

# Kapittel 7: Inferens for forventninger- ukjent standardavvik

- 7.1: Inferens for forventningen i en populasjon
- 7.2: Inferens for å sammenligne to forventninger

## 7.1 Inferens for forventningen i en populasjon

- t-fordelingen
- Ett-utvalgs t-konfidensintervall
- Ett-utvalgs t-test
- Matchede par t-prosedyrer
- Robusthet

# Ødelegger lagring søtheten av Cola?

En cola-produsent ønsker å teste hvor mye søtheten til en ny cola-drikk påvirkes av lagring. Søthets-tapet som følge av lagring ble bedømt av 10 profesjonelle smakstestere (ved å sammenligne søtheten før og etter lagring):



| Smakstester | Søthets-tap |                                      |
|-------------|-------------|--------------------------------------|
| • 1         | 2.0         |                                      |
| • 2         | 0.4         |                                      |
| • 3         | 0.7         | Vi ønsker altså å teste om           |
| • 4         | 2.0         | lagring medfører tap i søhet,        |
| • 5         | -0.4        | altså:                               |
| • 6         | 2.2         |                                      |
| • 7         | -1.3        | $H_0: \mu = 0$ versus $H_a: \mu > 0$ |
| • 8         | 1.2         |                                      |
| • 9         | 1.1         | der $\mu$ er forventet tap av søhet  |
| • 10        | 2.3         |                                      |

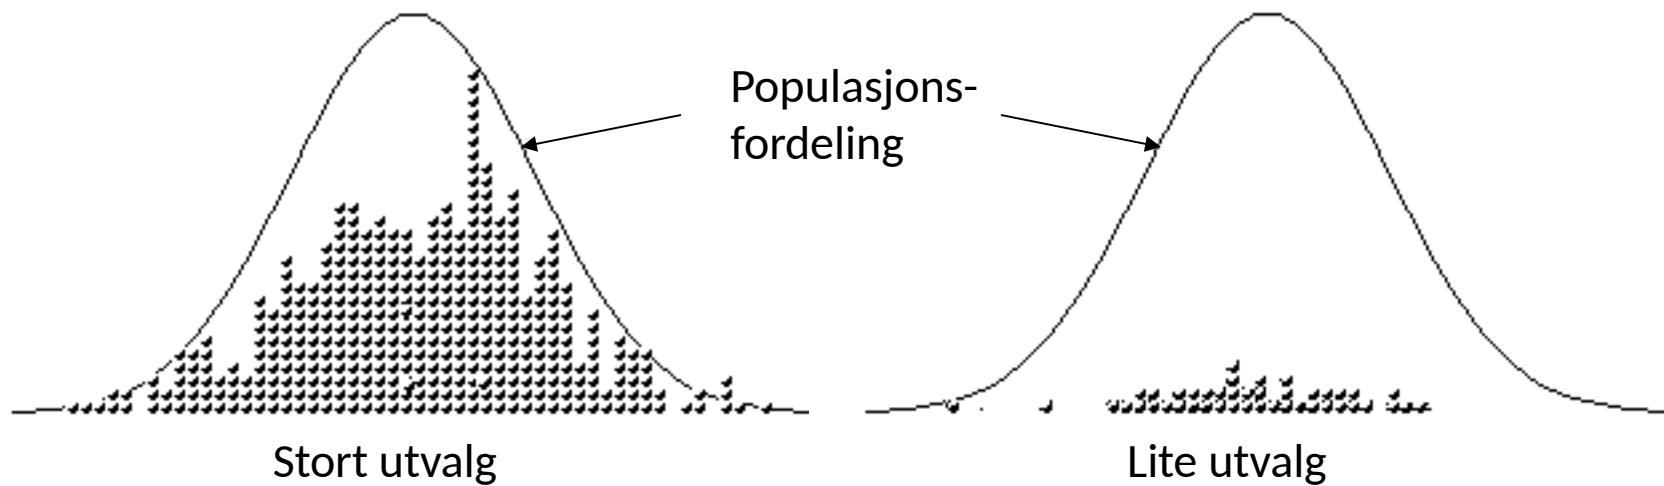
Dette ser kjent ut. Men siden dette er en ny cola-oppskrift har vi ikke noe populasjonsdata fra tidligere, og vi kjenner ikke populasjonsparameteren  $\sigma$ .

Dette er en veldig vanlig situasjon for relle data.

# Når $\sigma$ er ukjent

Empirisk standardavvik  $s$  gir oss et estimat for populasjonens standardavvik  $\sigma$ .

- Når utvalgsstørrelsen er stor, er det sannsynlig at utvalget representerer populasjonen godt. Da er  $s$  et godt estimat for  $\sigma$ .
- Men hvis utvalgsstørrelsen er liten, er  $s$  et dårlig estimat for  $\sigma$ .



Husk empirisk standardavvik

$$s = \sqrt{\frac{1}{n-1} \sum (x_i - \bar{x})^2}$$

der  $n-1$  kaltes antall frihetsgrader (degrees of freedom, df)

# En populasjon

- Anta  $x_1, \dots, x_n$  uavhengige fra  $N(\mu, \sigma)$
- Statistikk:  $\bar{x}$
- $\sigma$  kjent:  $z = (\bar{x} - \mu) / (\sigma / \sqrt{n})$
- $\sigma / \sqrt{n}$ : standardavvik for statistikk  $\bar{x}$
- $s / \sqrt{n}$ : estimert standardavvik for statistikk  $\bar{x}$
- Kalles *standardfeil*

$$\text{Standard Error, SE} = s / \sqrt{n}$$

# t-fordeling

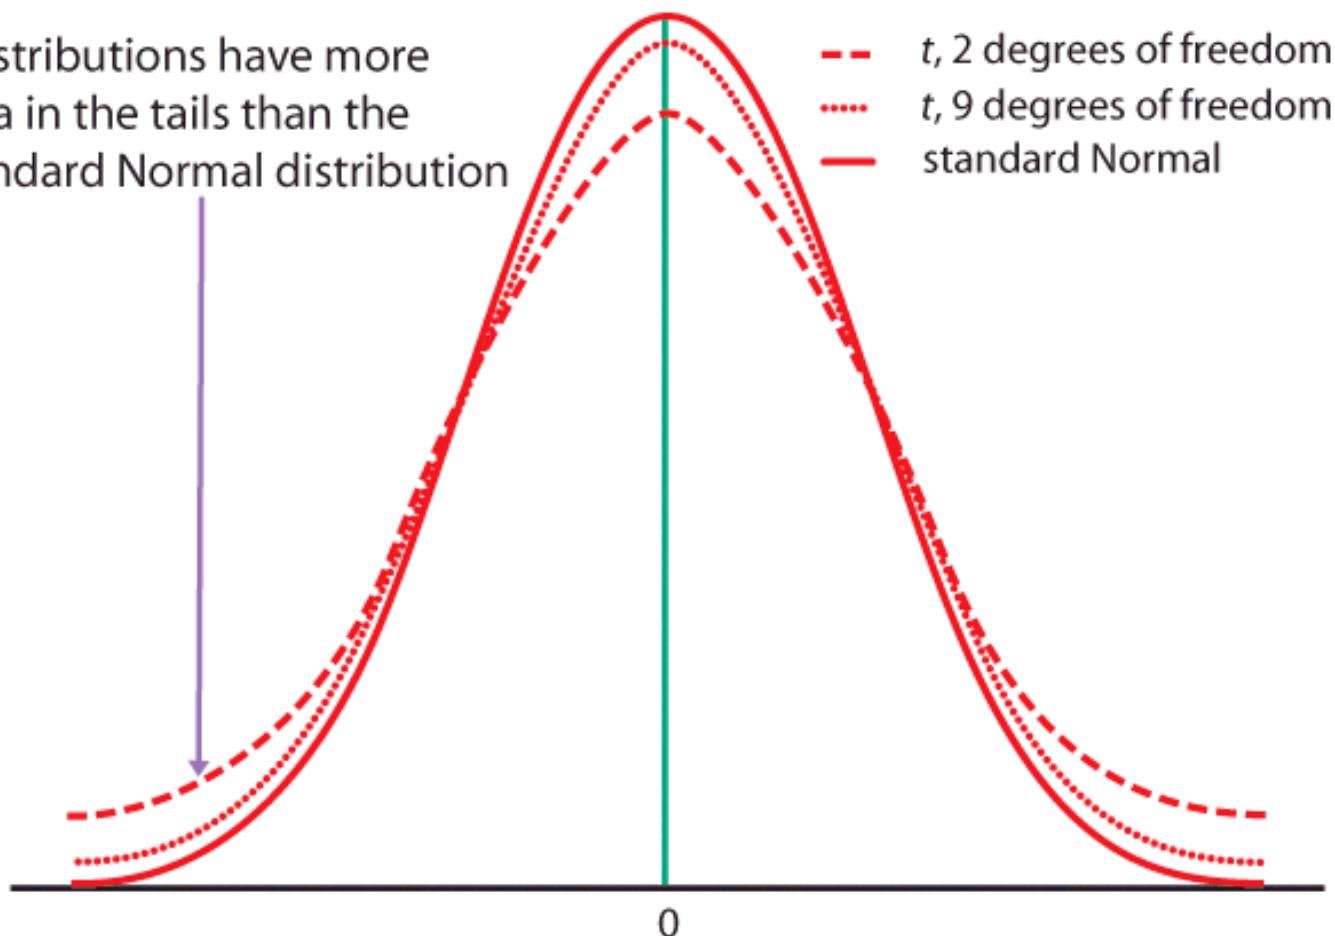
- $z = (\bar{x} - \mu) / (\sigma / \sqrt{n})$  er  $N(0,1)$ -fordelt
- $t = (\bar{x} - \mu) / (s / \sqrt{n})$  er *t-fordelt med  $n-1$  frihetsgrader*

