

Grundläggande matematisk statistik

Väntevärde, varians, standardavvikelse, kvantiler

Uwe Menzel, 2018

uwe.menzel@matstat.org

www.matstat.org

1

Väntevärdet

- X : diskret eller kontinuerlig slumpvariabel (slumpvariabel)
- $p_X(k)$: sannolikhetsfunktion; $f_X(x)$: täthetsfunktion

Väntevärde: viktat medelvärde, där varje utfall viktas med sin respektive sannolikhet.

Exempel : diskret slumpvariabel X

k	1	2	3
$p_X(k)$	$1/6$	$1/3$	$1/2$

← **OBS!**: det aritmetiska medelvärdet är:

$$M = \frac{1 + 2 + 3}{3} = 2$$

Väntevärde: $E(X)$ "Expectation"

$$E(X) = 1 \cdot \frac{1}{6} + 2 \cdot \frac{1}{3} + 3 \cdot \frac{1}{2} = \frac{1}{6} + \frac{4}{6} + \frac{9}{6} = \frac{14}{6} = \underline{\underline{2\frac{1}{3}}}$$

vikter, adderas till 1

- utfall som är mest sannolika får störst vikt
- mindre sannolika utfall får mindre vikt.

www.matstat.org

2

Väntevärden, definition

- X : diskret eller kontinuerlig slumpvariabel (s.v.)
- $p_X(k)$: sannolikhetsfunktion; $f_X(x)$: täthetsfunktion

Diskreta slumpvariabler:

$$E(X) = \sum_{k \in \Omega} k \cdot p_X(k)$$

- varje summand = utfall * dess sannolikhet
- summeras över alla k från Ω

Kontinuerliga slumpvariabler:

$$E(X) = \int_{-\infty}^{+\infty} x \cdot f_X(x) dx$$

- integral istället för summa

Väntevärden betecknas ofta med μ , dvs. $\mu = E(X)$

www.matstat.org

3

Väntevärden för en funktion av en slumpvariabel

Funktioner av slumpvariabler: X^2 ; $2 \cdot X$; X^3 ; e^X ; ...

$$E(X) = \int x \cdot f_X(x) dx$$

$$E(X^2) = \int x^2 \cdot f_X(x) dx$$

$$E(e^X) = \int e^x \cdot f_X(x) dx$$

$$M_X(t) = E(e^{tx}) \quad \text{"moment-generating function"}$$

$$E(X^n) = \left[\frac{d^n M_X}{dt^n} \right]_{t=0} \quad \begin{array}{l} \text{n:e moment} \\ \text{= n:e derivering för } t = 0 \end{array}$$

Allmänt:

<p>kontinuerlig</p> $E[g(X)] = \int g(x) \cdot f_X(x) dx$ <p style="text-align: center;">samma funktion</p>	<p>diskret</p> $E[g(k)] = \sum_k g(k) \cdot p_X(k)$ <p style="text-align: center;">samma funktion</p>
--	--

www.matstat.org

4


Väntevärden för funktioner av slumpvariabler

Exempel parkeringsavgift: anta att parkeringstiden är en slumpvariabel X som är likformigt fördelad på intervallet $(0, 1)$: ... man skriver också $X \sim U(0, 1)$ (U från "uniform")

Täthetsfunktionen är alltså:

$$f_X(x) = \begin{cases} 1 & 0 < X \leq 1 \\ 0 & \text{annars} \end{cases}$$

- likformigt fördelad på $(0, 1)$
- $X \sim U(0, 1)$



Väntevärde:

$$E(X) = \int x \cdot f_X(x) dx = \int_0^1 x \cdot 1 dx = \left[\frac{x^2}{2} \right]_0^1 = \frac{1}{2} \quad \text{"" medelparkeringstid}$$

www.matstat.org

5

Väntevärden för funktioner av slumpvariabler

Exempel, fortsättning : anta att parkeringsavgiften består av 10 kr engångsavgift plus 2 kr/timme. Parkeringsavgiften är alltså en slumpvariabel (Y).

