

SF1901: SANNOLIKHETSLÄRA OCH STATISTIK  
FÖRELÄSNING 12.  
MER HYPOTESPRÖVNING.  $\chi^2$ -TEST

Jan Grandell & Timo Koski

25.02.2016



- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test



- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt

- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.

- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.
  - signifikant\*, *signifikant\*\**, *signifikant\*\*\**

- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.
  - signifikant\*, *signifikant\*\**, *signifikant\*\*\**
  - $p$  -värden

- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.
  - signifikant\*, *signifikant\*\**, *signifikant\*\*\**
  - $p$  -värden
  - Styrkefunktion

- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.
  - signifikant\*, *signifikant\*\**, *signifikant\*\*\**
  - $p$  -värden
  - Styrkefunktion
  - ensidiga test



- Hypotesprövning och konfidensmetoden; exempel på tvåsidiga test
- Hypotesprövning: allmänt
  - Nollhypotes, mothypotes, Teststorhet (testvariabel), Kritiskt område, Signifikansnivå.
  - signifikant\*, *signifikant\*\**, *signifikant\*\*\**
  - $p$  -värden
  - Styrkefunktion
  - ensidiga test
- $\chi^2$  -test (inledning)

# HYPOTESPRÖVNING: FRÅN PÅSTÅENDE TILL PROCEDUR

- Vi har ett påstående om t.ex. ett populationsmedelvärde.

## EXEMPEL

*Vid rökning omvandlas nikotin till cotinin, en metabolite av nikotin, som kan mätas. Det påstås att den genomsnittliga nivån av cotinin hos alla rökare är 200.0 ng/mL.*

- Vi kollar nivån av cotinin hos  $n$  rökare, och får cotinivärdena  $x_1, \dots, x_n$ .
- Vi använder en statistisk procedur för att checka om påståendet om medelnivån 200.0 kan anses vara förenlig med dessa mätdata.
- Procedur: inför en statistisk modell, teststorhet, kritiskt område, beslutsregel, signifikansnivå och använd 'rare event principle'



*If, under a given assumption, the probability of an observed event is very small, we conclude that the assumption is likely not correct.*

$X_1, X_2, \dots, X_n$  är oberoende och  $N(\mu, \sigma)$ -fördelade, där  $\mu$  och  $\sigma$  är okända.

$$H_0 : \mu = \mu_0$$

mot

$$H_1 : \mu \neq \mu_0$$

$X_1, X_2, \dots, X_n$  är oberoende och  $N(\mu, \sigma)$ -fördelade, där  $\mu$  och  $\sigma$  är okända.

$$H_0 : \mu = \mu_0$$

mot

$$H_1 : \mu \neq \mu_0$$

Här verkar det rimligt att utgå från

$$t(X_1, \dots, X_n) = \frac{\bar{X} - \mu_0}{S/\sqrt{n}},$$

som under  $H_0$  är  $t(n-1)$ -fördelad, och att förkasta  $H_0$  om  $|t(x_1, \dots, x_n)|$  är för stor.

Vi får då

$$\alpha = P(|t(X_1, \dots, X_n)| > c \text{ om } H_0 \text{ sann}),$$

vilket ger  $c = t_{\alpha/2}(n-1)$ .

Kritiska området är alltså  $|t(x_1, \dots, x_n)| > t_{\alpha/2}(n-1)$

$$\Leftrightarrow \begin{cases} t(x_1, \dots, x_n) > t_{\alpha/2}(n-1) & \text{om } t(x_1, \dots, x_n) > 0 \text{ (A)} \\ -t(x_1, \dots, x_n) > t_{\alpha/2}(n-1) & \text{om } t(x_1, \dots, x_n) < 0 \text{ (B)} \end{cases}$$

Fall (A):

$$t(x_1, \dots, x_n) > t_{\alpha/2}(n-1) \Leftrightarrow \frac{\bar{x} - \mu_0}{s/\sqrt{n}} > t_{\alpha/2}(n-1)$$

$$\Leftrightarrow \bar{x} - \mu_0 > t_{\alpha/2}(n-1)s/\sqrt{n} \Leftrightarrow \mu_0 < \bar{x} - t_{\alpha/2}(n-1)s/\sqrt{n}$$

P.s.s. fås i fallet (B) att

$$\mu_0 > \bar{x} + t_{\alpha/2}(n-1)s/\sqrt{n}$$

Testet kan alltså utföras så att man bestämmer ett konfidensintervall och ser efter om det *hypotetiska värdet*  $\mu_0$  ligger utanför eller innanför detta; i det förra fallet förkastas  $H_0$ , inte i det senare.