$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}}$$

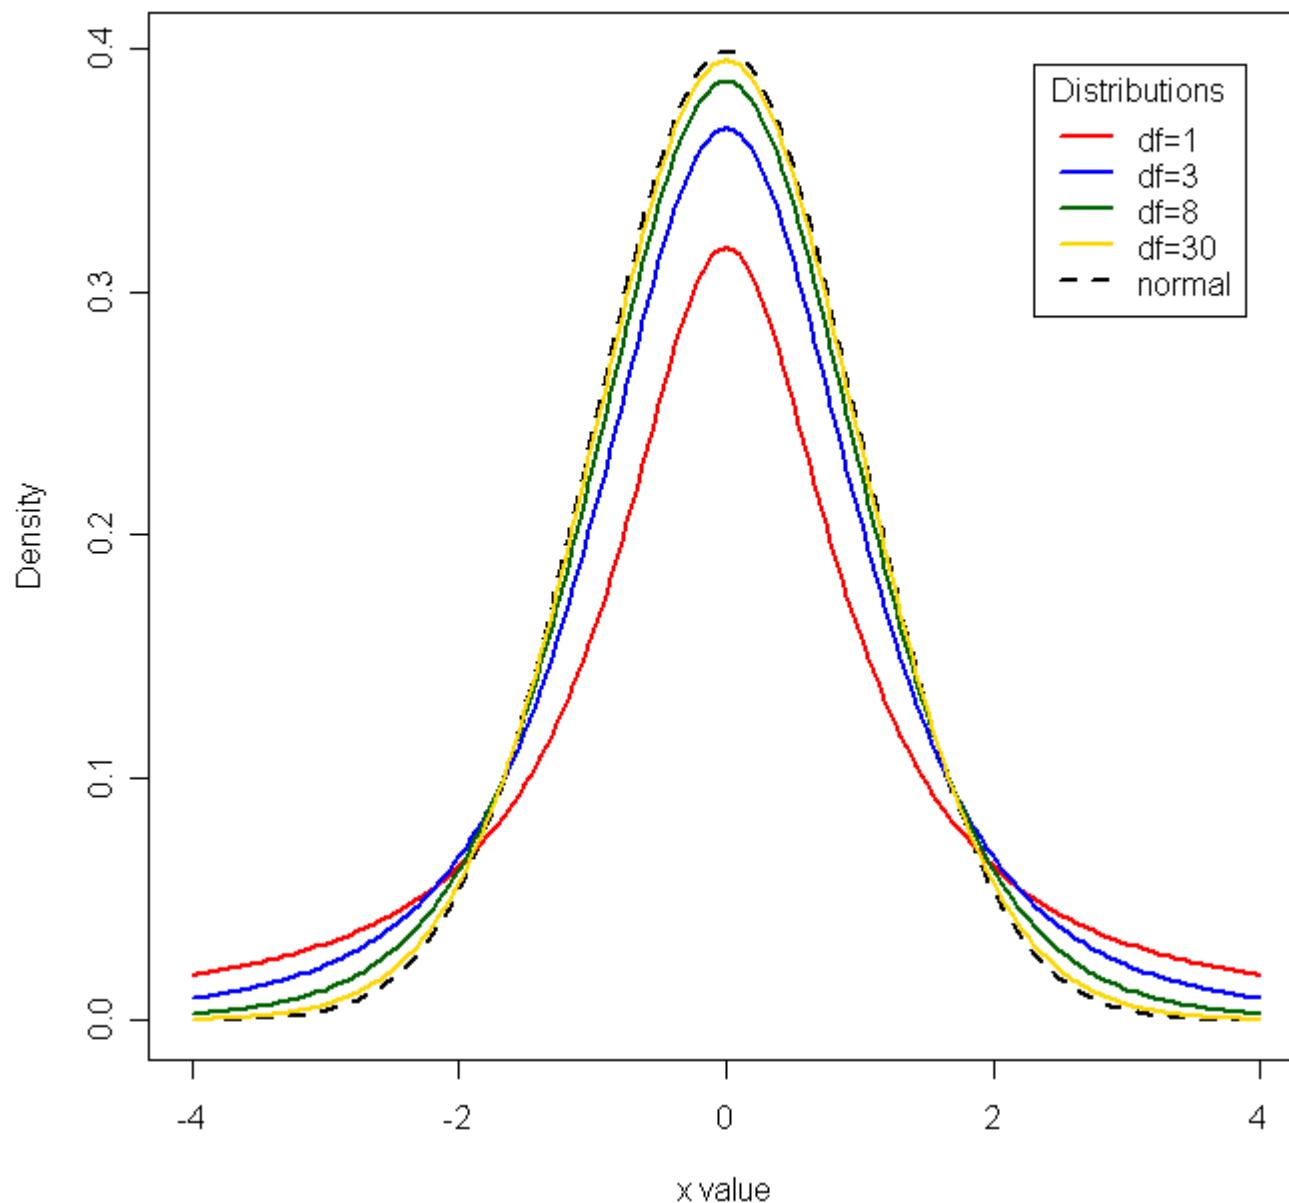
Kalles *ett-utvalgs t-statistikk*  
(eller ett-utvalgs t-observator)

- Form som normalfordeling
- Ekstra spredning/usikkerhet pga. ukjent  $\sigma$
- Nærmer seg  $N(0,1)$  når  $n$  vokser

$t$  distributions have more area in the tails than the standard Normal distribution

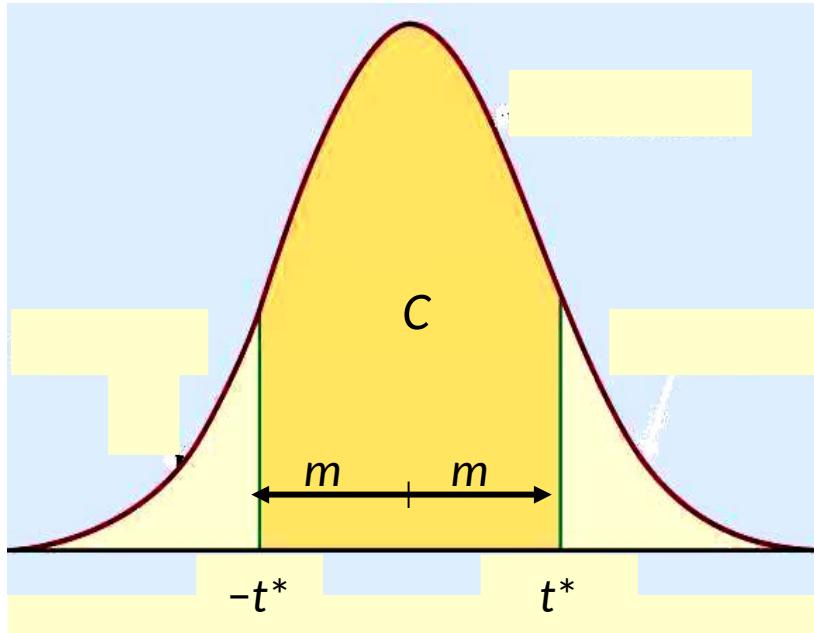


## Comparison of t Distributions



# Ett-utvalgs t-konfidensintervall

- $\sigma$  kjent:  $[\bar{x} - z^* \sigma / \sqrt{n}, \bar{x} + z^* \sigma / \sqrt{n}]$
- $z^*$  er verdien slik at arealet mellom  $-z^*$  og  $z^*$  i  $N(0,1)$  fordelingen er  $C$
- $\sigma$  ukjent:  $[\bar{x} - t^* s / \sqrt{n}, \bar{x} + t^* s / \sqrt{n}]$
- $t^*$  er verdien slik at arealet mellom  $-t^*$  og  $t^*$  i  $t(n-1)$  fordelingen er  $C$



- Feilmarginen er  $m = t^*s/\sqrt{n}$
- Eksakt hvis normalfordelte data
- Tilnærmet riktig ellers

Når  $\sigma$  er ukjent, bruker vi t-fordeling med " $n-1$ " frihetsgrader (degrees of freedom df).

**Tabell D viser  
z-verdier og t-verdier  
knyttet til typiske P-  
verdier/ konfidensnivåer**

Når  $\sigma$  er kjent, bruker vi normalfordeling og den standardiserte z-verdien.