Det gäller $Y = 10 + 2 \cdot X$ (Y är en funktion av en slumpvariabel, och därför också en slumpvariabel)

Kom ihåg: $f_X(x) = \begin{cases} 1 & 0 < X \leq 1 \\ 0 & \text{annars} \end{cases}$ täthetsfunktion för parkeringstiden

Väntevärdet för parkeringsavgiften:

$$E(Y) = E(10 + 2 \cdot X) = \int_{-\infty}^{+\infty} \underbrace{(10 + 2 \cdot X)}_{g(x)} \cdot \underbrace{f_X(x)}_{g(x)} dx = \int_0^1 (10 + 2 \cdot X) \cdot 1 dx = [10x]_0^1 + [x^2]_0^1 = 10 + 1 = \underline{11}$$

(det är 10 kr för engångsavgiften och 1 krona för den "förväntade" parkerings- tiden ½ timme!)

www.matstat.org

6

Variansen

- X : diskret eller kontinuerlig slumpvariabel (s.v.)
- $p_X(k)$: sannolikhetsfunktion; $f_X(x)$: täthetsfunktion

Variansen beskriver spridningen av en slumpvariabel. Beteckning: $V(X)$

Definition: $V(X) = E[(X - \mu)^2]$ där $\mu = E(X)$

Ofta används beteckningen σ^2 eller σ_x^2 för $V(X)$

Vi vet att: $E[g(X)] = \int g(x) \cdot f_X(x) dx$ sätter $g(x) = (x - \mu)^2$

respektive: $E[g(k)] = \sum_k g(k) \cdot p_X(k)$ sätter $g(k) = (k - \mu)^2$

kontinuerlig slumpvariabel

diskret slumpvariabel



$$V(X) = \int_{-\infty}^{+\infty} (x - \mu)^2 \cdot f_X(x) dx$$

$$V(X) = \sum_k (k - \mu)^2 \cdot p_X(k)$$


www.matstat.org

7

Varians, illustration

(för diskreta slumpvariabler)

$$V(X) = \sum_k \underbrace{(k - \mu)^2}_{\text{kvadrerat avstånd från medelvärdet}} \cdot p_X(k)$$



Utfallen som ligger långt bort från väntevärdet μ och som samtidigt har en stor sannolikhet $p_X(k)$ bidrar mycket till variansen, dvs. stora stolpar långt bort från väntevärdet μ orsakar stor varians.

www.matstat.org

8

Varians, alternativa uttryck

$$\begin{aligned}
 V(X) &= \int (x - \mu)^2 \cdot f_X(x) dx = \int (x^2 + \mu^2 - 2\mu x) \cdot f_X(x) dx \\
 &= \int x^2 \cdot f_X(x) dx + \underbrace{\mu^2 \cdot \int f_X(x) dx}_{= 1} - 2\mu \cdot \underbrace{\int x \cdot f_X(x) dx}_{= E(X) = \mu} \\
 &= E(X^2) + \mu^2 - 2 \cdot \mu^2 = \underline{E(X^2) - \mu^2} \quad \text{detta är ofta lättare att räkna}
 \end{aligned}$$

alltså:

$$V(X) = E(X^2) - \mu^2$$

$$E(X^2) = \int_{-\infty}^{+\infty} x^2 \cdot f_X(x) dx \quad \text{om } X \text{ kontinuerlig}$$

$$E(X^2) = \sum_k k^2 \cdot p_X(k) \quad \text{om } X \text{ diskret}$$

www.matstat.org

9

Beräkning av variansen

Exempel : diskret slumpvariabel med följande sannolikhetsfunktion:

k	1	2	3	4
$p_X(k)$	$1/8$	$2/8$	$4/8$	$1/8$

Beräkna variansen $V(X)$!

