

NTNU
Det skapende universitet

Medisinsk statistikk, termin IC

av
Stian Lydersen, professor i medisinsk statistikk
Regionalt kunnskapssenter for barn og unge
- Psykisk helse og barnevern (RKBU Midt-Norge)

Forelesning 3 januar 2013
Oppdatert 2 januar 2013

www.ntnu.no

Læringsmål statistikk (3 og 7 januar 2013)

8.1.5 redegjøre for følgende begreper innenfor beskrivende statistikk: gjennomsnitt (mean), median, percentiler, standardavvik (SD), standardfeil (SEM), frekvenstabell og krysstabell, og tolke hva disse forklarer om enkle eksemplardatasett

8.1.6 redegjøre for hva som fremstilles i grafotypene histogram, stolpediagram, Box-plot og spredningsplot.

8.1.7 redegjøre for begrepene konfidensintervall, nullhypotese, p-verdi, teststyrke, type I og type II-feil.

8.1.8 redegjøre for normalfordeling og binomisk fordeling, og velge egnet metode mellom uparet og paret T-test, uparet og paret ikke-parametrisk test, kjikvadrat-test, og tilhørende konfidensintervaller.

NTNU
Det skapende universitet

3

Innhold:

- Deskriptiv statistikk
- Enkel sannsynlighetsregning
- Randomiserte kontrollerte studier: Randomisering
- Populasjon og tilfeldige utvalg
- Statistisk inferens: Hypotesetesting og konfidensintervaller

www.ntnu.no

4

Hvorfor statistikk?

- For å kunne lese medisinsk litteratur inkl vitenskapelige artikler
- For å kunne utføre enkle statistiske analyser ifm hovedoppgaven

www.ntnu.no

5

Litteratur

- Bowers, D: "Medical Statistics from Scratch". 2ed, Wiley 2008.
- Aalen, Odd. m.fl.: Statistiske metoder i medisin og helsefag. Gydendal, 2006.
- Veierød, M. B., Lydersen, S, Laake, P (eds): "Medical Statistics in Clinical and Epidemiological Research". Gydendal, 2012.
- Gonick, L and Wollcott, S: "The Cartoon Guide to Statistics" Harper Collins, 1993

NTNU
Det skapende universitet

Editorial, NEJM, 1 January 2000:
Looking Back on the Millennium in Medicine.

The most important medical developments of the past millennium:

- Elucidation of Human Anatomy and Physiology
- Elucidation of the Chemistry of Life
- **Application of Statistics to Medicine**
- Development of Anesthesia
- Discovery of the Relation of Microbes to Disease
- Elucidation of Inheritance and Genetics
- Knowledge of the Immune System
- Development of Body Imaging
- Discovery of Antimicrobial Agents
- Development of Molecular Pharmacotherapy

www.ntnu.no

"Any serious investigator in biological and medical sciences must have a grasp of the basic principles (of statistics). With modern computer facilities there is little need for familiarity with the technical detail of statistical calculations. However, a physician should understand when such calculations are valid, when they are not, and how they should be interpreted."

(Campbell and Machin, 2007)


www.ntnu.no

"Statistikk": Forskjellige betydninger:

1. En samling tall –f.eks Statistisk årbok fra Statistisk sentralbyrå
2. Engelsk: "Statistic", norsk "observator" eller "testobservator": En funksjon av data som f.eks gjennomsnitt, maksimumsverdi eller Student's t observator.
3. (Matematisk) statistikk: En gren av matematikken med egen terminologi og metoder. Det vitenskapelige redskap for å trekke konklusjoner basert på data med elementer av usikkerhet.