## Moderate mengder rødvin

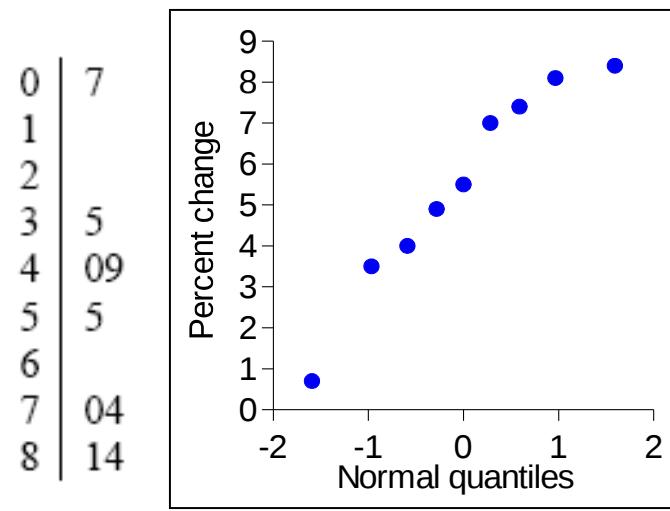
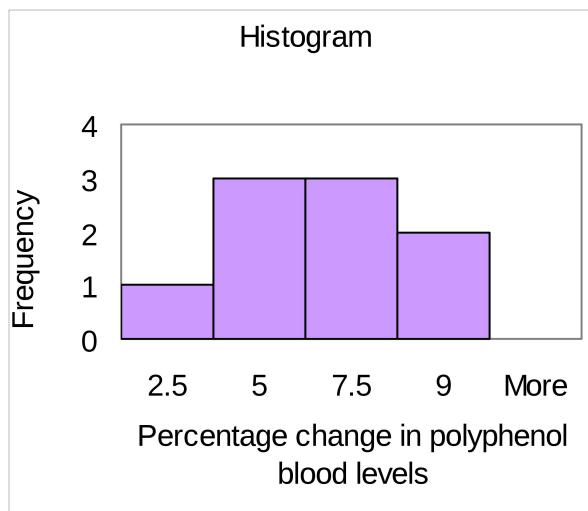
Å drikke rødvin i moderate mengder kan beskytte mot hjerteinfarkt. Polyphenolene i rødvinen virker på kolesterollet, noe som kanskje kan motvirke hjerteinfarkt.



For å undersøke om moderat inntak av rødvin øker forventet nivå av polyphenoler i blodet skulle en gruppe på 9 tilfeldig valgte friske menn drikke en moderat mengde rødvin hver dag i 2 uker. Nivået av polyphenoler i blodet ble målt både før og etter disse 2 ukene, og den prosentvise endringen var som følger:

Først: Er dataene tilnærmet normalfordelte?

0.7    3.5    4    4.9    5.5    7    7.4    8.1    8.4



Det er en lav verdi, men generelt ser det ut til at man kan anta at dataene kan antas å være tilnærmet normalfordelte.

Hva er 95% konfidensintervallet for forventet prosentvis økning av nivå av polyphenoler i blodet?

$$\text{Utvalgs-gjennomsnitt} = 5.5; s = 2.517; df = n - 1 = 8$$



**TABLE D**

*t* distribution critical values

| df | Upper-tail probability <i>p</i> |       |       |       |       |       |       |       |       |       |       |       |
|----|---------------------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|    | .25                             | .20   | .15   | .10   | .05   | .025  | .02   | .01   | .005  | .0025 | .001  | .0005 |
| 1  | 1.000                           | 1.376 | 1.963 | 3.078 | 6.314 | 12.71 | 15.89 | 31.82 | 63.66 | 127.3 | 318.3 | 636.6 |
| 2  | 0.816                           | 1.061 | 1.386 | 1.886 | 2.920 | 4.303 | 4.849 | 6.965 | 9.925 | 14.09 | 22.33 | 31.60 |
| 3  | 0.765                           | 0.978 | 1.250 | 1.638 | 2.353 | 3.182 | 3.482 | 4.541 | 5.841 | 7.453 | 10.21 | 12.92 |
| 4  | 0.741                           | 0.941 | 1.190 | 1.533 | 2.132 | 2.776 | 2.999 | 3.747 | 4.604 | 5.598 | 7.173 | 8.610 |
| 5  | 0.727                           | 0.920 | 1.156 | 1.476 | 2.015 | 2.571 | 2.757 | 3.365 | 4.032 | 4.773 | 5.893 | 6.869 |
| 6  | 0.718                           | 0.906 | 1.134 | 1.440 | 1.943 | 2.447 | 2.612 | 3.143 | 3.707 | 4.317 | 5.208 | 5.959 |
| 7  | 0.711                           | 0.896 | 1.119 | 1.415 | 1.895 | 2.365 | 2.517 | 2.998 | 3.499 | 4.029 | 4.785 | 5.408 |
| 8  | 0.706                           | 0.889 | 1.108 | 1.397 | 1.860 | 2.306 | 2.449 | 2.896 | 3.355 | 3.833 | 4.501 | 5.041 |

Utvalgsfordelingen er en t-fordeling med  $n - 1$  frihetsgrader.

For  $df = 8$  og  $C = 95\%$ :  $t^* = 2.306$ .

Feilmarginen  $m$  er:  $m = t^*s/\sqrt{n} = 2.306 * 2.517/\sqrt{9} \approx 1.93$ .

**Med 95% sikkerhet kan vi si at forventet prosentvis økning av nivå av polyphenoler i blodet for friske menn som drikker en moderat mengde rødvin hver dag er mellom 3.6% og 7.4%. Viktig: Konfidensintervallet viser hvor stor endringen av nivået av polyphenoler i blodet er, men ikke om det har en innvirkning på mنس helse!**

# Ett-utvalgs t-test

Fremgangsmåten for å teste en hypotese er som tidligere:

1. Formuler null- og alternativ-hypoteser ( $H_0$  versus  $H_a$ )
2. Velg signifikansnivå  $\alpha$
3. Beregn t-observator og antall frihetsgrader (beregnet ved å anta at parameterverdien gitt av  $H_0$  er sann)
4. Finn ønsket sannsynlighet fra Tabell D (sannsynligheten for at et utfall er like ekstremt eller mer ekstremt enn faktisk utfall)
5. Oppgi P-verdi og formuler en konklusjon

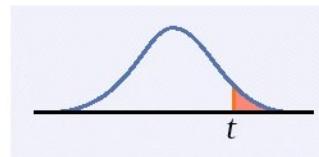
## THE ONE-SAMPLE $t$ TEST

Suppose that an SRS of size  $n$  is drawn from a population having unknown mean  $\mu$ . To test the hypothesis  $H_0: \mu = \mu_0$  based on an SRS of size  $n$ , compute the one-sample  $t$  statistic

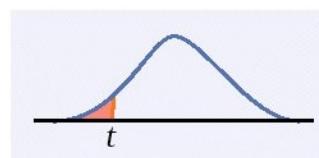
$$t = \frac{\bar{X} - \mu_0}{s/\sqrt{n}}$$

In terms of a random variable  $T$  having the  $t(n - 1)$  distribution, the  $P$ -value for a test of  $H_0$  against

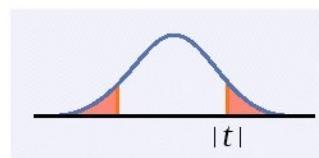
$$H_a: \mu > \mu_0 \text{ is } P(T \geq t)$$



$$H_a: \mu < \mu_0 \text{ is } P(T \leq t)$$



$$H_a: \mu \neq \mu_0 \text{ is } 2P(T \geq |t|)$$



These  $P$ -values are exact if the population distribution is normal and are approximately correct for large  $n$  in other cases.

**Definition, pg 454**

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W.H.Freeman and Company

## Søthet av cola (fortsettelse)



Er det bevis for at lagring medfører søthets-tap for den nye cola-oppskriften på et 0.05 signifikansnivå ( $\alpha = 5\%$ )?

$H_0: \mu = 0$  versus  $H_a: \mu > 0$  (ensidig test)

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{1.02 - 0}{1.196/\sqrt{10}} = 2.70$$

Antall frihetsgrader:  $df=10-1=9$

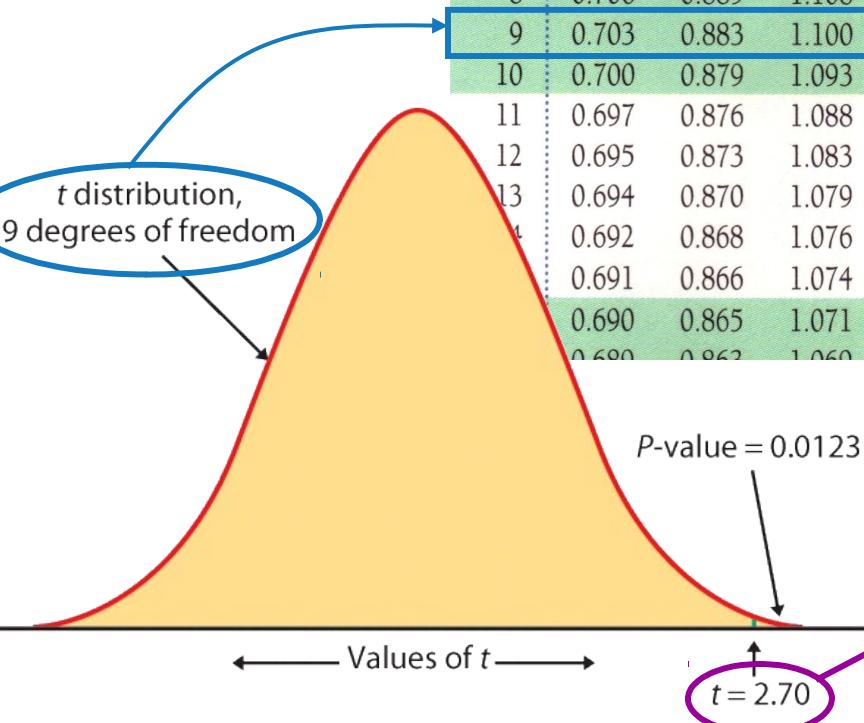
| Taster | Sweetness loss |
|--------|----------------|
| 1      | 2.0            |
| 2      | 0.4            |
| 3      | 0.7            |
| 4      | 2.0            |
| 5      | -0.4           |
| 6      | 2.2            |
| 7      | -1.3           |
| 8      | 1.2            |
| 9      | 1.1            |
| 10     | 2.3            |

