

Intro til hypotesetesting – Analyse av kontinuerlige data

21. april 2005

Tron Anders Moger

Seksjon for medisinsk statistikk, UIO


Repetisjon fra i går:

Normalfordelingen

- Variasjon i målinger kan ofte beskrives med normalfordelingen
- Fordelingen er symmetrisk og har to parametere:
 - Forventning: μ
 - Standardavvik (Standard deviation): σ
- Disse angir tyngdepunkt og spredning i fordelingen
- Viktig: Et intervall som er 1.96 standardavvik på hver side av forventningen dekker 95% av fordelingen

Normal distribution

mean = 165, std. deviation=5



Standardfeil (standard error)

- La oss si at du har samlet et utvalg på n observasjoner for å beregne et gjennomsnitt
- Samler du flere utvalg av samme størrelse får du ikke samme gjennomsnitt
- Standardavviket til gjennomsnittet kallas standardfeil og estimeres med $\frac{s}{\sqrt{n}}$
- Hvis observasjonene er normalfordelt, kan du være 95% sikker på at det samme gjennomsnittet (forventning) ligger i intervallet $\text{gj.snitt} \pm 1.96 * \text{standardfeil}$

Konfidensintervall i SPSS

- *Analyze- Descriptive Statistics - Explore*

Descriptives

Descriptives		Statistic	Std. Error
WEIGHT	Mean	70,7000	2,6548
	95% Confidence Interval for Mean	65,1435	
	Lower Bound	76,2565	
	Upper Bound	70,5000	
	5% Trimmed Mean	69,0000	
	Median	140,958	
	Variance	11,8726	
	Std. Deviation	50,00	
	Minimum	95,00	
	Maximum	45,00	
	Range	10,0000	
	Interquartile Range	,427	,512
	Skewness	,263	,992
	Kurtosis		

t-fordelingen

- Få observasjoner: Dårlig estimat for standardavviket
- Konfidensintervall basert på normalfordelingen vil være for smalt
- Betyr at et 95% konfidensintervall IKKE vil dekke 95% av den samme fordelingen
- Må bruke t-fordelingen isteden: Er også symmetrisk, men har større standardavvik

Eksempel: Gjennomsnittlig daglig energiinntak i kJ hos 11 friske kvinner målt over 10 dager

● SUBJECT	INTAKE
1	5260
2	5470
3	5640
4	6180
5	6390
6	6515
7	6805
8	7515
9	7515
10	8230
11	8770

Descriptives

INTAKE		Statistic	Std. Error
Mean		6753,64	344,36
95% Confidence Interval for Mean	Lower Bound	5986,35	
	Upper Bound	7520,93	
5% Trimmed Mean		6724,60	
Median		6515,00	
Variance		1304445	
Std. Deviation		1142,12	
Minimum		5260	
Maximum		8770	
Range		3510	
Interquartile Range		1875,00	
Skewness		,428	,661
Kurtosis		-,793	1,279

Ønsker å teste om kvinnenes energi-inntak er likt det anbefalte energi-inntaket (ett-utvalgs t-test):

- Anbefalt energi-inntak: 7725kJ
- Nullhypotese H_0 : Energi-inntaket er 7725kJ
- Alternativ hypotese H_1 : Energi-inntaket er forskjellig fra 7725 kJ

$$\text{Test} = \frac{\text{observert gj.snitt} - \text{forventet gj.snitt}}{\text{standardfeil til observert gj.snitt}}$$

$$= \frac{6753.6 - 7725}{1142.1 / \sqrt{11}} = -2.821$$

- Denne størrelsen er t-fordelt med 10 frihetsgrader (antall personer - 1)
- En stor positiv eller negativ verdi av testen indikerer at nullhypotesen er gal
- Hvordan vite om man skal forkaste H_0 eller ikke?

To VIKTIGE begreper

- *P-verdi*: Sannsynligheten for at det observerte gjennomsnittet er likt det forventede gjennomsnittet etter at testen er gjort
- Hvis *p-verdien* er lavere enn *signifikansnivået* forkastes nullhypotesen
- *Signifikansnivået* gir den øvre sannsynligheten for å forkaste nullhypotesen hvis den er sann
- Vanlige signifikansnivåer: 5% eller 1%
- Signifikansnivå 5% betyr at det er 5% sannsynlighet for å forkaste nullhypotesen når den er sann
- Medfører at man er minst 95% sikker på å ikke forkaste nullhypotesen hvis den er sann
- Eller: Man vil være minst 95% sikker på at man ikke forkaster nullhypotesen på grunn av tilfeldigheter
- Dette er begreper som benyttes i alle statistiske tester, ikke bare for t-tester

I SPSS: Analyze - Compare means - One-sample t test

Test variable: *intake*

Test value: 7725

One-Sample Statistics

	N	Mean	Std. Deviation	Std. Error Mean
INTAKE	11	6753,64	1142,12	344,36

One-Sample Test

	Test Value = 7725			95% Confidence Interval of the Difference	
	t	df	Sig. (2-tailed)	Mean Difference	Lower Upper
INTAKE	-2,821	10	,018	-971,36	-1738,65 -204,07

Hva blir konklusjonen av testen?

