

1.6 Disjunkta mängder

Givet utfallsrum Ω där händelser A uppfyller

$$A \subseteq \Omega \implies 0 \leq P(A) \leq 1, \quad P(\Omega) = 1$$


gäller att

$$A \cap B = \emptyset \implies P(A \cup B) = P(A) + P(B),$$

det vill säga att sannolikhet för $A \cup B$ är summan för sannolikheter för A och B , givet att A och B är disjunkta mängder.

1.6.1 Generellt

$$A_1, A_2, \dots \quad \text{uppräknligt många parvis disjunkta mängder} \implies P(A_1 \cup A_2 \cup \dots) = \sum_{i=1}^n P(A_i)$$



Figur. Venndiagram med disjunkta mängder.

1.7 Räknelagar

$$P(A^C) = 1 - P(A)$$

$$P(\emptyset) = 0$$

$$P(A \setminus B) = P(A) - P(A \cap B)$$

$$P(A \cup B \cup C) = P(A) + P(B) + P(C) - P(A \cap B) - P(A \cap C) - P(B \cap C) + P(A \cap B \cap C)$$

2 Föreläsning 2

25 mars 2015


2.1 Mer om klassisk sannolikhetsdef.

- Betingade sannolikheter
- Bayes formel
- Totala sannolikhetslagen

2.2 Multiplikationsprincipen

Om vi tur och ordning utför k operationer och den första kan göras på n_1 den andra på n_2 osv. Då blir antalet möjliga "kombinationssätt"

$n_1 n_2 \cdots n_k$ stycken.



Figur. Decision tree.

Exempel A, B, C, D ska ställa sig i kö. Antal kombinationer blir $4 \cdot 3 \cdot 2 \cdot 1$.

Exempel Givet $A = \{1, 2, \dots, n\}$, hur många delmängder finns det till A ?

Skapa en delmängd genom n val

steg 1	skall 1	vara med i delmängd?	2 val
steg 2	skall 2	vara med i delmängd?	2 val
		⋮	
steg n	skall n	vara med i delmängd?	2 val

Vilket ger totalt 2^n möjliga mängder.

Exempel Hur många delmängder finns det till A med exakt k element?

$$k=2: \frac{n(n-1)}{2}$$

$k=n$: Antag att det finns x delmängder av storlek k .

$$\underbrace{x}_{\text{val av delmängd}} \cdot \underbrace{k(k-1)\cdots 1}_{\text{sätt att ordna k-tupel}} = \underbrace{n(n-1)\cdots(n-k+1)}_{\text{välja k-tipler (utan rep.) direkt}}$$

Vi definierar binominalkoefficienten

$$x = \binom{n}{k} = \frac{n \cdots (n-k+1)}{k(k-1) \cdots 1} = \frac{(n)_k}{k!} = \frac{n!}{k!(n-k)!}.$$

Uppkommer exempelvis vid expansion av monom

$$(a+b)^n = \underbrace{(a+b) \cdots (a+b)}_{n \text{ st}} = \sum_{k=0}^n \binom{n}{k} a^k b^{n-k}.$$

Multinomial

$$(a+b+c)^n = \sum_{\substack{k_1+k_2+k_3=n \\ k_1, k_2, k_3 \geq 0}} \binom{n}{k_1 k_2 k_3} a^{k_1} b^{k_2} c^{k_3} \quad \text{där} \quad \binom{n}{k_1 k_2 k_3} = \frac{n!}{k_1! k_2! k_3!}.$$

2.3 Case study — Poker

52 kort

4 färger ♠, ♥, ♦, ♣

13 valörer 1, 2, ..., 13

Vi får 5 kort, antalet händer, utan ordning är

$$\binom{52}{5} = \frac{52 \cdot 51 \cdot 50 \cdot 49 \cdot 48}{5 \cdot 4 \cdot 3 \cdot 2 \cdot 1}.$$

Likformigt sannolikhetsfördelning.

2.3.1 “Färg (flush)”

$$\begin{aligned} n(\text{“färg”}) &= 4 \cdot \binom{13}{5} \\ P(\text{“färg”}) &= \frac{4 \cdot \binom{13}{5}}{\binom{52}{5}}. \end{aligned}$$

Alternativ, håll reda på ordning man får korten i

$$52 \cdot 51 \cdot 50 \cdot 49 \cdot 48 \quad \text{sätt}$$

$$52 \cdot 12 \cdot 11 \cdot 10 \cdot 9.$$

2.3.2 “Två par”

$$\underbrace{\binom{13}{2}}_{\text{Val av parvalör}} \cdot \underbrace{11}_{\text{Val av udda valör}} \cdot \underbrace{\binom{4}{2}}_{\text{Parfärgerna i lägsta parv.}} \cdot \underbrace{\binom{4}{2}}_{\text{Parfärgerna i högsta parv.}} \cdot \underbrace{4}_{\text{Högsta parvalören}}$$

2.4 Betingade sannolikheter

2.4.1 Kast av en blå och en röd tärning

$$\Omega = \{(1, 1), (1, 2), \dots, (5, 6), (6, 6)\} \quad \text{där } (a, b) = (\text{blå}, \text{röd})$$

$$n = n(\Omega) = 36$$

$$P(\text{röd} + \text{blå} = 5) = \frac{4}{36}$$


6
5
4	⊗
3	.	⊗
2	.	.	⊗	.	.	.
1	.	.	.	⊗	.	.
	1	2	3	4	5	6

$$P(\text{summan}=4 \mid \text{blå tärn}=2) = \frac{1}{6} \quad \text{ty svarar mot } P(\text{röd}=2)$$

$$P(\text{summan}=4 \mid \text{blå tärn}=2) = P(\text{röd tärn}=2 \mid \text{blå tärn}=2)$$

6	.	⊗
5	.	⊗
4	.	⊗
3	⊕	⊗
2	.	⊗
1	.	⊗	⊕	.	.	.
	1	2	3	4	5	6

$$P(A|B) = P(A \cap B|B) = \frac{P(A \cap B)}{P(B)} \quad \text{krav } P(B) > 0$$



Figur. Venndiagram visande $A \cap B$.

$$\begin{aligned}
 P(\text{summan}=4 | \text{blå tärn}=2) &= \frac{P(\text{summan}=4 \text{ och blå tärn}=2)}{P(\text{blå tärn}=2)} \\
 &= \frac{\frac{1}{36}}{\frac{1}{6}} = \frac{1}{6}
 \end{aligned}$$

$$P(\text{blå tärn}=2 | \text{summan}=4) = \frac{\frac{1}{36}}{\frac{1}{3}} = \frac{1}{3}$$

$$P(A \cap B) = \underbrace{P(A|B)}_{\text{ofta denna man begriper}} P(B)$$

$$P(A|B) = \frac{P(A)}{P(B)} P(B|A) \quad (\text{Bayes formel})$$


[Venndiagram med en stor mängd B och en liten mängd A med skärning, gemensam bit ger att $A|B$ sannolikt med $B|A$, leder till "paradoxa"]

Givet disjunkta mängder b_1, \dots, b_n som täcker Ω ,

$$P(A) = P(A \cap B_1) + \dots + P(A \cap B_n) \quad (\text{total sannolikhetslag})$$

3 Föreläsning 3

30 mars 2015



Figur. Venn-diagram med skärande A och B.

3.1 Betingade sannolikheter vid disjunkta händelser

3.1.1 Två händelser

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad \text{om } P(B) > 0.$$

Om $P(A|B) = P(A) \implies P(A \cap B) = P(A)P(B) \stackrel{\text{def}}{\iff} A$ och B oberoende händelser.

Exempel

6	⊕	⊕	⊕	·	·	·
5	⊗	⊗	⊗	⊗	⊗	⊗
4	⊕	⊕	⊕	·	·	·
3	⊗	⊗	⊗	⊗	⊗	⊗
2	⊕	⊕	⊕	·	·	·
1	⊗	⊗	⊗	⊗	⊗	⊗
	1	2	3	4	5	6

$A =$ Tärningskast $1 \leq 3$, $B =$ Tärningskast 2 udda

$$P(A \cap B) = \frac{9}{36} \quad P(A) = \frac{18}{36} = \frac{1}{2} \quad P(B) = \frac{18}{36} = \frac{1}{2}$$

$$P(A)P(B) = \frac{1}{4}$$


Exempel

6	⊗	·	·	·	·	·
5	·	⊕	·	·	·	·
4	·	·	⊕	·	·	·
3	·	·	·	⊕	·	·
2	·	·	·	·	⊕	·
1	·	·	·	·	·	⊕
	1	2	3	4	5	6

$A =$ tärning 1 visar en etta, $B =$ summan av tärningarna är sju

$$P(A \cap B) = \frac{1}{36} = P(A)P(B) \quad P(B) = \frac{6}{36} \quad P(A) = \frac{1}{6}$$

3.1.2 Tre händelser



Figur. Venn-diagram med A,B,C.

$$\begin{aligned}
 P(A \cap B) &= P(A) P(B) \\
 P(A \cap C) &= P(A) P(C) \\
 P(B \cap C) &= P(B) P(C) \\
 &\text{och} \\
 P(A \cap B \cap C) &= P(A) P(B) P(C)
 \end{aligned}$$

3.1.3 Generellt

$$P(A_1^c \cap A_2 \cap A_3 \cap A_4^c \cap \dots \cap A_n^c) = P(A_1^c) P(A_1) \dots P(A_n^c) \quad \text{för alla } 2^n \text{ komb av komplement!}$$

3.2 Stokastiska variabler

Exempel


$X =$ summan av tärningskastet

Stokastisk variabel – reellvärd funktion definierad på ett utfallsrum (med ett sannolikhetsmått)

Möjliga värden på $X = \Omega_X = \{2, 3, 4, \dots, 12\} \subseteq \mathbb{R}$. (utfallsrum)

$$P(\{\omega; X(\omega) = x\}) = P(X = x) = p_X(x) \quad x \in \Omega_X$$

Sannolikhetsfunktion, diskret frekvensfunktionsrum.




Exempel

$Y =$ maximum av de två poängen på tärning 1 och 2

$$\Omega_Y = \{1, \dots, 6\} \quad P_Y(y), \quad y \in \Omega_Y$$

$$\begin{aligned} P_Y(1) = P(Y=1) &= \frac{1}{36} \\ P_Y(2) = P(Y=2) &= \frac{3}{36} \\ &\vdots \\ P_Y(6) = P(Y=6) &= \frac{11}{36} \end{aligned}$$

3.2.1 Bernoullifördelning

Figur. Venn med A i Ω .

$$I_A = \begin{cases} 1 & \text{om } \omega \in A \\ 0 & \text{om } \omega \notin A \end{cases}$$

(Indikatorfunktion för händelsen A)

$$\Omega_{I_A} = \{0, 1\} \quad P_{I_A}(0) = 1 - P(A) \quad P_{I_A}(1) = P(A)$$

(Bernoulli-fördelad)

Exempel

$A =$ händelsen att vi får två sexor i kast med två tärningar

$$I_A \sim \text{Bernoulli} = \frac{1}{36}$$

3.2.2 Binomialfördelning

Kast av en tärning n gånger.

$X =$ Antalet 6:or bland de n kasten.

$$\begin{aligned} n=1 \quad P_X(0) &= 1 - P_X(1) = \frac{5}{6} \\ &P_X(1) = \frac{1}{6} \\ n=2 \quad P_X(0) &= \frac{5}{6} \cdot \frac{5}{6} = \frac{25}{36} \\ &P_X(1) = 2 \cdot \frac{1}{6} \cdot \frac{5}{6} = \frac{10}{36} \quad (\text{det resterande}) \\ &P_X(2) = \frac{1}{6} \cdot \frac{1}{6} = \frac{1}{36} \\ n=n \quad P_X(k) &= P(X=k) = \binom{n}{k} \left(\frac{1}{6}\right)^k \left(1 - \frac{1}{6}\right)^{n-k} \\ &k = 0, 1, \dots, n \\ &(\text{Binomialfördelad stokastisk variabel}) \end{aligned}$$

3.3 Kontinuerlig stokastisk fördelning

X stokastisk variabel $\Omega_X = \{x_1, x_2, \dots\}$

$$P_X(x_i) = p(x_i) \quad i = 1, 2, 3, \dots$$


$$p(x_i) \geq 0, \quad \sum_{i=1}^{\infty} p(x_i) = 1$$

$\Omega_X \subseteq \mathbb{R}$ Ett intervall, typiskt $[0, 1], [a, b], [0, \infty)$ eller hela \mathbb{R} .

Sannolikstäthet:

$$\begin{aligned} f_X(x) &\geq 0 && \text{på hela } \mathbb{R} \\ f_X(x) &= 0 && x \notin \Omega_X \\ \int_{-\infty}^{\infty} f_X(x) dx &= \int_{\Omega_X} f_X(x) dx = 1 \end{aligned}$$

$$P(X \in A) = \int_A f_X(x) dx$$




Figur. Intervallet $[a, b] = \Omega_X$, där A är delmängd av Ω_X och dess integral upp till $f_X(x)$ är utritad.

$$P(X \in A) = \int_A \frac{1}{b-a} dx = \frac{\ell(A)}{b-a}$$

3.4 (Kumulerad) fördelningsfunktion

$$P(X \leq x) = F_X(x) = \int_{-\infty}^x f_X(u) du$$


$$\iff \frac{d}{dx} F_X(x) = f_X(x)$$



Figur. Graf med integral för kurva av u upp till x .

