

Faculty of Health Sciences

Basal statistik

Den generelle lineære model mv., i SPSS

Lene Theil Skovgaard

19. oktober 2020



Den generelle lineære model mv.

- ▶ Ikke-lineære sammenhænge
- ▶ Opbygning af modeller
- ▶ Sammenligning af modeller
- ▶ Endnu et eksempel

E-mail: ltsk@sund.ku.dk



Terminologi

for **kvantitativt outcome**, f.eks. vitamin D

Regression: Kovariaterne er også **kvantitative**

- ▶ Simpel (**lineær**) regression:
kun en enkelt kovariat
- ▶ Multipel (**lineær**) regression:
to eller flere kovariater

Variansanalyse: Kovariaterne er **kategoriske**
(grupper, class-variable, faktorer)

- ▶ Ensidet variansanalyse: kun en enkelt kovariat
- ▶ Tosidet variansanalyse: to kovariater

Generel lineær model: **Begge typer kovariater** i samme model

- ▶ Kovariansanalyse:
Netop en kvantitativ og en kategorisk kovariat



Forklarende variable = Kovariater

Outcome	Dikotom	Kategorisk	Kvantitativ	Kategoriske og kvantitative
Dikotom parret	2*2-tabeller Mc Nemar	χ^2 -test svært, mixed models		Logistisk regression Mixed models
Kategorisk	Kontingenstabeller/ χ^2 -test		Generaliseret logistisk regression	
Ordinale	svært, f.eks. proportional odds modeller			
Kvantitativ parret	Mann-Whitney Wilcoxon signed rank	Kruskal-Wallis Friedman		Robust multipel regression
Normalfordelte residualer	T-test uparret/parret	Variansanalyse ensidet/tosidet	Multipel regression Den generelle lineære model	Kovariansanalyse
Censureret	Log-rank test		Cox regression	
Korrelerede kvantitative Nf. residualer	Varianskomponent-modeller Mixed models		Modeller for gentagne målinger	



Den generelle lineære model

Outcome: Kvantitativ variabel Y

Kovariater: ► Kategoriske (class):

Fortolkning af parameter:

Forskel fra aktuel gruppe til referencegruppe,
for fastholdt værdi af alle andre kovariater.

► Kvantitative:

Her antages linearitet

Fortolkning af parameter:

1 enheds ændring i X svarer til

β enheders ændring i Y ,

for fastholdt værdi af alle andre kovariater.



Linearitet

Skal alt så kunne beskrives ved hjælp af linier?

Nej, fordi:

- ▶ Man kan **transformere** en eller flere af de indgående variable
Eksempel: Biokemisk iltforbrug (s. 7-17)
- ▶ Man kan benytte **polynomier** ved at tilføje kovariater i forskellige potenser (s. 23-26)
bruges dog mest som modelcheck
- ▶ Tilføje en kovariat, der er relateret til den oprindelige kovariat, f.eks. logaritmetransformationen
- ▶ Man kan lave stykvisse lineære funktioner, kaldet **lineære splines**
Eksempel: Væksthormon (s. 27-34)



Biologisk iltforbrug

Iltsvind i lukkede flasker (boc, **b**iochemical **o**xygen **c**onsumption),
som funktion af antal dage (days)

4 flasker til hvert tidspunkt


<i>days</i>				
1	105	97	104	106
2	136	161	151	153
3	173	179	174	174
5	195	182	201	172
7	207	194	206	213
10	218	193	235	229

Vedr. omstrukturering af data, samt figur næste side: se s. 93-94



Illustration af iltsvind

Sammenhængen mellem iltsvind (boc) og antallet af dage (days) ses at være **ikke-lineær**.



Vi ønsker at bestemme *asymptoten*, dvs. iltsvindet efter *lang* tid, dvs. når tiden går mod uendelig (∞)

Transformation til linearitet

Biologerne hævder at vide, at iltsvindet kan beskrives ved funktionen

$$\text{boc} = \gamma \exp(-\beta/\text{days})$$

Denne relation er klart **ikke-lineær**, men den kan **transformeres til linearitet** ved brug af den (naturlige) logaritme:

$$\log(\text{boc}) = \log(\gamma) - \beta/\text{days}$$

Vi vil gerne bestemme

$$\text{boc}(\infty) = \gamma \quad \exp(0) = \gamma$$



Omparametrisering

Med definitionerne

Outcome: $y = \log \text{boc} = \log(\text{boc})$

Kovariat: $x = \text{invdays} = 1/\text{days}$

Intercept: $\alpha = \log(\gamma)$

kan vi skrive ligningen som

$$y = \alpha - \beta x$$

altså en **lineær relation**, bare med en negativ hældning ($-\beta$)



Den lineære regression

Variabeldefinitioner og analyse ses s. 95-96

Bemærk, at vi her har benyttet *den naturlige logaritme* til at transformere iltforbruget (dette valg kommenteres s. 19)

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,976 ^a	,952	,950	,05845

a. Predictors: (Constant), invdays


b. Dependent Variable: logboc

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	5,431	,019		286,761	,000	5,392	5,471
	invdays	-,808	,039	-,976	-20,833	,000	-,888	-,727



Den transformerede relation

Se s. 97



Dette plot ser pænt lineært ud, med rimelig varianshomogenitet.
Vi finder:

$$\log b_{oc} = 5.431 - 0.808 \times invdays$$

Fortolkning af resultaterne

Den lineære regressionsmodel giver os estimerne (fra s. 11):

$$\text{intercept} : \hat{\alpha} = \log(\hat{\gamma}) = 5.431(0.019)$$

$$\text{slope} : \hat{\beta} = -0.808(0.039)$$


Ved at bemærke, at $\text{boc}(\infty) = \gamma = \exp(\alpha)$,
finder vi estimatet af $\text{boc}(\infty)$ til $\exp(5.431) = 228.38$

med 95% konfidensinterval
 $(\exp(5.392), \exp(5.471)) = (219.6, 237.7)$



Tilbagetransformeret relation

er besværlig at lave i SPSS!!, se s. 98 - 99
så denne er lavet i SAS.



Analyse på original skala

kræver *ikke-lineær regression* (mere om dette lidt senere)

Her benyttes Analyze/Regression/Nonlinear Regression, hvor man sætter boc i Dependent og i Model Expression skriver selve det ikke-lineære udtryk $\gamma \exp(-\beta \text{days})$.

Herefter klikker man i Parameters og tilføjer

- ▶ Name: gamma, Starting Value: 228 Add
- ▶ Name: beta, Starting Value: 0,8 Add

og til sidst: Continue

Bemærk, at resultaterne er *meget* tæt på dem fra før



Output fra ikke-lineær regression

Kun parameterestimerne er interessante:


Parameter Estimates

Parameter	Estimate	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
gamma	230,584	4,538	221,172	239,997
beta	,833	,058	,713	,952



Fit fra ikke-lineær regression

Det automatiske plot fra SAS ser således ud:
(Dette plot synes ikke at være muligt i SPSS??)



Bemærk, at der på denne skala *ikke* er varianshomogenitet.

Transformation med logaritmer

– men hvilken logaritme?