- Bilda ett konfidensintervall

$I_\mu = (\bar{x} - t_{\alpha/2}(f)s/\sqrt{n}, \bar{x} + t_{\alpha/2}(f)s/\sqrt{n})$ ,  $f = n - 1$  och förkasta  $H_0$  om

$$I_\mu \not\ni \mu_0.$$



# HYPOTESPRÖVNING: SAMMANFATTNING AV EXEMPLET

$X_1, X_2, \dots, X_n$  är oberoende och  $N(\mu, \sigma)$ -fördelade,  $\mu$  och  $\sigma$  okända.

$$H_0 : \mu = \mu_0$$

mot

$$H_1 : \mu \neq \mu_0.$$

- Bilda ett konfidensintervall  $I_\mu = (\bar{x} - t_{\alpha/2}(f)d, \bar{x} + t_{\alpha/2}(f)d)$  och förkasta  $H_0$  om

$$I_\mu \not\ni \mu_0.$$

- Detta verkar rimligt.  $I_\mu$  ger ju de "troliga" värdena på  $\mu$ , och om  $\mu_0$  inte hör dit, så bör ju  $H_0$  förkastas.



$$H_0 : \Delta = 0$$

mot

$$H_1 : \Delta \neq 0.$$

$$\underline{I_\Delta = \bar{z} \pm \lambda_{\alpha/2} \sigma / \sqrt{n}}$$

om  $\sigma$  känd och

$$\underline{I_\Delta = \bar{z} \pm t_{\alpha/2}(n-1)s / \sqrt{n}}$$

om  $\sigma$  okänd. Förkasta  $H_0$  om

$$I_\Delta \not\supset 0.$$

- En forskare mäter en storhet  $\theta$  som på grund av ett mätfel är  $N(0, \sigma)$ , och får värdet  $x$ , dvs.  $x$  är således en observation från  $N(\theta, \sigma)$ .
- Forskaren vill pröva en viss hypotes

$$H_0 : \theta = 2.0.$$

Signifikansnivån skall vara 0.05.

- Som testvariabel väljs det erhållna mätvärdet  $x$  ( $= t(x)$ ).
- Kritiska området blir (se föreläsning 10)

Om  $|x - 2.0| \geq 1.96 \cdot \sigma$  förkasta  $H_0$

Om  $|x - 2.0| < 1.96 \cdot \sigma$  förkasta ej  $H_0$ .

Men  $(x - 1.96\sigma, x + 1.96\sigma)$  är ett tvåsidigt 95 % konfidensintervall för  $\theta$ . Testet kan alltså utföras så att man bestämmer konfidensintervallet och ser efter om det *hypotetiska värdet*  $\theta_0$  ligger utanför eller innanför detta; i det förra fallet förkastas  $H_0$ , inte i det senare.

Låt oss betrakta den allmänna situationen, dvs.:

Vi har en uppsättning data  $x_1, x_2, \dots, x_n$  som ses som utfall av s.v.

$$X_1, X_2, \dots, X_n.$$

Dessa variabler antages vara oberoende och likafördelade och deras gemensamma fördelning beror av en okänd parameter  $\theta$ .

En hypotes är en mängd av  $\theta$ -värden. Formaliserat betyder detta att vi vill testa en *nollhypotes*

$$H_0 : \theta \in H_0$$

mot ett *alternativ* (eller en mothypotes)

$$H_1 : \theta \in H_1.$$

Att testa  $H_0$  är detsamma som att avgöra om våra data är "förenliga" med  $H_0$ .

- Om  $H_0$  ej är sann vill vi *förkasta*  $H_0$  till förmån för  $H_1$ .



Att testa  $H_0$  är detsamma som att avgöra om våra data är "förenliga" med  $H_0$ .

- Om  $H_0$  ej är sann vill vi *förkasta*  $H_0$  till förmån för  $H_1$ .
- Vi bildar därför en *teststorhet*  $t = t(x_1, \dots, x_n)$





Att testa  $H_0$  är detsamma som att avgöra om våra data är "förenliga" med  $H_0$ .

- Om  $H_0$  ej är sann vill vi *förkasta*  $H_0$  till förmån för  $H_1$ .
- Vi bildar därför en *teststorhet*  $t = t(x_1, \dots, x_n)$
- och ett *kritiskt område*  $C$ .

- Test: Fökasta  $H_0$  om  $t \in C$ .