---

|                    |             |
|--------------------|-------------|
| Average            | 1.02        |
| Standard deviation | 1.196       |
| Degrees of freedom | $n - 1 = 9$ |

| df | Upper tail probability $p$ |       |       |       |       |       |       |       |       |       |       |       |
|----|----------------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|    | .25                        | .20   | .15   | .10   | .05   | .025  | .02   | .01   | .005  | .0025 | .001  | .0005 |
| 1  | 1.000                      | 1.376 | 1.963 | 3.078 | 6.314 | 12.71 | 15.89 | 31.82 | 63.66 | 127.3 | 318.3 | 636.6 |
| 2  | 0.816                      | 1.061 | 1.386 | 1.886 | 2.920 | 4.303 | 4.849 | 6.965 | 9.925 | 14.09 | 22.33 | 31.60 |
| 3  | 0.765                      | 0.978 | 1.250 | 1.638 | 2.353 | 3.182 | 3.482 | 4.541 | 5.841 | 7.453 | 10.21 | 12.92 |
| 4  | 0.741                      | 0.941 | 1.190 | 1.533 | 2.132 | 2.776 | 2.999 | 3.747 | 4.604 | 5.598 | 7.173 | 8.610 |
| 5  | 0.727                      | 0.920 | 1.156 | 1.476 | 2.015 | 2.571 | 2.757 | 3.365 | 4.032 | 4.773 | 5.893 | 6.869 |
| 6  | 0.718                      | 0.906 | 1.134 | 1.440 | 1.943 | 2.447 | 2.612 | 3.143 | 3.707 | 4.317 | 5.208 | 5.959 |
| 7  | 0.711                      | 0.896 | 1.119 | 1.415 | 1.895 | 2.365 | 2.517 | 2.998 | 3.499 | 4.029 | 4.785 | 5.408 |
| 8  | 0.706                      | 0.889 | 1.108 | 1.397 | 1.860 | 2.306 | 2.449 | 2.896 | 3.355 | 3.833 | 4.501 | 5.041 |
| 9  | 0.703                      | 0.883 | 1.100 | 1.383 | 1.833 | 2.262 | 2.398 | 2.821 | 3.250 | 3.690 | 4.297 | 4.781 |
| 10 | 0.700                      | 0.879 | 1.093 | 1.372 | 1.812 | 2.228 | 2.359 | 2.764 | 3.169 | 3.581 | 4.144 | 4.587 |
| 11 | 0.697                      | 0.876 | 1.088 | 1.363 | 1.796 | 2.201 | 2.328 | 2.718 | 3.106 | 3.497 | 4.025 | 4.437 |
| 12 | 0.695                      | 0.873 | 1.083 | 1.356 | 1.782 | 2.179 | 2.303 | 2.681 | 3.055 | 3.428 | 3.930 | 4.318 |
| 13 | 0.694                      | 0.870 | 1.079 | 1.350 | 1.771 | 2.160 | 2.282 | 2.650 | 3.012 | 3.372 | 3.852 | 4.221 |
| 14 | 0.692                      | 0.868 | 1.076 | 1.345 | 1.761 | 2.145 | 2.264 | 2.624 | 2.977 | 3.326 | 3.787 | 4.140 |
| 15 | 0.691                      | 0.866 | 1.074 | 1.341 | 1.753 | 2.131 | 2.249 | 2.602 | 2.947 | 3.286 | 3.733 | 4.073 |
| 16 | 0.690                      | 0.865 | 1.071 | 1.337 | 1.746 | 2.120 | 2.235 | 2.583 | 2.921 | 3.252 | 3.686 | 4.015 |
| 17 | 0.690                      | 0.863 | 1.069 | 1.332 | 1.740 | 2.110 | 2.224 | 2.567 | 2.899 | 3.222 | 3.646 | 3.965 |

For  $df = 9$  ser vi bare på denne linjen i tabellen



Den beregnede verdi av  $t$  er 2.7. Vi finner de to nærmeste  $t$ -verdiene:

$$2.398 < t = 2.7 < 2.821$$

så

$$0.02 > \text{øvre hale } p > 0.01$$

For en en-sidig  $H_a$ , er dette P-verdien (mellan 0.01 og 0.02);

for en to-sidig  $H_a$ , hadde P-verdien vært det dobbelte (mellan 0.02 og 0.04).



## Søthet av cola (fortsettelse)

Er det bevis for at lagring medfører søthets-tap for den nye cola-oppskriften på 0.05 signifikansnivå ( $\alpha = 5\%$ )?

$H_0: \mu = 0$  versus  $H_a: \mu > 0$  (ensidig test)

$$t = \frac{\bar{x} - \mu_0}{s/\sqrt{n}} = \frac{1.02 - 0}{1.196/\sqrt{10}} = 2.70$$

- $-2.398 < t = 2.70 < 2.821$ , altså er  $0.02 > p > 0.01$ .
- $p < \alpha$ , altså er resultatet signifikant.

| Taster | Sweetness loss |
|--------|----------------|
| 1      | 2.0            |
| 2      | 0.4            |
| 3      | 0.7            |
| 4      | 2.0            |
| 5      | -0.4           |
| 6      | 2.2            |
| 7      | -1.3           |
| 8      | 1.2            |
| 9      | 1.1            |
| 10     | 2.3            |

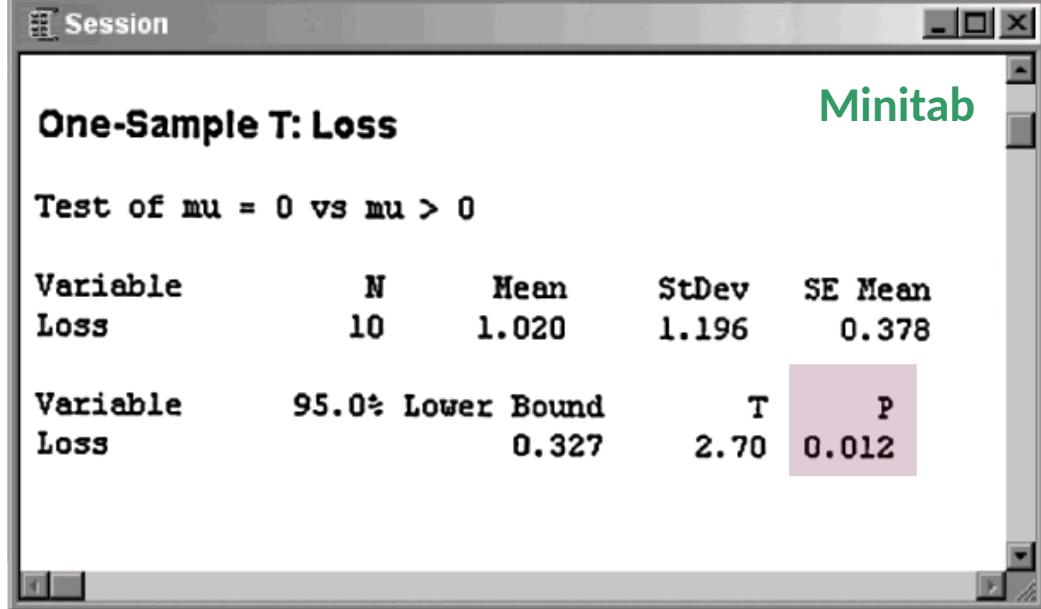
|                    |             |
|--------------------|-------------|
| Average            | 1.02        |
| Standard deviation | 1.196       |
| Degrees of freedom | $n - 1 = 9$ |

| df | Upper tail probability $p$ |       |       |       |       |       |       |       |       |       |       |       |
|----|----------------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
|    | .25                        | .20   | .15   | .10   | .05   | .025  | .02   | .01   | .005  | .0025 | .001  | .0005 |
| 9  | 0.703                      | 0.883 | 1.100 | 1.383 | 1.833 | 2.262 | 2.398 | 2.821 | 3.250 | 3.690 | 4.297 | 4.781 |

$t$ -testen har en signifikant p-verdi. Vi forkaster  $H_0$ .