www.ntnu.no

9 Tre typer statistikk:

- Deskriktiv
 - Grafer
 - Oppsummerende tall
- Bekreftende
 - Hypotesetesting
 - Konfidensintervall
- Prediktiv


www.ntnu.no

10 Deskriktiv statistikk:

Grafer og oppsummeringstall


www.ntnu.no

11 Typer data:

- Skalavariabel - f.eks høyde i cm
- Kategorisk variabel
 - Ordinal, f.eks "Føler du deg deprimert?" 1 = "Ikke i det hele tatt", 2 = "Litt", 3 = "Endel", 4 = "Svært mye"
 - Nominal, f.eks Sivilstand: 1 = "ugift", 2 = "gift", 3 = "samboer", 4 = "skilt", 5 = "enke(mann)"


www.ntnu.no

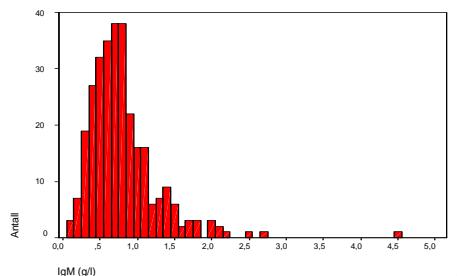
Konsentrasjon av serum IgM (g/l) hos 298 friske barn, 6 mnd - 6 år gamle (Altman, 1991)

0.8	1.1	0.7	0.5	0.5	0.5	0.9	0.7	0.4	0.7	0.5	4.5	1.0	1.4	0.8
0.8	0.7	0.6	1.6	0.8	0.2	1.5	0.2	0.7	1.0	1.2	0.7	0.5	0.6	0.6
0.9	0.5	0.4	1.0	1.7	1.1	1.1	0.5	0.4	0.3	0.6	0.8	0.4	1.7	1.1
0.7	0.2	1.2	0.5	0.3	1.5	0.6	1.0	0.8	0.1	0.8	0.3	1.0	1.0	0.8
0.6	0.3	0.5	0.6	0.6	0.4	0.5	1.5	0.5	0.8	0.4	0.5	0.4	0.4	0.4
1.0	0.4	1.5	1.0	0.9	2.7	0.9	1.5	0.7	0.5	0.7	0.5	0.9	1.5	1.0
1.4	0.7	0.4	0.6	1.4	0.4	1.1	1.4	0.4	0.3	0.7	1.0	1.7	0.6	0.6
0.7	0.7	1.1	0.4	0.9	0.8	0.6	1.1	0.6	1.0	1.4	0.3	0.7	0.9	0.7
1.8	0.6	0.9	0.9	0.9	0.5	0.5	0.7	1.1	0.5	2.3	1.2	1.3	0.5	0.8
0.8	0.8	0.6	1.2	0.6	0.3	0.7	1.0	0.8	0.6	0.4	0.4	0.5	1.3	0.3
0.8	0.4	0.3	1.1	0.3	0.8	0.8	0.0	0.4	0.6	0.5	0.4	0.7	0.7	0.9
1.2	1.8	2.5	0.8	0.8	0.2	0.9	0.6	0.7	1.4	1.4	0.6	2.0	1.3	0.8
0.3	1.3	0.5	0.7	1.2	0.5	0.7	0.5	0.7	1.0	0.2	1.1	1.0	0.8	1.0
0.5	0.5	1.3	0.5	0.7	0.4	0.9	0.4	0.6	0.8	0.7	0.7	0.8	1.1	0.7
0.8	0.8	0.9	0.4	0.6	0.7	0.1	0.7	0.8	0.7	0.4	1.1	0.8	0.5	0.6
0.7	0.8	0.3	0.8	0.6	0.8	1.4	0.8	0.7	0.6	0.5	0.9	0.8	0.9	0.4
0.8	0.5	0.2	0.8	2.0	0.5	0.9	0.4	0.3	0.4	0.9	0.5	2.1	0.5	1.4
1.1	0.4	0.7	0.3	0.5	0.7	0.7	0.6	0.6	0.8	0.6	0.7	0.6	0.6	0.6
0.8	0.3	1.1	0.3	0.4	2.0	0.8	1.3	0.5	0.6	0.7	2.1	1.8	0.3	
0.3	0.2	0.9	1.3	0.6	0.7	0.9	0.6	0.6	1.1	0.3	0.7	0.6	0.9	


www.ntnu.no

13

Histogram - IgM data:



NTNU
Det skapende universitet

www.ntnu.no

14

Example: EORTC Quality of life questionnaire

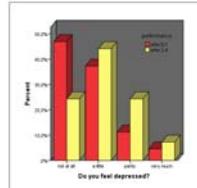
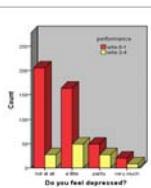
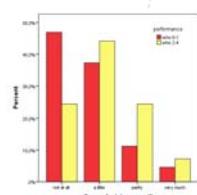
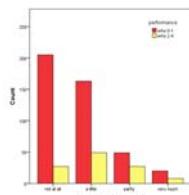
do you feel depressed? * performance Crosstabulation

do you feel depressed?	performance		Total
	who 0-1	who 2-4	
1: not at all	205	27	232
2: a little	163	49	212
3: partly	49	27	76
4: very much	20	8	28
Total	437	111	548

NTNU
Det skapende universitet

www.ntnu.no

15



www.ntnu.no

16

Noen nyttige grafer

- Én kategorisk variabel:
 - Bar chart (stolpediagram)
 - Pie chart (kakediagram)
- To kategoriske variable:
 - Clustered bar chart (klynget stolpediagram)

NTNU
Det skapende universitet

www.ntnu.no

17

Noen nyttige grafer (forts.)

- Én skalavariabel:
 - Histogram
 - Sammenlikne data med normalfordeling: Q-Q plot (lettere å lese og tolke enn "normal curve overlay" i histogram)
- To skalavariable:
 - Scatterplot

NTNU
Det skapende universitet

www.ntnu.no

18

Noen nyttige grafer (forts.)

- Én skalavariabel og én kategorisk variabel (sammenlikne skalavariablene i to eller flere grupper):
 - Dot plot eller scatter plot (ved "få" observasjoner)
 - Box plot (ved "mange" observasjoner)

NTNU
Det skapende universitet

www.ntnu.no

19

Beskrivelse av fordelingen

- Skalavariabel, evt også ordinale variable: sentrum og spredning:
 - Gjennomsnitt og standardavvik
 - Median og kvartiler
- Kategoriske data:
 - Frekvenstabell
 - Krysstabell



www.ntnu.no

20

Data: x_1, x_2, \dots, x_n

$$\text{Gjennomsnitt: } \bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\text{(Empirisk) varians: } s^2 = \frac{1}{(n-1)} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - n(\bar{x})^2 \right]$$

$$\text{(Empirisk) standardavvik: } s = \sqrt{\frac{1}{(n-1)} \sum_{i=1}^n (x_i - \bar{x})^2}$$

Lettere å regne ut



www.ntnu.no

21

Data sortert: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$

Median:

$x_{((n+1)/2)}$ hvis n er oddetall

$(x_{(n/2)} + x_{(n/2+1)}) / 2$ hvis n er partall

Medianen deler tallmaterialet "på midten".

Like mange observasjoner under som over medianen.

Nedre kvartil, median, øvre kvartil:

Deler tallmaterialet i fire like store deler.



www.ntnu.no

22

Eksempel: Antall dager i sykehus.

Behandling A:

26, 15, 37, 11, 13, 10, 17, 21, 131, 38

Sortert:

10, 11, 13, 15, 17, 21, 26, 37, 38, 131

Behandling B

141, 32, 115, 22, 26, 12, 203, 65, 40, 15, 32, 49, 243

Sortert:

12, 15, 22, 26, 32, 32, 40, 49, 65, 115, 141, 203, 243

Hva blir median og kvartiler for behandling A?



www.ntnu.no

23

Statistics		
	Days_in_hospital	
1	N	Valid
		10
		Missing
Mean		31,90
Std. Deviation		36,238
Percentiles	25	12,50
	50	19,00
	75	37,25
2	N	Valid
		13
		Missing
Mean		76,54
Std. Deviation		75,835
Percentiles	25	24,00
	50	40,00
	75	128,00

Hvilke(t) mål vil du bruke på sentrum og spredning i fordelingene?



www.ntnu.no

24

Gjennomsnitt og standardavvik har gunstige matematiske egenskaper.