$X \sim \text{Binomialfördelning}(3, p=0,2)$

$$\begin{aligned}\Omega_X &= \{0, 1, 2, 3\} \\ P_X(0) &= \binom{3}{0} 0.2^0 (1-0.2)^3 = 0.8^3 \\ P_X(1) &= \binom{3}{1} 0.2^1 (1-0.2)^2 = 3 \cdot 0.2 \cdot 0.8^2 \\ P_X(2) &= \binom{3}{2} 0.2^2 (1-0.2)^1 = 3 \cdot 0.2^2 \cdot 0.8 \\ P_X(3) &= \binom{3}{3} 0.2^3 (1-0.2)^0 = 0.2^3\end{aligned}$$



Figur. Graf $F_X(x)$ mot x .

$F_X(x)$ går från 0 till 1, specifikt

$$\begin{aligned}F_X(x) &\rightarrow 1 \quad \text{när } x \rightarrow +\infty \\ F_X(x) &\rightarrow 0 \quad \text{när } x \rightarrow -\infty\end{aligned}$$

$$\sum_{x_i \leq x, x_i \in \Omega_X} P_X(x_i) = F_X(x).$$

3.5 Oberoende försöksupprepningar

3.5.1 Geometrisk fördelning

Gör oberoende försöksupprepningar tills A inträffar och $X =$ antalet försök som behövs.

$$\begin{aligned}P(X=1) &= p \\ P(X=2) &= (1-p)p \\ &\vdots \\ P(X=n) &= (1-p)^{n-1}p\end{aligned}$$

3.5.2 Negativ binomialfördelning


Gör oberoende försöksupprepningar tills A inträffar k gånger och $Y =$ antalet försök som behövs.

$$\begin{aligned}P(Y=n) &= \binom{n-1}{k-1} p^{k-1} (1-p)^{n-k} p \\ &\quad (p \text{ inträffar } k\text{:te gången i försök } n)\end{aligned}$$

4 Föreläsning 4

20 april 2015

4.1 Endimensionella diskreta SV



Figur. Mängddiagram med mängd Ω innehållande ω med pil till $X(\omega)$ på horisontell axel.

Ändligt eller uppräkneligt oändligt: $\Omega_X = \{X(\omega); \omega \in \Omega\}$. Sannolikhetsfunktion (PDF) för X (diskret frekvensfunktion)

$$p_X(x) = P(X = x) = P(\omega \in \{X(\omega) = x\}) \quad x \in \Omega_X.$$


Beteckning för mängdnotation

$$P(x \in A) = \sum_{x \in A} P_X(x), \quad A \subset \mathbb{R}.$$

Kumulerad fördelningsfunktion (CDF)

$$F(x) = P(X \leq x) = \sum_{u \in \Omega_X, u \leq x} P_X(u), \quad \text{för alla } x \in \mathbb{R}$$

har utseende som trappstegsfunktion.



Figur. Graf med F för k till $k+2$, med annotation att steget vid $k+2$ är sannolikhet att $X = k+2$.

Exempel

Vänta på första 6:a när vi kastar en tärning upprepande gånger. X = antalet kast som behövs.

Ω komplicerat, men detta kan undvikas.

$$\begin{aligned} p_X(k) = P(X = k) &= P(\text{inte 6:a i de } k-1 \text{ första försöken och 6:a i försök } k) \\ &= \underbrace{\left(\frac{5}{6}\right)^{k-1}}_{\text{geometrisk frekvensfunktion, } \frac{1}{6}} \frac{1}{6}, \quad k = 1, 2, \dots \end{aligned}$$

(Lätt att se att $\sum_{k=1}^{\infty} p_X(k) = 1$, exempelvis genom geometrisk summa)

Om X istället är antalet kast till och med n :te gången vi får en sexa?


$$\begin{aligned} p_X(k) = P(X = k) &= \{k = n, n+1, \dots\} \\ &= \binom{k-1}{n-1} \left(\frac{5}{6}\right)^{k-n} \left(\frac{1}{6}\right)^{n-1} \frac{1}{6} \end{aligned}$$

Detta är en negativ binomialfördelning(n, p).

Repetition

$$Y \sim \text{bin}(n, p) \quad P_Y = \binom{n}{k} p^k (1-p)^{n-k} \quad k = 0, \dots, n$$

Exempel – plocka utan återläggning



Figur. Mängddiagram med n element totalt. Delmängder med r "speciella" element, $n-r$ "icke-speciella".

Dra m element utan återläggning. $Y =$ Antalet dragna som är speciella och

$$p_Y(k) = \frac{\binom{r}{k} \binom{n-r}{m-k}}{\binom{n}{m}}, \quad 0 \leq k \leq r, \quad 0 \leq m-k \leq n-r$$

som kallas en hypergeometrisk fördelning. Om m litet relativt n och r så betar sig denna approximativt som en binomialfördelning.

Binomialfördelning

$$X_n \sim \text{bin}(n, p_n) \quad \text{där} \quad n p_n = \lambda \iff p_n = \frac{\lambda}{n}, \quad \lambda \text{ godtyckligt positivt tal } (n \geq \lambda)$$

Om n stor, $n \geq k$ med k fixt, så

$$P(X_n = k) = \binom{n}{k} p_n^k (1-p_n)^{n-k} = \frac{n(n-1)\cdots(n-k+1)}{k!} \frac{\lambda^k}{n^k} \left(\frac{1-\lambda/n}{1-\lambda/n}\right)^k$$

notera att med $(n)_k = n(n-1)\cdots(n-k+1)$ så kommer

$$\frac{(n)_k}{n^k} \rightarrow 1 \quad \text{när} \quad n \rightarrow \infty$$

och

$$\frac{\left(1 - \frac{\lambda}{n}\right)^n}{\left(1 - \frac{\lambda}{n}\right)^k} \rightarrow \frac{e^{-\lambda}}{1^k} \quad \text{när} \quad n \rightarrow \infty$$

vilket leder till att

$$P(X_n = k) \rightarrow \frac{\lambda^k e^{-\lambda}}{k!} \quad k = 0, 1, 2, \dots$$

binomialfördelning går alltså mot en normalfördelning när $n \rightarrow \infty$.

Användning för ovanstående slutsats?

$X \sim \text{bin}(n, p)$ och om n stort och p litet så fungerar approximationen

$$p_X(k) \approx \frac{(np)^k e^{-np}}{k!} = \frac{\lambda^k e^{-\lambda}}{k!} \quad \lambda > 0$$

bra för små k relativt n .

4.2 Reella SV


X har en kontinuerlig sannolikhetsfördelning om

$$P(X \in A) = \int_A f_X(x) dx, \quad f_X(x) \geq 0, \quad A \subseteq \mathbb{R}, \quad \underbrace{\int_{\mathbb{R}} f_X(x) dx}_{\text{sannolikhetstäthet}} = 1$$

Ska titta på

- Likformig fördelning på $[a, b]$, $a < b$
- Binomialfördelning (λ) , $\lambda > 0$
- Normalfördelning (μ, σ^2) , $\mu \in \mathbb{R}$, $\sigma \in \mathbb{R}^+$

4.2.1 Likformig fördelning



Figur. Graf med puls med area 1, "komplex" (komplicerad) mängd.

$$\int_A f(x) dx = \int_{A \cap [a, b]} \frac{1}{b-a} dx = \frac{\text{längden}(A \cap [a, b])}{\text{längden}([a, b])}$$


Fördelningsfunktion

$$F(x) = \int_{-\infty}^x f(u) du = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & x \geq b \end{cases}$$

Hänger ihop med frekvensfunktion genom derivata, $F'(x) = f(x)$, förutsatt kontinuerlig SV.

4.2.2 Exponentiell fördelning

$T =$ livslängden för en teknisk apparat, $T \geq 0$. $P(T \leq t)$?



Figur. Graf med $f(t)$ mot tid med $F(t)$ till t inritat.

“Teknisk apparat som ny!” – vi bortser från allt åldrande:


$$P(T \geq t + s | T \geq s) = P(T \geq t)$$

skulle kräva

$$P(T \geq t) = e^{-\lambda t}.$$

Vi har

$$F_T = 1 - e^{-\lambda t}, \quad t \geq 0 \implies f_T(t) = \frac{d}{dt} F_T(t) = \lambda e^{-\lambda t}, \quad t \geq 0$$



Figur. Graf över $f_T(t)$ med start i λ och punkten $(\frac{1}{\lambda}, \lambda e^{-1})$ inritad.

Γ -fördelning(α, λ)

$$f(t) = \frac{x^\alpha t^{\alpha-1} e^{-\lambda t}}{\Gamma(\alpha)}, \quad \lambda > 0, \quad t \geq 0, \quad \underbrace{\alpha \geq 0}_{\text{formparameter}}$$

om $\alpha = n \in \mathbb{Z}$ så $\Gamma(\alpha) = (n - 1)!$

Titta på normalfördelning själva innan övning.


5 Föreläsning 5

22 april 2015

5.1 Normalfördelning $(\mu, \sigma^2) = N(\mu, \sigma^2)$

μ väntevärde, σ^2 varians.

$N(0,1)$:



Figur. Graf över $f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2}$ med $F(x)$ inritad till ett x . Max i $(0, \frac{1}{\sqrt{2\pi}})$, inritat.

Definition

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} = \varphi(x),$$

är pdf ty

$$\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} dx = 1,$$


och dess cdf är

$$F_{N(0,1)}(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}u^2} du = \Phi(x).$$

Några viktiga värden för $\Phi(x)$

$\Phi(0)$	$= \frac{1}{2}$	p.g.a. symmetri
$\Phi(1)$	$\approx 85\%$	
$\Phi(-1)$	$\approx 15\%$	
$\Phi(c)$	$= 0.975$	$\implies c = 1.96$
$\Phi(c)$	$= 0.95$	$\implies c = 1.65$
$\Phi(c)$	$= 0.995$	$\implies c = 2.58$

5.1.1 p -fraktilen — även quantile, fractile och percentiler



Figur. Graf av cdf upp till 1. p en proportion av 0 – 1 markerat på y -axel, med linje längs $y = p$ till $F(x)$ och sen ner till p -fraktil.

5.1.2 Generell normalfördelning från $N(0, 1)$

Antag X en $N(0, 1)$ -variabel. Ansätt $Y = a + bX$ $a, b \in \mathbb{R}$ $b > 0$, då fås cdf

$$F_Y(y) = P(Y \leq y) = P(a + bX \leq y) = P\left(X \leq \frac{y-a}{b}\right) = \Phi\left(\frac{y-a}{b}\right)$$

och pdf

$$f_Y(y) = \frac{d}{dy} F_Y(y) = \frac{d}{dy} \Phi\left(\frac{y-a}{b}\right) = \varphi\left(\frac{y-a}{b}\right) \frac{1}{b} = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{y-a}{b}\right)^2} \left(= e^{-\frac{1}{2}\left(\frac{y-\mu}{\sigma}\right)^2} \right).$$

Så vi har

$$N(\mu, \sigma^2) \underbrace{\sim}_{\text{täthet}} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\frac{(x-\mu)^2}{\sigma^2}} \quad \text{och omvänt} \quad Y = \frac{X-\mu}{\sigma} \sim N(0, 1).$$

Not kring kontinuerliga och diskreta fördelningar

Kan gå från kontinuerlig till diskret genom en SV, måste vara vaksam.

$$Y = \begin{cases} 0 & X \leq x \\ 1 & X > x \end{cases}$$

$X \sim N(0, 1)$, $Y = |X - 1|$, $f_Y(y) = ?$

$$F_Y(y) = P(Y \leq y) = P(|X - 1| \leq y) = P(1 - y \leq X \leq 1 + y) = \Phi(1 + y) - \Phi(1 - y)$$

$$f_Y(y) = \frac{d}{dy} F_Y(y) = \Phi(1 + y) - \Phi(1 - y) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(1+y)^2}{2}} + \frac{1}{\sqrt{2\pi}} e^{-\frac{(1-y)^2}{2}}$$

5.2 Två och n -dimensionella SV

X = summan av två tärningar, Y = maximala poängen hos två tärningar

$$p_{(X,Y)}(x, y) = P(X = x, Y = y) \quad (x, y) \in \Omega_{(X,Y)} = \{\text{möjliga utfall på } (x, y)\}$$

$$\begin{aligned} P(x, y) &= \frac{1}{36} & (x, y) &= (2, 1) \\ &= \frac{2}{36} & (x, y) &= (3, 2) \\ &\vdots \end{aligned}$$

$$\Omega_{(X,Y)} = \{(2, 1), (3, 2), (4, 2), (4, 3), (5, 3), (5, 4), (7, 4), (7, 5), \dots, (12, 6)\}$$

$$p_{(X,Y)}(x, y) = 0 \quad \text{om } (x, y) \in \Omega_{(X,Y)} \text{ men } (x, y) \in \Omega_X \times \Omega_Y$$

$$p_X(x) = P(X = x) = \sum_y P(X = x, Y = y) = \sum_y p_{(X,Y)}(x, y), \quad y \in \Omega_Y$$

$$P_Y(y) = \sum_x p_{(X,Y)}(x, y), \quad x \in \Omega_X$$

Om $(X = x)$ och $(Y = y)$ oberoende $\implies p_{(X,Y)}(x, y) = P(X = x, Y = y) = P(X = x) P(Y = y)$.

