

SF1901: SANNOLIKHETSLÄRA OCH STATISTIK
FÖRELÄSNING 11.
MER OM KONFIDENSINTERVALL.
HYPOTESPRÖVNING

Jan Grandell & Timo Koski

22.02.2016



- Konfidensintervall för skillnaden mellan två väntevärden
 - Två stickprov
 - konfidensintervall för skillnaden mellan två väntevärden $\mu_1 - \mu_2$ i $N(\mu_1, \sigma_1)$ och $N(\mu_2, \sigma_2)$ med kända σ_1 och σ_2 .
 - konfidensintervall för skillnaden mellan två väntevärden mellan $\mu_1 - \mu_2$ i $N(\mu_1, \sigma_1)$ och $N(\mu_2, \sigma_2)$ med okända σ_1 och σ_2 .
 - Stickprov i par/Matched Pairs
- Hypotesprövning: inledande exempel & Hypotesprövningens beståndsdelar

SATS

Låt x_1, \dots, x_n vara ett slumpmässigt stickprov från $N(\mu, \sigma)$ där μ är okänt. Då är

$$I_\mu = (\bar{x} - \lambda_{\alpha/2}D, \bar{x} + \lambda_{\alpha/2}D)$$

om σ är känt ($D = \sigma/\sqrt{n}$)

samt

$$I_\mu = (\bar{x} - t_{\alpha/2}(f)d, \bar{x} + t_{\alpha/2}(f)d)$$

om σ är okänt ($d = s/\sqrt{n}$, $f = n - 1$)

ett tvåsidigt konfidensintervall för μ med konfidensgraden $1 - \alpha$.

TVÅ STICKPROV, KONFIDENSINTERVALL FÖR SKILLNAD MELLAN VÄNTEVÄRDEN.

Normalfördelning

Modell:

X_1, X_2, \dots, X_{n_1} är $N(\mu_1, \sigma_1)$ (stickprov 1)

Y_1, Y_2, \dots, Y_{n_2} är $N(\mu_2, \sigma_2)$ (stickprov 2)

där alla X en och Y na är oberoende.

TVÅ STICKPROV, KONFIDENSINTERVALL FÖR SKILLNAD MELLAN VÄNTEVÄRDEN.

a) σ_1 och σ_2 kända

Vi vill nu skaffa oss ett konfidensintervall för $\mu_1 - \mu_2$. En naturlig skattning av $\mu_1 - \mu_2$ är $\bar{X} - \bar{Y}$. Eftersom den är en linjärkombination av oberoende normalfördelade variabler, så gäller att

$$\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

är $N(0, 1)$ -fördelad.

TVÅ STICKPROV, KONFIDENSINTERVALL FÖR SKILLNAD MELLAN VÄNTEVÄRDEN.

Av detta leds vi till

$$I_{\mu_1 - \mu_2} = \bar{x} - \bar{y} \pm \lambda_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}.$$

Om $\sigma_1 = \sigma_2 = \sigma$ reduceras detta till att

$$\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{\sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

är $N(0, 1)$ -fördelad och

$$I_{\mu_1 - \mu_2} = \bar{x} - \bar{y} \pm \lambda_{\alpha/2} \sigma \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}.$$



TVÅ STICKPROV, KONFIDENSINTERVALL FÖR SKILLNAD MELLAN VÄNTEVÄRDEN.

b) $\sigma_1 = \sigma_2 = \sigma$ okänd

Vi betraktar nu fallet då $\sigma_1 = \sigma_2 = \sigma$, men där σ är okänd. Detta skattas med s där s^2 är den *sammanvägda* stickprovsvariansen.

Man kan visa att man skall välja

$$s^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$$

och att

$$\frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{S \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

är $t(n_1 + n_2 - 2)$ -fördelad.

TVÅ STICKPROV, KONFIDENSINTERVALL FÖR SKILLNAD MELLAN VÄNTEVÄRDEN.

Vi får

$$\underline{I_{\mu_1 - \mu_2} = \bar{x} - \bar{y} \pm t_{\alpha/2}(n_1 + n_2 - 2)s\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}.}$$

SATS

Låt x_1, \dots, x_{n_1} och y_1, \dots, y_{n_2} vara slumpmässiga, av varandra oberoende stickprov från $N(\mu_1, \sigma_1)$ respektive $N(\mu_2, \sigma_2)$.