Eks:

Hvis gjennomsnitt og standardavvik for hvert av r utvalg er gitt, kan man beregne dem for det totale tallmaterialet:

$$\text{Gjennomsnitt totalt: } \bar{x}_{total} = \frac{n_1 \bar{x}_1 + n_2 \bar{x}_2 + \dots + n_r \bar{x}_r}{n_1 + n_2 + \dots + n_r}$$

$$\text{Varians totalt: } s_{total}^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2 + \dots + (n_r - 1)s_r^2}{n_1 + n_2 + \dots + n_r - r}$$

$$\text{Standardavvik totalt: } s_{total} = \sqrt{s_{total}^2}$$



www.ntnu.no

25

Normalfordelingen

- I en del situasjoner er skalavariablene (tilnærmet) normalfordelt, dvs symmetrisk og med en spesiell "klokkeformet" fasong.

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

- Når data er normalfordelt:
 - Ca 68% ligger innen 1 standardavvik fra gjennomsnittet
 - Ca 95% ligger innen 2 standardavvik fra gjennomsnittet
- Visse metoder forutsetter at data er (tilnærmet) normalfordelt. F.eks Students t-test, vanlig regresjonsanalyse

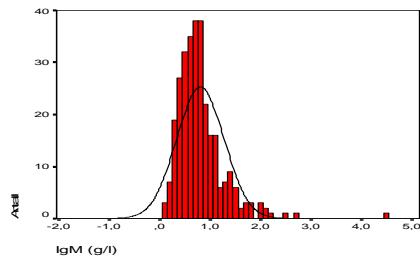
www.ntnu.no



Det skapende universitet

26

Histogram m/normalfordelingskurve
IgM data

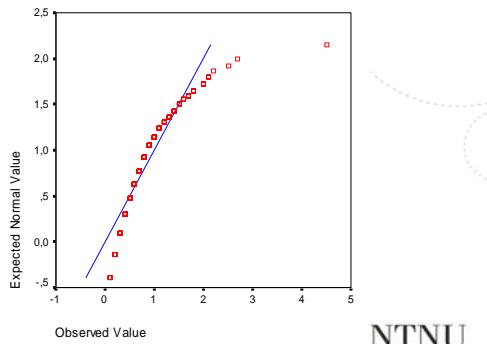


Det skapende universitet

www.ntnu.no

27

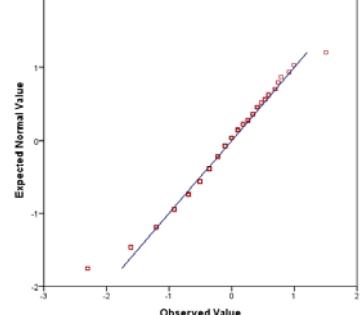
Normal Q-Q Plot of IgM (g/l)



www.ntnu.no

28

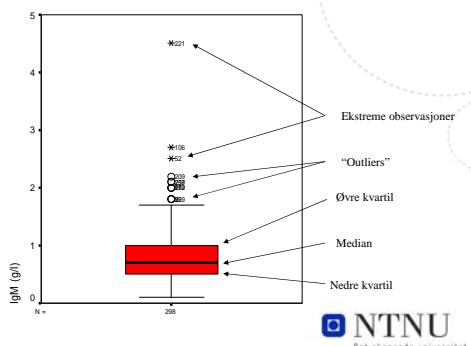
Normal Q-Q Plot of ln_IgM



Det skapende universitet

29

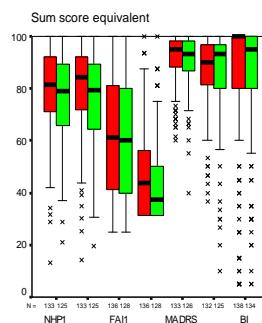
Box plot



www.ntnu.no

30

Box plot - eksempel



Det skapende universitet

31

Eksempel - IgM data:

- Gjennomsnitt: 0,803
- Standardavvik: 0,47
- Median (50% under): 0,7
- Nedre kvartil (25% under): 0,5
- Øvre kvartil (75% under): 1,0



www.ntnu.no

32

Eksempel - EORTC data

	Performance status	
	who 0-1	who 2-4
Gjennomsnitt	1.73	2.14
Standardavvik	0.83	0.87
median	2	2



www.ntnu.no

33

Valg av deskriptiv statistikk for sentrum og spredning i fordelingen

- Gjennomsnitt og standardavvik ELLER median og kvartiler ELLER begge deler?
 - Avhenger av målsettingen med analysen.
- Hvis data er symmetrisk fordelt (for eksempel normalfordelt):
 - Median = gjennomsnitt
- Hvis data ikke er normalfordelt:
 - Ganske vanlig å oppgi median og kvartiler. OK å oppgi gjennomsnitt og standardavvik. Med standardavviket har ikke samme enkle tolkning som i normalfordelingen.
- OK å anta normalfordeling i små datasett?
 - JA, hvis rimelig antakelse basert på annen kunnskap eller inspeksjon av data.