Definition

Om X och Y har sannolikhetsfunktion $p_{(X,Y)}(x, y) = p_X(x) p_Y(y)$ så sägs X och Y vara oberoende eller ekvivalent

X, Y oberoende om $P(X \in A, Y \in B) = P(X \in A) P(Y \in B)$ för alla händelser A och B "snälla" delmängder av \mathbb{R} .

5.2.1 (X, Y) tvådimensionell kontinuerlig SV


Sannolikhetstäthet $f_{(X,Y)} \geq 0$,

$$P((X, Y) \in A) = \iint_A f_{(X,Y)}(x, y)$$

$$\iint_{\mathbb{R}^2} f_{(X,Y)}(x, y) = 1$$

Exempel

Tvådimensionell täthet som svarar mot likformigt val av punkt i enhetskvadraten $\{(x, y): 0 \leq x \leq 1, 0 \leq y \leq 1\}$ och 0 utanför.



Figur. Figur med enhetskvadrat i x - y plan som bas och med en höjd c .

$$1 = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f_{(X,Y)}(x, y) dx dy = \int_0^1 \int_0^1 c dx dy = 1 c \implies c = 1.$$

$$f_X(x) = \int_{-\infty}^{\infty} f_{(X,Y)}(x, y) dy = \{\text{i exemplet}\} = 1, \quad 0 \leq x \leq 1$$

$$f_{(X,Y)}(x, y) = \{\text{i exemplet}\} = f_X(x) f_Y(y).$$

Matematiken bakom

Tvådimensionell fördelningsfunktion

$$F_{(X,Y)}(x, y) = P(X \leq x, Y \leq y) = \begin{cases} \sum_{(u,v)} p_{(X,Y)}(u, v) & u \leq x, v \leq y \\ \int_{-\infty}^y \int_{-\infty}^x f_{(X,Y)}(u, v) du dv & \end{cases}$$

$$\frac{d}{dy} F_{(X,Y)}(x, y) = \int_{-\infty}^x f_{(X,Y)}(u, v) dy$$

$$\frac{d}{dx} \frac{d}{dy} F_{(X,Y)}(x, y) = f_{(X,Y)}(u, v)$$

Med oberoende

$$F_{(X,Y)}(x, y) = F_X(x) F_Y(y)$$

$$\frac{d}{dx} \frac{d}{dy} F_{(X,Y)}(x, y) = f_X(x) f_Y(y).$$

6 Föreläsning 6

27 april 2015

6.1 Tvådimensionell SV

(X, Y) har en täthet $f(x, y) \geq 0$, $(x, y) \in \mathbb{R}^2$,

$$\iint_{\mathbb{R}^2} f(x, y) dx dy = 1.$$

Om A är en liten omgivning till (x, y) så

$$P((X, Y) \in A) \approx \text{arean av } A \times f(x, y).$$

Tätheten för X : $f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy$

Tätheten för Y : $f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx$

6.1.1 Oberoende

$$P(X \in A, Y \in B) = P(X \in A) P(Y \in B) \iff X \text{ och } Y \text{ oberoende}$$

$$\implies f(x, y) = f_X(x) f_Y(y)$$

x avbildat på $f_{(X|Y)}(x|y)$, den betingade sannolikhetstätheten för X givet att $Y = y$


$$\approx P(X = x \pm \varepsilon | Y = y \pm \varepsilon).$$

Definition

$$f_{(X|Y)}(x|y) \triangleq \frac{f(x, y)}{f_Y(y)} = \{\text{oberoende}\} = \frac{f_X(x) f_Y(y)}{f_Y(y)}.$$

6.1.2 Fördelning för $X + Y$?

$$\begin{aligned} F_{X+Y}(t) \triangleq P(X + Y \leq t) &= \int_{-\infty}^{\infty} \int_{-\infty}^{t-x} f(x, y) dy dx \\ &= f_{X+Y}(t) = \frac{d}{dt} F_{X+Y}(t) \\ &= \int_{-\infty}^{\infty} \frac{d}{dt} \int_{-\infty}^{t-x} f(x, y) dy dx \\ &= \int_{-\infty}^{\infty} 1 \cdot f(x, t-x) dx \end{aligned}$$



Figur. $F_{X+Y}(t) \triangleq P(X + Y \leq t)$

Specifikt om X och Y oberoende så fås faltning

$$f_{X+Y}(t) = f_X * f_Y(t).$$

Exempel $X \sim \text{Exp}(\lambda)$ $Y \sim \text{Exp}(\lambda)$ oberoende

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & x < 0 \end{cases}$$

$$f_Y(y) = \begin{cases} \lambda e^{-\lambda y} & y \geq 0 \\ 0 & y < 0 \end{cases}$$

$$f_{X+Y}(t) = \int_{-\infty}^{\infty} \underbrace{f_X(x)}_{=0, x < 0} \underbrace{f_Y(t-x)}_{=0, x > t} dx = \begin{cases} 0 & t < 0 \\ \int_0^t \lambda e^{-\lambda x} \lambda e^{-\lambda(t-x)} dx & t \geq 0 \end{cases}$$

det senare är en Γ -täthet ($\lambda^2 e^{-\lambda t}$), $\Gamma(2, \lambda)$.

För heltal

Givet att (X, Y) har sannolikhetsfunktion $P(x, y)$ för $(x, y) \in \mathbb{Z}^2$ så

$$P_{X+Y}(z) = \sum_x p(x, z-x) = \{\text{oberoende}\} = \sum_x p(x) p(z-x),$$

om både X och $Y \geq 0$ så

$$P_{X+Y}(z) = \sum_{x=0}^z p(x) p(z-x), \quad z = 0, 1, 2, \dots$$

$X \sim \text{poisson}(\lambda_1)$ och $Y \sim \text{poisson}(\lambda_2)$ oberoende $\implies X + Y \sim \text{poisson}(\lambda_1 + \lambda_2)$

$$X \sim \text{bin}(n, p) \quad Y \sim \text{bin}(m, p)$$

$$\text{oberoende} \implies X + Y \sim \text{bin}(n+m, p)$$

Rekursiv intuition

$$P(X \in A, Y \in B, Z \in C) = P(X \in A) P(Y \in B) P(Z \in C)$$

$$p(x, y, z) = p_X(x) p_Y(y) p_Z(z)$$

$$f(x, y, z) = f_X(x) f_Y(y) f_Z(z).$$

Om X_1, \dots, X_n oberoende och alla har fördelningsfunktion F ,

$$P(\max(X_1, \dots, X_n) \leq x) = P(X_1 \leq x, \dots, X_n \leq x) = \{\text{oberoende}\}$$


$$= P(X_1) \dots P(X_n \leq x) = F(x)^n$$

$$f_{\max(X_1, \dots, X_n)} = n F(x)^{n-1} f(x).$$

För minimum

$$F_{\min(X_1, \dots, X_n)}(x) = 1 - (1 - F(x))^n \implies f_{\min(X_1, \dots, X_n)}(x) = n f(x) (1 - F(x))^{n-1}.$$

6.2 Teoretisk median



Figur. Graf illustrerande teoretisk median, värdet m som delar fördelningen i två delar med samma area.

Givet $f(x)$ sannolikhetstäthet för X så definieras m , den teoretiska medianen, som

$$F_X(m) = \int_{-\infty}^m f(x) dx = \frac{1}{2}.$$

Den teoretiska medianen m uppfyller alltså

$$\begin{aligned} P(X \geq m) &= \frac{1}{2} \\ P(X \leq m) &= \frac{1}{2} \end{aligned}$$

6.2.1 Väntevärdet $\mu = E[X]$

$$\mu = E[X] \triangleq \int_{-\infty}^{\infty} x f(x) dx \quad \left(\text{om } \int_{-\infty}^{\infty} |x| f(x) dx < \infty \right)$$

och i diskret fall

$$\sum_{x \in \Omega_X} x p_X(x) \quad \left(\text{om } \sum_{x \in \Omega_X} |x| p_X(x) < \infty \right)$$


Exempel Exponentialfördelning

$X \sim \exp(\lambda)$

$$\begin{aligned} F(x) &= 1 - e^{-\lambda x} \\ F(m) = \frac{1}{2} &\implies m = \frac{\ln 2}{\lambda} \end{aligned}$$


$$\int f g = F g - \int F g'$$

$$\begin{aligned} E[X] &= \int_0^{\infty} x \lambda e^{-\lambda x} dx \\ &= [-x e^{-\lambda x}]_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx \\ &= \int_0^{\infty} e^{-\lambda x} dx \\ &= \frac{1}{\lambda} \end{aligned}$$



Figur. Exponentialfördelning $\lambda e^{-\lambda x}$ med area upp till m . $E[X] = \frac{1}{\lambda}$ inritat.

Exempel Gaussfördelning



Figur. Symmetrisk och m i symmetrilinje $\mu = 0$.

$$\sum_{x=0}^{\infty} \frac{x \lambda^x e^{-\lambda}}{x!} = \lambda \underbrace{\left(\frac{\lambda^{x-1} e^{-\lambda}}{(x-1)!} \right)}_{=1}$$

Givet $Y = g(X)$ och X har täthet $f(x)$,

Sats

$$E[Y] = \int_{-\infty}^{\infty} g(x) f(x) dx \quad \left(\text{om } \int_{-\infty}^{\infty} |g(x)| f(x) dx < \infty \right)$$

$$E[Y] = \sum_{x \in \Omega_X} g(x) p_X(x) dx \quad \left(\text{om } \sum_{x \in \Omega_X} |g(x)| f(x) dx < \infty \right)$$

Exempel


$X =$ poäng 1 tärningskast, $Y = X^2$

$$\Omega_Y = \{1, 4, 9, 16, 25, 36\} \quad \frac{1}{6} \cdot 1 + \dots + \frac{1}{6} \cdot 36 = E[Y] = 3.5$$

$$E[X^2] = \sum_{i=1}^6 i^2 \frac{1}{6} = \frac{91}{6}$$

$Y = \begin{cases} 1 & \text{om utfallet jämnt} \\ 0 & \text{om utfallet udda} \end{cases}$, $g(x) = \begin{cases} 1 & \text{om } x \text{ jämn} \\ 0 & \text{om } x \text{ ojämn} \end{cases}$

$$E[Y] = 0 \cdot \frac{1}{2} + 1 \cdot \frac{1}{2} = \frac{1}{2}$$



Figur. Figur illustrerande Markovs olikhet.

Markovs olikhet

$$P(X \geq k\mu) \leq \frac{1}{k}$$

$$\begin{aligned} \mu &= \int_0^{\infty} x f(x) dx \\ &\geq \int_0^{k\mu} x f(x) dx + \int_{k\mu}^{\infty} (k\mu) f(x) dx \\ &\geq k\mu P(X \geq k\mu) \end{aligned}$$

6.2.2 Varians

$$\sigma^2 = \text{variansen för } X = \text{Var}[x] \triangleq E[(X - E[X])^2] = E[X^2] - (E[X])^2$$

6.2.3 Standardavvikelse

$$\sigma = \sqrt{\sigma^2} = \text{standardavvikelse för } X$$

Not Markov på varians ger Chebyshevs olikhet.

7 Föreläsning 7

extrainsatt

29 april 2015

7.1 Mått för stokastiska variabler?

7.1.1 Väntevärden och varians

$$E[X] = \int_{-\infty}^{\infty} x f_X(x) dx = \mu_X = \mu$$

$$E[X] = \sum_{z \in \Omega_X} x p_X(x)$$

Sats

$$Y = g(X) \in \mathbb{R} \quad E[Y] = \int_{-\infty}^{\infty} g(x) f_X(x) dx$$

Givet

$$z = g(X, Y) \quad (X, Y) \sim \text{tvådimensionell SV med täthet } f(x, y)$$

Sats

$$E[z] = \iint_{\mathbb{R}} g(x, y) f(x, y) dx dy$$

Följdsats – Summa för SV

X, Y tvådimensionella (kontinuerliga) SV $Z = a + bX + cY$

$$\begin{aligned} E[Z] &= \int (a + bX + cY) f(x, y) dx dy \\ &= \int \int_{\mathbb{R}^2} a f(x, y) dx dy + \int \int_{\mathbb{R}^2} b x f(x, y) dx dy \\ &\quad + \int \int_{\mathbb{R}^2} c y f(x, y) dx dy \\ &= a + b E[X] + c E[Y] \end{aligned}$$

Kan nu visa (från förra gången), $\sigma^2 = \text{Var}[X] \triangleq E[(X - E[X])^2] = E[X^2] - (E[X])^2$

“Steiners sats”

$$\begin{aligned} E[(X - E[X])^2] &= E[X^2 + E[X]^2 - 2E[X]X] \\ &= E[X^2] + (E[X])^2 - 2E[X]E[X] \\ &= E[X^2] - (E[X])^2 \end{aligned}$$

□

Från förra gången

$$Z = \text{poäng i ett tärningskast} \quad E[Z] = 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{6} + \dots + 6 \cdot \frac{1}{6} \quad E[Z^2] = 1^2 \cdot \frac{1}{6} + 2^2 \cdot \frac{1}{6} + \dots + 6^2 \cdot \frac{1}{6}$$

$$\sigma^2 = \text{Var}[Z] = E[Z^2] - E[Z]^2 = \frac{91}{6} - (3.5)^2 = \frac{35}{12}$$

$$\sigma = \sqrt{\frac{35}{12}}$$

Givet X och Y är *oberoende* kontinuerliga tätheter f_X och $f_Y \implies f(x, y) = f_X(x) f_Y(y)$