Om σ_1 och σ_2 är kända så är

$$I_{\mu_1 - \mu_2} = (\bar{x} - \bar{y} - \lambda_{\alpha/2} D, \bar{x} - \bar{y} + \lambda_{\alpha/2} D)$$

ett tvåsidigt konfidensintervall för $\mu_1 - \mu_2$ med konfidensgraden $1 - \alpha$; här

är $D = \sqrt{\sigma_1^2 / n_1 + \sigma_2^2 / n_2}$.

SATS

Om $\sigma_1 = \sigma_2 = \sigma$ där σ är okänt så är

$$I_{\mu_1 - \mu_2} = (\bar{x} - \bar{y} - t_{\alpha/2}(f)d, \bar{x} - \bar{y} + t_{\alpha/2}(f)d)$$

ett tvåsidigt konfidensintervall för $\mu_1 - \mu_2$ med konfidensgraden $1 - \alpha$; här är $d = s\sqrt{1/n_1 + 1/n_2}$ där $f = (n_1 - 1) + (n_2 - 1)$.

In an experiment designed to test the effectiveness of paroxetine for treating bipolar depression, subjects were measured using the Hamilton Depression scale with results as follows:

Placebo group	$n_1 = 43$	$\bar{x} = 21.57, s_1 = 3.87$
Paroxetine treatment group	$n_2 = 33$	$\bar{y} = 20.38, s_2 = 3.91$

TWO SAMPLES

We assume that we have independent samples and normal distributions. We must assume this, we have just summaries of data, no chance of looking at histograms or boxplots.

We insert data in pooling (sammanvägning)

$$s^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} = \frac{(43 - 1) \cdot 3.87^2 + (33 - 1) \cdot 3.91^2}{43 + 33 - 2} \\ = 15.11$$

We choose $\alpha = 0.05$. The quantiles are found from the t-distribution with $43 + 33 - 2 = 74$ degrees of freedom. This gives us $t_{0.025} = 1.993$ (by `>>tinv(0.975, 74)` in Matlab).



TWO SAMPLES; THE CONFIDENCE INTERVAL COMPUTED

$$s^2 = \frac{(43 - 1) \cdot 3.87^2 + (33 - 1) \cdot 3.91^2}{43 + 33 - 2} = 15.11$$

$$t_{0.025}(74) = 1.993$$

$$\begin{aligned} I_{\mu_1 - \mu_2} &= \bar{x} - \bar{y} \pm t_{\alpha/2}(n_1 + n_2 - 2) s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} \\ &= (21.57 - 20.38) \pm 1.993 \cdot \sqrt{15.11} \cdot \sqrt{\frac{1}{43} + \frac{1}{33}} \\ &= 1.19 \pm 1.7930 = [-0.603, 2.938] \end{aligned}$$



TVÅ STICKPROV FÖR PAROXETINE; KONFIDENSINTERVALL MED KONFIDENS GRAD 0.95

$$I_{\mu_1 - \mu_2} = [-0.603, 2.938]$$

*Men vad säger detta för oss ? Vilken **kunskap** om paroxetine har de givna data gett oss i form av detta konfidensintervall?*

Vi kommer att få ett svar med hjälp av teorin om hypotesprövning. Men först ett fall till.

We shall deal with a testing situation that is treacherously close to the comparison of two means (=två stickprov) above.

We present this by an example. Suppose that we want to test the effectiveness of a low-fat diet. The weight of n subjects is measured before and after the diet. The results are x_1, \dots, x_n and y_1, \dots, y_n , respectively. Obviously x_i and y_i would be dependent, but the samples corresponding to different subjects are independent.

We have

Diet	Subject			
	1	2	...	n
weight before diet	x_1	x_2	...	x_n
weight after diet	y_1	y_2	...	y_n

Let us assume x_j for the j th subject is a sample from $N(\mu_j, \sigma_1)$ and y_j a sample from $N(\mu_j + \Delta, \sigma_2)$. Δ is the population mean difference for *all* matched pairs. Δ is the population parameter for the effectiveness of the low-fat diet.



- There is, as in case of two means, two series of observations. But the model for two means (=två stickprov) is inapplicable, the pairs x_j, y_j are now matched to each other, (two measurements of the weight of one and the same person). The data consists of n matched pairs.
- The unknown parameters are $\mu_1, \dots, \mu_n, \sigma_1, \sigma_2$ och Δ .
- μ_1, \dots, μ_n reflect differences between subjects, whereas Δ reflects the systematic difference between the weights before and after the low fat diet. If $\Delta < 0$ then the weight after diet is in average lower than before the diet.
- Note that σ_1 and σ_2 can be different.