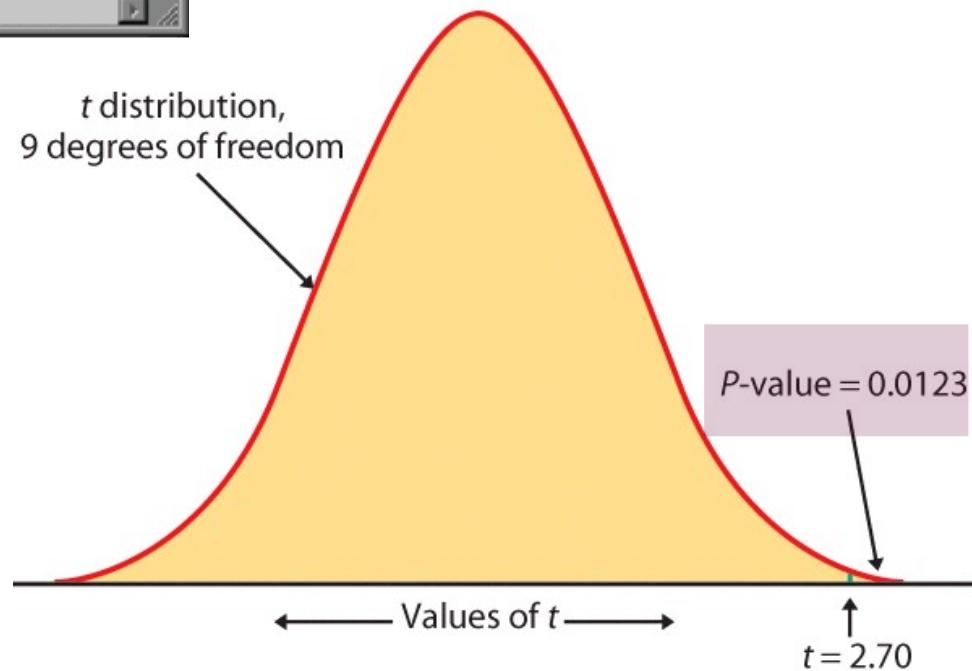
**Det er et signifikant forventet tap av søthet som følge av lagring.**

## Søthet av cola (fortsettelse)



$$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} = \frac{1.02 - 0}{1.196/\sqrt{10}} = 2.70$$

$$df = n - 1 = 9$$



## • Parrede (matchede) t-prosedyrer

Noen ganger vil vi sammenligne behandlinger på de samme individene. Dette gir oss observasjoner som ikke er uavhengige – de er parret eller matchede to og to:

- Eks. Før og etter behandling (blodtrykk før og etter behandling med betablokker, søtsmak før og etter lagring)
- Eks. Tvillingstudier, begrenser effekten av genetiske forskjeller ved å se på en variabel i sett av tvillinger
- Eks. Ved å bruke folk som matcher hverandre i alder, kjønn, utdanning i sosiale studier, kan man kansellere ut effekten av slike underliggende lurevariable

I slike situasjoner kan vi bruke par-data til å teste forskjell i forventning mellom de to fordelingene. Vi studerer variabelen  $X_{\text{diff}} = (X_1 - X_2)$ , og tester

$$H_0: \mu_{\text{diff}} = 0 ; \quad H_a: \mu_{\text{diff}} > 0 \text{ (eller } < 0, \text{ eller } \neq 0)$$

**Dette er det samme som å teste i en ett-utvalgs-situasjon . Data for individ nr  $i$  er da  $x_{\text{diff}} = x_{1i} - x_{2i}$**

# Søthet av cola (*om igjen*)



Søthets-tapet pga lagring ble bedømt av 10 profesjonelle smakstestere (som sammenlignet søtheten **før og etter**):

| Smakstester | Søthets-tap |                                      |
|-------------|-------------|--------------------------------------|
| • 1         | 2.0         | Vi ønsker å teste om lagring         |
| • 2         | 0.4         | medfører tap i søthet, altså:        |
| • 3         | 0.7         |                                      |
| • 4         | 2.0         |                                      |
| • 5         | -0.4        | $H_0: \mu = 0$ versus $H_a: \mu > 0$ |
| • 6         | 2.2         |                                      |
| • 7         | -1.3        |                                      |
| • 8         | 1.2         |                                      |
| • 9         | 1.1         |                                      |
| • 10        | 2.3         |                                      |

Selv om teksten ikke sa det eksplisitt, er dette et pre-/post-test design og variabelen er differensen i søthet av cola før ( $X_1$ ) minus etter lagring ( $X_2$ ).

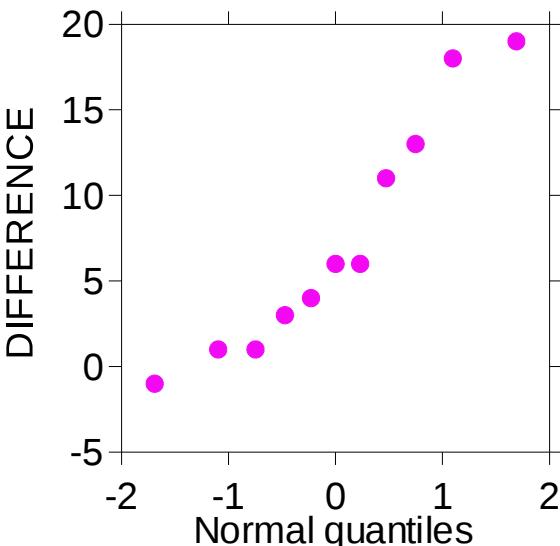
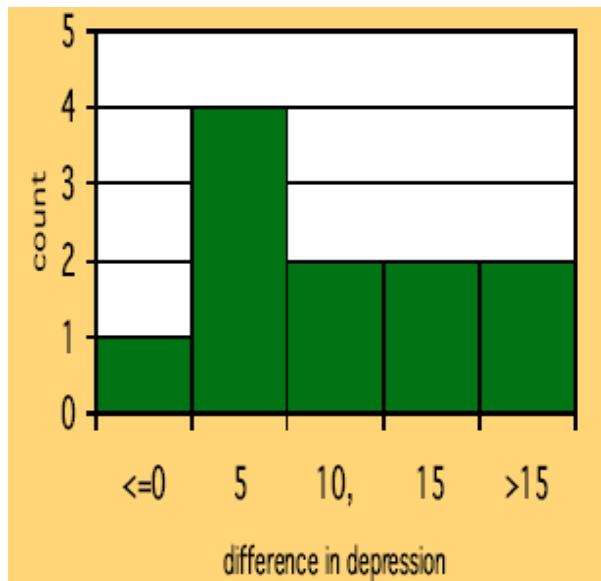
En parret signifikanstest er altså akkurat det samme som en ett-utvalgs signifikanstest.

# Gir koffeinavholdenhet økt depresjon?

11 individer som er diagnostisert som koffeinavhengige blir forhindret fra å innta koffein-holdig mat og drikke og får i stedet daglige piller. Noen ganger inneholder disse pillene koffein og noen ganger inneholder de en placebo. Forskjellen i depresjonsnivå når individene får koffein kontra når de får placebo ble evaluert.

| Subject | Depression with Caffeine | Depression with Placebo | Placebo - Caffeine |
|---------|--------------------------|-------------------------|--------------------|
| 1       | 5                        | 16                      | 11                 |
| 2       | 5                        | 23                      | 18                 |
| 3       | 4                        | 5                       | 1                  |
| 4       | 3                        | 7                       | 4                  |
| 5       | 8                        | 14                      | 6                  |
| 6       | 5                        | 24                      | 19                 |
| 7       | 0                        | 6                       | 6                  |
| 8       | 0                        | 3                       | 3                  |
| 9       | 2                        | 15                      | 13                 |
| 10      | 11                       | 12                      | 1                  |
| 11      | 1                        | 0                       | -1                 |

- Det er 2 datapunkter for hvert individ, men vi ser bare på differansen i depresjonsnivå ( $x = x_{2i} - x_{1i}$ )
- Utvalgsfordelingen ser ut til å være passende for en  $t$ -test.



## Gir koffeinavholdenhet økt depresjon?

For hvert individ i utvalget har vi beregnet forskjellen i depresjonsnivå (placebo minus koffein).

Det var 11 “differanse”-verdier, altså er  $df = n - 1 = 10$ .

Vi beregner at  $\bar{x} = 7.36; s = 6.92$

$$H_0: \mu_{\text{diff}} = 0 ; H_1: \mu_{\text{diff}} > 0$$

$$t = \frac{\bar{x} - 0}{s/\sqrt{n}} = \frac{7.36}{6.92/\sqrt{11}} = 3.53$$

| Subject | Depression with Caffeine | Depression with Placebo | Placebo - Caffeine |
|---------|--------------------------|-------------------------|--------------------|
| 1       | 5                        | 16                      | 11                 |
| 2       | 5                        | 23                      | 18                 |
| 3       | 4                        | 5                       | 1                  |
| 4       | 3                        | 7                       | 4                  |
| 5       | 8                        | 14                      | 6                  |
| 6       | 5                        | 24                      | 19                 |
| 7       | 0                        | 6                       | 6                  |
| 8       | 0                        | 3                       | 3                  |
| 9       | 2                        | 15                      | 13                 |
| 10      | 11                       | 12                      | 1                  |
| 11      | 1                        | 0                       | -1                 |

For  $df = 10$ :  $3.169 < t = 3.53 < 3.581 \rightarrow 0.005 > p > 0.0025$

Koffeinavholdenhet gir en signifikant økning av depresjon.

# • Robusthet

t-prosedyrene er eksakt riktige når populasjonen er eksakt normalfordelt. I praksis vil vi ikke alltid ha eksakt normalfordeling, men t-prosedyrene er **robuste** i forhold til mindre avvik fra normalitet – resultatene blir ikke så gale selv om normalitetsantakelsen ikke holder. Viktige faktorer er:

- **Tilfeldig utvalg.** Utvalget **må** være et SRS fra populasjonen.
- **Uteliggere og skjevhet.** Påvirker gjennomsnittet og derfor også t-prosedyrene. MEN, betydningen av dette avtar med økende antall observasjoner på grunn av sentralgrenseteoremet (CLT).