Sats

$$E[XY] = E[X] E[Y]$$

Bevis

$$\begin{aligned} E[XY] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f_X(x) y f_Y(y) dx dy \\ &= \int_{-\infty}^{\infty} y f_Y(y) \left(\int_{-\infty}^{\infty} x f_X(x) dx \right) dy \\ &= E[X] E[Y] \end{aligned} \quad \square$$

Följdsats

$$\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y]$$

Bevis

$$\begin{aligned} \text{Var}[X + Y] &= E[(X + Y)^2] - (E[X + Y])^2 \\ &= E[X^2 + Y^2 + 2XY] - (E[X] + E[Y])^2 \\ &= (E[X^2] + E[Y^2] + 2E[XY]) - (E[X]^2 + E[Y]^2 + 2E[X]E[Y]) \\ &= \text{Var}[X] + \text{Var}[Y] + 2(E[XY] - E[X]E[Y]) \\ &= \text{Var}[X] + \text{Var}[Y] \end{aligned} \quad \square$$

Generalisering

$$E[XY] - E[X]E[Y] = E[(X - E[X])(Y - E[Y])] \triangleq \text{kovariansen mellan/av } X \text{ och } Y.$$

Positiv om hög \rightarrow hög och låg \rightarrow låg, negativ om hög \rightarrow låg och låg \rightarrow hög.

$$\text{Var}[a + bX] = b^2 \text{Var}[X]$$

7.1.2 Kovarians

$$\text{Kov}[X, X] = \text{Var}[X]$$

$$\text{Kov}[a + b_1 X_1 + \dots + b_n X_n, c + d_1 Y_1 + \dots + d_m Y_m] = \sum_{i=1}^n \sum_{j=1}^m b_i d_j \text{Kov}(X_i, Y_j) \quad \left(= \mathbf{b}^2 \underbrace{\mathbf{C}_{n,m}}_{\sigma_i^2 \text{ på diag}} \mathbf{d} \right).$$

Specialfall

$$\begin{aligned} \text{Var}[a + b_1 X_1 + \dots + b_n X_n] &= \sum_{i=1}^n \sum_{j=1}^n b_i b_j \text{Kov}(X_i, X_j) \\ &= \sum_{i=1}^n b_i^2 \text{Var}[X_i] + 2 \sum_{i < j} b_i b_j \text{Kon}[X_i, X_j]. \end{aligned}$$

7.2 Mått för specifika fördelningar

En likformig fördelning

$$U \sim \text{likformigt fördelad på } [0, 1]$$

Väntevärde

$$E[U] = \int_{-\infty}^{\infty} u f_U(u) du = \int_0^1 u \cdot 1 du = \left[\frac{u^2}{2} \right]_0^1 = \frac{1}{2}$$

Varians

$$\text{Var}[U] = E[U^2] - \left(\frac{1}{2}\right)^2 = \int_0^1 u^2 \cdot 1 du - \frac{1}{4} = \frac{1}{3} - \frac{1}{4} = \frac{1}{12}$$

Standardavvikelse

$$E\left[\left|U - \frac{1}{2}\right|\right] = \frac{1}{4}$$

$$\sigma = \sqrt{\frac{1}{12}} = \sqrt{E[(U - E[U])^2]} > \frac{1}{4}$$

och mer generellt

$$E[|U - E[U]|]^2 \leq \text{Var}[U - E[U]].$$

$$Z \sim \text{Likf}[a, b]$$

Konvertering till $[0, 1]$

$$\frac{Z - a}{b - a}, \quad \frac{E[Z] - a}{b - a} = 2 \quad \implies \quad E[Z] = \frac{a + b}{2}$$

$$\frac{\text{Var}[Z] - a}{b - a} = \frac{1}{12}$$

7.2.1 Normalfördelning

$$X \sim N(0, 1)$$

Väntevärde

$$E[X] = 0$$

Varians

$$\begin{aligned} \text{Var}[X] &= E[X^2] - (E[X])^2 = E[X^2] \\ &= \int_{-\infty}^{\infty} x \left(x \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \right) dx \\ &= \left[-x \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \right]_{-\infty}^{\infty} + \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = 1 \end{aligned}$$

Standardavvikelse

$$\sigma = \sqrt{\sigma^2} = 1$$

$$f_X(x) = \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}} \quad X \sim N[\mu, \sigma^2]$$

$$\frac{X - \mu}{\sigma} \sim N(0, 1) \implies \frac{E[X] - \mu}{\sigma} = 0$$

$$\frac{\text{Var}[X]}{\sigma^2} = 1$$

7.2.2 Exponentialfördelning

$$Y \sim \text{Expf}(\lambda)$$

Väntevärde

$$E[Y] = \int_0^{\infty} y \lambda e^{-\lambda y} dy = \dots = \frac{1}{\lambda}$$

Varians

$$E[Y^2] = \int_0^{\infty} y^2 \lambda e^{-\lambda y} dy = \dots = \dots = \frac{2}{\lambda^2}$$

$$\text{Var}[Y] = \frac{2}{\lambda^2} - \left(\frac{1}{\lambda}\right)^2 = \frac{1}{\lambda^2}$$

Standardavvikelse

$$\sigma = \frac{1}{\lambda} \quad (=E[Y])$$

7.2.3 Γ -fördelning

$$Z \sim \Gamma\text{-fördelning}(n, \lambda)$$

$$Z = Y_1 + \dots + Y_n, \quad \text{oberoende expf}[\lambda]$$

Väntevärde

$$E[Z] = E[Y_1] + \dots + E[Y_n] = n \frac{1}{\lambda} = \frac{n}{\lambda}$$

Varians

$$\text{Var}[Z] = \text{Var}[Y_1] + \dots + \text{Var}[Y_n] = \frac{n}{\lambda^2}$$

Standardavvikelse

$$\sigma = \frac{\sqrt{n}}{\lambda}$$

Medelvärden

$$E\left[\frac{Z}{n}\right] = \frac{E[Z]}{n} = \frac{n \cdot \frac{1}{\lambda}}{n} = \frac{1}{\lambda}$$

$$\text{Var}\left[\frac{Z}{n}\right] = \frac{\text{Var}[Z]}{n^2} = \frac{n \cdot \frac{1}{\lambda^2}}{n^2} = \frac{1}{\lambda^2 n}$$

$$X_1, \dots, X_n \text{ oberoende} \quad E[X_i] = \mu \quad \text{och} \quad \text{Var}[X_i] = \sigma^2$$

$$E[\bar{X}] = \mu$$

$$\sqrt{\text{Var}[\bar{X}]} = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$$

7.2.4 Poissonfördelning

$$X \sim \text{Poisson}(\lambda)$$

Väntevärde

$$E[X] = \lambda$$

Varians

$$\text{Var}[X] = \lambda$$

Standardavvikelse

$$\sigma = \sqrt{\lambda}$$

Svårsmält slutkaos!

7.2.5 Binomialfördelning

Genom summor.

Väntevärde

$$n p$$

Varians

$$n p (1 - p)$$

7.2.6 Multinomialfördelning

På likartat sätt

$$X_1, \dots, X_k \sim \text{Multinomial}(n, p_1, \dots, p_k)$$

Kovarians

$$X_i + X_j \sim \text{Bin}(n, p_i + p_j)$$

$$\text{Kov}[X_i, X_j] = -n p_i p_j$$

8 Föreläsning 8

4 maj 2015

- Betingade väntevärden och variabler
- Momentgenererande funktioner
- Approximation av väntevärden och varianser
- Stora talens lag
- Centrala gränsvärdesatsen

8.1 Repetition

$$f_{(X|Y)}(x|y) \triangleq \frac{f(x, y)}{f_Y(y)}$$

För väntevärden gäller att

$$E[X|Y=y] = \int_{-\infty}^{\infty} x f_{(X|Y)}(x|y) dx = \{\text{säg}\} = g(y) \quad (\text{SV}).$$

$$g(Y) = E[X|Y].$$

Det existerar räknelag som säger att

$$E[X] = E[E[X|Y]].$$

För varians gäller att

$$\text{Var}[X|Y=y] = \int_{-\infty}^{\infty} (x - E[X|Y=y])^2 f_{(X|Y)}(x|y) dx = h(y)$$

$$h(Y) = \text{Var}[X|Y].$$

Det existerar räknelag som säger att

$$\text{Var}[X] = \text{Var}[E[X|Y]] + E[\text{Var}[X|Y]].$$

8.2 Momentgenererande funktioner

Momentgenererande funktioner definieras

$$M_X(t) = \begin{cases} \int_{-\infty}^{\infty} e^{tx} f_X(x) dx = E[e^{tX}] & \text{om kontinuerlig} \\ \sum_{x \in \Omega_X} e^{tx} p_X(x) & \text{om diskret,} \end{cases}$$

där $M_X(t) < \infty$ i öppet intervall kring 0.

Om $M_X(t) = M_{X'}(t)$ för t i öppet intervall kring 0 \implies X och X' har samma fördelning.

Kan kasta om integrering och derivata

$$\begin{aligned} \left[\frac{d}{dt} M_X(t) \right]_{t=0} &= \left[\int_{-\infty}^{\infty} x e^{tx} f(x) dx \right]_{t=0} = \int_{-\infty}^{\infty} x f(x) dx = E[X] \\ \left[\frac{d^2}{dt^2} M_X(t) \right]_{t=0} &= \left[\int_{-\infty}^{\infty} x^2 e^{tx} f(x) dx \right]_{t=0} = \int_{-\infty}^{\infty} x^2 f(x) dx = E[X^2] \\ &\vdots \\ \left[\frac{d^n}{dt^n} M_X(t) \right]_{t=0} &= \left[\int_{-\infty}^{\infty} x^n e^{tx} f(x) dx \right]_{t=0} = \int_{-\infty}^{\infty} x^n f(x) dx = E[X^n]. \end{aligned}$$

Exempel Normalfördelning

Givet $Z \sim N(0, 1)$,

$$\begin{aligned} E[e^{tZ}] &= \int_{-\infty}^{\infty} e^{tz} \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz \\ &= e^{\frac{t^2}{2}} \underbrace{\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{(t-z)^2}{2}} dz}_{=1} \\ &= e^{\frac{t^2}{2}}. \end{aligned}$$

$$E[z] = \left[\frac{d}{dt} \left(e^{\frac{t^2}{2}} \right) \right]_{t=0} = \left[\frac{2t}{2} e^{\frac{t^2}{2}} \right]_{t=0} = 0$$

$$E[z^2] = \left[\frac{d^2}{dt^2} \left(e^{\frac{t^2}{2}} \right) \right]_{t=0} = \left[e^{\frac{t^2}{2}} + t^2 e^{\frac{t^2}{2}} \right]_{t=0} = 1$$

Givet $Y = a + bX$

$$m_Y(t) = E[e^{(a+bX)t}] = e^{at} E[e^{btX}] = e^{at} M_X(bt).$$

Givet $X \sim N(\mu, \sigma^2)$ så har X samma fördelning som $Y = \mu + \sigma Z$, $Z \sim N(0, 1)$

$$M_X(t) = M_Y(t) = e^{\mu t} e^{\frac{\sigma^2 t^2}{2}}.$$

$$\begin{aligned} X \sim \text{Bin}(1, p) &= (1-p)e^{t0} + p e^{t1} \\ &= (1-p) + p e^t \end{aligned}$$

Om $Y = X_1, \dots, X_n$ X_i oberoende $\text{Bin}(1, p)$ så $Y \sim \text{Bin}(n, p)$.