Alle logaritmer er proportionale, så resultaterne bliver ens (efter tilbagetransformation), men der er visse fif:

- ▶ Hvis den forklarende variabel transformeres, er det i reglen for at opnå linearitet
 - ▶ Brug gerne 2-tals logaritmer her, for så kan estimatet fortolkes som effekten af *fordobling* af kovariaten.
 - ▶ Man kan også vælge en logaritme med grundtal 1.1, så estimatet fortolkes som effekten af *10% ændring* af kovariaten.

$$\log_{1.1}(x) = \frac{\log_{10}(x)}{\log_{10}(1.1)}$$



Transformation med logaritmer, II

- ▶ Hvis outcome transformeres, kan det være
 - ▶ for at opnå linearitet
 - ▶ for at opnå ens spredninger (varianshomogenitet)Her er der en vis fordel ved at bruge den **naturlige** logaritme (den som tidligere har heddet $\ln$, men som altså hedder $\log$ i computersprog), fordi

$$\text{Spredning}(\log(y)) \approx \frac{\text{Spredning}(y)}{y} = CV$$

dvs. en konstant **variationskoefficient (CV)** på Y betyder konstant spredning på $\log(Y)$,

I dette eksempel ser vi (fra outputtet s. 11), at variationskoefficienten for iltforbruget er 5.8%



Andre transformationer

Selv om logaritmer er langt det hyppigste valg af transformation, bruges af og til andre:

- ▶ I eksemplet med biokemisk iltforbrug (boc) brugte vi **den inverse** til kovariaten (1/dage), fordi vi havde en specifik viden om den biologiske mekanisme, og dermed om sammenhængen mellem outcome og kovariat
- ▶ Somme tider bruges **kvadratrod** for at få konstante spredninger (eller evt. normalfordelte residualer), hvis man har trompetfacon på den oprindelige skala, men omvendt trompet på logaritme skala, **men det bliver ret svært at fortolke**




Modeller med logaritmetransformerede data

<i>Modelformel</i>	<i>Tilbagetransformeret</i>	Fortolkning
$y = \alpha + \beta x$	<i>(ikke relevant)</i>	1 enheds tilvækst i x svarer til β enheders tilvækst i y
$\log_2(y) = \alpha + \beta x$	$y = \alpha_* \beta_*^x$ $\alpha_* = 2^\alpha, \beta_* = 2^\beta$	1 enheds tilvækst i x svarer til en faktor 2^β på y
$y = \alpha + \beta \log_2(x)$	<i>(ikke relevant)</i>	En faktor 2 på x svarer til β enheders tilvækst i y
$\log_2(y) = \alpha + \beta \log_2(x)$	$y = \alpha_* x^\beta$ $\alpha_* = 2^\alpha$	En faktor 2 på x svarer til en faktor 2^β på y



Eksempel om væksthormon (fra øvelserne i denne uge)

Væksthormon for drenge, op til 20-års alderen



Ikke udpræget lineært, men hvad så?

Ingen specifik formel haves....

Polynomier

Et p 'te grads polynomium:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2 + \cdots + \beta_p x^p$$

Et første-grads polynomium er **en linie**:

$$y = \beta_0 + \beta_1 x$$

Et anden-grads polynomium er **en parabel**:





$$y = \beta_0 + \beta_1 x + \beta_2 x^2$$

som kan være glad ($\beta_2 > 0$) eller sur ($\beta_2 < 0$)

Ser man lokalt på en parabel, kan den beskrive en afvigelse fra linearitet.



Polynomier af 1.-4. grad



Polynomial regression

$$Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \cdots + \beta_p x_i^p + \varepsilon_i$$

Med kovariaterne

$$Z_1 = X, \quad Z_2 = X^2, \quad \cdots, \quad Z_p = X^p$$

er det bare en sædvanlig **lineær multipel regression**


$$Y_i = \beta_0 + \beta_1 z_{1i} + \beta_2 z_{2i} + \cdots + \beta_p z_{pi} + \varepsilon_i$$

Kovariaterne $Z_1, \dots, Z_p$ er selvfølgelig
korrelerede, men de er ikke **lineært** afhængige.



Polynomier til beskrivelse af Serum IGF-1

Væksthormon (kvadratrodstransformeret), som funktion af alder



med overlejlrede polynomier af 1., 2. og 3. grad (se s. 103)

Men vi tror ikke rigtigt på disse modeller....

fordi de svinger for meget

Specielt ude i enderne kan de opføre sig meget underligt.

Splines: Lokale polynomier

Lineære splines:

- ▶ Opdel i aldersgrupper, med passende tærskelværdier, f.eks.
 $a_1 = 10, a_2 = 12, a_3 = 13, a_4 = 15$
- ▶ Fit en lineær effekt af alder i hver aldersgruppe
- ▶ Sørg for at de “mødes” i tærskelværdierne

Resultatet er en **knækket linie** (men stadig en **lineær model**)

$$y_i = \alpha + \lambda_0 x + \lambda_1 I(x > a_1)(x - a_1) + \cdots + \lambda_k I(x_i > a_k)(x - a_k) + \varepsilon_i$$

Splines kan også være kvadratiske, kubiske etc.



Fortolkning af parametre


- ▶ α : Intercept, forventet outcome ved alder 0
- ▶ λ_0 : hældning (effekt af aldersøgning med 1 år), frem til alder a_1
- ▶ λ_1 : knæk i "linien" ved alder a_1
 - ▶ $\lambda_1 = 0$: "linien" fortsætter hen over a_1 uden at knække
 - ▶ $\lambda_1 > 0$: "linien" knækker, og får større hældning efter a_1
 - ▶ $\lambda_1 < 0$: "linien" knækker, og får mindre hældning efter a_1

Hældning i aldersintervallet (a_1, a_2) er $\lambda_0 + \lambda_1$

- ▶ λ_2 :
knæk i "linien" ved alder a_2
Samme fortolkning som λ_1 , blot ved en anden alderstærskel
Hældning i aldersintervallet (a_2, a_3) er $\lambda_0 + \lambda_1 + \lambda_2$
- ▶ osv. osv.



Lineær spline for Serum IGF-1



Estimator:

$$\lambda_0 = 0.70, \lambda_1 = -0.16, \lambda_2 = 2.38, \lambda_3 = -1.15, \lambda_4 = -2.42$$

(Denne tegning kan ikke laves i SPSS, kun fittet for sig selv, se s. 105)

At fitte lineære splines

Ud over selve kovariaten (her age) skal man tilføje en ekstra kovariat for hver tærskelværdi

For tærsklen ved 13 definerer vi således en variabel:

- ▶ For personer under 13 år sættes til den 0
- ▶ For personer over 13 år, defineres den som alder minus 13, så den f.eks. får værdien 2.4 for en person med alderen 15.4 år

```
extra_age10=max(age-10,0)
```

```
extra_age12=max(age-12,0)
```

```
extra_age13=max(age-13,0)
```


```
extra_age15=max(age-15,0)
```



Udseendet af lineære splines

4 stk, for tærskelværdierne 10, 12, 13 og 15:

- ▶ De er alle 0 op til deres respektive tærskel
- ▶ Herefter stiger de med 1 år pr. år, så de tæller "*år fra tærskel*"



Output, lineær spline

Se s. 104


Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	8,283	1,867		4,436	,000
	age	,704	,218	,606	3,231	,001
	extra_age10	-,163	,556	-,117	-,292	,770
	extra_age12	2,384	1,251	1,357	1,905	,058
	extra_age13	-1,152	1,281	-,555	-,899	,369
	extra_age15	-2,418	,539	-,727	-4,489	,000

Evidens for et knæk omkring 15-års alderen,
og *måske* omkring 12-års alderen...

*Alternativ parametrisering af lineære splines

Hvis man ændrer de nye kovariater til disse
(se s. 106):



så får man i stedet estimater for hældningerne i de enkelte
aldersintervaller (ret teknisk):

*Output fra alternativ parametrisering

af lineære splines (kode s. 106)

Nu fortolkes estimaterne som

hældningerne i de successive intervaller:

Op til alder 10, mellem 10 og 12, mellem 12 og 13,
mellem 13 og 15, samt over 15 år

Coefficients^a

		Unstandardized Coefficients		Standardized Coefficients		
Model		B	Std. Error	Beta	t	Sig.
1	(Constant)	8,283	1,867		4,436	,000
	ny_age	,704	,218	,159	3,231	,001
	ny_age10	,542	,404	,109	1,340	,181
	ny_age12	2,926	,950	,320	3,079	,002
	ny_age13	1,774	,420	,382	4,220	,000
	ny_age15	-,644	,175	-,194	-3,681	,000

Kan GLM så klare alt?