$$\mu = E(X) = 1 \cdot \frac{1}{8} + 2 \cdot \frac{2}{8} + 3 \cdot \frac{4}{8} + 4 \cdot \frac{1}{8} = \frac{21}{8} \quad \mu^2 = \frac{21^2}{64}$$

$k \cdot p_X(k)$

$$E(X^2) = 1^2 \cdot \frac{1}{8} + 2^2 \cdot \frac{2}{8} + 3^2 \cdot \frac{4}{8} + 4^2 \cdot \frac{1}{8} = \frac{61}{8}$$

$k^2 \cdot p_X(k)$

$$V(X) = \frac{61}{8} - \frac{21^2}{64} = \frac{61 \cdot 8 - 21^2}{64} = \underline{\underline{0.73}} \quad V(X) \text{ för tärning ??}$$

www.matstat.org

10

Standardavvikelsen

$$D(X) = \sqrt{V(X)} \quad D(X) \geq 0 \text{ positiva roten väljs}$$

Betecknas också med σ eller σ_x alltså $\sigma_x = D(X)$

Standardavvikelsen $D(X)$ har samma enhet (meter, sekund, ...) som slumpvariabeln X .

Variationskoefficient

$$R(X) = \frac{D(X)}{E(X)}$$

- spridning i relation till väntevärdet (om väntevärdet är stort kan eventuellt en större spridning accepteras).
- dimensionslös
- anges ofta i %


www.matstat.org

11

Medianen

”mellersta värdet” i en empirisk punktmängd, en täthetsfunktion, ...

a) diskreta slumpvariabler




b) kontinuerliga slumpvariabler

Medianen delar täthetsfunktionen i två delar med samma area under kurvan. Därför gäller för fördelningsfunktionen:

$$F_X(x_{0.5}) = 0.5$$

$x_{0.5}$ = beteckning för medianen



www.matstat.org

12

Medianen

- Medianen är inte detsamma som väntevärdet!
- Medianen och väntevärdet sammanfaller bara om fördelningen är symmetrisk!

Exempel: $F_Y(y) = y^2$ för $0 < X \leq 1$; 0 annars

Beräkna medianen!:

$$F_X(x_{0.5}) = 0.5 \quad x_{0.5} = \text{median}$$

$$\Rightarrow x_{0.5}^2 = \frac{1}{2} \quad x_{0.5} = \sqrt{\frac{1}{2}}$$


www.matstat.org

13

Exempel

Slumpvariabel X med
täthetsfunktion

$$f_X(x) = \begin{cases} 2 \cdot x & 0 < x \leq 1 \\ 0 & \text{annars} \end{cases}$$



Väntevärde:

$$E(X) = \int_{-\infty}^{+\infty} x \cdot f_X(x) dx = \int_0^1 x \cdot 2 \cdot x dx = \int_0^1 2 \cdot x^2 dx = 2 \cdot \left[\frac{x^3}{3} \right]_0^1 = \underline{\underline{\frac{2}{3}}}$$

Varians:

$$E(X^2) = \int_{-\infty}^{+\infty} x^2 \cdot f_X(x) dx = \int_0^1 x^2 \cdot 2 \cdot x dx = 2 \cdot \int_0^1 x^3 dx = 2 \cdot \left[\frac{x^4}{4} \right]_0^1 = \frac{1}{2}$$

$$V(X) = E(X^2) - \mu^2 = \frac{1}{2} - \frac{4}{9} = \frac{9}{18} - \frac{8}{18} = \underline{\underline{\frac{1}{18}}}$$

www.matstat.org

14


Exempel, forts.