Sats

Om X och Y oberoende SV så är

$$\begin{aligned} M_{X+Y}(t) &= E[e^{(X+Y)t}] = M_X(t) M_Y(t) \\ &= E[e^{tX} e^{tY}]. \end{aligned}$$

Givet $X \sim \text{Poisson}(\lambda)$,

$$\begin{aligned} E[e^{tX}] &= \sum_{k=0}^{\infty} e^{tk} \frac{\lambda^k e^{-\lambda}}{k!} \\ &= \sum_{k=0}^{\infty} \frac{(e^t \lambda)^k e^{-\lambda}}{k!} \\ \{\text{Taylor}\} &= e^{-\lambda} e^{e^t \lambda} = e^{\lambda(e^t - 1)}. \end{aligned}$$

Sista minutens svammelTM

$Y = g(X)$, $\mu = E[X]$, $\sigma^2 = \text{Var}[X]$ liten

$$Y = g(\mu + (X - \mu)) \approx \{1:\text{a ordnings Taylor}\} \approx g(\mu) + (X - \mu) g'(\mu)$$

$$E[Y] \approx g(\mu) \quad \text{Var}[Y] \approx g'(\mu)^2 \text{Var}[X].$$

8.3 Stora talens lag

8.3.1 Repetition

Y stokastisk variabel med $E[Y] = \mu$ och $\text{Var}[Y] = \sigma^2$

Chebychevs olikhet

$$P(|Y - \mu| \geq k\sigma) \leq \frac{1}{k^2}$$

[ty Markov på $P((Y - \mu)^2 \geq k^2 \sigma^2)$]

8.3.2 Stora talens lag

Sats

Om X_1, \dots, X_n, \dots är oberoende med samma fördelning och $E(X_i) = \mu$ existerar så konvergerar

$$\frac{X_1 + \dots + X_n}{n} = \bar{x}_n$$

mot μ i meningen att $\forall \varepsilon > 0$ gäller att

$$P(|\bar{X}_n - \mu| \leq \varepsilon) \rightarrow 1 \quad \text{när } n \rightarrow \infty$$

$$(\Leftrightarrow P(|\bar{X}_n - \mu| \geq \varepsilon) \rightarrow 0 \quad \text{när } n \rightarrow \infty)$$

Bevis

Vi antar här att $\text{Var}[X_i] = \sigma^2 < \infty$.

$$E[\bar{X}_n] = \mu$$

$$\text{Var}\left[\frac{1}{n}(X_1 + \dots + X_n)\right] = \frac{1}{n^2} \left(\underbrace{\text{Var}[X_1]}_{\sigma^2} + \dots + \underbrace{\text{Var}[X_n]}_{\sigma^2} \right) = \frac{\sigma^2}{n}$$

$$P(|\bar{X}_n - \mu| \geq \varepsilon) = P\left(|\bar{X}_n - \mu| \geq \left(\frac{\omega \sqrt{n}}{\sigma}\right) \frac{\sigma}{\sqrt{n}}\right) \leq \frac{1}{\left(\frac{\varepsilon \sqrt{n}}{\sigma}\right)^2} = \frac{\sigma^2}{\varepsilon^2 n} \rightarrow 0 \quad \square$$

Specialfall

$$X \sim \text{Bin}(n, p)$$

$$\frac{X}{n} \quad \text{konvergerar i sannolikhet mot } p.$$

relativ frekvens

$$X \sim \text{Poisson}(\lambda)$$

$$\frac{X}{\lambda} \quad \text{konvergerar i sannolikhet mot } 1 \quad \text{när } \lambda \rightarrow \infty.$$

X och Y oberoende och $X \sim N(\mu_X, \sigma_X^2)$ och $Y \sim N(\mu_Y, \sigma_Y^2)$, då är

$$X + Y \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2).$$

$$\begin{aligned} M_{X+Y}(t) &= M_X(t) M_Y(t) \\ &= \left(e^{\mu_X t} e^{\frac{\sigma_X^2}{2} t^2} \right) \left(e^{\mu_Y t} e^{\frac{\sigma_Y^2}{2} t^2} \right) \\ &= e^{(\mu_X + \mu_Y)t} e^{\frac{(\sigma_X^2 + \sigma_Y^2)t^2}{2}} \end{aligned}$$

Givet X_i oberoende $N(\mu, \sigma^2)$ [ska snart visa att det kravet inte behövs!] så

$$\sqrt{n} \frac{\sum_{i=0}^n X_i - n\mu}{\sigma} \sim N(0, 1).$$

8.3.3 Centrala gränsvärdessatsen**Sats**

Givet X_1, X_2, \dots oberoende likafördelade $E[X_i] = \mu$ och $\text{Var}[X_i] = \sigma^2 < \infty$ så gäller

$$P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq x\right) \rightarrow F_{N[0,1]}$$

$$\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq x\right)$$

$$\frac{\frac{X}{n} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx N(0, 1) \quad \text{om } n \text{ stort.}$$

Handviftande bevis

$$M\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}\right)(t) \rightarrow e^{\frac{t^2}{2}}, \quad n \rightarrow \infty$$

$$\sum_{i=0}^n \left(\frac{\frac{1}{n} X_i - \mu/n}{\sigma/\sqrt{n}}\right) = \sum_{i=0}^n \underbrace{\frac{X_i - \mu}{\sqrt{n}\sigma}}_{T_i}$$

Taylor

$$M_X(t) = 1 + \mu t + \frac{E[X^2]}{2} t^2 + R$$

$$M_{Y_i}(t) = 1 + \frac{t^2}{n} + R$$

Slutsats

$$\left(1 + \frac{t^2}{n} + R\right)^n \longrightarrow e^{t^2/2}$$

(□)

9 Föreläsning 9

6 maj 2015

9.1 Repetition

X_1, \dots, X_n, \dots oberoende och likfördelade med $E[X_i] = \mu$ och $\text{Var}[X_i] = \sigma^2 < \infty$

$$P\left(\frac{(X_1 + \dots + X_n)}{\sqrt{n} \sigma} \leq x\right) \xrightarrow{n \rightarrow \infty} \Phi(x)$$

X_1, \dots, X_n är approximativt $N(n\mu; \sigma^2 n)$.

$$\text{Var}[X_1 + \dots + X_n] = n \text{Var}[X_i] = n \sigma^2$$

$$\text{Var}\left[\frac{X_1 + \dots + X_n}{n}\right] = \frac{\sigma^2}{n}$$

20 tärningskast S_{20} = summan av dem


$$E[\text{ett kast}] = 3.5$$

$$\text{Var}[\text{ett kast}] = \frac{91}{6} - 3.5^2 = \frac{35}{12}$$

S_{20} approximativt $N(70; \frac{35}{12} \cdot 20)$

$$\sqrt{20} \sigma \approx 7.64$$

9.1.1 Halvtalskorrektion



Figur. Normalfördelade staplar centrerad i 70 med 80 inringat. Halvtalskorrigeringsens area mellan 79.5-80.5 inritat.

$$P(S_{20} > 80) = 1 - P(S_{20} \leq 80) \approx 1 - \Phi\left(\frac{80 - 70}{7.64}\right)$$

$$P(S_{20} \geq 80) = 1 - P(S_{20} \leq 80) \approx 1 - \Phi\left(\frac{79 - 70}{7.64}\right)$$


$$P(S_{20} > 80) = 1 - P(S_{20} \leq 80) \approx 1 - \Phi\left(\frac{80 + 0.5 - 70}{7.64}\right)$$

$$P(S_{20} \geq 80) = 1 - P(S_{20} \leq 80) \approx 1 - \Phi\left(\frac{79 - 0.5 - 70}{7.64}\right)$$

$$P(S_{20} = 80) = \Phi\left(\frac{80 + 0.5 - 70}{7.64}\right) - \Phi\left(\frac{79 - 0.5 - 70}{7.64}\right)$$

Ok för tillräckligt stora summor. Tumregel för binomialfördelning, $np(1-p) \geq 5$.

9.2 Poissonprocesser



Figur. Poissonprocess

$N(t)$ = antalet pulser i intervallet $(0, t] \sim \text{Poisson}(tc)$, c intensitetsparameter

$N((a, b]) = N(b) - N(a)$ = antalet pulser i intervallet $(a, b] \sim \text{Poisson}((b-a)c)$ ($a < b$)

Om $(a, b] \cap (c, d] = \emptyset$, så är $N((a, b])$ och $N((c, d])$ oberoende.

En poissonprocess karakteriseras av att $A_1, A_2, A_3, \dots = T_1, T_2 - T_1, T_3 - T_2, \dots$ är en följd av oberoende $\text{expf}(c)$. $E[\Delta_i] = \frac{1}{c}$.

9.2.1 Beteckningskrock

$\text{Expf}(\lambda)$ Poisson(λ)

$\text{Expf}(c)$

$N(t) \sim \text{Poisson}(ct = \lambda)$

9.2.2 Not

$T_n \sim \Gamma$ -fördelad(n, c)

n formparameter, c ini. parameter

$$P(N(t) \leq k) = \sum_{j=0}^k \frac{(ct)^j e^{-ct}}{j!} = P(T_{k+1} > t)$$

9.3 Simuleringar

Startar med U_1, U_2, \dots ; en följd av oberoende Likf $([0, 1])$ -variabel.

$$f_{U_i}(x) = \begin{cases} 1 & x \in [0, 1] \\ 0 & x \notin [0, 1] \end{cases}$$

$$F_{U_i}(x) = \begin{cases} 0 & x \leq 0 \\ x & x \in [0, 1] \\ 1 & x \geq 1 \end{cases}$$

Givet $X \sim \text{Expf}(\lambda)$, kan vi få likformig?

$$U = F_X(x) = 1 - e^{-\lambda X}$$

$$\begin{aligned} P(1 - e^{-\lambda X} \leq u) &= P(e^{-\lambda X} \geq 1 - u) \\ &= P(-\lambda X \geq \ln(1 - u)) \\ &= P\left(X \leq -\frac{\ln(1 - u)}{\lambda}\right) \\ &= 1 - e^{-\lambda\left(-\frac{\ln(1 - u)}{\lambda}\right)} \\ &= u \end{aligned}$$

Generellt

$$X \sim F(x) \implies F(X) \sim \text{Likf}[0, 1] \quad \text{om } X \text{ kontinuerlig.}$$

Kan gå åt andra hållet

$$F(X) = U$$

$$F^{-1}(F(X)) = X = F^{-1}(U).$$

Normalfördelning?

$$\Phi^{-1}(U) \sim N(0, 1)$$

Tidigare användes två likformiga variabler för att framställa tvådimensionell fördelning genom polära koordinater. Givet X, Y oberoende $N(0, 1)$

$$R^2 = X^2 + Y^2 \sim \text{Expf}\left(\frac{1}{2}\right)$$

$$\frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} = \frac{1}{2\pi} e^{-\frac{(x^2+y^2)}{2}}$$

$$\theta = \text{Likf}(0, 2\pi)$$

$$R^2 = U_1 \longrightarrow \text{Expf}\left(\frac{1}{2}\right) \quad \Theta = U_2 \longrightarrow \text{Likf}[0, 2\pi]$$

$$\left(\sqrt{R^2} \cos \theta, \sqrt{R^2} \sin \theta\right),$$

två normalfördelade variabler!

9.3.1 Monte Carlo – simuleringar

Z_1, \dots, Z_n oberoende $N(0, 1)$

$$Y = Z_1^2 + \dots + Z_n^2 \sim \chi^2\text{-fördelad}(n) \quad \leftarrow \left(\text{släkt med } \Gamma\left(\frac{n}{2}, \frac{1}{2}\right) \right)$$

Kan dela upp fördelningen med koordinatbyte så en axel blir längs diagonal.

$$\bar{Z} = \frac{1}{n} \left(\sum_{i=1}^n Z_i \right) \sim N\left(0, \frac{1}{n}\right) \quad (\text{en variabel})$$

$$\sum_{i=1}^n (Z_i - \bar{Z})^2 \sim \chi^2\text{-fördelad}(n-1) \quad (n-1 \text{ variabler})$$

(stickprovsvarians $(n-1)S_z^2$)

10 Föreläsning 10

11 maj 2015

10.1 χ^2 -fördelning

Givet Z_1, \dots, Z_n oberoende $N(0, 1)$ så är

$$\sum_{i=1}^n Z_i^2 \sim \chi^2\text{-fördelning}(n).$$

$$\bar{Z} = \frac{1}{n} \left(\sum_{i=1}^n Z_i \right) \sim N \left(0, \frac{\sigma^2}{\sqrt{n}} \right)$$

$$\sum_{i=1}^n (Z_i - \bar{Z})^2 \sim \chi^2\text{-fördelad}(n-1)$$

$\triangleq (n-1)S_Z^2$

Där

$$S_Z^2 = \frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2$$

kallas för stickprovsvariansen för Z_1, \dots, Z_n ,

$$f_{Z_1, \dots, Z_n}(Z_1, \dots, Z_n) = \frac{1}{(2\pi)^{n/2}} e^{-\frac{1}{2}(\sum Z_i^2)}.$$

10.2 Student's t -fördelning

Om U och V är oberoende, $U \sim N(0, 1)$ och $V \sim \chi^2(r)$, då sägs

$$T = \frac{U}{\sqrt{\frac{V}{r}}}$$

vara (Student's) t -fördelad(r).

Påstående

Om X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$ så är

$$\sqrt{n} \frac{\bar{X} - \mu}{S_X} \sim t\text{-fördelad}(n-1).$$

Bevis

$$\sqrt{n} \frac{\bar{Z}}{S_Z} \sim t\text{-fördelad}(n-1)$$

ty

$$\sqrt{n} \frac{\bar{Z}}{S_Z} = \frac{\sqrt{n}\bar{Z}}{\sqrt{\frac{(n-1)S_Z^2}{n-1}}} \leftarrow N(0, 1) \cdot \leftarrow \chi^2(n-1)$$

Om $Z_i = \frac{X_i - \mu}{\sigma}$ oberoende $N(0, 1) \implies \bar{Z} = \frac{\bar{X} - \mu}{\sigma}$.

$$\begin{aligned}
 S_Z^2 &= \frac{\sum_{i=1}^n (Z_i - \bar{Z})^2}{n-1} \\
 &= \frac{\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma} - \frac{\bar{X} - \mu}{\sigma} \right)^2}{n-1} \\
 &= \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2(n-1)} \\
 &= \frac{S_X^2}{\sigma^2} \\
 \implies \sqrt{n} \frac{\bar{Z}}{S_Z} &= \frac{\sqrt{n} \left(\frac{\bar{X} - \mu}{\sigma} \right)}{\sqrt{\frac{S_X^2}{\sigma^2}}} = \sqrt{n} \frac{\bar{X} - \mu}{S_X} \sim t\text{-fördelad}(n-1).
 \end{aligned}$$

500 häftstiftkast, 128 spets nedåt

$$p = P(\text{spets nedåt i enskilt kast}) = \frac{128}{500} = 25.6\% \quad \leftarrow \text{observerad relativ frekvens}$$

Innan:

$X = \text{antal stift med spets nedåt} \sim \text{Bin}(n, p)$, p okänd

$$\hat{p} = \frac{X}{n} = (\text{teoretisk}) \text{ relativ frekvens}$$

\hat{p} är en punktskattning av p

Om p riktiga parametern så är

$$E[\hat{p}] = E_p[\hat{p}] = E_p\left[\frac{X}{n}\right] = \frac{np}{n} = p,$$

$$\text{Var}[\hat{p}] \quad (=E[(\hat{p} - p)^2]) \quad = \frac{1}{n^2} \text{Var}[X] = \frac{p(1-p)}{n}$$

$$\sqrt{\text{Var}(\hat{p})} = \text{standardfelet (teoretiskt)} = \sqrt{\frac{p(1-p)}{n}}$$

(definition om punktskattningen är väntevärdesriktig)

10.3 Skattade standardfel

$$\sqrt{\frac{\frac{X}{n} \left(1 - \frac{X}{n}\right)}{n}} = \sqrt{\frac{\frac{X}{n} \left(1 - \frac{X}{n}\right)}{n}} = \sqrt{\frac{X(n-X)}{n^3}}$$

X_1, \dots, X_n oberoende $\text{Expf}(\lambda)$, λ okänd. Hur skatta λ ?