## Spesielt:

- Når  $n < 15$ , må data være tilnærmet normalfordelte og uten uteliggere
- Når  $15 > n > 40$ , er det ok med noe skjevhetsmen ikke uteliggere
- Når  $n > 40$ , er t-observatoren ok selv med sterk skjevhet i underliggende fordeling

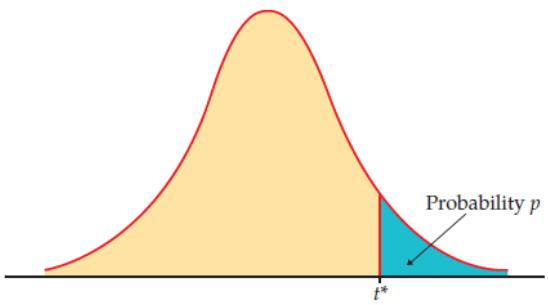


Table entry for  $p$  and  $C$  is the critical value  $t^*$  with probability  $p$  lying to its right and probability  $C$  lying between  $-t^*$  and  $t^*$ .

TABLE D

### ***t* distribution critical values**

## 7.2

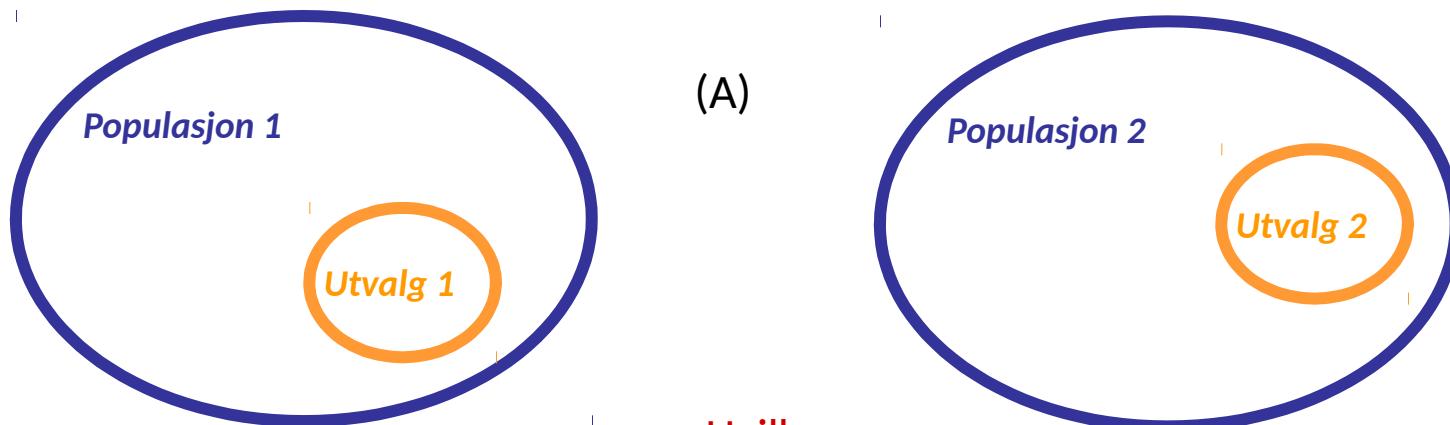
# Sammenligning av to forventinger

- To-utvalgs z-statistikk
- To-utvalgs t-prosedyrer
- To-utvalgs t-tester
- To-utvalgs t-konfidensintervall
- Robusthet
- To-utvalgs t-prosedyrer når variansene er like

# Sammenlikning av to forventninger

- Effekt av økt kalsium på blodtrykk
  - En gruppe får økt kalsium i diett
  - Kontrollgruppe får placebo
- Bank: To kampanjer for å øke bruk av kredittkort
  - Et tilfeldig utvalg eksponert for kampanje 1
  - Et annet tilfeldig utvalg eksponert for kamp. 2

- Sammenligning av to utvalg

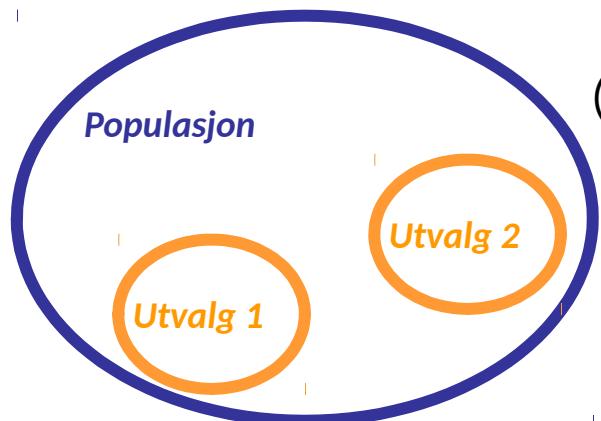


(A)

Hvilken

---

situasjon har vi?



(B)

Vi sammenligner ofte to behandlinger på to uavhengige utvalg.

Er forskjellene vi observerer et resultat av variasjon i utvalgene (B), eller er det en ekte forskjell, dvs. at utvalgene kommer fra to forskjellige populasjoner (A)?

# Notasjon

| Populasjon | Variabel | Forventning | Standard avvik |
|------------|----------|-------------|----------------|
| 1          | $x_1$    | $\mu_1$     | $\sigma_1$     |
| 2          | $x_2$    | $\mu_2$     | $\sigma_2$     |

| Populasjon | Utvalgstørrelse | Gjennomsnitt | Standard avvik |
|------------|-----------------|--------------|----------------|
| 1          | $n_1$           | $\bar{x}_1$  | $s_1$          |
| 2          | $n_2$           | $\bar{x}_2$  | $s_2$          |

# Statistikk for to-utvalg med kjente standardavvik

Av interesse:  $\mu_1 - \mu_2$

Naturlig estimat:  $\bar{x}_1 - \bar{x}_2$

$$\mu_{\bar{x}_1 - \bar{x}_2} = \mu_1 - \mu_2$$

Varians  $\bar{x}_2 - \bar{x}_2$  er  $\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$

$$z = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \text{ er } N(0,1)$$

Men veldig uvanlig at man kjenner standardavvikene!

# To-utvalg – ukjente varianser

- I praksis:  $\sigma_1$  og  $\sigma_2$  ukjente
- Estimeres ved  $s_1$  og  $s_2$ , får da

$$\text{Statistikk } t = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

- Ikke  $t$ -fordelt! En  $t$ -fordeling erstatter en  $N(0,1)$ -fordeling bare når et enkelt standardavvik  $\sigma$  i en z-statistikk erstattes med ett empirisk standardavvik  $s$
- Men: Tilnærmet  $t(k)$ -fordelt med passende antall frihetsgrader  $k$
- To måter å estimere  $k$  på: En metode som beregnes fra data (med dataprogram), eller den minste verdien av  $(n_1-1)$  og  $(n_2-1)$

# To-utvalgs $t$ -konfidensintervall

Når vi har to tilfeldige, uavhengige utvalg av størrelser  $n_1$  og  $n_2$  fra to normalfordelte populasjoner med ukjente forventninger  $\mu_1$  og  $\mu_2$ , har følgende konfidensintervall for  $(\mu_1 - \mu_2)$

$$(\bar{x}_1 - \bar{x}_2) \pm t^* \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$$

minst konfidensnivå  $C$ . Her er  $t^*$  verdien slik at arealet mellom  $-t^*$  og  $t^*$  i  $t(k)$ -fordelingen er  $C$ . Antall frihetsgrader  $k$  beregnes av et dataprogram eller vi bruker den minste verdien av  $n_1 - 1$  and  $n_2 - 1$ .

# Eks. ny læringsmetode for lesing

- 21 elever prøver ny metode
- 23 elever følger dagens metode

TABLE 7.4

DRP scores for third-graders

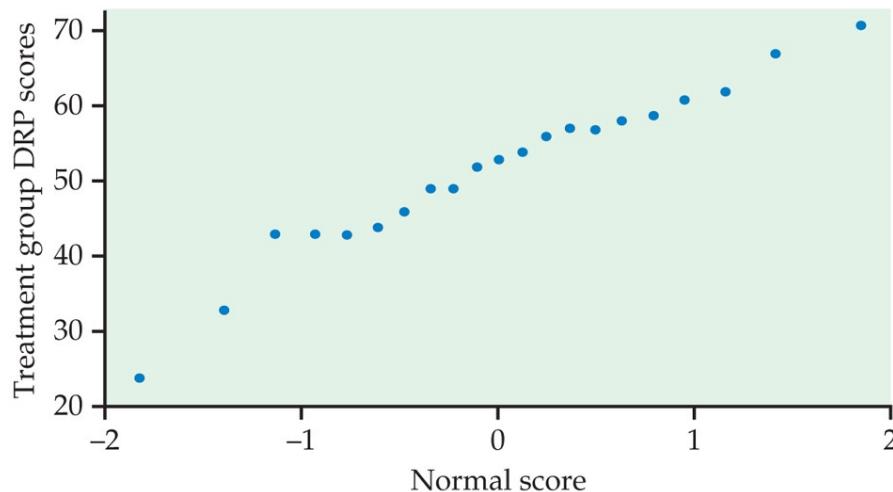
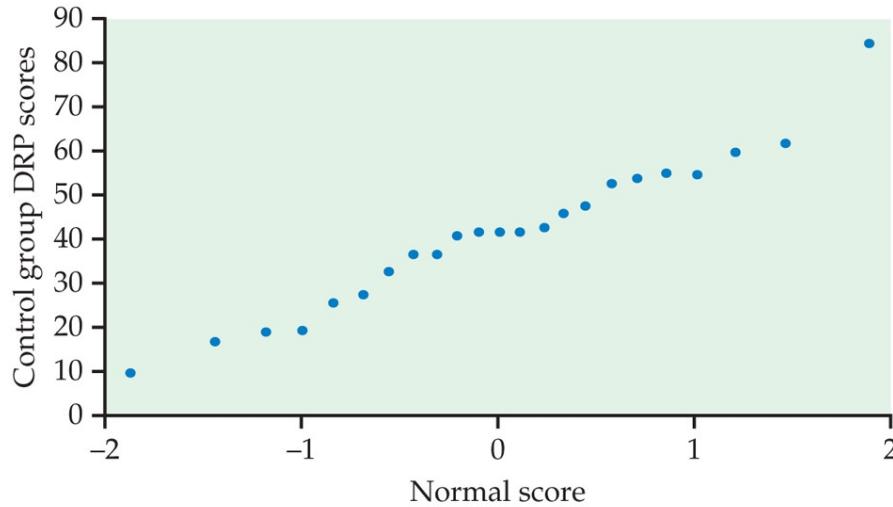
| Treatment group |    |    |    | Control group |    |    |    |
|-----------------|----|----|----|---------------|----|----|----|
| 24              | 61 | 59 | 46 | 42            | 33 | 46 | 37 |
| 43              | 44 | 52 | 43 | 43            | 41 | 10 | 42 |
| 58              | 67 | 62 | 57 | 55            | 19 | 17 | 55 |
| 71              | 49 | 54 |    | 26            | 54 | 60 | 28 |
| 43              | 53 | 57 |    | 62            | 20 | 53 | 48 |
| 49              | 56 | 33 |    | 37            | 85 | 42 |    |