Det är lämpligt att utgå från ett praktiskt problem. Antag först att två personer A och B utför upprepade mätningar på *ett och samma objekt*. Om antalet mätningar är lika, får vi då mätvärden x_1, \dots, x_n respektive y_1, \dots, y_n , vilka kan betraktas som två oberoende stickprov.

Om normalfördelning föreligger och personerna arbetar med samma (okända) precision, kan vi med den föregående analysen (två stickprov) avgöra t.ex. hur stor den systematiska skillnaden $\mu_1 - \mu_2$ är mellan personerna.



Nu antar vi i stället att varje person utför en mätning på vart och ett av n olika objekt. De erhållna mätvärdena kan skrivas

Person	Objekt			
	1	2	...	n
A	x_1	x_2	...	x_n
B	y_1	y_2	...	y_n

Det föreligger liksom förut två serier av mätvärden, men den tidigare modellen är oanvändbar, eftersom skillnader kan föreligga mellan objekten, alldeles oavsett om det föreligger skillnader mellan personerna eller ej. Tydligt hänger observationerna ihop på något sätt parvis, eftersom de två och två härrör från samma objekt.



En i många fall realistisk modell är följande. Värdet x_j för det j :te objektet antas komma från en normalfördelning $N(\mu_j, \sigma_1)$ och y_j från en annan fördelning $N(\mu_j + \Delta, \sigma_2)$.



Man har då okända parametrar $\mu_1, \dots, \mu_n, \sigma_1, \sigma_2$ och Δ . Olikheter mellan μ_1, \dots, μ_n avspeglar olikheter mellan objekten, medan Δ anger den systematiska skillnaden mellan B :s och A :s mätningar. Om $\Delta > 0$ är B :s värden i genomsnitt större än A :s.



Vi har alltså här antagit att det systematiska felet är oberoende av objektets verkliga värde, vilket kan vara realistiskt om det inte är för stora skillnader mellan objekten. Observera också att personerna inte behöver arbeta med samma precision (σ_1 och σ_2 tillåts vara olika).



Vanligen är man mest intresserad av Δ . För att få kunskap härom använder man ett trick, som bäst belyses av ett exempel.



EXEMPEL PÅ STICKPROV I PAR

På ett bryggeri gör man varje dag analyser av alkoholhalten i öl. Dessa analyser utförs av två kemister A och B. Man vill undersöka om det finns någon systematisk skillnad mellan As och Bs mätningar. Varje dag, under n dagar låter man A och B, oberoende av varandra, analysera samma prov.



KTH Matematik

Vi leds då till följande modell:

$$\begin{aligned} X_1, X_2, \dots, X_n &\text{ är } N(\mu_i, \sigma_A) && \text{(As analyser)} \\ Y_1, Y_2, \dots, Y_n &\text{ är } N(\mu_i + \Delta, \sigma_B) && \text{(Bs analyser)} \end{aligned}$$

där alla X en och Y na är oberoende. Vi menar här att X_i är $N(\mu_i, \sigma_A)$ -fördelad och att Y_i är $N(\mu_i + \Delta, \sigma_B)$ -fördelad.

Tricket är nu att bilda

$$Z_i = Y_i - X_i$$

som är $N(\Delta, \sigma)$ -fördelad, med

$$\sigma \left(= \sqrt{\sigma_A^2 + \sigma_B^2 - 2Cov} \right).$$

Vi har nu återfört problemet till fallet med ett stickprov, och kan ge konfidensintervall för Δ på samma sätt som vi gjorde för μ , dvs.