10.4 Momentmetoden

Momentmetoden säger att vi skall använda ekvationssystemet

$$\frac{1}{n} \left(\sum_{i=1}^n X_i \right) = \bar{X} = E[X_i] = \frac{1}{\lambda}$$

(empiriskt förstamoment)

och lös detta

$$\hat{\lambda} = \frac{1}{\bar{X}}.$$

X_1, \dots, X_n oberoende $N(\mu; \sigma^2)$, båda okända.

$$\frac{1}{n} \left(\sum_{i=1}^n X_i \right) = \bar{X} = E[X_i] = \mu$$

$$\frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) = E[X^2] = \text{Var}[X_i] + (E[X_i])^2 = \sigma^2 + \mu^2$$

empiriska andramomentet

$\hat{\mu} = \bar{X}$ är väntevärdesriktig punktskattning av μ . ([sic] $\hat{\mu} = \bar{X}$ wr. p.s. av μ)

$$\hat{\mu} = \bar{X}$$

$$\sigma^2 = \frac{1}{n} \left(\sum_{i=1}^n X_i^2 \right) - (\bar{X})^2 = \frac{1}{n} \left(\sum_{i=1}^n (X_i - \bar{X})^2 \right) = \frac{(n-1) S_X^2}{n}$$

Exempel

X_1, \dots, X_n oberoende poissonfördelade med parameter λ .

$$p_\lambda(x_1, \dots, x_n) = p(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n \frac{\lambda^{x_i} e^{-\lambda}}{x_i!} \quad L(\lambda; x_1, \dots, x_n)$$

Fixera ett tänkt utfall, leta upp λ som maximerar sannolikheten för det utfallet. Kalla detta för

$$\hat{\lambda}(x_1, \dots, x_n).$$

Uppskattningen $\hat{\lambda}(x_1, \dots, x_n)$ kallas för den teoretiska maximum likelihood-uppskattningen av λ .

$$\frac{d}{d\lambda} \sum_{i=1}^n \ln \left(\frac{\lambda^{x_i} e^{-\lambda}}{x_i!} \right) = 0$$

$$\frac{d}{d\lambda} \left(\sum_{i=1}^n x_i \ln(\lambda) - n\lambda - \sum_{i=1}^n \ln(x_i!) \right) = \frac{n\bar{x}}{\lambda} - n = 0$$

$\Rightarrow 0$

$$\Rightarrow \hat{\lambda} = \bar{x}.$$

11 Föreläsning 11

13 maj 2015

1. Mer om punktskattningar
2. Konfidensintervall

11.1 ML-skattningar av μ och σ^2 i normalfördelade stickprov

$$X_1, \dots, X_n \text{ oberoende } X_i \sim N(\mu, \sigma^2) \quad \mu \in \mathbb{R}, \sigma^2 \in \mathbb{R}^+$$

Hur skatta paret av parametrar om båda är okända?

Hitta $\hat{\mu}$ och $\hat{\sigma}^2$ som maximerar likelihood-funktionen $L(\mu, \sigma^2, X_1, \dots, X_n) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2} \frac{(x_i - \mu)^2}{\sigma^2}}$.

$$\begin{cases} \frac{d}{d\mu} \ln L(\mu, \sigma^2) = 0 \\ \frac{d}{d\sigma} \ln L(\mu, \sigma^2) = 0 \quad \left(\frac{d}{d\sigma^2} \text{ ger samma slutresultat} \right) \end{cases}$$

$$L(\mu, \sigma^2) = \frac{1}{(2\pi)^{\frac{n}{2}}} \frac{1}{\sigma^n} e^{-\frac{1}{2} \frac{\sum_{i=1}^n (x_i - \mu)^2}{\sigma^2}}$$

$$-n \ln \sigma - \frac{\frac{1}{2} \sum_{i=1}^n (x_i - \mu)^2}{\sigma^2}$$

$$\begin{cases} -\sum_{i=1}^n (X_i - \mu) = 0 \\ -\frac{n}{\sigma} + \sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^3} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \bar{X} \\ \hat{\sigma}^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n} \end{cases}$$


(samma skattning som momentuppskattningar)

Exempel

ML-skattning för ett stickprov på

$$f_{\theta}(x) = \begin{cases} \frac{1}{\theta}, & 0 \leq x \leq \theta \\ 0, & x > \theta \end{cases}, \quad \theta > 0,$$

$$L(\theta; X_1, \dots, X_n) = \prod_{i=1}^n f_{\theta}(x_i) = \left(\frac{1}{\theta}\right)^n \quad \text{om } \theta \geq \max(X_1, \dots, X_n).$$



Figur. Likelihoodfunktionen. Maximeras om $\hat{\theta} = \max(X_1, \dots, X_n)$.


11.2 Filosofidags

11.2.1 Enstickprovsmodeller

X_1, \dots, X_n oberoende likfördelade där X_i har fördelningsfunktion $F \in \mathcal{F}$ = klass av fördelningsfunktion; kan vara diskreta heltalsvärda fördelningar, kan vara kontinuerliga fördelningar.

\mathcal{F} kan t.ex. vara {positiva förd., väsentligen kont. täthet f .}

Ofta tillägg av tekniskt villkor, typ $\text{Var}_f[X_i] = \sigma_q^2 < \infty$.



Figur. Kontinuerligt f .

$$\mu = \text{väntevärdet} = \int_0^{\infty} x f(x) dx = \mu(f)$$

$$\begin{array}{l} \bar{X} \text{ p.s. } \mu \\ S^2 \text{ p.s. } \sigma^2 \\ m^2, \quad \int_0^m f(x) dx = \frac{1}{2} \end{array}$$

(p.s. = punktskattning)

Ordnat stickprov

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

$$\hat{m} = \begin{cases} X\left(\left[\frac{n+1}{2}\right]\right) & n \text{ udda} \\ \frac{X\left(\left[\frac{n}{2}\right]\right) + X\left(\left[\frac{n}{2}\right] + 1\right)}{2} & n \text{ jämnt} \end{cases}$$

Om vi känt till fördelningen

Säg expf

$$\begin{array}{l} \mu = \frac{1}{\lambda} \\ \sigma^2 = \frac{1}{\lambda^2} \\ m = \frac{\ln 2}{\lambda} \\ \text{o.s.v.} \end{array}$$

1. Hittar vi en bra skattning för $\lambda, \hat{\lambda}$. ($\hat{\lambda} = \frac{1}{\bar{X}}$)

2. $\hat{\mu} = \frac{1}{\hat{\lambda}^2} = \bar{X}$, $\hat{\sigma}^2 = \frac{1}{\hat{\lambda}^2} = \frac{1}{(\bar{X})^2}$, $\hat{m} = \frac{\ln 2}{\hat{\lambda}} = \frac{\ln 2}{\bar{X}}$

$$\gamma = \mu + 1.65 \sigma$$

(95%-fraktilen i sannoliketsfördelningen)

$$\hat{\gamma} = \hat{\mu} + 1.65 \hat{\sigma} \longrightarrow \bar{X} + 1.65 S$$


Empirisk fördelning

Lägg $\frac{1}{n}$ i varje observation,

$$\hat{F}(x) = \frac{\text{Antalet}\{i \leq n, X_i \leq x\}}{n}, \quad x \in \mathbb{R}$$

11.3 Bayesisk statistik

X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$, $\mu \in \mathbb{R}$, $\sigma^2 \geq 0$.



Figur. X_i placerade längs realaxel.

Skatta

$$\hat{\mu} = \bar{X} \approx \mu$$

$$S^2 = \frac{1}{n-1} \left(\sum_{i=1}^n (X_i - \bar{X})^2 \right) \approx \sigma^2$$


$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right), \quad \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

$$\sqrt{n} \frac{\bar{X} - \mu}{S} \sim (\text{students}) t\text{-fördelad}(n-1)$$

$n=7$

t -fördelad(7-1) = t -fördelad(6)

$$P\left(\sqrt{n} \frac{\bar{X} - \mu}{S} \leq c\right) \iff P\left(\mu \geq \bar{X} - \frac{1.9435}{\sqrt{n}}\right) = 0.95$$




Figur. Två fördelningar, en normalfördelning och en t -fördelning. där t -fördelningen har 95+% markerat och text som säger att den arean är 1.65 för $t(6)$.

$\left[\bar{X} - \frac{1.9435}{\sqrt{n}}, \infty \right)$ är ett 95% nedåt begränsat konfidensintervall för μ .

Tvåsidigt konfidensintervall

$$P\left(-c \leq \frac{\sqrt{n}(\bar{X} - \mu)}{S} \leq c\right) = F_{t(n-1)}(c) - F_{t(n-1)}(-c) \\ = q$$

$$P\left(\bar{X} - \frac{cS}{\sqrt{n}} \leq \mu \leq \bar{X} + \frac{cS}{\sqrt{n}}\right) = q$$



Figur. En t -fördelning centrerad i 0 med $n=7$ och $q=0.99$ där areor 0.5% på vardera sidor är markerade.

Dyrare med tvåsidigt intervall. Dyrare med högre precision.

$$\sqrt{n} \frac{\bar{X} - \mu}{\sigma} \sim N(0, 1) \quad \text{om } \sigma \text{ känt}$$

För stora n kan vi approximera med normalfördelningen. För små n är det viktigt att använda rätt fördelning.

12 Föreläsning 12

18 maj 2015

- Repetition konfidensintervall
- Nya konfidensintervall
- Hypotesprövning

12.1 Repetition för konfidensintervall

X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$

Känd varians, söker konfidensintervall för μ .

$$\underbrace{\sqrt{n} \frac{\bar{X} - \mu}{\sigma}}_{\text{(pivot)}} \sim N(0, 1)$$

Ensidigt uppåt begränsat konfidensintervall för μ .

$$P\left(\underbrace{\sqrt{n} \frac{\bar{X} - \mu}{\sigma} \geq c}_{1 - \Phi(c) = q}\right) = q$$

Ex. $q = 0.95 \implies c = -1.65$

$$P\left(\mu \leq \bar{X} - c \frac{\sigma}{\sqrt{n}}\right) = q$$

$$\mu \in \left(-\infty; \bar{X} - c \frac{\sigma}{\sqrt{n}}\right] \quad (q \cdot 100\%)$$

$q = 0.95$

$$\mu \in \left(-\infty; \bar{X} + 1.65 \frac{\sigma}{\sqrt{n}}\right] \quad (95\%)$$

σ okänd:

$$\underbrace{\sqrt{n} \frac{\bar{X} - \mu}{S}}_{\text{(pivot)}} \sim t\text{-fördelad}(n - 1)$$

$X \sim \text{Bin}(n, p)$

$$\frac{X - np}{\sqrt{np(1-p)}} \approx N(0, 1) \quad \text{när } n \text{ stort (om } np(1-p) \text{ stort)}$$

med $\hat{p} = \frac{X}{n}$

$$\frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \approx \left\{ \frac{\sqrt{\hat{p}(1-\hat{p})}}{\sqrt{p(1-p)}} \approx 1, \quad n \text{ stort} \right\} \approx \frac{\hat{p} - p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}}$$

Exempel

99% symmetriskt konfidensintervall för p . (n stort)

$$P\left(-2.58 \leq \frac{\hat{p} - p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}} \leq 2.58\right) \approx 2\Phi(2.58) - 1 = 0.99$$

$$p = \hat{p} \pm 2.58 \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \quad (\approx 99\%)$$

$$p = \hat{p} \pm 1.96 \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \quad (\approx 95\%)$$

Standardfelet skalar som rot mot stickprovsstorlek.