Nej

der findes ikke-lineære modeller, der

- ▶ ikke kan transformeres til linearitet
- ▶ indeholder parametre med meget veldefineret betydning (typisk fysiologi/kinetik), som kun estimeres *pænt* i en ikke-lineær model (f.eks. Michaelis-Menten kinetik)

Eksempel: Model til at kvantificere **RES**-systemet i leveren:



RES-systemet i leveren

Lad Y_i betegner den målte koncentration af en radioaktiv tracer, målt til tiden t_i efter en bolus injektion ved tid 0.

Så siger **1. ordens kinetik**,
at sammenhængen bør være

$$y_i = \beta(1 - e^{-\gamma t_i}) + \varepsilon_i,$$

$$\varepsilon_i \sim N(0, \sigma^2)$$

Her kan ikke transformeres til linearitet!



Mindste kvadraters metode

kræver her

- ▶ startværdier (gæt på parametrene værdier)
kan være ganske vanskeligt, og der er ingen generelle retningslinier
- ▶ iterationer (trinvis forbedrede fit)
klares heldigvis af programmet



Mindste kvadraters metode

Her benyttes Analyze/Regression/Nonlinear Regression, hvor man sætter konc i Dependent og i Model Expression skriver selve det ikke-lineære udtryk $\text{beta} * (1 - \exp(-\text{gamma} * \text{tid}))$.

Herefter klikker man i Parameters og tilføjer

- ▶ Name: gamma, Starting Value: 0,05 Add
- ▶ Name: beta, Starting Value: 2000 Add

og til sidst: Continue

Output ses s. 39-40



*Output fra ikke-lineær regression

fra opsætning forrige side:

Iteration History^b

Iteration Number ^a	Residual Sum of Squares	Parameter	
		beta	gamma
1.0	4370990,225	2000,000	,050
1.1	382995,386	1958,555	,082
2.0	382995,386	1958,555	,082
2.1	26354,953	2169,165	,077
3.0	26354,953	2169,165	,077
3.1	25286,735	2174,161	,077
4.0	25286,735	2174,161	,077
4.1	25286,715	2174,048	,077
5.0	25286,715	2174,048	,077
5.1	25286,715	2174,044	,077

Derivatives are calculated numerically.

- Major iteration number is displayed to the left of the decimal, and minor iteration number is to the right of the decimal.
- Run stopped after 10 model evaluations and 5 derivative evaluations because the relative reduction between successive residual sums of squares is at most $SSCON = 1,000E-8$.

Når et “*stabil*” fit er fundet, stopper processen (konvergens)



Output, fortsat

Parameter Estimates

Parameter	Estimate	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
beta	2174,044	28,346	2115,541	2232,548
gamma	,077	,002	,073	,082

ANOVA^a

Source	Sum of Squares	df	Mean Squares
Regression	63048136,28	2	31524068,14
Residual	25286,715	24	1053,613
Uncorrected Total	63073423,00	26	
Corrected Total	3455129,115	25	

Dependent variable: konc

a. $R^2 = 1 - (\text{Residual Sum of Squares}) / (\text{Corrected Sum of Squares}) = ,993$.

Fittet svarende til disse parameterestimer fremgår af s. 41




Fittet fra ikke-lineær regression

Estimater:

- ▶ $\hat{\beta} = 2174.0(28.3)$, $CI=(2115.5, 2232.5)$
- ▶ $\hat{\gamma} = 0.0773(0.0023)$, $CI=(0.0726, 0.0819)$

Det automatiske plot fra SAS ser således ud:

Dette plot synes ikke at være muligt i SPSS??



Den generelle lineære model

er et slagkraftigt værktøj,
men altså med **visse begrænsninger**:

Outcome: kvantitativ variabel Y
(med ca. normalfordelte residualer)

Kovariater: ▶ Kategoriske (class)
 ▶ Kvantitative:
 Her antages linearitet
 ▶ Interaktioner

Men hvordan vælges modellen?



Opbygning af model

bør følge problemstillingen som beskrevet i protokollen

- ▶ Her bør der være specificeret
 - ▶ primært outcome
 - ▶ de vigtigste hypoteser (videnskabelige spørgsmål)
 - ▶ sekundære outcomes og hypoteser
- ▶ pludselige indskydelser (evt. baseret på tegninger), samt tests, der ikke var specificeret i protokollen, betegnes som **fisketur**, og skal bekræftes i en ny (confirmative) analyse, før der kan skabes tillid til resultaterne.

Det betaler sig at gøre forarbejdet ordentligt,
så man ikke bliver berømt på sine fejlkonklusioner



Eksempel: Modelbygning for Vitamin D

Problemformulering i protokol:

- ▶ Er der forskel på vitamin D i de forskellige lande?
 - efter korrektion for allerede “*etablerede*” kovariater.
- ▶ Hvis ja, så hvorfor?

Hypoteser:

- ▶ **Primær:**
 - pga forskel i **fedme** (bmi)
fordi vitamin D er fedtopløseligt
 - ▶ pga forskelle i **solvaner** (sunexp)
fordi solen laver vitamin D i huden
 - ▶ pga forskelle i **spisevaner** (vitdintake)
nogle steder spiser man måske flere (fede) fisk
 - ▶ pga aldersforskelle....?
 - ▶
 - ▶



Vitamin D i de 4 lande

Tabel over median værdier:

Land	Nr	Antal	Vitamin D	Alder	Body Mass Index	Vitamin D Indtag
Denmark	1	53	47.80	71.51	25.39	8.29
Finland	2	54	46.60	71.92	27.98	12.41
Ireland	4	41	44.80	72.05	26.39	5.46
Poland	6	65	32.50	71.69	29.37	5.16


Polen ligger lavt i vitamin D niveau, og

- ▶ højt i body mass index
- ▶ lavt i vitamin D indtag



Første skridt

Er der overhovedet signifikant forskel på landene?



Modeldiagram: Country $\rightarrow$ Vitamin D

Uanset om man ser på utransformerede data eller logaritmetransformerede data, finder man en forskel på landene ($P = 0.000$), idet Polen findes at ligge lavere end de øvrige.

Vi vælger at køre videre på **logaritmeskala**.

Sammenligning af landene

Outcome Y: kvantitativ, Y=lvitd, **log2-transformeret**

Kovariat X: kategorisk, X=country

Derfor: Ensidedt variansanalyse, **på log2-skala:**

Sammenligning af 4 middelværdier (se s. 108)

Tests of Between-Subjects Effects

Dependent Variable: lvitd

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	12,928 ^a	3	4,309	8,377	,000
Intercept	5799,200	1	5799,200	11272,756	,000
country	12,928	3	4,309	8,377	,000
Error	107,519	209	,514		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,107 (Adjusted R Squared = ,095)



Sammenligning af landene, II

Parameter Estimates

Dependent Variable: *lvitd*

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	4,890	,089	54,961	,000	4,714	5,065
[country=1]	,471	,133	3,547	,000	,209	,732
[country=2]	,558	,132	4,223	,000	,297	,818
[country=4]	,567	,143	3,963	,000	,285	,849
[country=6]	0 ^a	.	.	.	.	.

a. This parameter is set to zero because it is redundant.

Fortolkning af estimerer

Den estimerede forskel, f.eks. mellem Finland og Polen er en faktor

$$2^{0.558} = 1.47$$

altså svarende til 47% større niveau af vitamin D i Finland sammenlignet med Polen. Konfidensintervallet for denne sammenligning udregnes på samme måde ud fra konfidensintervallet (ikke vist ovenfor af pladshensyn) som

$$(2^{0.297}, 2^{0.818}) = (1.23, 1.76)$$

altså fra 23% over til 76% over.