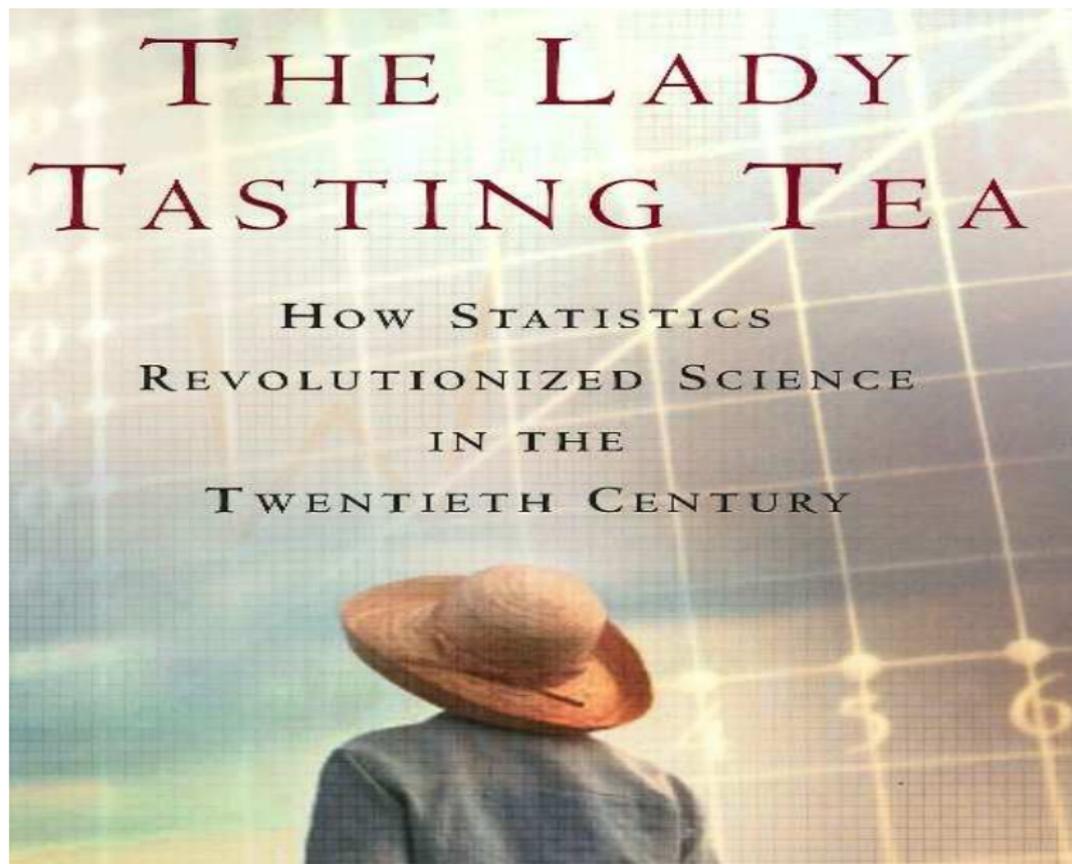
$$\underline{l_{\Delta} = \bar{z} \pm \lambda_{\alpha/2} \sigma / \sqrt{n}}$$

om σ känd och

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

om σ okänd, där

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z})^2.$$



- David Salsburg: The Lady Tasting Tea. How Statistics Revolutionized Science in the Twentieth Century. W.H. Freeman Co, New York 2001.

Denna populärvetenskapliga bok innehåller mycket mer än enbart hypotesprövning. I själva verket behandlas allt som ingår i denna kurs på ett underhållande vis.

- Vi kommer att formulera en rätt så abstrakt svit av begrepp och modeller.
- Därför börjar vi med ett exempel.

En person påstår att hen har extrasensory perception (ESP), som yttrar sig i förmåga att med förbundna ögon avgöra om krona eller klave kommer upp vid kast med ett mynt.



- Låt p vara den okända sannolikheten att hen svarar rätt vid ett sådant kast.
- Man kastar ett symmetriskt mynt 12 gånger och med ledning av antalet korrekta svar x pröva vad som kallas nollhypotesen

$$H_0 : p = 1/2$$

(som innebär att personen bara gissar).

- Modellen: För varje p gäller att x är en observation av $X \in \text{Bin}(12, p)$ och speciellt, om H_0 är sann, att $X \in \text{Bin}(12, 1/2)$.

En procedur:

- Förekasta H_0 , d.v.s påstå att personen har ESP, om x är tillräckligt stort, säg om $x \geq a$, men inte annars.
- Storheten a bör bestämmas så att sannolikheten är liten att H_0 förkastas om H_0 skulle vara sann. Därigenom garderar vi oss mot att påstå att personen har ESP om detta inte är sant.
- Angivna sannolikhet kallar vi **felrisken** eller **signifikansnivån** (ofta 0.05, 0.01 och 0.001)

Börja med felrisken 0.05; vi säger vi att felrisken skall vara ca (men inte mer än) 0.05. Dvs. $P(X \geq a)$, om $p = 1/2$, bör vara ca 0.05, ty om $x \geq a$ i detta fall kommer vi felaktigt att påstå att H_0 är falsk, d.v.s att personen har ESP.

$$P(X \geq a) = \sum_{i=a}^{12} \binom{12}{i} \left(\frac{1}{2}\right)^{12} \lesssim 0.05. \quad (1)$$

För att lösa denna ekvation i a kan man pröva sig fram.