www.ntnu.no

34

Hvordan sjekke om data avviker fra normalfordelingen?

- Hvis median avviker mye fra gjennomsnitt, så er data ikke symmetrisk fordelt (og dermed ikke normalfordelt). (Men ikke omvendt!)
- Statistisk test:
 - Kolmogorov-Smirnoff mye brukt men lite egnet.
 - Shapiro-Wilk noe bedre egnet.
- Histogram med normalfordelingskurve: Vanskelig å vurdere
- Q-Q plott: Velegnet!



www.ntnu.no

35

Eksempel - postoperativ kvalme

Behandling * Kvalmeklasse Krysstabell

Behandling	Nei	Kvalme		Total
		lite eller ingen	betydelig	
Ja	Antall %	18 60,0%	12 40,0%	30 100,0%
	Antall %	24 82,8%	5 17,2%	29 100,0%
Total	Antall %	42 71,2%	17 28,8%	59 100,0%

Risikoreduksjon i dette utvalget: 82,8% - 60,0% = 22,8%

Hva kan vi si om effekt av behandling i en populasjon av aktuelle pasienter?

www.ntnu.no

36

Enkel sannsynlighetsregning



www.ntnu.no

37

Sannsynlighet for gutt:

Antall levendefødsler	Antall gutter	Andel gutter
10	8	0,8
100	55	0,55
1000	525	0,525
10000	5139	0,5139
100000	51127	0,51127
3760358	1927054	0,51247
17989361	9219202	0,51248
34832051	17857857	0,51268

NTNU
Det skapende universitet
www.ntnu.no

38

Sannsynlighet (Def 3.1)

- Et forsøk gjennomføres n ganger. Begivenheten A inntreffer n_A av gangene. Den relative hyppigheten n_A/n tenderer mot et tall når antall forsøk tenderer mot uendelig. Dette tallet, $P(A)$, kalles *sannsynligheten* for A. Engelsk: *Probability*

NTNU
Det skapende universitet
www.ntnu.no

39

Sannsynlighetsmodell: Forsøk, utfallsrom, sannsynligheten til hvert enkeltutfall

- Terningkast: $P(1) = P(2) = P(3) = P(4) = P(5) = P(6) = 1/6$
- Barnefødsel. $P(\text{jente}) = 0.487$, $P(\text{gutt}) = 0.513$
- Behandling med penicillin. Realistisk for enkelte pasientgrupper: $P(\text{frisk}) = 0.6377$, $P(\text{forblir syk}) = 0.3622$, $P(\text{anafylaktisk sjokk}) = 0.0001$

NTNU
Det skapende universitet
www.ntnu.no

40

Aalen et al (2006), side 49: ... Det er for eksempel mennesker som har kastet en terning svært mange ganger, og da har funnet ut at hvert av utfallene opptrer i omtrent 1/6 av tilfellene.

NTNU
Det skapende universitet
www.ntnu.no

41

3.4 Regneregler for sannsynlighet

Regel 3.2 Komplementregelen

$$P(A) + P(\bar{A}) = 1$$

Regel 3.3 Addisjonsregelen:
For disjunkte A og B har vi

$$P(A \cup B) = P(A) + P(B)$$

Regel 3.4 Den generelle addisjonsregel:

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

NTNU
Det skapende universitet
www.ntnu.no

42

Positiv uritest Syk (*Chlamydia trachomatis*) 757

A = "Pasienten har positiv uritest" $P(A) = 81/757 = 10.7\%$

B = "Pasienten er syk" $P(B) = 89/757 = 11.8\%$

$P(A \mid B) = 72/89 = 80.9\%$

$$P(A \mid B) = \frac{72/757}{89/757} = \frac{P(A \cap B)}{P(B)}$$

NTNU
Det skapende universitet
www.ntnu.no

43

Definisjon av betinget sannsynlighet for A gitt B:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Regel 3.5