Täthetsfunktion $f_X(x) = \begin{cases} 2 \cdot x & 0 < x \leq 1 \\ 0 & \text{annars} \end{cases}$

Fördelningsfunktion

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \int_0^x 2 \cdot t dt = 2 \cdot \left[\frac{t^2}{2} \right]_0^x = \underline{\underline{x^2}}$$

$$F_X(x) = \begin{cases} 0 & x < 0 \\ x^2 & 0 < x \leq 1 \\ 1 & x > 1 \end{cases}$$



Median


$$F_X(x_{0.5}) = 0.5 \Rightarrow x_{0.5}^2 = 0.5 \Rightarrow x_{0.5} = \underline{\underline{\sqrt{0.5}}}$$

www.matstat.org

15

Kvantiler

x_α = beteckning för α -kvantil $0 < \alpha \leq 1$



Kvantiler delar empiriska data och fördelnings- eller täthetsfunktioner i mindre enheter. **Lättast att komma ihåg:** Kvantilen x_α ligger så att arean under täthetsfunktionen **höger** om x_α är just α .

OBS!: Det finns en alternativ definition, i synnerhet i engelsk litteratur! Enligt den definitionen ligger x_α så att arean under täthetsfunktionen **vänster** om x_α är just α . I föreläsningen används dock den förstnämnda definitionen!

Om arean till **höger** om kvantilen är α , så måste arean till **vänster** vara $1 - \alpha$ (axiom 2). Med hjälp av definitionen för fördelningsfunktionen följer:

$$F_X(x_\alpha) = 1 - \alpha$$

Kvantiler beräknas vanligtvis med denna formel (om det är möjligt att lösa denna ekvation för att ta fram x_α).

www.matstat.org

16

Exempel: Beräkning av kvantilen $x_{0.05}$

Låt X vara en slumpvariabel med följande täthetsfunktion: $f_X(x) = \begin{cases} 2 \cdot e^{-2x} & x \geq 0 \\ 0 & x < 0 \end{cases}$

1. **Fördelningsfunktion:**

$$F_X(x) = \int_{-\infty}^x f_X(t) dt = \int_0^x 2 \cdot e^{-2t} dt = 2 \cdot \left[\frac{e^{-2t}}{-2} \right]_0^x = [e^{-2t}]_x^0 = \underline{\underline{1 - e^{-2x}}} \quad \text{för } x \geq 0, \text{ annars } 0$$


2. **Beräkning av kvantilen $x_{0.05}$** $F_X(x_\alpha) = 1 - \alpha$ med $\alpha = 0.05$

$$1 - e^{-2 \cdot x_{0.05}} = 1 - 0.05 = 0.95$$

$$e^{-2 \cdot x_{0.05}} = 0.05$$

$$-2 \cdot x_{0.05} = \ln 0.05$$

$$x_{0.05} = -\frac{1}{2} \cdot \ln 0.05 \approx \underline{\underline{1.5}}$$

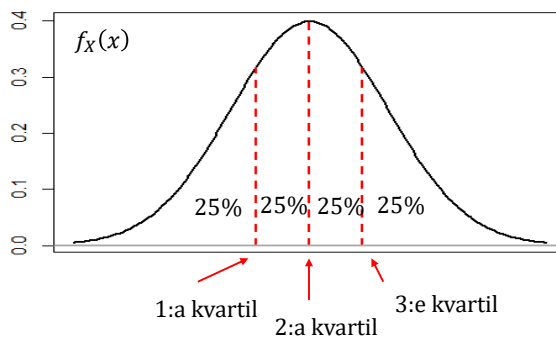


www.matstat.org

17

Kvartiler

Kvartiler delar täthetsfunktioner i 4 lika stora delar.



Sammanhang med kvartilerna:

$$1:a \text{ kvartil} = x_{0.75}$$

$$2:a \text{ kvartil} = x_{0.5} \text{ (median)}$$

$$3:e \text{ kvartil} = x_{0.25}$$

- 2:a kvartilen är samtidigt medianen (för symmetriska täthetsfunktioner är det samtidigt väntevärdet).
- Avståndet mellan 1:a och 3:e kvartil kallas också **IQR** ("Inter-Quartile Range"). Detta kan också användas som ett (grovt) mått för spridningen av ett stickprov.