Hvordan forklarer vi forskellen mellem landene?

kan vi f.eks. forklare det ved forskelle i body mass index?

Country $\rightarrow$ BMI $\rightarrow$ Vitamin D

eller måske bare noget af det?



BMI er en mellemkommende variabel (mediator)



Model med bmi som kovariat (se s. 109)

Tests of Between-Subjects Effects

Dependent Variable: **lvtd**

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	18,222 ^a	4	4,556	9,269	,000
Intercept	188,938	1	188,938	384,439	,000
country	9,992	3	3,331	6,777	,000
bmi	5,294	1	5,294	10,772	,001
Error	102,224	208	,491		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,151 (Adjusted R Squared = ,135)

Parameter Estimates

Dependent Variable: **lvtd**

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,992	,347	17,274	,000	5,308	6,675
[country=1]	,379	,133	2,857	,005	,118	,641
[country=2]	,534	,129	4,134	,000	,280	,789
[country=4]	,468	,143	3,275	,001	,186	,750
[country=6]	0 ^a	.	.	.	.	.
bmi	-,038	,012	-3,282	,001	-,061	-,015

a. This parameter is set to zero because it is redundant.

Fortolkning af nye estimater

Den estimerede forskel mellem Finland og Polen, for folk **med samme BMI**, er en faktor

$$2^{0.534} = 1.45$$

altså næsten det samme som før (meget lidt confounding).
Konfidensintervallet for denne sammenligning bliver

$$(2^{0.280}, 2^{0.789}) = (1.21, 1.73)$$

en ubetydelighed lavere end den ujusterede forskel fra s. 49



Kunne bmi forklare forskellen på landene?


Nej,

- ▶ Selv om bmi i sig selv er stærkt signifikant (negativ effekt, estimeret til $-0.038(0.012)$, $P = 0.001$), er der stadig stærkt signifikant forskel på landene, når vi har korigeret for bmi ($P = 0.000$), så der er masser af plads til andre bud på forklarende variable

fra protokollen, vel at mærke.



Modeldiagram - med “det hele”



og så er der interaktionerne...

Kan vi så forklare forskellen på landene

ved hjælp af alle de 3 specificerede kovariater samtidig?

Tests of Between-Subjects Effects

Dependent Variable: lvtld

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	40,345 ^a	7	5,764	14,750	,000
Intercept	116,267	1	116,267	297,555	,000
country	5,596	3	1,865	4,774	,003
bmi	3,791	1	3,791	9,703	,002
sunexp	1,080	2	,540	1,381	,254
lvtldintake	19,940	1	19,940	51,031	,000
Error	80,102	205	,391		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,335 (Adjusted R Squared = ,312)

Næh.....der er stadig signifikant forskel på landene



Output, fortsat

Parameter Estimates

Dependent Variable: `lvitd`

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,358	,360	14,876	,000	4,648	6,068
[country=1]	,319	,122	2,621	,009	,079	,558
[country=2]	,248	,123	2,020	,045	,006	,490
[country=4]	,459	,128	3,597	,000	,207	,711
[country=6]	0 ^a	.	.	.	.	.
bmi	-,033	,010	-3,115	,002	-,053	-,012
[sunexp=1]	-,216	,130	-1,662	,098	-,472	,040
[sunexp=2]	-,144	,122	-1,183	,238	-,385	,096
[sunexp=3]	0 ^a	.	.	.	.	.
lvitdintake	,255	,036	7,144	,000	,185	,326

a. This parameter is set to zero because it is redundant.



Fortolkning af estimater

fra output på forrige side

- ▶ 1 enheds stigning i **BMI** giver en faktor $2^{-0.033} = 0.977$ på vitamin D niveauet, dvs. et fald på 2.3%, med konfidensgrænser $(2^{-0.053}, 2^{-0.012}) = (0.964, 0.992)$, svarende til et fald på mellem 0.8% og 3.6%.
- ▶ **Solvanerne** ser ikke ud til at betyde så meget, men mønstret ser fornuftigt ud, så *måske* ville effekten vise sig i et større materiale.

Forskellen på “ligeglade” og solhadere estimeres her til en faktor $2^{-0.144+0.216} = 1.05$, altså svarende til 5% større niveau af vitamin D hos “ligeglade” i forhold til solhadere.
Konfidensgrænser: se side 60-65.



Fortolkning af estimer, fortsat

fra output på forrige side

- ▶ En 10% øgning i **vitamin D indtag** (dvs. en faktor 1.1 på denne), svarer til en faktor $1.1^{0.255} = 1.025$ på vitamin D niveauet, altså kun en stigning på 2.5% (se s. 21, nederste modelformel).
Konfidensgrænserne er $(1.1^{0.185}, 1.1^{0.326}) = (1.018, 1.032)$, svarende til en stigning på mellem 1.8% og 3.2%.
- ▶ Den estimerede forskel mellem Finland og Polen, for folk **med samme BMI, solvaner og vitamin D indtag**, er en faktor $2^{0.248} = 1.19$ altså noget mindre end tidligere, svarende til at vi har kunnet forklare en vis del af forskellen mellem de to lande (faktisk er denne forskel kun lige akkurat signifikant).

Konfidensintervallet for denne sammenligning er $(2^{0.006}, 2^{0.490}) = (1.004, 1.40)$



Sammenligning mellem andre lande

Den estimerede forskel mellem lande som **Irland og Danmark** fremgår ikke direkte af output, men kan nemt udregnes til faktoren

$$2^{0.459-0.319} = 1.10$$

altså svarende til 10% større niveau af vitamin D i Irland sammenlignet med Danmark.

For at få konfidensintervallet for denne sammenligning kan man i SPSS f.eks. benytte parvise sammenligninger af alle landene i stedet for (se s. 111 samt output s. 61-62).



Irland vs. Danmark, og “ligeglade” vs. solhadere

Disse sammenligninger fremkommer ikke automatisk, fordi der ikke er tale om sammenligninger til referencen.

Det kan løses på flere måder, afhængigt af program:

- ▶ Omkodning, så vi får en anden reference
- ▶ Direkte valg af en bestemt reference-værdi
- ▶ Kombination af parameterestimer, f.eks. differenser (SAS)
- ▶ Multiple parvise sammenligninger, som vist på næste side



Output fra parvise sammenligninger

Se s. 111

Pairwise Comparisons

Dependent Variable: ivtd

(I) country	(J) country	Mean Difference (I-J)	Std. Error	Sig. ^b	95% Confidence Interval for Difference ^b	
					Lower Bound	Upper Bound
DK	SF	,070	,126	,578	-,179	,320
	EI	-,141	,132	,288	-,401	,119
	PL	,319*	,122	,009	,079	,558
SF	DK	-,070	,126	,578	-,320	,179
	EI	-,211	,137	,124	-,481	,059
	PL	,248*	,123	,045	,006	,490
EI	DK	,141	,132	,288	-,119	,401
	SF	,211	,137	,124	-,059	,481
	PL	,459*	,128	,000	,207	,711
PL	DK	-,319*	,122	,009	-,558	-,079
	SF	-,248*	,123	,045	-,490	-,006
	EI	-,459*	,128	,000	-,711	-,207

Based on estimated marginal means

*. The mean difference is significant at the ,05 level.

b. Adjustment for multiple comparisons: Least Significant Difference (equivalent to no adjustments).