Den generelle multiplikasjonsregelen

$$P(A \cap B) = P(A|B)P(B) = P(B|A)P(A)$$



www.ntnu.no

A og B er stokastisk uavhengige hvis

$$P(A|B) = P(A)$$

Regel 3.6 mm:

A og B er stokastisk uavhengige hvis og bare hvis

$$P(A \cap B) = P(A)P(B)$$

Regel 3.7:

Hvis A_1, A_2, \dots, A_n er stokastisk uavhengige så er

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1)P(A_2) \cdots P(A_n)$$



www.ntnu.no

45

Eksempel:

Sannsynlighet for to gutter i to enkeltfødsler:

$$P(G_1 \cap G_2) = P(G_1)P(G_2) = 0.513 \cdot 0.513 = 0.263$$



www.ntnu.no

Aalen et al, eksempel 3.4 s 56:

"... Vi antar da uavhengigheten mellom hver fødsel med hensyn til barnets kjønn. Egentlig kan en ikke bare gå ut fra at det er avhengighet i dette tilfellet. Det bør undersøkes om en slik antakelse stemmer med virkeligheten. Det finnes flere undersøkelser om dette, og det viser seg at det ikke er full stokastisk uavhengighet med hensyn til barns kjønn i en familie. Enkelte familier har en tendens til å få jenter og andre en tendens til å få gutter. ..."



www.ntnu.no

47

Lippert, T, Skjærven, R, Salvesen, K. Å: Hvorfor får noen bare gutter eller bare jenter? Tidsskr Nor Lægeforen 2005; 125: 3414-7

Studie basert på kvinner som har født to, tre og fire barn i perioden 1967 – 2003 (Norsk fødselsregister): 540 699 kvinner og 1 382 974 fødsler.

Andel gutter 51.33%.



www.ntnu.no

Lippert et al (2005):

"Det er ikke holdepunkter for at sannsynligheten for å få gutt eller jente avviker fra populasjons gjennomsnittet hos noen spesielle foreldrepær. Den viktigste forklaringen på at det er flere rene gutte- og jentesøkenflokker enn statistisk fordeling forutsier, er at en del mødre med bare gutter eller bare jenter føder flere barn, i hva vi tror er et forsøk på å få et barn av motsatt kjønn."



www.ntnu.no

49

Altså:

Barnets kjønn (ved enkeltfødsler) er uavhengig av kjønnsfordeling på eldre søskjen, Norge 1967 – 2003.

Men:

Singh, N., Pripp, A. H., Brekke, T., & Stray-Pedersen, B. 2010, "Different sex ratios of children born to Indian and Pakistani immigrants in Norway", BMC Pregnancy and Childbirth, vol. 10.



www.ntnu.no

50

Singh et al (2010). Indian populations living in Norway

Time period	Birth order of child	Female / male	Female sex ratio, % (95% confidence interval)
1969-1886	1	259/297	87 (73 to 102)
	2	197/207	95 (77 to 114)
	3	85/79	108 (75 to 141)
	4	26/28	93 (42 to 142)
1987-1996	1	283/250	113 (94 to 132)
	2	208/204	102 (82 to 122)
	3	64/103	62 (43 to 82)
	4	12/33	36 (12 to 60)
1997-2005	1	273/235	116 (96 to 136)
	2	202/237	85 (69 to 101)
	3	68/99	69 (47 to 90)
	4	8/17	47 (8 to 87)

Natural female sex ratio: $(1 - 0.513) / 0.513 = 95\%$



51

Singh et al (2010):

"Our findings indicate that the female-to-male ratio of higher birth order children seems to have declined among Indian immigrants, but not among Pakistani immigrants, after the introduction of ultrasound scanning technology in Norway in 1987. Lower proportions of female births than expected were not found in the pre-ultrasound era. This imbalance could reflect the selective abortion of female fetuses due to prenatal sex determination by ultrasound."



www.ntnu.no