www.matstat.org

18


Linjärtransformation av slumpvariabler

X, Y : slumpvariabler
 a, b : reella tal

$$Y = a \cdot X + b$$

linjärtransformation

a) **speciellt fall**: $a = 1$ $Y = X + b$ b konstant



- väntevärdet förskjuts med b
- variansen oförändrad

tärning: $\Omega_X = \{1, 2, 3, 4, 5, 6\}$

$\Omega_{X+2} = \{3, 4, 5, 6, 7, 8\}$

www.matstat.org

19

Linjärtransformation av slumpvariabler


X, Y : slumpvariabler
 a, b : reella tal

$$Y = a \cdot X + b$$

linjärtransformation

b) **speciellt fall**: $b = 0$ $Y = a \cdot X$

a konstant = skalering,
ombyte av enhet, t.ex. m \rightarrow cm
på x -axeln



- väntevärdet förskjuts
- variansen förändras

tärning:

$\Omega_X = \{1, 2, 3, 4, 5, 6\}$

$\Omega_{5 \cdot X} = \{5, 10, 15, 20, 25, 30\}$

www.matstat.org

20

Räknerregler för linjärtransformation av slumpvariabler

$$E(a \cdot X + b) = a \cdot E(X) + b$$

$Y = a \cdot X + b$ linjärtransformation

$$V(a \cdot X + b) = a^2 \cdot V(X)$$

en förskjutning med b påverkar inte variansen

$$D(a \cdot X + b) = |a| \cdot D(X)$$

Bevis (för kontinuerliga slumpvariabler):

$$\begin{aligned} E(a \cdot X + b) &= \int (a \cdot x + b) \cdot f_X(x) dx = a \cdot \underbrace{\int x \cdot f_X(x) dx}_{= E(X)} + b \cdot \underbrace{\int f_X(x) dx}_{= 1} \\ &= \underline{a \cdot E(X) + b} \end{aligned}$$

$$\begin{aligned} V(a \cdot X + b) &= \int [(a \cdot x + b) - \underbrace{(a \cdot \mu + b)}_{E(a \cdot X + b)}]^2 \cdot f_X(x) dx = a^2 \cdot \int (x - \mu)^2 \cdot f_X(x) dx \\ &= \underline{a^2 \cdot V(X)} \end{aligned}$$

www.matstat.org

21

Standardiserade slumpvariabler

X : slumpvariabel Låt $E(X) = \mu$ (väntevärde)

$V(X) = \sigma^2$ (varians)

$D(X) = \sigma$ (standardavvikelse)

Låt oss definiera en ny slumpvariabel genom linjärtransformation:
(subtrahera väntevärdet μ från X och dela med standardavvikelsen σ)

$$Y = \frac{X - \mu}{\sigma}$$

detta är en linjärtransformation: $Y = \underbrace{\frac{1}{\sigma}}_a \cdot X - \underbrace{\frac{\mu}{\sigma}}_b$

www.matstat.org

22

Standardiserade slumpvariabler

Väntevärde och standardavvikelse för Y blir:

$$Y = \frac{X - \mu}{\sigma}$$

$$E(Y) = E\left(\frac{X - \mu}{\sigma}\right) = E\left(\frac{1}{\sigma} \cdot X - \frac{\mu}{\sigma}\right) = \frac{1}{\sigma} \cdot E(X) - \frac{\mu}{\sigma} = \underline{\underline{0}}$$

$$V(Y) = V\left(\frac{X - \mu}{\sigma}\right) = V\left(\frac{1}{\sigma} \cdot X - \frac{\mu}{\sigma}\right) = \frac{1}{\sigma^2} \cdot V(X) = \underline{\underline{1}}$$

Låt X vara en slumpvariabel med $E(X) = \mu$ och $D(X) = \sigma$. Den standardiserade slumpvariabeln $Y = \frac{X - \mu}{\sigma}$ har väntevärdet 0 och standardavvikelsen 1.

OBS!: Detta säger dock ingenting om fördelningen för Y . Slumpvariabeln Y har i största allmänhet **inte** samma fördelning som X .

www.matstat.org