Output fra parvise sammenligninger, II

Pairwise Comparisons

Dependent Variable: lvttd

(I) sunexp	(J) sunexp	Mean Difference (I-J)	Std. Error	Sig. ^a	95% Confidence Interval
					Lower Bound
Avoid sun	Sometimes in sun	-,072	,099	,468	-,266
	Prefer sun	-,216	,130	,098	-,472
Sometimes in sun	Avoid sun	,072	,099	,468	-,123
	Prefer sun	-,144	,122	,238	-,385
Prefer sun	Avoid sun	,216	,130	,098	-,040
	Sometimes in sun	,144	,122	,238	-,096

Pairwise Comparisons

Dependent Variable: lvttd

(I) sunexp	(J) sunexp	95% Confidence Interval for ^a .
		Upper Bound
Avoid sun	Sometimes in sun	,123
	Prefer sun	,040
Sometimes in sun	Avoid sun	,266
	Prefer sun	,096
Prefer sun	Avoid sun	,472
	Sometimes in sun	,385

Based on estimated marginal means

a. Adjustment for multiple comparisons: Least Significant Difference (equivalent to no adjustments).



Effekt af 10% øgning i vitd intake

Her defineres en ny kovariat:

`lvitdintake11 = LG10(vitdintake)/LG10(1.1)`

således at 1 enhed af denne svarer til en 10% forøgelse af vitdintake. Vi får så outputtet:

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,358	,360	14,876	,000	4,648	6,068
[country=1]	,319	,122	2,621	,009	,079	,558
[country=2]	,248	,123	2,020	,045	,006	,490
[country=4]	,459	,128	3,597	,000	,207	,711
[country=6]	0 ^a	.	.	.	.	.
bmi	-,033	,010	-3,115	,002	-,053	-,012
[sunexp=1]	-,216	,130	-1,662	,098	-,472	,040
[sunexp=2]	-,144	,122	-1,183	,238	-,385	,096
[sunexp=3]	0 ^a	.	.	.	.	.
lvitdintake11	,035	,005	7,144	,000	,025	,045



Output fra ekstra sammenligninger

- ▶ Irland vs. Danmark: 0.141, CI= $(-0.119, 0.401)$
- ▶ “Sometimes in sun” vs. “Avoid Sun”:
0.072, CI= $(-0.123, 0.266)$
- ▶ En 10% øgning i Vitamin D indtag:
0.035, CI= $(0.025, 0.045)$

Disse skal nu tilbagetransformeres,
hvorved vi får







Tilbagetransformerede estimater



- ▶ Den estimerede forskel **Irland vs. Danmark** er en faktor: $2^{0.141} = 1.103$, svarende til, at Irland ligger ca. 10.3% højere end Danmark, CI=(-7.1%, 32.0%)
- ▶ Forskellen **“ligeglade” vs. solhadere** estimeres til en faktor $2^{0.072} = 1.051$, svarende til en øgning på 5.1% i vitamin D status, CI=(-8.2%, 20.2%)
- ▶ En 10% øgning i Vitamin D indtag estimeres til en faktor $2^{0.035} = 1.025$, svarende til en øgning i Vitamin D status på 2.5%, CI=(1.7%, 3.2%)



Husk også modelkontrol (se s. 112ff)



Modelkontrol, II



Note om T-test og F-test

Et T-test tester typisk, om en parameter kan være 0

- ▶ Forskel på 2 middelværdier, $\mu_1 - \mu_2$
- ▶ En hældning β , f.eks. en lineær effekt af bmi eller alder

Et F-test tester *flere* sådanne på en gang

- ▶ Identitet af middelværdier af vitamin D for 4 lande ($\mu_1 = \mu_2 = \mu_3 = \mu_4$, $df=3$)
- ▶ *Samtidig* fjernelse af flere kovariater på en gang, f.eks. 3 kostvariable ($\beta_1 = \beta_2 = \beta_3 = 0$, $df=3$)



*Modelreduktion - F test

Vi skal sammenligne to modeller:

Den oprindelige med *alle* kovariater (nr. 1)

og den simple (hypotesen, model nr. 2 uden 3 af kovariaterne)

Kan vi forsvare at bruge den simpleste af dem?

Beskriver den data tilstrækkeligt godt?

NB: Modellerne skal være “nestede”, dvs. den ene fremkommer af den anden, typisk ved at sætte parametre til nul (“fjerne effekter”).


Se på **ændring** i model-kvadratsum:

Hvor meget **mindre** forklares af den simple model?

$$\Delta SS = SS_{\text{model1}} - SS_{\text{model2}}$$



Forståelse



Flere parametre kan forklare (lidt) mere variation: $\Delta SS > 0$

Spørgsmålet er: **Hvor meget mere?**

Hvor stor skal ΔSS være, før vi erklærer testet signifikant?

Det er det, F-testet svarer på. Her er vores hypotese (model 2), at fire parametre (svarende til effekten af 3 kovariater) er lig med 0

Udelad flere kovariater på en gang?

I VitaminD-eksemplet har vi p.t. 4 kovariater:

- ▶ bmi (df=1)
- ▶ sunexp (df=2)
- ▶ lvitdintake (df=1)
- ▶ country (df=3)

Bidrager de 3 øverste med noget forklaringsevne tilsammen?

Det gør de selvfølgelig, fordi 2 af dem selvstændigt gør det, men for *princippets skyld*:

Dette kan testes ved et **F-test**, der sammenligner 2 modeller:

Den *med* de 3 kovariater og den *uden* disse 3,

Her finder vi $F = 17.54 \sim F(4, 205)$, $P < 0.0001$,

(se s. 72 eller alternativt s. 114)



Udelad flere kovariater på en gang, II

Her gør vi dette "*håndholdt*", altså ved at køre modellen både med og uden de 3 kovariater og så sammenligne de SS-størrelser, man får fra dette.

Vi har her størrelserne:

- ▶ Model kun med country (s. 47): $SS=107.519$, $df=209$
- ▶ Model med country og 3 yderligere kovariater (s. 55):
 $SS=80.102$, $df=205$

Dette giver os et F-test:

$$\frac{(107.519 - 80.102)/4}{80.102/205} = 17.54 \sim F(4, 205), \quad P < 0.0001$$

Se evt også s. 114



Hypoteser vedr. interaktioner

Hvilke kunne vi forestille os at se på?

- ▶ `sunexp*lvitdintake`:
måske optages vitamin D fra kosten bedre,
hvis man samtidig får sol?
nok lidt spekulativt.....
- ▶ `country*sunexp`:
Pga breddegrad: Solen sydpå er nok lidt mere effektiv
(det så vi i forelæsningen om ANOVA)
- ▶ `country*lvitdintake`:
næppe...*og dog*
- ▶

Kun **præ-specificerede**, og **fortolkelige** interaktioner
bør inkluderes i modellen.



Interaktionen sunexp*lvitdintake (se s. 115)

Tests of Between-Subjects Effects

Dependent Variable: lvitd

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	40,918 ^a	9	4,546	11,605	,000
Intercept	115,499	1	115,499	294,814	,000
country	5,669	3	1,890	4,824	,003
bmi	3,894	1	3,894	9,940	,002
sunexp	1,305	2	,652	1,665	,192
sunexp * lvitdintake	,573	2	,287	,731	,483
lvitdintake	15,916	1	15,916	40,625	,000
Error	79,529	203	,392		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,340 (Adjusted R Squared = ,310)

Ikke nogen særlige forskelle på effekten af vitamin D indtag, afhængig af solvaner.

Interaktioner sunexp*lvitdintake, II

Parameter Estimates

Dependent Variable: lvitd

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,600	,416	13,459	,000	4,780	6,420
[country=1]	,321	,122	2,631	,009	,080	,561
[country=2]	,261	,124	2,111	,036	,017	,505
[country=4]	,462	,128	3,610	,000	,210	,714
[country=6]	0 ^a	.	.	.	.	.
bmi	-,033	,011	-3,153	,002	-,054	-,012
[sunexp=1]	-,508	,281	-1,808	,072	-1,063	,046
[sunexp=2]	-,413	,293	-1,409	,160	-,992	,165
[sunexp=3]	0 ^a	.	.	.	.	.
[sunexp=1] * lvitdintake	,281	,055	5,116	,000	,173	,389
[sunexp=2] * lvitdintake	,268	,054	4,922	,000	,161	,375
[sunexp=3] * lvitdintake	,173	,077	2,239	,026	,021	,325
lvitdintake	0 ^a	.	.	.	.	.

a. This parameter is set to zero because it is redundant.