- Vi samlet inn data på energi-inntaket til 11 kvinner for å studere om dette var signifikant forskjellig fra det anbefalte energi-inntaket på 7725kJ.
- I gjennomsnitt lå energi-inntaket til kvinnene 971kJ lavere enn det anbefalte inntaket.
- 95% konfidensintervall for differansen er (-1739, -205).
- Dette betyr at vi kan være 95% sikre på at den *sanne* differansen (ergo differansen vi hadde funnet hvis vi hadde data på alle kvinner istedenfor kun 11) ligger i dette intervalllet.
- Differansen er signifikant på 5%-signifikansnivå, p-verdien er 0.02.

MERK FØLGENDE:

- Hvis konfidensintervallet hadde omsluttet verdien 0, hadde p-verdien vært over 5%
- Det er altså en 1-1 sammenheng mellom p-verdier og konfidensintervall.
- Den gjennomsnittlige differansen mellom målingene og den forventede verdien er *effektmålet* i studien
- I en rapport oppgir man vanligvis effektmål, 95% konfidensintervall for effektmålet, samt p-verdien i konklusjonen

**Eksempel: Energiintak i kJ hos 11 friske kvinner
målt før menstruasjon og etter menstruasjon**

SUBJECT PREMENST POSTMENS

1	5260.0	3910.0
2	5470.0	4220.0
3	5640.0	3885.0
4	6180.0	5160.0
5	6390.0	5645.0
6	6515.0	4680.0
7	6805.0	5265.0
8	7515.0	5975.0
9	7515.0	6790.0
10	8230.0	6900.0
11	8770.0	7335.0

Number of cases read: 11 Number of cases listed: 11

To målinger på samme individ:

Parret t-test

- Hvis du har to like målinger per individ i et utvalg, sier vi at de er parrede
- Målingene vil være avhengige
- Eksempel: To blodtrykksmålinger av samme mann på en uke, vil ligge nærliggende hverandre
- Baserer testen på differansen mellom målingene, reduserer dataene til ett utvalg
- H_0 : Pre - og post menstruelle energinntak er like


Konfidensintervall og p-verdier for paret t-test i SPSS

- *Analyze - Compare Means - Paired-Samples T Test.*
- Klikk på de to variabelene du vil teste, og flytt dem over til høyre

Konklusjonen av testen blir:

- Vi gjennomførte en studie for å undersøke om energi-inntaket hos kvinner forandrer seg før og etter menstruasjon.
- Vi samlet inn data på 11 kvinner, og i gjennomsnitt var energi-inntaket 1320kJ høyere etter menstruasjon sammenlignet med før.
- 95% konfidensintervall for forskjellen er (1074kJ, 1566kJ).
- Forskjellen er signifikant på 5%-nivå, p-verdien er <0.01.

Grafisk fremstilling



ID	GROUP	ENERGY
1	0	6 . 13
2	0	7 . 05
	...	
12	0	10 . 15
13	0	10 . 88
14	1	8 . 79
15	1	9 . 19
	...	
21	1	11 . 85
22	1	12 . 79

Eksempel:

24 timers
energiforbruk

(MJ/dag) i

2 grupper av
kvinner: 13 tynne og
9 overvektige

Number of cases read: 22
Number of cases listed: 22

To-utvalgs t-test

- Har her to uavhengige grupper: De som er tynne og de som er overektige
- Vil teste om det er forskjellig energiforbruk
- H_0 : energiforbruket er det samme for tynne og overektige
- I SPSS: *Analyze - Compare Means - Independent-Samples T Test*
- Flytt Energy til “Test-variable”
- Flytt Group til “Grouping variable”
Trykk på “Define Groups” og skriv 0 og 1 for de to gruppene

Group Statistics

GROUP		N	Mean	Std. Deviation	Std. Error Mean
ENERGY	lean	13	8.0662	1.2381	.3434
	obese	9	10.2978	1.3979	.4660

Independent Samples Test

		Levene's Test for Equality of Variances			t-test for Equality of Means					95% Confidence Interval of the Difference	
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	Lower	Upper	
ENERGY	Equal variances assumed	1.002	.329	-3.946	20	.001	-2.2316	.5656	-3.4115	-1.0518	
	Equal variances not assumed			-3.856	15.919	.001	-2.2316	.5788	-3.4592	-1.0041	




Over 0.05: Les første linje (Equal variances assumed)

Ellers: Les andre linje (Equal variances not assumed)

Konklusjon

- Gjennomsnittlig energiforbruk for tynne og overvektige kvinner var henholdsvis 8.1MJ/dag og 10.3MJ/dag
- Den gjennomsnittlige forskjellen mellom gruppene var -2.2MJ/dag, 95% KI (-3.4,-1.1)
- Forskjellen mellom gruppene var signifikant på 5%-nivå, med p-verdi <0.01.
- Hva hvis vi har mer enn 2 uavhengige grupper?
Enveis variansanalyse, ANOVA