- Test: Förkasta  $H_0$  om  $t \in C$ .
- $t$  bestäms av situationen och  $C$  av *signifikansnivån* (eller felrisken)  $\alpha$ :

$$\begin{aligned}\text{signifikansnivån} &= \alpha \geq P(H_0 \text{ förkastas om } H_0 \text{ sann}) \\ &= P(T(X_1, \dots, X_n) \in C \text{ om } H_0 \text{ sann}).\end{aligned}$$

Man arbetar med flera signifikansnivåer samtidigt, t.ex. med nivåerna 0.05, 0.01 och 0.001. Kodbeteckningarna *signifikant\**, *signifikant\*\** respektive *signifikant\*\*\** är för att markera att ett resultat är signifikant på en nivå (men inte för ett lägre  $\alpha$ -värde bland dessa tre). Med denna symbolik betyder alltså *signifikant\** att  $\alpha = 0.05$  ger signifikans men inte  $\alpha = 0.01$ , alltså inte heller  $\alpha = 0.001$ .

Låt oss betrakta ett test sådant att hypotesen  $H_0$  förkastas om testvariabeln  $t = t_{\text{obs}} = t(x)$  är "stor".

Vi förutsätter också att stickprovsvariabeln  $t(X)$  har en given känd sannolikhetsfördelning under  $H_0$ .  $p$ -värdet eller *observerade signifikansnivån* är sannolikheten

$$p = P(t(X) \geq t(x)),$$

beräknad under förutsättningen att  $H_0$  är sann. Om  $p$ -värdet är "tillräckligt litet" förkastas  $H_0$ ; vi tror alltså inte på  $H_0$  om testresultatet är "osannolikt" då  $H_0$  är sann.

- Med risknivån  $\alpha$  garderar vi oss således mot felet att förkasta  $H_0$  då  $H_0$  är sann.

- Med risknivån  $\alpha$  gararderar vi oss således mot felet att förkasta  $H_0$  då  $H_0$  är sann.
- Vi bör välja  $H_0$  så att detta är det allvarligaste felet.

- Med risknivån gararderar vi oss således mot felet att förkasta  $H_0$  då  $H_0$  är sann.
- Vi bör välja  $H_0$  så att detta är det allvarligaste felet.
- Det andra möjliga felet är att ej förkasta  $H_0$  då  $H_0$  är falsk. Vi bildar *styrkefunktionen*

$$h(\theta) = P(H_0 \text{ förkastas}) \quad \text{om } \theta \text{ är det sanna värdet.}$$



$h(\theta) = P(H_0 \text{ förkastas})$  om  $\theta$  är det sanna värdet.

- För  $\theta \in H_0$  gäller således att  $h(\theta) \leq \alpha$ .
- Ett test är "bra" om  $h(\theta)$  är stor då  $\theta \in H_1$ .

För att få något bestämt ta  $\sigma = 0.04$  Antag forskaren vill pröva hypotesen  $H_0 : \theta = 2.0$ . Låt den alternativa hypotesen vara

$$H_1 : \theta \leq 1.9 \text{ eller } \theta \geq 2.1.$$

Forskaren är angelägen om att verkligen förkasta  $H_0$  om  $\theta$  skulle avvika så mycket från 2.0 som  $H_1$  anger. Vi undersöker hur stor sannolikheten är att forskaren gör detta.

Vi tergår til exemplet ovan: Testet lyder ju nu: Förcasta  $H_0$  om

$$|x - 2.0| > 1.96 \cdot 0.04.$$

Alltså blir

$$h(\theta) = P(|X - 2.0| > 1.96 \cdot 0.04) \quad \text{om } X \in N(\theta, 0.04).$$

Den komplementära sannolikheten att  $X$  ligger mellan gränserna  $2.0 \pm 1.96 \cdot 0.04$ :

$$1 - h(\theta) = \Phi\left(\frac{2.0 + 1.96 \cdot 0.04 - \theta}{0.04}\right) - \Phi\left(\frac{2.0 - 1.96 \cdot 0.04 - \theta}{0.04}\right)$$


varav

$$h(\theta) = 1 - \Phi\left(1.96 + \frac{2.0 - \theta}{0.04}\right) + \Phi\left(-1.96 + \frac{2.0 - \theta}{0.04}\right).$$



# STYRKEFUNKTION (TVÅSIDIGT TEST).

Denna styrkefunktion har minimum (= 0.05, vilket är den fastställda signifikansnivån) för  $\theta = 2.0$  och att den är ungefär 0.70 eller däröver för  $\theta$ -värden inom  $H_1$ . Styrkan är inte särskilt stor, det finns två utvägar att förbättra den: att öka mätprecisionen dvs. minska  $\sigma$  eller utföra experiment med flera observationer.