Ikke nogen særlige forskelle på effekten af vitamin D indtag, afhængig af solvaner, dog mindre effekt for solelskere....

Interaktionen country*sunexp (se s. 116)

Tests of Between-Subjects Effects

Dependent Variable: lvtld

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	45,847 ^a	13	3,527	9,408	,000
Intercept	106,407	1	106,407	283,849	,000
country	1,166	3	,389	1,037	,377
bmi	2,881	1	2,881	7,686	,006
lvtldintake	20,926	1	20,926	55,822	,000
country * sunexp	5,502	6	,917	2,446	,026
sunexp	,637	2	,319	,850	,429
Error	74,599	199	,375		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,381 (Adjusted R Squared = ,340)

Her er der en **signifikant interaktion**.

Vi forsøger at forstå den ved at se på effekten af sunexp for hvert land separat



Effekt af sol, opdelt efter land

Parameter Estimates

Dependent Variable: **ivtd**

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,672	,422	13,434	,000	4,839	6,504
[country=1]	-,078	,320	-,244	,808	-,708	,552
[country=2]	-,253	,324	-,782	,435	-,891	,385
[country=4]	-,508	,412	-1,234	,219	-1,321	,304
[country=6]	0 ^a	.	.	.	.	.
bmi	-,029	,010	-2,772	,006	-,049	-,008
ivtdintake	,263	,035	7,471	,000	,194	,333
[country=1] * [sunexp=1]	-,286	,228	-1,253	,212	-,735	,164
[country=1] * [sunexp=2]	-,189	,202	-,937	,350	-,588	,209
[country=1] * [sunexp=3]	0 ^a	.	.	.	.	.
[country=2] * [sunexp=1]	-,361	,228	-1,581	,116	-,811	,089
[country=2] * [sunexp=2]	,050	,200	,250	,803	-,345	,445
[country=2] * [sunexp=3]	0 ^a	.	.	.	.	.
[country=4] * [sunexp=1]	,645	,348	1,854	,065	-,041	1,332
[country=4] * [sunexp=2]	,241	,339	,711	,478	-,427	,909
[country=4] * [sunexp=3]	0 ^a	.	.	.	.	.
[country=6] * [sunexp=1]	-,732	,300	-2,437	,016	-1,324	-,139
[country=6] * [sunexp=2]	-,597	,297	-2,014	,045	-1,182	-,012
[country=6] * [sunexp=3]	0 ^a	.	.	.	.	.
[sunexp=1]	0 ^a	.	.	.	.	.
[sunexp=2]	0 ^a	.	.	.	.	.
[sunexp=3]	0 ^a	.	.	.	.	.


a. This parameter is set to zero because it is redundant.

Der ser ud til at være en tendens til effekt af sunexp i Polen og Irland, men ikke i Danmark og Finland.

Men mønstret for Irland er ret svært at forstå....se figur næste side

Illustration af country*sunexp

Profile Plots



Hvad sker der for Irland?



Interaktioner country*lvitdintake (se s. 117)

Tests of Between-Subjects Effects

Dependent Variable: lvitd

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	45,451 ^a	10	4,545	12,242	,000
Intercept	118,219	1	118,219	318,421	,000
country	5,481	3	1,827	4,921	,003
bmi	4,010	1	4,010	10,800	,001
sunexp	1,084	2	,542	1,459	,235
country * lvitdintake	5,106	3	1,702	4,584	,004
lvitdintake	14,037	1	14,037	37,808	,000
Error	74,996	202	,371		
Total	6007,382	213			
Corrected Total	120,447	212			

a. R Squared = ,377 (Adjusted R Squared = ,347)

Her ses overraskende nok en signifikant interaktion...se næste side



Interaktioner country*lvitdintake, II

Parameter Estimates

Dependent Variable: lvitd

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	5,451	,367	14,874	,000	4,729	6,174
[country=1]	-,211	,245	-,860	,391	-,695	,273
[country=2]	,493	,353	1,395	,165	-,204	1,190
[country=4]	,827	,279	2,967	,003	,277	1,376
[country=6]	0 ^a	.	.	.	.	.
bmi	-,034	,010	-3,286	,001	-,054	-,013
[sunexp=1]	-,217	,127	-1,707	,089	-,467	,034
[sunexp=2]	-,135	,119	-1,135	,258	-,370	,100
[sunexp=3]	0 ^a	.	.	.	.	.
[country=1] * lvitdintake	,430	,062	6,923	,000	,307	,552
[country=2] * lvitdintake	,166	,087	1,897	,059	-,007	,338
[country=4] * lvitdintake	,086	,081	1,060	,290	-,074	,245
[country=6] * lvitdintake	,228	,057	3,993	,000	,116	,341
lvitdintake	0 ^a	.	.	.	.	.

a. This parameter is set to zero because it is redundant.


Den signifikante interaktion ses mestendels at skyldes, at effekten af vitamin D indtaget er langt større i Danmark end i de øvrige lande.

Det har formentlig en ret speciel forklaring.....

Repetition: Sammenligning af to grupper

- som ikke er helt sammenlignelige, pga en **confounder**, som er:
En variabel, som


- ▶ har en effekt på outcome
- ▶ er relateret til gruppen
(der er forskel på værdierne i de to grupper)



Eksempel: Vægt vs. køn og højde

Illustration af confounding og kovariansanalyse

Kovariaten x er her en confounder for gruppeforskellen:



Eksempel om mænds og kvinders vægt

fra forelæsningen om kovariansanalyse:

Vægt vs. køn, Outcome er $\log_{10}$ vægt:

Kovariater	Mænd vs. kvinder ratio (CI)	P-værdi
kun kønnet	1.14 (1.07, 1.23)	0.0002
køn og højde	1.04 (0.97, 1.12)	0.28

Den observerede forskel i ($\log_{10}$) vægt mellem mænd og kvinder *kan* altså tilskrives højdeforskellen mellem kønnene.



Alternativt eksempel

Det kan **også** forekomme, at

- ▶ Tilsyneladende ens grupper (f.eks. blodtryk hos mænd og kvinder) udviser forskelle, når der bliver korrigeret for inhomogeniteter (f.eks. fedmegrad)

Vi så også dette i eksemplet med P-piller og hormoner i ANCOVA-forelæsningsen


Man skal (på protokolstadiet) nøje overveje, hvilke variable med potentiel betydning for outcome, der skal medtages i modellen!

- ▶ ... uden at gå for meget på fisketur!!
- ▶ og man skal huske at tænke på, at **fortolkningen** skifter afhængig af de øvrige kovariater i modellen



Eksempel: Fedmegrad og blodtryk

Systolisk blodtryk (bp) **vs.** fedmegrad = vægt/ideelvægt (obese):
begge på logaritmisk skala (se s. 118, dog er figuren her ikke lavet i SPSS)



Resultater, Blodtryk vs. køn

Outcome $\log_{10}bp$:

Kovariat	Mænd vs. kvinder ratio (CI)	P-værdi
kun kønnet	1.02 (0.96, 1.07)	0.56
køn og fedmegrad	1.07 (1.01, 1.13)	0.02

Fedmegrad er en **confounder** for kønnet, idet der er forskel på fedmegrad for mænd og kvinder. Kvinder estimeres til en fedmegrad på 16.7% højere end mænd (CI: 9.3%-24.5%)




Illustration af kovariansanalysen

To **parallelle linier** (figuren her er lavet i SAS, se s. 120)

Samme relation til fedmegråd for de to køn

ikke lavet i SPSS




Forsigtig konklusion:

Kvinder har ligeså højt blodtryk som mænd, fordi de er federe...