Grafisk fremstilling



Styrkeberegninger

- Alle eksemplene bruker små datasett
- Hvis man har mye data, vil usikkerheten bli mindre, og konfidensintervallene smalere
- Dette gjør at det er lettere å få signifikante forskjeller/resultater
- Ikke bare positivt: Med svært mye data vil alle nullhypoteser kunne forkastes. Dette betyr at vi kan få signifikante funn som ikke har klinisk relevans
- Vanlig å gjøre styrkeberegninger før studiestart, dvs man bestemmer seg for hvor stor forskjell må være for å være klinisk relevant, så beregner man hvor mye data man trenger for å kunne påvise denne forskjellen

Antagelser

1. *Uavhengighet*: Alle observasjoner er uavhengige. Oppnåes ved tilfeldig trekning av individer; for parret t-test får vi uavhengighet ved å se på *differansen* mellom målingene.
2. *Normalfordelte data* (Sjekk: histogram, tester, Q-Q plot imorgen)
3. *Lik varians* eller *standardavvik i gruppene*

Hva hvis antagelsene ikke holder?

- *Bruk ikke-parametriske metoder*
Par data: Sign test eller Wilcoxon
To-utvalg: Mann-Whitney
- Eller
- Transformer dataene (log-transformasjon)

Parametriske metoder vi har sett:

- Effektmål: μ estimert ved gjennomsnitt
- Estimering:
 - Konfidensintervall for μ
 - Konfidensintervall for $\mu_1 - \mu_2$
(basert på gjennomsnitt og standardavvik)
- Testing:
 - Ett-utvalgs t-test
 - To-utvalgs t-test
- Metodene baserer seg på at dataene er normalfordelte (evt. gjennomsnittet normalfordelt)

Ikke-parametriske metoder:

- Effektmål: Median, siden den ikke påvirkes av noen få ekstreme observasjoner i motsetning til gjennomsnittet
- Estimering
 - Vanlig å oppgi 25%-fraktilen og 75%-fraktilen som et ”konfidensintervall” for medianen
- Testing:
 - Parrede data: Sign test og Wilcoxon signed rank test
 - To uavhengige utvalg: Mann-Whitney test/Wilcoxon rank-sum test
- Gjør (nesten) ingen antagelser om spesielle fordelinger

Ikke-parametriske tester

- De fleste testene baserer seg på rangsummer, og ikke de observerte verdiene.
Summer av ranger antas tilnærmet normalfordelt, så vi kan bruke normaltilnærming for testobservatoren
- Ved to eller flere like verdier, gis de en gjennomsnittsrang

Parede data (ett utvalg)

- Eksempel: Daglig energi-inntak i kJ hos de 11 kvinnene
SUBJECT PREMENST POSTMENS

1	5260.0	3910.0
2	5470.0	4220.0
3	5640.0	3885.0
4	6180.0	5160.0
5	6390.0	5645.0
6	6515.0	4680.0
7	6805.0	5265.0
8	7515.0	5975.0
9	7515.0	6790.0
10	8230.0	6900.0
11	8770.0	7335.0

Number of cases read: 11 Number of cases listed: 11

Sign test

- Nullhypotesen er at differansen er 0
- Antar uavhengige observasjoner, ingen fordelingsantakelse
- Under nullhypotesen vil vi forvente at like mange differanser er over og under 0
- Testen teller opp antall positive differanser
- P-verdi fra binomisk fordeling når n er liten, normalfordeling når n stor
- SPSS: Analyze->nonparametric tests->two related samples. Kryss av sign under test

To uavhengige utvalg: Wilcoxon/Mann-Whitney

- Nullhypotesen er her at fordelingen i de to gruppene/utvalgene er like
- For t-test: Forventningene like
- Antagelser: Uavhengighet innen og mellom grupper, lik fordeling i begge grupper
- Rangerer alle observasjonene som om de kom fra samme gruppe
- P-verdien beregnes fra tabeller eller normalfordelingen

ID	GROUP	ENERGY
1	0	6 . 13
2	0	7 . 05
...	0	10 . 15
12	0	10 . 88
13	1	8 . 79
14	1	9 . 19
15	1	11 . 85
...	1	12 . 79
21	1	22
22	1	22

Number of cases read: 22

Number of cases listed: 22

14

I SPSS:

- Analyze->nonparametric tests->two independent samples tests
- Test type: Mann-Whitney U

Oppsummering, ikke-parametriske tester

- Fordeler: Ingen strenge antakelser om fordeling
- Ulemper: For normalfordelte data vil ikke-parametriske tester ha dårligere styrke, dvs. hvis utvalgene er små, vil man ikke finne noen signifikante forskjeller
- Får ikke noe annet enn p-verdier fra ikke-parametriske tester