Om  $H_0$  omfattar flera  $\theta$ -värden kommer sannolikheten  $P(H_0 \text{ förkastas})$ , om  $H_0$  är sann, att bli beroende av vilket  $\theta$ -värde inom  $H_0$  som är det rätta, d.v.s. vår gamla beskrivning av  $\alpha$  fungerar inte längre. Därför sätter vi i stället

$$\alpha = \max_{\theta \in H_0} h(\theta).$$

Vi låter denna högsta felrisk vara den på förhand bestämda signifikansnivån. Om vi tar t.ex.  $\alpha = 0.01$ , är risken att vi förkastar  $H_0$ , om  $H_0$  är sann, högst lika med 0.01. Problemet är alltså att komma underfund med för vilket  $\theta \in H_0$  som felrisken är störst, och det brukar vara lätt.

Ett mynt ger krona med den okända sannolikheten  $p$ . Man vill pröva  $H_0 : p = 1/2$  mot  $H_1 : p \neq 1/2$ . Myntet kastas  $n = 30$  gånger, varvid krona kommer upp  $x = 5$  gånger.

Fixera signifikansnivån till 0.01. Vi skall förkasta  $H_0$  om  $x \leq a$  eller  $x \geq b$ .  $a$  och  $b$  väljs så att, om  $H_0$  sann,  $P(X \leq a) \lesssim 0.005$ ,  $P(X \geq b) \lesssim 0.005$ .



En tabell över binomialfördelningen ger  $a = 7$ ,  $b = 30 - 7 = 23$ . ( $P(X \leq a) = P(X \geq b) = 0.0026$  signifikansnivån är 0.0052) I det angivna fallet föreligger alltså signifikans på den valda nivån, ty  $x \leq 7$ .

Låt oss som övning alternativt använda  $P$ -värdet (jämför ovan).

$$P/2 = \sum_{i=0}^5 \binom{30}{i} \left(\frac{1}{2}\right)^i \left(\frac{1}{2}\right)^{30-i}$$

varav  $P = 0.00032$ . Resultatet är således signifikant\*\*\*, och vi förkastar alltså hypotesen att myntet är välgjort.

$X_1, X_2, \dots, X_n$  är oberoende och  $N(\mu, \sigma)$ -fördelade, där  $\mu$  och  $\sigma$  är okända.

$$H_0 : \mu = \mu_0$$

mot

$$H_1 : \mu > \mu_0 \quad \text{eller} \quad \mu < \mu_0.$$

Låt oss anta att stort värde på  $\mu$  är en önskad egenskap. Det kan vara naturligt att vi gör en åtgärd, t.ex. köper någon ny utrustning, som bör öka värdet på  $\mu$ .

Det är naturligt att vi endast vill köpa denna nya utrustning om vi är någolunda säkra på att den verkligen ger ett högre värde på  $\mu$  än  $\mu_0$

Det är då naturligt att testa

$$H_0 : \mu = \mu_0$$

mot

$$H_1 : \mu > \mu_0.$$

Testet blir då att vi förkastar  $H_0$  om  $t(x_1, \dots, x_n)$  är för stor, eller mera precist om

$$t > t_\alpha(n-1) \quad \text{eller om} \quad \bar{x} > \mu_0 + t_\alpha(n-1)s/\sqrt{n}.$$

Tolkningen är att vi kräver, för att förkasta  $H_0$ , att  $\bar{x}$  är tillräckligt mycket större än  $\mu_0$  för att det inte ska vara troligt att skillnaden är slumpmässig.

Givetvis skulle vi mycket väl kunna vilja påstå att  $\mu = \mu_0$ , och då skulle vi ju vilja testa  $H_0 : \mu \neq \mu_0$  mot  $H_1 : \mu = \mu_0$ .

Detta går inte, eftersom inga observationer i världen skulle kunna få oss att förkasta detta  $H_0$ .

Den som gör ett test, "vill" därför ofta att  $H_0$  ska förkastas. Det är nog detta som gör att begreppet signifikant misstolkas.

$\chi^2$ -testet är ett så kallat "**goodness of fit**"<sup>1</sup>-test

Den enklaste situationen:

Ett försök kan utfalla på  $r$  olika sätt:  $A_1, A_2, \dots, A_r$ . Låt  $x_1, x_2, \dots, x_r$  vara antalet gånger som alternativen  $A_1, A_2, \dots, A_r$  förekommer i  $n$  försök.