Exempel

X_1, \dots, X_n oberoende $\text{Expf}(\lambda)$

För stora stickprov

$$\bar{X} \approx N\left(\frac{1}{\lambda}, \frac{1}{n\lambda^2}\right)$$

$$\frac{\bar{X} - \frac{1}{\lambda}}{\sqrt{\frac{1}{n\lambda^2}}} = \sqrt{n} \frac{\bar{X} - \frac{1}{\lambda}}{\frac{1}{\lambda}} \underset{(\text{pivot})}{\approx} N(0, 1)$$

Alternativ, exakta metoder

$$2\lambda \left(\sum_{i=1}^n X_i\right) \sim \chi^2(2n)$$

från $\text{Expf}(\frac{1}{2}) = \chi^2(2)$

Exempel

X_1, \dots, X_n oberoende $\text{Poisson}(\lambda)$, n stort

$$\bar{X} \approx N\left(\lambda; \frac{\lambda}{n}\right)$$

$$\frac{\bar{X} - \lambda}{\sqrt{\frac{\lambda}{n}}} = \sqrt{n} \frac{\bar{X} - \lambda}{\sqrt{\lambda}} \approx N(0, 1)$$

Om observerat $\bar{X} = 3.5$, $n = 20$, $\approx 95\%$ symmetriskt konfidensintervall

$$\lambda = \bar{X} \pm 1.96 \sqrt{\frac{\bar{X}}{20}} \quad (\approx 95\%),$$

observerat konfidensintervall

$$\lambda = 3.5 \pm 1.96 \sqrt{\frac{3.5}{20}} \quad (\approx 95\%).$$

Exempel

X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$ och μ okänt. Konfidensintervall för σ^2 ?

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

Undre bägränsning

$$P\left(\frac{(n-1)S^2}{\sigma^2} \geq c\right) = 1 - F_{\chi^2(n-1)}(c) = q$$

$$\sigma^2 \leq \frac{(n-1)S^2}{c} \quad (q \cdot 100\%).$$

Exempel

X_1, \dots, X_n oberoende $E[X_i]$ existerar och $\text{Var}[X_i] = \sigma^2 < \infty$ och vi vet σ^2 .

$$\sqrt{n} \frac{\bar{X} - \mu}{\sigma} \approx N(0, 1) \quad \text{ty c.gr.v.s}$$

(pivot)

n stort nog, storleksordning 30.

Om σ^2 okänd används $\sqrt{n} \frac{\bar{X} - \mu}{S} \approx N(0, 1)$, och väldigt stora n krävs.

12.2 Hypotestester

12.2.1 Exempel

Vi misstänker att en tärning är manipulerad så att $p = P(\text{"sex"} > \frac{1}{6}) > \frac{1}{6}$. Vi vill visa att vi har rätt genom att göra ett antal experiment (n) där vi kastar tärningen och räknar antalet sexor.

$$X \sim \text{Bin}(p)$$

Det vi vill motbevisa är att $H_0: p = \frac{1}{6}$ (ev. $p \leq \frac{1}{6}$).

Naturliga beslutsregler

- Vi hade rätt om $X \geq c \in \mathbb{Z}$ är välvalt.
- Vi hade kanske fel om $X < c$.

$$P_{H_0}(X \geq c) = P_{\text{Bin}(n,p)}(X \geq c) \approx 1 - \Phi\left(\frac{c - n\frac{1}{6} - \frac{1}{2}}{\sqrt{n\frac{1}{6}\frac{5}{6}}}\right) \lesssim \alpha = \text{signifikansnivån} \quad n \text{ stort}$$


X kallas för testvariabel, $p = \frac{1}{6}$ som kritiskt värde.

Typiska val av $\alpha = 0.05, 0.01, 0.001$

Testets styrka i alternativet p ($p \geq \frac{1}{6}$).

$$\begin{aligned} P_p(X \geq c) &= P_p(\text{förkasta nollhypotesen}) \\ &= 1 - \Phi\left(\frac{c_\alpha(n) - np - \frac{1}{2}}{\sqrt{np(1-p)}}\right) \end{aligned}$$

Denna är ensidig. Enbart större än $\frac{1}{6}$. Vanligt med tvåsidig, d.v.s. avvikelser åt båda håll straffas.



Figur. Illustration för styrka för kurvor för olika n .

X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$

$$H_0: \mu = \mu_0, \quad \text{ofta } \mu_0 = 0$$

$$T = \sqrt{n} \frac{\bar{X} - \mu_0}{S} \sim t\text{-fördelad}(n-1)$$

$$H_1: \mu \neq \mu_0 \quad \text{tvåsidigt test} \quad |T| \geq c$$

$$H_1': \mu > \mu_0 \quad \text{ensidigt test} \quad T > c'$$

$$H_1'': \mu < \mu_0 \quad \text{ensidigt test} \quad T < c''$$



Figur. Konfidensintervallet, konfidsgrad som är $1 - \alpha$.

12.3 Tvåstickprov

$$\frac{\bar{X} - \bar{Y} - (\mu_X - \mu_Y)}{S_p \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t(m+n-2)$$

$$S_p^2 = \frac{(n-1)S_X^2 + (m-1)S_Y^2}{m+n-2}$$

$$X_1, \dots, X_n \quad X_i \sim N(\mu_X, \sigma^2) \quad Y_1, \dots, Y_m \quad Y_i \sim N(\mu_Y, \sigma^2)$$

Inlämningsuppgiften: hur stora stickprov behöver göras för att kunna garantera rätt styrka? m.m.

13 Föreläsning 13

21 maj 2015

Tvåstickprovsmetoder

1. Normalfördelad
2. Binomialfördelad

Nästa gång: linjär regression och tvådimensionella normalfördelningar.

13.1 Enstickprov

Exempel

X_1, \dots, X_n oberoende $N(\mu, \sigma^2)$, σ^2 okänt. $H_0: \mu = 0$ mot $H_1: \mu \neq 0$.


Tvåsidigt t-test

Teststatistika

$$T = \sqrt{n} \frac{\bar{X} - 0}{S_X} \stackrel{H_0}{\sim} t\text{-förd}(n-1).$$

Förkasta nollhypotesen om $|T| \geq c$, d.v.s. om $T \leq -c$ eller $T \geq c$

$$P_{H_0}(|T| \geq c) = 2(1 - F_{t(n-1)}(c)) = \alpha, \quad \alpha = \text{signifikansnivå}, c = \text{kritiska värdet}.$$



Figur. Normalfördelning med kritiska värdet inritat.

Vid genomförande av testet använder man observationerna X_1, \dots, X_n och beräknar ett utfall på T , t . Om $t < -c$ så tror vi på alternativet $\mu < 0$ och om $t > c$ så tror vi på alternativet $\mu > 0$.

$$\mu = \bar{X} \pm c \frac{S}{\sqrt{n}} \quad ((1 - \alpha) \cdot 100\%)$$

Exempel – Test av medianer

X_1, \dots, X_n oberoende med fördelningsfunktion F .

$$H_0: m = m_0 \quad (m: F(m) = \frac{1}{2})$$


$T =$ antalet $X_i \leq m_0$

$$T \sim \text{Bin}(n, \frac{1}{2}) \quad F(m_0) = \frac{1}{2}$$

Förkasta om $|T - \frac{n}{2}| \geq c$ för lämpliga c .


Om $T \geq \frac{n}{2} + c$, tyder på $m < m_0$.

Om $T \leq \frac{n}{2} - c$, tyder på $m > m_0$.



Figur. Stickprov kring median.

13.2 Tvåstickprov



Figur. Figur som visar två normalfördelademängder med väntevärde μ_X och μ_Y och stickprov utritade.

Två oberoende stickprov

$$X_1, \dots, X_n \quad Y_1, \dots, Y_m, \quad X_i \sim N(\mu_X, \sigma_X^2), Y_j \sim N(\mu_Y, \sigma_Y^2).$$

Om både σ_X^2 och σ_Y^2 är kända så

$$\hat{\mu}_X = \bar{X} \sim N\left(\mu_X; \frac{\sigma_X^2}{n}\right)$$

$$\hat{\mu}_Y = \bar{Y} \sim N\left(\mu_Y; \frac{\sigma_Y^2}{m}\right).$$

Differensen

$$\Delta_\mu = \mu_Y - \mu_X \approx \hat{\mu}_Y - \hat{\mu}_X \sim N\left(\mu_Y - \mu_X, \frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}\right)$$

Pivot

$$\frac{\bar{Y} - \bar{X} - (\mu_Y - \mu_X)}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}}} \sim N(0, 1).$$

$$\Delta_\mu = (\hat{\mu}_Y - \hat{\mu}_X) \pm c \sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}} \quad ((2\Phi(c) - 1) 100\%)$$

$$\frac{\bar{Y} - \bar{X} - \Delta_\mu}{\sqrt{\frac{S_X^2}{n} + \frac{S_Y^2}{m}}} \approx N(0, 1) \quad \text{om både } m \text{ och } n \text{ stora.}$$

X_1, \dots, X_n Y_1, \dots, Y_n oberoende $X_i \sim N(\mu_X, \sigma^2)$ och $Y_j \sim N(\mu_Y, \sigma^2)$
 σ^2 (samma i båda stickproven) känd.

Från tidigare enstickprovsteorin vet vi att

$$\bar{X}, \frac{(n-1)S_X^2}{\sigma^2} \quad \text{och} \quad \bar{Y}, \frac{(m-1)S_Y^2}{\sigma^2}$$

är oberoende

$$\begin{aligned} \bar{X} &\sim N\left(\mu_X, \frac{\sigma^2}{n}\right) & \frac{(n-1)S_X^2}{\sigma^2} &\sim \chi^2(n-1) \\ \bar{Y} &\sim N\left(\mu_Y, \frac{\sigma^2}{m}\right) & \frac{(m-1)S_Y^2}{\sigma^2} &\sim \chi^2(m-1). \end{aligned}$$

Vad kan vi säga om

$$\Delta_\mu = \mu_y - \mu_x?$$

$$\frac{\bar{Y} - \bar{X} - \Delta_\mu}{\sigma \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim N(0, 1)$$

(och oberoende)

$$\frac{(m+n-2)S_P^2}{\sigma^2} = \frac{(n-1)S_X^2 + (m-1)S_Y^2}{\sigma^2}$$

$$\left(S_p^2 = \frac{(n-1)S_X^2 + (m-1)S_Y^2}{m+n-2} \right)$$

$$\frac{\bar{Y} - \bar{X} - \Delta_\mu}{S_p \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t\text{-fördelad}(m+n-2)$$

o.s.v. för konstruktion av konfidensintervall.

13.3 Tvåstickprovs t -test (samma modell)

$$H_0: \Delta_\mu = 0 \quad T = \frac{\bar{Y} - \bar{X} - 0}{S_p \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t\text{-fördelad}(n+m-2)$$

Exempel (tvåsidig mothypotes)

$$H_1: \Delta_\mu \neq 0$$

$T \leq -c$ eller $T \geq c \implies$ förkasta H_0 . $2(1 - F_{t(m+n-2)}(c)) = \alpha \quad \leftarrow$ signifikansnivå.

Avgörande för styrkan blir $m, n \dots$ och $\frac{\mu_Y - \mu_X}{\sigma}$.

Om oberoende mellan paren $(X_1, Y_1), (X_2, Y_2) \dots (X_n, Y_n)$, så måste mått inom paren exempelvis

$$\Delta_i = Y_i - X_i \sim N(\Delta, \sigma^2)$$

och använder enstickprovsteori för analys av $E[Y_i - X_i] = E[Y_i] - E[X_i]$. Kan öka precision på resultaten genom att valda par eliminerar vissa variabler, exempel ålder.

Exempel

$$X \sim \text{Bin}(n, p_X) \quad Y \sim \text{Bin}(m, p_Y)$$

$p_Y - p_X$? söker konfidensintervall

Sätt $\hat{p}_X = \frac{X}{n}$ och $\hat{p}_Y = \frac{Y}{m}$.

Pivot

$$\frac{\hat{p}_Y - \hat{p}_X - (p_Y - p_X)}{\sqrt{\frac{p_Y(1-p_Y)}{m} + \frac{p_X(1-p_X)}{m}}}$$

och vi gör antagande att m och n stort så att vi kan approximera som

$$\frac{\hat{p}_Y - \hat{p}_X - (p_Y - p_X)}{\sqrt{\frac{\hat{p}_Y(1-\hat{p}_Y)}{m} + \frac{\hat{p}_X(1-\hat{p}_X)}{m}}} \approx N(0, 1).$$

Då får vi konfidensintervall

$$p_Y - p_X = \hat{p}_Y - \hat{p}_X \pm c \sqrt{\frac{\hat{p}_Y(1-\hat{p}_Y)}{m} + \frac{\hat{p}_X(1-\hat{p}_X)}{m}} \quad ((2\Phi(c) - 1) \cdot 100\%).$$

14 Föreläsning 14

25 maj 2015

- Linjär regression
- Tvådimensionella normalfördelningar
- Nästa gång löser vi Aug. 2014 omtenta


14.1 Linjär regression

x_1, \dots, x_n deterministiska värden på en inställningsvariabel $x \in \mathbb{R}$. För varje inställning gör vi ett försök och mäter en svarsvariabel y_1, \dots, y_n , innan förs- så Y_1, \dots, Y_n (oberoende).

$$E[Y_i] = \alpha + \beta x$$

$$Y_i = E[Y_i] + \varepsilon_i \quad \leftarrow \text{residual.}$$

$\text{Var}[Y_i] = \sigma^2$ likadana för alla i (x_i) (homo"scedastisk" modell) + normalfördelningsantagande



Figur. Mätningar längs x och linjär regression.

Statistik för α, β och σ . Hur skattar man? Maximum likelihood-skattningar.