Table 7-4

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W.H.Freeman and Company

# Ny læringsmetode: (Normale) Kvantilplott



# Ny læringsmetode for lesing

- 21 elever prøver ny metode
- 23 elever følger dagens metode
- Frihetsgrader: Minste av  $n_1 - 1 = 20$  og  $n_2 - 1 = 22$

| Gruppe     | n  | $\bar{x}$ | s     |
|------------|----|-----------|-------|
| Behandling | 21 | 51.48     | 11.01 |
| Kontroll   | 23 | 41.52     | 17.15 |

$$(\bar{x}_1 - \bar{x}_2) \pm t^* \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} = 9.96 \pm t^* \sqrt{\frac{11.01^2}{21} + \frac{17.15^2}{23}} = 9.96 \pm 4.31t^*$$

- Konservativt valg: t(20)-fordeling:  $t^* = 2.086$   
95% KI: [0.97, 18.95]
- Minitab: t(37)-fordeling:  $t^* = 2.026$ ,  
95% KI: [1.23, 18.69]

## THE TWO-SAMPLE $t$ SIGNIFICANCE TEST

Suppose that an SRS of size  $n_1$  is drawn from a normal population with unknown mean  $\mu_1$  and that an independent SRS of size  $n_2$  is drawn from another normal population with unknown mean  $\mu_2$ . To test the hypothesis  $H_0: \mu_1 = \mu_2$ , compute the **two-sample  $t$  statistic**

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$$

and use  $P$ -values or critical values for the  $t(k)$  distribution, where the degrees of freedom  $k$  are either approximated by software or are the smaller of  $n_1 - 1$  and  $n_2 - 1$ .

**Definition, pg 489**

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W.H.Freeman and Company

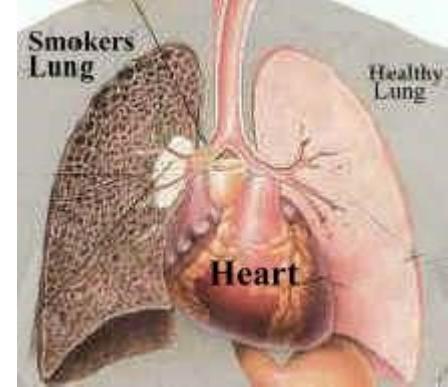
# To-utvalgs $t$ -tester

- For å teste  $H_0: \mu_1 = \mu_2$  mot  $H_a: \mu_1 > \mu_2$  ( $H_a: \mu_1 - \mu_2 > 0$ )
  - P-verdi =  $P(T \geq t)$
- For å teste  $H_0: \mu_1 = \mu_2$  mot  $H_a: \mu_1 < \mu_2$  ( $H_a: \mu_1 - \mu_2 < 0$ )
  - P-verdi =  $P(T \leq t)$
- For å teste  $H_0: \mu_1 = \mu_2$  mot  $H_a: \mu_1 \neq \mu_2$  ( $H_a: \mu_1 - \mu_2 \neq 0$ )
  - P-verdi =  $2P(T \geq |t|)$ ,

der  $T$  er t-fordelt med  $k$  frihetsgrader

## Ødelegger røyking hos foreldrene lungene til barna deres?

Forsert vital kapasitet (FVC) er volumet (i milliliter) av luft som en person kan puste ut etter maksimal innpust.



FVC ble målt for et utvalg av barn som ikke hadde vært utsatt for røyking hos foreldrene og et utvalg av barn som hadde vært utsatt for røyking hos foreldrene.

| Foreldrene røyker | FVC $\bar{x}$ | s    | n  |
|-------------------|---------------|------|----|
| Ja                | 75.5          | 9.3  | 30 |
| Nei               | 88.2          | 15.1 | 30 |



Vi ønsker å finne ut om røyking hos foreldrene senker barns lungekapasitet målt av FVC-testen.

**Er forventet FVC lavere i populasjonen av barn som har vært utsatt for røyking hos foreldrene?**

$$H_0: \mu_{røyk} = \mu_{ikke-røyk} \Leftrightarrow (\mu_{røyk} - \mu_{ikke-røyk}) = 0$$

$$H_a: \mu_{røyk} < \mu_{ikke-røyk} \Leftrightarrow (\mu_{røyk} - \mu_{ikke-røyk}) < 0 \text{ (en-sidig)}$$



Forskjellen i utvalgs-gjennomsnittene følger tilnærmet en t-fordeling:

$$t \left( 0, \sqrt{\frac{s_{smoke}^2}{n_{smoke}} + \frac{s_{no}^2}{n_{no}}} \right), df \ 29$$

Vi beregner t-observatoren:

$$t = \frac{\bar{x}_{røyk} - \bar{x}_{ikke-røyk}}{\sqrt{\frac{s_{røyk}^2}{n_{røyk}} + \frac{s_{ikke-røyk}^2}{n_{ikke-røyk}}}} = \frac{75.5 - 88.2}{\sqrt{\frac{9.3^2}{30} + \frac{15.1^2}{30}}} = -12.7$$

$$t = \frac{-12.7}{\sqrt{2.9 + 7.6}} \approx -3.9$$

| Røyking hos foreldrene | FVC $\bar{x}$ | s    | n  |
|------------------------|---------------|------|----|
| Ja                     | 75.5          | 9.3  | 30 |
| Nei                    | 88.2          | 15.1 | 30 |

I tabell D, for antall frihetsgrader=29, finner vi:

$$|t| > 3.659 \Rightarrow p < 0.0005 \text{ (en-sidig)}$$

Det er en veldig signifikant forskjell, og vi forkaster  $H_0$  ( $p < 0.0005$ ).

**Lungekapasiteten blir signifikant svekket hos barn av røykende foreldre.**

# Ny læringsmetode for lesing

- 21 elever prøver ny metode
- 23 elever følger dagens metode
- $H_0: \mu_1 = \mu_2$  mot  $H_a: \mu_1 > \mu_2$

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} = \frac{51.48 - 41.52}{\sqrt{\frac{11.0^2}{21} + \frac{17.1^2}{23}}} = 2.31$$

| Gruppe     | n  | $\bar{x}$ | s     |
|------------|----|-----------|-------|
| Behandling | 21 | 51.48     | 11.01 |
| Kontroll   | 23 | 41.52     | 17.15 |

Frihetsgrader:

Minste av  $n_1 - 1 = 20, n_2 - 1 = 22$

$P(t > 2.31)$  er mellom 0.01 og 0.02 fra Tabell D

# Egenskaper to-utvalgs t-test

- Mer robust enn ett-utvalgs t-test
- Svært presise når  $n_1 \approx n_2$  og formene på fordelingene er ganske like
- Større utvalg trengs når ulike former på fordelinger
- Velg så like utvalgstørrelser som mulig!