---

<sup>1</sup>En källa översätter detta som "**anpassningsgrad**".



Låt  $p_1, p_2, \dots, p_r$  vara givna sannolikheter, dvs  $\sum_{i=1}^r p_i = 1$ . Vi vill testa

$$H_0 : P(A_i) = p_i \text{ för } i = 1, \dots, r$$

mot

$$H_1 : \text{ej alla } P(A_i) = p_i.$$

För att göra detta bildar vi

$$Q_{\text{obs}} = \sum_{i=1}^r \frac{(x_i - np_i)^2}{np_i}.$$

Man kan visa att  $Q$  är approximativt  $\chi^2(r-1)$ -fördelad under  $H_0$ .

För att göra resultatet troligt, betraktar vi  $r = 2$ . Då gäller, med  $X = X_1$  och  $p = p_1$  att

$$\begin{aligned} Q &= \frac{(X_1 - np_1)^2}{np_1} + \frac{(X_2 - np_2)^2}{np_2} = \frac{(X - np)^2}{np} + \frac{(n - X - n(1 - p))^2}{n(1 - p)} \\ &= \frac{(X - np)^2}{np} + \frac{(X - np)^2}{n(1 - p)} = \frac{(X - np)^2}{np(1 - p)}. \end{aligned}$$

Eftersom  $X$  är  $\text{Bin}(n, p)$  så gäller att  $\frac{X - np}{\sqrt{np(1 - p)}}$  är appr.  $N(0, 1)$ . Således följer att  $\frac{(X - np)^2}{np(1 - p)}$  är appr.  $\chi^2(1)$ .

Vi gör nu följande test:

Förkasta  $H_0$  om

$$Q_{\text{obs}} > \chi_{\alpha}^2(r - 1).$$

Om  $n$  är stort, har detta test approximativt signifikansnivån  $\alpha$ .

Det går inte att generellt ange hur stort  $n$  skall vara för att approximationen skall vara tillfredsställande. Som tumregel brukar man använda: Tillse att insatta värden på  $np_j$  är minst lika med 5.

Vid 96 kast med en tärning erhöles följande antal ettor, tvåor, etc: 15, 7, 9, 20, 26, 19. Man önskar pröva om tärningen kan antas vara symmetrisk. Hypotesen  $H_0$  blir alltså

$$H_0 : P(A_1) = 1/6, \dots, P(A_6) = 1/6.$$

$\chi^2$ -metoden kan användas, ty alla  $np_j = 96 \cdot 1/6 = 16$  och är alltså tillräckligt stora.

Man får

$$Q_{\text{obs}} = \frac{(15 - 16)^2}{16} + \frac{(7 - 16)^2}{16} + \frac{(9 - 16)^2}{16} + \frac{(20 - 16)^2}{16} + \frac{(26 - 16)^2}{16} + \frac{(19 - 16)^2}{16} = 16.0.$$

Antalet frihetsgrader är  $f = r - 1 = 6 - 1 = 5$ . Eftersom  $Q_{\text{obs}}$  något överstiger  $\chi_{0.01}^2(5) = 15.1$  kan man påstå att tärningen inte är symmetrisk: Resultatet är signifikant\*\*. Med dator erhålls  $P = P(Q > 16.0) \approx 0.0068$  då  $Q$  är  $\chi^2(5)$ .

Ofta vill vi låta sannolikheterna  $p_1, p_2, \dots, p_r$  bero av en okänd parameter  $\theta = (\theta_1, \dots, \theta_s)$ , och testa hypotesen

$$H_0 : P(A_i) = p_i(\theta), \text{ för } i = 1, \dots, r,$$

och för något värde på  $\theta$ .



Skattar vi  $\theta$  med ML-metoden, och bildar

$$Q_{\text{obs}} = \sum_{i=1}^r \frac{(x_i - np_i(\theta_{\text{obs}}^*))^2}{np_i(\theta_{\text{obs}}^*)},$$

så är  $Q$  approximativt  $\chi^2(r - s - 1)$ -fördelad under  $H_0$ .  
Detta resultat kallas ibland för *stora  $\chi^2$ -satsen*.

# $\chi^2$ -TEST MED SKATTNING AV PARAMETRAR: ANTALET FRIHETSGRADER

Grundregeln är att antalet frihetsgrader fås av

antalet fria kvadratsummor – antalet skattade parametrar.