12	11	10	9
0.00024	0.00293	0.01611	0.05371

För $a = 10$ blir summan 0.016 och närmare 0.05 kan man inte komma, eftersom man inte vill överskrida detta tal. Om personen svarar rätt minst 10 gånger bör man alltså påstå att han har ESP, men inte annars.

Om man sänker felrisken från 0.05, först till 0.01, sedan till 0.001 :

Felrisk \lesssim 0.05	$a = 10$
0.01	11
0.001	12

I det sista fallet måste vi alltså kräva helt riktigt svar. Vi ser att det inte går att minska felrisken hur mycket som helst; skulle man vara så rädd för felaktigt uttalande att man vill ha en felrisk på, säg, 10^{-6} , måste man kasta myntet mer än 12 gånger.

HYPOTESPRÖVNING: BEGREPP I SAMBAND MED EXEMPLET OM ESP

- $X \in \text{Bin}(12, p)$: en testvariabel, x observerat värde på X
- $x \geq a$: ett kritiskt område (ett ensidigt test)
- H_0 : $p = 1/2$ nollhypotes
- Beslutsregel: Förkasta H_0 om observationen hamnar i kritiskt område.
- Bestäm a så att $P(X \geq a) = \alpha$, $\alpha =$ felrisk, signifikansnivå.
- $P(X \geq a) = \sum_{i=a}^{12} \binom{12}{i} \left(\frac{1}{2}\right)^{12}$ om H_0 sann.

Nytt påstående: 'Jag kan i nio fall av tio svara rätt.' Detta är en mothypotes (hypotes mot H_0)

$$H_0 : p = 1/2$$

$$H_1 : p = 9/10$$

Tag $\alpha = 0.05$. Fökasta H_0 om $x \geq 10$.

- $h(0.9) = P(X \geq 10) = \sum_{i=10}^{12} \binom{12}{i} \left(\frac{9}{10}\right)^i \left(\frac{1}{10}\right)^{12-i}$

Detta är sannolikheten för att H_0 förkastas om $p = 9/10$ sant.
(=TESTETS STYRKA.)

$$h(p) = \sum_{i=10}^{12} \binom{12}{i} (p)^i (1-p)^{12-i} \text{ kallas testets styrkefunktion.}$$

Du kan själv testa din egen förmåga för ESP med Rhines och Zeners test, som är ungefär som ovan men har fem symboler och räknar signifikans med t -fördelning (jfr. nedan). Se:

<http://www.scientificpsychic.com/esp/esptest.html>

Vi avslutar denna föreläsning genom att ta fram de generiska beståndsdelarna av varje tillfälle av hypotesprövning/statistiskt test samt tänket i statistiska test-