## Lik varians: Pooled t-metoder to-utvalg

- Hittil har vi benyttet oss av at to-utvalgs t-statistikk er tilnærmet t-fordelt når vi bruker de estimerte standardavvikene  $s_1$  og  $s_2$
- Dersom de to underliggende normale populasjons-fordelingene har *samme* standardavvik  $\sigma$  (dvs  $\sigma_1 = \sigma_2 = \sigma$ ), og vi erstatter den  $N(0,1)$ -fordelte z-statistikken med en t-statistikk ved å bytte ut  $\sigma$  med et *samlet* estimat på  $\sigma$ , da er t-statistikken eksakt t-fordelt
- (Erstatter da bare ett enkelt standardavvik i en z-statistikk med ett estimert standardavvik)

# Statistikk for to-utvalg

Av interesse:  $\mu_1 - \mu_2$

Naturlig estimat:  $\bar{x}_1 - \bar{x}_2$

$$\mu_{\bar{x}_1 - \bar{x}_2} = \mu_1 - \mu_2$$

Varians  $\bar{x}_1 - \bar{x}_2$  er  $\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}$

$$z = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \text{ er } N(0,1)$$

- Dersom  $\sigma_1 = \sigma_2 = \sigma$  og  $\sigma$  er ukjent, erstatter vi bare ett enkelt standardavvik  $\sigma$  i en z-observator med ett estimert standardavvik, da er t-observatoren eksakt t-fordelt

# *t*-metoder for samlede («pooled») to-utvalg

- Begge de empiriske variansene  $s_1^2$  og  $s_2^2$  estimerer  $\sigma^2$
- Den beste måten å utnytte begge disse til å estimere  $\sigma$ , er å ta et gjennomsnitt vektet med de respektive frihetsgradene  $n_1$  og  $n_2$
- Det samlede estimatet av  $\sigma$  er da

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

- t-statistikken
- $$t = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

er da eksakt t-fordelt med frihetsgrader  $n_1 + n_2 - 2$

# *t*-metoder for samlede («pooled») to-utvalg

## THE POOLED TWO-SAMPLE *t* PROCEDURES

Suppose that an SRS of size  $n_1$  is drawn from a normal population with unknown mean  $\mu_1$  and that an independent SRS of size  $n_2$  is drawn from another normal population with unknown mean  $\mu_2$ . Suppose also that the two populations have the same standard deviation. A level  $C$  confidence interval for  $\mu_1 - \mu_2$  is

$$(\bar{x}_1 - \bar{x}_2) \pm t^* s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

Here  $t^*$  is the value for the  $t(n_1 + n_2 - 2)$  density curve with area  $C$  between  $-t^*$  and  $t^*$ .

To test the hypothesis  $H_0: \mu_1 = \mu_2$ , compute the pooled two-sample *t* statistic

$$t = \frac{\bar{x}_1 - \bar{x}_2}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

In terms of a random variable  $T$  having the  $t(n_1 + n_2 - 2)$  distribution, the *P*-value for a test of  $H_0$  against

$$H_a: \mu_1 > \mu_2 \quad \text{is} \quad P(T \geq t)$$

$$H_a: \mu_1 < \mu_2 \quad \text{is} \quad P(T \leq t)$$

$$H_a: \mu_1 \neq \mu_2 \quad \text{is} \quad 2P(T \geq |t|)$$

**Definition, pg 499**

*Introduction to the Practice of Statistics, Fifth Edition*

© 2005 W.H. Freeman and Company

# Eksempel: Kalsium og blodtrykk

- Gir økt inntak av kalsium redusert blodtrykk?

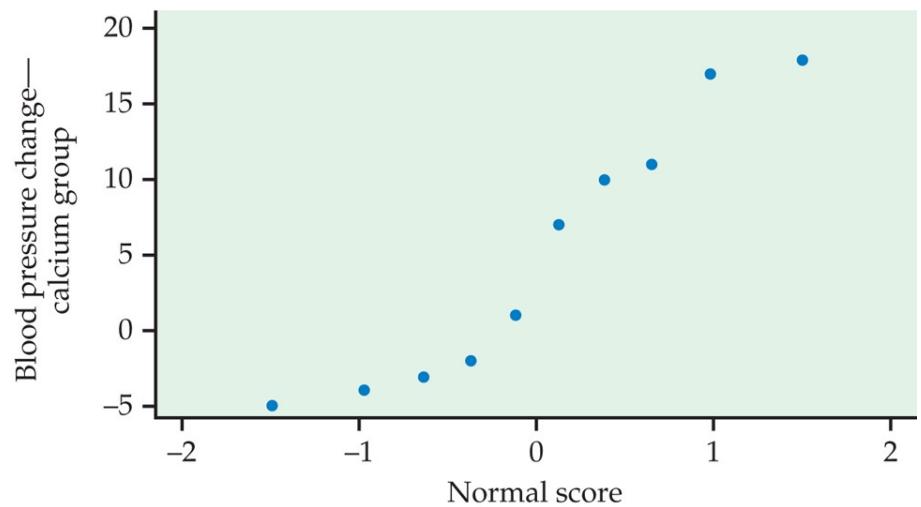
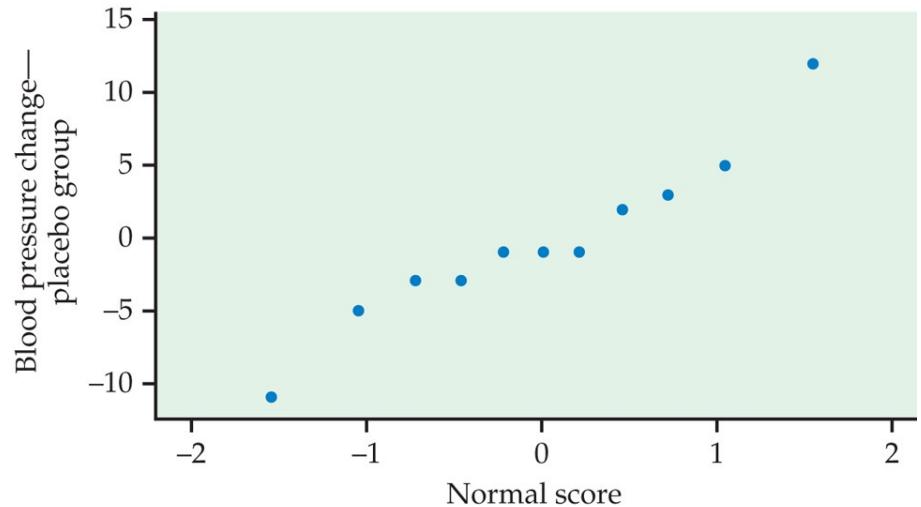
| TABLE 7.5<br>Seated systolic blood pressure |     |          |               |     |          |
|---|-----|----------|---------------|-----|----------|
| Calcium group                               |     |          | Placebo group |     |          |
| Begin                                       | End | Decrease | Begin         | End | Decrease |
| 107   | 100 | 7        | 123           | 124 | -1       |
| 110   | 114 | -4       | 109           | 97  | 12       |
| 123   | 105 | 18       | 112           | 113 | -1       |
| 129   | 112 | 17       | 102           | 105 | -3       |
| 112   | 115 | -3       | 98            | 95  | 3        |
| 111   | 116 | -5       | 114           | 119 | -5       |
| 107   | 106 | 1        | 119           | 114 | 5        |
| 112   | 102 | 10       | 114           | 112 | 2        |
| 136   | 125 | 11       | 110           | 121 | -11      |
| 102   | 104 | -2       | 117           | 118 | -1       |
|   |     |          | 130           | 133 | -3       |

Table 7-5  
*Introduction to the Practice of Statistics, Fifth Edition*  
© 2005 W.H.Freeman and Company

- NB: Nedgang (decrease) er positiv når det er en reduksjon, negative ved oppgang

# Eksempel: Kalsium og blodtrykk

- Kvantilplott: Ser ut til å passe ganske bra med normalfordeling for begge grupper
- Kalsium-gruppen har en litt kort venstre hale
- Må gjøre en signifikanstest for å besvare spørsmålet: gir økt inntak av kalsium redusert blodtrykk?



# Eksempel: Kalsium og blodtrykk

- Gruppe 1 med forventning  $\mu_1$  fikk kalsium-tilskudd, gruppe 2 med forventning  $\mu_2$  fikk placebo
- Naturlig med ensidig null-hypotese, for forsøk med rotter hadde vist at kalsium ga en nedgang, ingen grunn til å ro at det skulle øke blodtrykket. Hypoteser:  $H_0: \mu_1 = \mu_2$ ,  $H_a: \mu_1 > \mu_2$
- Numeriske beskrivelser av data

| Gruppe | Behandling | n  | $\bar{x}$ | s     |
|--------|------------|----|-----------|-------|
| 1      | Kalsium    | 10 | 5.000     | 8.743 |
| 2      | Placebo    | 11 | -0.273    | 5.901 |

- De empiriske standardavvikene utelukker ikke like populasjons-standardavvik, forskjell i estimatene kan lett være pga. tilfeldigheter
- Vi vil anta like populasjons-standardavvik

# Eksempel: Kalsium og blodtrykk

- Den samlede empiriske variansen er

$$s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2} = \frac{(10 - 1)*8.743^2 + (11 - 1)*5.901^2}{10 + 11 - 2} = 54.536$$

som gir  $s_p = 7.385$ . Den samlede to-utvalgs t-statistikken er

$$t = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{5.000 - (-0.273)}{7.385 \sqrt{\frac{1}{10} + \frac{1}{11}}} = 1.634$$

- $P$ -verdi= $P(T \geq 1.634)$  der  $T$  er  $t(19)$ -fordelt ( $10+11-2=19$ )
- Tabell D sier oss at  $P$ -verdien er mellom 0.05 og 0.10. Analyse i Minitab gir  $P$ -verdi=0.059
- Konklusjon: Forsøket fant bevis for at kalsium muligens reduserer blodtrykket, men resultatet er ikke på 5%- (eller 1%-)nivå

# Antagelsen om like populasjons-standardavvik

- Vansklig å verifisere
- Derfor kan t-metodene for samlede («pooled») to-utvalg noen ganger være risikable å bruke
  - Ganske robuste mot både ikke-normalitet og ulike populasjons-standardavvik når utvalgsstørrelsene  $n_1$  og  $n_2$  er ganske like
  - Når utvalgsstørrelsene  $n_1$  og  $n_2$  er veldig forskjellige, er metodene sensitive for ulike populasjons-standardavvik, og man skal være forsiktige med å bruke dem med mindre utvalgsstørrelsene er store