Husk også de tidligere eksempler på confounding

Kolesterol vs. chokoladespisning og køn....



Kolesterol og chokoladespisning
er

- ▶ **positivt** relaterede
for hvert køn separat
- ▶ **negativt** relaterede
for mennesker

Ingen særlig kønsforskel i kolesterol – og dog...

Vi så det også i eksemplet med **hjernevægt hos mus**


Men læg mærke til følgende:

Selv om fordelingen af kovariaten er **ens i de to grupper**, kan det være af stor betydning at medtage den i analysen.



Men vi svarer samtidig på **et andet videnskabeligt spørgsmål!!**

Simuleret eksempel



Uden x i modellen: Ingen særlig forskel på grupperne...?

Med x i modellen: Tydelig forskel på grupperne
(her den lodrette afstand mellem linierne)

Effekt af at medtage en ekstra forklarende variabel

- ▶ **Besvarelse af et andet videnskabeligt spørgsmål**
- ▶ undgå at maskere forskel, f.eks. en nedsættelse af hormonkoncentrationen ved indtagelse af P-piller (fordi man sammenligner unge P-pille brugere med ældre kvinder)
- ▶ nedsættelse af residualvariationen, med deraf følgende lavere standard errors, dvs. større styrke

Hvis kovariaten *ikke* er vigtig, risikerer man

- ▶ at *forøge* residualvariationen lidt (fordi man har færre frihedsgrader) og at forøge standard errors meget, hvis kovariaten er korreleret til nogle af dem, der allerede er medtaget (*kollinearitet*) .



Appendix

med uddybende kommentarer til diverse slides:

- ▶ Biokemisk iltforbrug, transformationer, s. 93-99
- ▶ Ikke-lineær regression, s. 100-101, 107
- ▶ Udglatning og polynomie-fit, s. 102-103
- ▶ Lineære splines, s. 104-106
- ▶ Vitamin D, GLM, s. 108-114
- ▶ Interaktioner, s. 115-117
- ▶ Blodtryk og fedme, s. 118-120



Data vedr. biokemisk iltforbrug

Slide 7

Omstrukturering fra 6 linier med oplysning om alle 4 flasker den pågældende dag til 24 linier med kun en enkelt måling af iltforbrug pr. linie:

Benyt `/data/Restructure` og afkryds

Restructure selected variables into cases, klik Next.

Under How many variable groups? afkrydses One, klik Next,

Under Case Group Identification skiftes til

Use selected variable, og days sættes over i Variable.



Omstrukturering, fortsat, samt figur

Slide 7

Herefter går man ind i `Variables to be Transposed`, skriver `boc` i `Target Variable` og sætter `boc1`, `boc2`, `boc3` og `boc4` i det store felt, hvorefter der klikkes `Next`.

Endelig går man i `Create index variable` og sætter kryds ved `None` og klikker `Next`, og under `Variables to Cases: Options` klikkes blot `Finish`

Figuren slide 8

Benyt `Graphs/Chart Builder` og vælg `Scatter` (det simple længst til venstre), og dobbeltklik det op i det store felt. Sæt `days` over på X-aksen og `boc` over på Y-aksen.



Analyse af biokemisk iltforbrug

Slide 10

Definition af nye variable:

Først skal vi logaritmetransformere iltforbruget. Dette gøres under Transform/Compute, hvor man som Target Variable sætter det nye variabelnavn, her logboc, og i feltet Numeric Expression skriver $\text{Ln}(\text{boc})$

Dernæst skal vi udregne den reciprokke tid, igen under Transform/Compute, hvor man som Target Variable sætter invdays, og i feltet Numeric Expression skriver $1/\text{days}$

Derefter følger man opskriften på simpel lineær regression, se de næste sider



Regressionsanalyse med transformerede variable

Slide 11

Gå ind i menuen Analyze/Regression/Linear, og i boksen sættes logboc som Dependent og invdays som Independent(s)

Man skal efterfølgende huske at gå ind i Statistics og afkrydse Parameter Estimates og Confidence intervals



Plot med regressionslinie

Slide 12

Først laves plottet ved at gå ind i Graph/Chart Builder/Scatter og i den fremkomne boks trækker man logboc over på Y-aksen, og invdays over på X-aksen.

For at tegne linien dobbeltklikker man efterfølgende på grafen og klikker på ikonet Add Fit Line at Total og derefter i Properties-boksen afkrydse Linear og klikke Apply.

Man kan endvidere vælge, om man vil have liniens ligning skrevet på linien eller ej (flueben ved Attach label to line kan fjernes) Farven på linien kan vælges under Lines: klik på farven og Apply/Close



*Tilbagetransformeret relation

Slide 14

Her må vi tilbagetransformere den lineære relation, hvilket er *lidt besværligt*:

I regressionsopsætningen fra s. 96 klikkes på Save, hvorefter man under Predicted Values vælger Unstandardized, som så kommer til at ligge i datasættet under navnet PRE_1.


Disse tilbagetransformeres til oprindelig skala ved at benytte Transform/Compute og som Target Variable sætte f.eks. predikteret og i Numeric Expression skrive $\exp(\text{PRE}_1)$.

Gå nu ind i Graph/Chart Builder, vælg Scatter, og træk i den fremkomne boks predikteret over på Y-aksen og days over på X-aksen. Dobbeltklik på den fremkomne graf og klik på ikonet Add Fit Line at Total og derefter i Properties-boksen afkrydse Spline og klikke Apply.



Tilbagetransformeret relation, II

Dette bliver resultatet i SPSS....



Det er formentlig meget besværligt (eller umuligt) at få såvel kurve som observationer på samme figur.....

Ikke-lineær regression

Slide 15-16

Her benyttes Analyze/Regression/Nonlinear Regression, hvor man sætter `boc` i Dependent og i Model Expression skriver selve det ikke-lineære udtryk $\text{gamma} \cdot \exp(-\text{beta}/\text{days})$.

Herefter klikker man i Parameters og tilføjer

- ▶ Name: `gamma`, Starting Value: 228 Add
- ▶ Name: `beta`, Starting Value: 0,8 Add

og til sidst: Continue



Plot af ikke-lineært fit

Slide 17

Fra opsætningen s. 100 benyttes Save for at gemme de predikterede værdier: Kryds af under Predicted Values.

Herefter benyttes Graphs/Chart Builder/Scatter (det simple længst til venstre), days sættes på X-aksen og PRED_1 på Y-aksen.

Efterfølgende dobbeltklikkes på grafen, og man vælger Add Interpolation Line, hvorefter man afkrydser i Spline.

Det ser dog ikke umiddelbart ud til at være muligt at få usikkerheder på disse prediktioner, så grænserne må man undvære. Ligeledes kommer selve observationerne heller ikke med på figuren.



Udglattet kurve, en såkaldt *Loess*-kurve

Slide 22

Her skal vi begrænse det datamateriale, vi ser på. Dette gøres i Data/Select Cases, hvor der afkrydses i If og skrives `5<age<20 & sex='male'`.

Herefter laver vi en tegning med Graphs/Chart Builder, hvor vi vælger det simple Scatter. Sæt age over på X-aksen og sigf1 over på Y-aksen.

Ved efterfølgende at dobbeltklikke på grafen, kan man lægge en udglattet kurve på ved at klikke på Add Fit Line at Total og derefter i Properties-boksen afkrydse Loess/Apply:

Farven på kurven kan vælges under Lines: klik på farven og Apply/Close



Polynomiale fit

Slide 26

De 3 forskellige polynomier (af grad hhv 1,2 og 3) kan formentlig kun (på rimelig simpel vis) tegnes hver for sig. Ellers skal man til at have flere versioner af datasættet sat i forlængelse af hinanden.....