Rare Event Rule

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



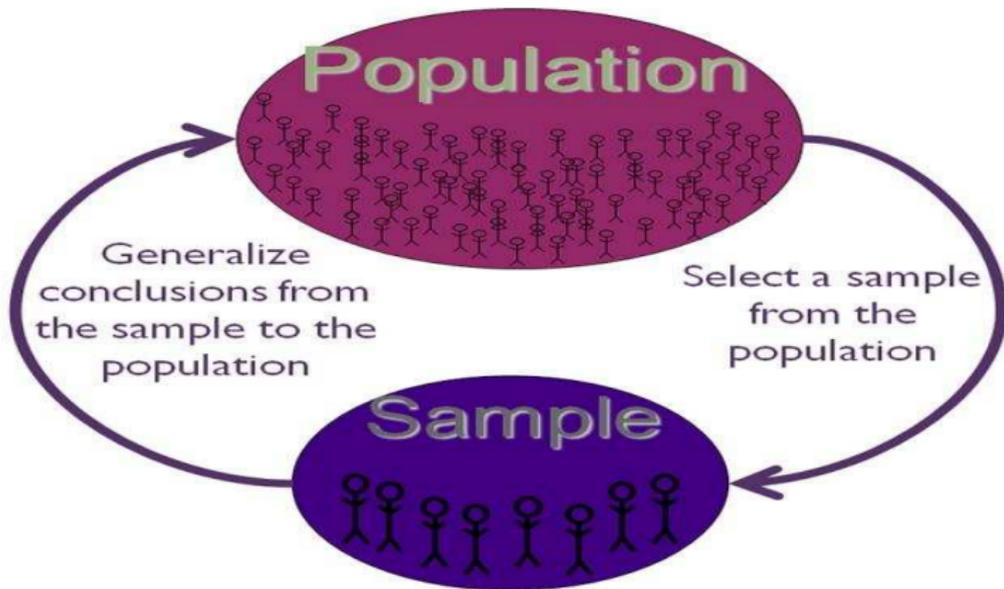
DEFINITION

*In statistics, a **hypothesis** is a claim or statement about a property of a population. A **hypothesis test** (or a significance test) is a standard procedure for checking a claim about a property of a population.*

Example of a hypothesis:

- In genetics, G. Mendel claims that under certain circumstances, the percentage of the offspring peas with yellow pods is 25 %.

A **hypothesis** is a claim or statement about a property of a population.



Standard procedure contains: *null hypothesis, alternative hypothesis, test statistic, significance level, critical value, decision rule, proceed assuming null hypothesis is true, with the logic of the rule of rare event.*

THE INDIVIDUAL COMPONENTS OF A STATISTICAL TEST

- Given a claim identify a statistical model for your population and the **null hypothesis** and the **alternative hypothesis**.
- Given a claim and sample data, compute the value of the **test statistic**
- Given **significance level**, identify the **critical values**.
- Given a value of a test statistic, identify significance level, identify the **p -value**.

We shall now explain what this, excluding for the moment p -value, is.



THE STRUCTURE AND LOGIC A STATISTICAL TEST: NULL AND ALTERNATIVE HYPOTHESIS

- The **null hypothesis** (denoted by H_0) is a statement that the value of a population parameter (such as proportion, mean, standard deviation) is equal to some claimed value. Examples:

$$H_0 : p = 0.5 \quad H_0 : \mu = 0.86$$

We assume that H_0 is true and reach a conclusion either to **reject H_0** or **fail to reject H_0** .

- The **alternative hypothesis** (denoted by H_1) is a statement that the value of a population parameter is somehow different from the null hypothesis.

$$H_1 : p > 0.5 \quad H_1 : p < 0.5 \quad H_1 : p \neq 0.5$$



THE STRUCTURE AND LOGIC A STATISTICAL TEST: TEST STATISTIC

The **test statistic** is a value computed from the sample data and it is used to make the decision about the rejection of the null hypothesis. The test statistic is used to for determining whether there is significant evidence against the null hypothesis. Examples:

- Test statistic (=testvariabel) for proportion: $z = \frac{\hat{p} - p}{\sqrt{\frac{pq}{n}}}$.
- Test statistic for mean: $z = \frac{\bar{x} - \mu}{\frac{\sigma}{\sqrt{n}}}$ or $t = \frac{\bar{x} - \mu}{\frac{s}{\sqrt{n}}}$.

THE STRUCTURE AND LOGIC OF A STATISTICAL TEST: A STATISTICAL TEST: CRITICAL REGION, SIGNIFICANCE LEVEL

- The **critical region** (or **rejection region**) is the set of all values of the test statistic that cause us to reject the null hypothesis.
- The **significance level** denoted by α is the probability that the test statistic will fall in the critical region when the null hypothesis is actually true. Common choices of α are 0.05, 0.01 and 0.10.
- A **critical value** is any value that separates the critical region, where we reject the null hypothesis, from the values of the test statistic that do not lead to rejection of the null hypothesis.



TWO-TAILED, LEFT-TAILED, RIGHT-TAILED

The *tails* in a density curve are the regions bounded by critical values. Some hypothesis tests are two-tailed, some are right-tailed and some are left-tailed.

- **Two-tailed test:** the critical region in two parts, significance level is a sum of two areas under the density curve. The significance level is divided equally between the two tails.
- **Left-tailed test:** the critical region in the left tail of the density curve.
- **Right-tailed test:** the critical region in the right tail of the density curve.



- Hypotesprövning: allmänt
 - Nollhypotes, mothypotes
 - Teststorhet (testvariabel)
 - Kritiskt område, Signifikansnivå,
 - Styrkefunktion
- Tvåsidiga test
- Hypotesprövning och konfidensintervall