Vad är likelihood-funktionen?

$$\begin{aligned} L(\alpha, \beta, \sigma) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2} \frac{(y_i - (\alpha + \beta x_i))^2}{\sigma^2}} \\ &= \frac{1}{(\sqrt{2\pi} \sigma)^n} e^{-\frac{1}{2} \frac{\sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2}{\sigma^2}} \end{aligned}$$

Fixera σ^2 , då optimeras (maximeras) L av argumentet som

$$(\hat{\alpha}, \hat{\beta}) = \operatorname{argmin} \left(\sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2 \right), \quad x_i \text{ och } y_i \text{ kända.}$$

Får ekvationssystem

$$\begin{aligned} \frac{d}{d\alpha} \sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2 &= -2 \sum_{i=1}^n (y_i - (\alpha + \beta x_i)) = 0 \\ \frac{d}{d\beta} \sum_{i=1}^n (y_i - (\alpha + \beta x_i))^2 &= -2 \sum_{i=1}^n x_i (y_i - (\alpha + \beta x_i)) = 0 \end{aligned}$$

Insubstitution av

$$\bar{y} - \alpha - \beta \bar{x} = 0$$

ger

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \left(= \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} Y_i \sim N\left(\beta, \frac{\sigma^2}{\sum_{j=1}^n (x_j - \bar{x})^2}\right) \right)$$

(teoretisk varians)

och vidare

$$\hat{\alpha} = \underbrace{\bar{Y} - \hat{\beta} \bar{x}}_{\text{oberoende, visas separat}} \sim N\left(\alpha, \sigma^2 \left(\frac{1}{n^2} + \bar{x}^2 \frac{1}{\sum_{j=1}^n (x_j - \bar{x})^2}\right)\right).$$

$$0 = -\frac{d \ln L(\hat{\alpha}, \hat{\beta}, \sigma)}{d\sigma} \implies \sigma^2 = \frac{1}{n} \sum_{i=1}^n (y_i - (\hat{\alpha} + \hat{\beta} x_i))^2 = \frac{n-2}{n} S^2$$

$$\text{där } S^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - (\hat{\alpha} + \hat{\beta} x_i))^2.$$


Sats

I en linjär regressionsmodell med α , β och σ^2 som intercept-, lutnings- och variansparametrar (och med normalfördelningsantagande) så gäller

$$\begin{aligned} \hat{\beta} &\sim N\left(\beta, \frac{\sigma^2}{\sum_{j=1}^n (x_j - \bar{x})^2}\right) \\ \bar{Y} &\sim N\left(\alpha + \beta \bar{x}, \frac{\sigma^2}{n}\right) \\ \frac{(n-2)S^2}{\sigma^2} &\sim \chi^2\text{-fördelad}(n-2) \end{aligned}$$

(alla oberoende).

$$\begin{aligned} \hat{\alpha} &= \bar{Y} - \hat{\beta} \bar{x} \\ &= \alpha(1, 1, \dots, 1) + \beta(x_1, x_2, \dots, x_n) \end{aligned}$$



Figur. Geometrisk tolkning rörande oberoende.

14.2 Pivoter för konfidensintervall

$$\sigma^2 \text{ känt} \quad \frac{\hat{\beta} - \beta}{\sigma \sqrt{\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim N(0, 1)$$

Exempel

Symmetrisk 99%

$$\beta = \hat{\beta} \pm 2.58 \frac{\sigma}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad (99\%).$$

Om σ^2 okänt

$$\frac{\hat{\beta} - \beta}{S \sqrt{\frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t\text{-fördelad}(n-2).$$

För α fås


$$\frac{\hat{\alpha} - \alpha}{\sigma \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim N(0, 1) \quad (\text{känt } \sigma)$$

och

$$\frac{\hat{\alpha} - \alpha}{S \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t\text{-fördelad}(n-2) \quad (\text{okänt } \sigma).$$

$$\hat{\alpha} + \hat{\beta} x_0 = \bar{Y} + \hat{\beta} (x_0 - \bar{x}) \sim N\left(\alpha + \beta x_0, \sigma^2 \left(\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}\right)\right)$$

$$\hat{\alpha} + \beta X = \hat{\alpha} + \hat{\beta} (x - \bar{x})$$



Figur. Skärande linjer med skärningspunkt i (\bar{X}, \bar{Y}) . Nya mätningen x_0 i räkningarna inritad.

$$\frac{\hat{\alpha} + \hat{\beta} x_0 - (\alpha + \beta x_0)}{S \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}} \sim t(n-2)$$

Låt Y_{n+1} vara en ny observation vid inställning x_0

$$\hat{\alpha} + \hat{\beta} x_0 - Y_{n+1} \sim N\left(0, \sigma^2 \left(1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}\right)\right)$$

$$Y_{n+1} = \hat{\alpha} + \hat{\beta} x_0 \pm c S \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}} \quad [(2 F_{t(n-2)}(c) - 1) \cdot 100\%]$$

Detta kallas för prediktionsintervall.


14.3 Tvådimensionell normalfördelning

X och Y tvådimensionellt normalfördelningar

$$\begin{aligned} E[X] &= \mu_X & E[Y] &= \mu_Y \\ \text{Var}[X] &= \sigma_X^2 & \text{Var}[Y] &= \sigma_Y^2 \\ \text{och } S &= \frac{\text{Kov}[X, Y]}{\sigma_X \sigma_Y}, & -1 < s < 1. \end{aligned}$$

Fördelningsfunktion

$$f_{(X,Y)}(x, y) = \frac{1}{2\pi \sigma_X \sigma_Y \sqrt{1 - \rho^2}} e^{-\frac{1}{2} \left(\left(\frac{x - \mu_X}{\sigma_X} \right)^2 + \left(\frac{y - \mu_Y}{\sigma_Y} \right)^2 + 2\rho \left(\frac{x - \mu_X}{\sigma_X} \right) \left(\frac{y - \mu_Y}{\sigma_Y} \right) \right)}.$$



Figur. Skärning av en tvådimensionell normalfördelning.

$$f_{(Y|X)}(y|x) = N\left(\mu_Y + \rho \frac{x - \mu_X}{\sigma_X} \sigma_Y, \sigma_Y^2 (1 - \rho^2)\right)$$

15 Föreläsning 15

27 maj 2015

15.1 Tentan från 27 Augusti 2014

15.1.1 1.

Tre tärningar kastas

a) $P(\underbrace{\text{summa}=4}_A)$, $A = \{(1, 1, 2), (1, 2, 1), (2, 1, 1)\}$. Totala antalet $6 \times 6 \times 6$.

$$\frac{3}{6^3}$$

b)

$$1 - \frac{4}{6^3}$$

c)

$$A = \{3 \times (1, 1, 6), 3! \times (1, 2, 3)\}$$

$$\frac{3 + 3!}{6^3} = \frac{9}{6^3}$$

15.1.2 2.

$$P(A) = 0.2, P(B) = 0.4, P(C) = 0.9, \quad A, B, C \text{ oberoende.}$$

a) $P = (1 - 0.2)(1 - 0.4)(1 - 0.9) = 0.8 \times 0.6 \times 0.1 = 0.048$ b) $X =$ antalet som inträffar. $E(X) = ?$

$$I_A = \begin{cases} 1 & \text{om } A \text{ inträffar} \\ 0 & \text{om } A \text{ inte inträffar} \end{cases}$$

$$X = I_A + I_B + I_C \implies E[X] = E[I_A] + E[I_B] + E[I_C] = 0.2 + 0.4 + 0.9 = 1.5$$

c)

$$\text{Var}[I] = E[I^2] - E[I]^2 = \{\text{här, ty } I = I^2\} = E[I] - E[I]^2$$

$$\text{Var}[X] = \{\text{ober.}\} = \text{Var}[I_A] + \text{Var}[I_B] + \text{Var}[I_C] = 0.2 \times 0.8 + 0.4 \times 0.6 + 0.9 \times 0.1 = 0.49$$

15.1.3 3.

a) ML-skattning?

$$L(\theta, x_1, \dots, x_4) = \prod_{i=1}^4 \frac{\left(\frac{1}{\theta}\right)^{x_i} e^{-\frac{1}{\theta}}}{x_i!} = \frac{1}{x_1! \dots x_4!} \left(\frac{1}{\theta}\right)^{\sum_{i=1}^4 x_i} e^{-4\frac{1}{\theta}}$$

$$\begin{aligned} \frac{d}{d\theta} \ln L(\theta) &= 0 + \frac{d}{d\theta} \left(-\ln(\theta) \sum_{i=1}^4 x_i \right) + \frac{4}{\theta^2} \\ \iff -\frac{1}{\theta} \left(\sum_{i=1}^4 x_i \right) + \frac{4}{\theta^2} &= 0 \implies \hat{\theta} = \frac{1}{\bar{X}} \end{aligned}$$

b) Sätt in siffror.

15.1.4 4.

a) $\hat{\lambda} = \frac{1}{\bar{X}}$ obs. $\hat{\lambda} = \frac{1}{3.8}$ (Momentmetod eller maximum likelihood)

b) Ex. $E[X_i = \frac{1}{\lambda}]$ skattas av $\frac{1}{\lambda} = 3.8$

c)

$$P(X \leq m) = \frac{1}{2} \implies m = \frac{\ln 2}{\lambda} \text{ skattas av } 3.8 \ln(2)$$

d)

$$\begin{aligned} P(X > 5) &= 1 - F(5) \\ &= 1 - (1 - e^{-\lambda 5}) = e^{-\lambda 5} \\ \text{skattas av } &e^{-\frac{5}{3.8}}. \end{aligned}$$

e) $E[\bar{X}] = \frac{1}{\lambda}$ väntevärdesriktig

$$\sqrt{\text{Var}[\bar{X}]} = \sqrt{\frac{\frac{1}{\lambda^2}}{15}} = \frac{1}{\sqrt{15} \lambda} \text{ skattas av } \frac{1}{\sqrt{15} \hat{\lambda}}.$$

15.1.5 5.

$X_1, \dots, X_8 \quad X_i \sim N(\mu, \sigma^2)$ (olika)

Observerat $\bar{X} = 15.27$, $S = 0.47$

a) Observerat 95% konfidensintervall för μ ? σ okänd gör att vi skall använda t -fördelning.

Pivot

$$\sqrt{n} \frac{\bar{X} - \mu}{S} \sim t\text{-fördelad}(8 - 1 = 7) \quad F_{t(7)}(c) = 0.975 \text{ (ur tabell)} = 2.365$$

Teoretiskt intervall

$$\mu = \bar{X} \pm 2.365 \frac{S}{\sqrt{n}} \quad (95\%)$$

observerat intervall

$$\mu = 15.27 \pm \frac{2.36 \times 0.47}{\sqrt{8}}.$$

b) $H_0: \mu = 15$ mot $H_1: \mu > 15$

Alternativ 1, ensidigt t -test

$$\sqrt{n} \frac{\bar{X} - 15}{S} \underset{H_0 \text{ sann}}{\sim} t(7).$$

Förkasta H_0 om $T \implies c' \quad F(c') = 0.99 \implies c' = 2.998$

Observerat $t = \sqrt{8} \frac{15.27 - 15}{0.47} < 3 \implies$ Vi kan inte förkasta nollhypotesen

Alternativ 2, Genomför testet genom att bilda ett nedåt begränsat konfidensintervall I för μ med konfidensgrad 99%. Förkasta om H_0 om $\mu \notin I$.

$$\mu \geq \bar{X} - 2.998 \times \frac{5}{\sqrt{8}} \quad (99\%)$$

$$\mu \geq 15.27 - \frac{2.98 \times 0.47}{\sqrt{8}}$$

15.1.6 6.

a)

$$f(x) = (1-p)^{x-1} p \quad x = 1, 2, \dots,$$

$$P(X \in \{2, 4, \dots\}) = \sum_{k=1}^{\infty} (1-p)^{2k-1} p = \frac{p}{1-p} \sum_{k=1}^{\infty} ((1-p)^2)^k = \dots = \frac{1/4}{3/4} \left(\frac{1}{1 - (\frac{3}{4})^2} - 1 \right) = \frac{3}{7}.$$

b) $X_1 =$ antalet till första gången vi får A , $X_2 =$ antalet mellan första och andra gången vi får A

$$P(X_1 + X_2 = \text{"jämn"}) = P(X_1 + X_2 \in \{2, 4, 6, 8, \dots\})$$

ekvivalent med

$$P(\text{"båda jämna"} \cup \text{"båda udda"}) = \left(\frac{3}{7}\right)^2 + \left(\frac{4}{7}\right)^2.$$

15.1.7 7.

a)

$$n(\Omega) = \binom{15}{5}, \quad n(A) = \binom{12}{5}$$

$$P(A) = \frac{\binom{12}{5}}{\binom{15}{5}}$$

b)

$$P(B) = \frac{\binom{1}{1} \binom{2}{0} \binom{12}{4}}{\binom{15}{5}}$$

15.1.8 8.

a) $Z = \min(X, Y) \implies P(Z \leq z) = 1 - P(\min(X, Y) > z) = 1 - P(X > z) P(Y > z) = 1 - e^{-(\frac{1}{4} + \frac{1}{2})z}$
 derivering...

b) $Z = \max(X, Y) \implies$ likartat...**15.1.9 9.**

a) $\hat{\alpha} = \bar{Y} - \hat{\beta} \bar{x} = 1.23 - 0.22 \times 0.32$

b) $\hat{\alpha} + \hat{\beta} 2$

⋮