Først laver vi en tegning med Graphs/Chart Builder, hvor vi vælger det simple Scatter, sætter age over på X-aksen og sigf1 over på Y-aksen.

Ved efterfølgende at dobbeltklikke på grafen, og videre på Add Fit Line at Total kan man i Properties-boksen afkrydse enten Linear, Quadratic eller Cubic

Farven på kurverne kan vælges under Lines: klik på farven og Apply/Close



Lineære splines

Slide 27-32

Definition af nye variable:

Benyt Transform/Compute, hvor man som Target Variable sætter det nye variabelnavn, her f.eks. `extra_age12`, og i feltet Numeric Expression skriver `max(age-12,0)`

Ligeledes med de 3 øvrige variable.

Fit derefter en model med disse 4 ekstra kovariater, sammen med den oprindelige age ved at benytte menuen

Analyze/Regression/Linear, og i boksen sættes `ssigf1` som Dependent og age samt alle 4 extra-variable i Independent(s)

Man skal efterfølgende huske at gå ind i Statistics og afkrydse Parameter Estimates og Confidence intervals



Illustration af fit med lineære splines

Slide 29

Det er nok virkelig indviklet (eller umuligt?) at få data og splines på samme figur....men man kan tegne selve fittet ved først at gemme de predikterede værdier ved at benytte Save og vælge Predicted Values. De kommer til at hedde PRE_1 i datasættet.

Herefter går man i Herefter laver vi en tegning med Graphs/Chart Builder, hvor vi vælger Lines (det simple længst til venstre), og dobbeltklik det op i det store felt. Sæt PRED_1 over på Y-aksen og age over på X-aksen.



Alternativ parametrisering af lineære splines

Slide 33-34

så man i stedet får estimater for
hældningerne i de enkelte aldersintervaller

Definition af de alternative variable:

Benyt Transform/Compute, hvor man som Target Variable sætter det nye variabelnavn, her f.eks. `ny_age12`, og i feltet Numeric Expression skriver `min(extra_age12,1)`

Ligeledes med de 3 øvrige variable: `min(age,10)`,
`min(extra_age10,2)` og `min(extra_age13,2)` og
`ny_age15=extra_age15`

Fit derefter en model med disse 5 kovariater, i analogi med den beskrevne fremgangsmåde på forrige side.



Ikke-lineær regression

Slide 38-41

Her benyttes Analyze/Regression/Nonlinear Regression, hvor man sætter konc i Dependent og i Model Expression skriver selve det ikke-lineære udtryk $\text{beta} * (1 - \exp(-\text{gamma} * \text{tid}))$.

Herefter klikker man i Parameters og tilføjer

- ▶ Name: gamma, Starting Value: 0,05 Add
- ▶ Name: beta, Starting Value: 2000 Add

og til sidst: Continue

Mht figur af fit, se tilsvarende s. 17



ANOVA, sammenligning af D-vitamin i 4 lande

Slide 47

Først skal vi udregne 2-tals logaritmen af vitamin D. Dette gøres under Transform/Compute, hvor man som Target Variable sætter det nye variabelnavn, her lvitd, og i feltet Numeric Expression skriver $\text{LG10}(\text{vitd})/\text{LG10}(2)$

Til variansanalysen benyttes

Analyze/General Linear Model/Univariate, hvor vi sætter lvitd i Dependent Variable og country i Fixed Factor(s).

Her kan vi vælge at se parameterestimer under Options, hvor vi afkrydser Parameter estimates)



Model med bmi som kovariat, ANCOVA

Slide 51

Til kovariansanalyse benyttes

Analyze/General Linear Model/Univariate, hvor vi sætter lvidt i Dependent Variable, country i Fixed Factor(s) og bmi i Covariate(s)

For at undgå at få interaktionen med i modellen, klikkes nu på Model, hvorefter man vælger Custom, markerer begge kovariater, skifter fra Interaction til Main Effects og klikker på pilen og Continue.

Husk også i Options at vælge Parameter Estimates



Model med 4 kovariater

Slide 55-56

Selve analysen foregår som skitseret på s. 109, altså: Benyt Analyze/General Linear Model/Univariate, hvor vi sætter lvitd i Dependent Variable, country og sunexp i Fixed Factor(s) og såvel bmi som lvitdintake i Covariate(s)

For at undgå at få interaktionen med i modellen, klikkes nu på Model, hvorefter man vælger Custom, markerer alle kovariater, skifter fra Interaction til Main Effects og klikker på pilen og Continue.

Husk også i Options at vælge Parameter Estimates



Parvise sammenligninger

Slide 59-62

For at foretage alle parvise sammenligninger af lande og sol-grupper i opsætningen med

Analyze/General Linear Model/Univariate, går man ind i Options, hvor man sætter såvel country som sunexp over i Display Means for.

Desuden afkrydses i Compare main effects, hvor man evt. også kan vælge, at der skal korrigeres for multiple sammenligninger (her er dog bare brugt LSD(none), da vi tænkes at være i situationer med præ-specificerede sammenligninger).



Modelkontrol for model med 4 kovariater

Slide 66-67

Den automatiske modelkontrol i SPSS er ikke særlig god.....

Brug i stedet nedenstående:

I regressionsopsætningen fra s. 20 klikkes på Save, hvorefter man typisk vil vælge

- ▶ Under Predicted Values: vælg Unstandardized, som så kommer til at ligge i datasættet under navnet PRE_1
- ▶ Under Residuals er der 5 muligheder, f.eks.
 - ▶ Unstandardized: De *sædvanlige*, altså observeret minus forventet, kaldet RES_1 i datasættet
 - ▶ Studentized deleted: Normerede Press-residualer (altså hvor den pågældende observation er udeladt ved fit af modellen), kaldet SDR_1 i datasættet



Modelkontrol, II

Slide 66-67

Ud fra det udbyggede datasæt dannet s. 112 kan vi nu lave diverse figurer:

- ▶ Benyt Graph/Chart Builder, vælg Scatter, klik Unstandardized Predicted Values over på X-aksen og Unstandardized Residuals over på Y-aksen.
- ▶ Vælg Analyze/Descriptive Statistics/Q-Q Plots og sæt Unstandardized Residuals over i Variables.
- ▶ Benyt Graph/Chart Builder, vælg Histogram og klik det ønskede residual (f.eks. RES_1) ned på X-aksen. Klik så på Distribution Curve og afkryds Normal, klik Apply og Close
- ▶ Evt. yderligere check af varianshomogenitet, se tidligere forelæsninger.



Udeladelse af flere kovariater samtidig

Slide 71-72

Det er ikke så let at gennemskue, hvordan dette foregår i SPSS....

Hvis alle kovariater var kvantitative (altså i en multipel regressionsanalyse) kan man i `Analyze/Regression/Linear` definere flere modeller på en gang og få dem sammenlignet med et F-test.

Men når vi som her også har kategoriske kovariater, er vi nødt til bruge `Analyze/General Linear Model/Univariate`, og denne opsætning tillader ikke definition af flere modeller på en gang.

I så fald er man nødt til at lave sine kategoriske variable om til dummy-variable, f.eks. skal `country` så blive til 3 dummy-variable....



Interaktionen *sunexp*lvitdintake*

Slide 74-75

Følg opskriften fra s. 110, men i Model markeres *sunexp* og *lvitdintake* samtidig, der skiftes fra Main Effects til Interaction og klikkes på pilen og Continue.

For at få de enkelte effekter af *lvitdintake* skal denne udelades af Model, medens interaktionen bibeholdes.



Interaktionen *country*sunexp*

Slide 76-78

Følg opskriften fra s. 110, men i Model markeres sunexp og country samtidig, der skiftes fra Main Effects til Interaction og klikkes på pilen og Continue.

For at få de enkelte effekter af sunexp skal denne udelades af Model



Interaktionen *country*lvitdintake*

Slide 79-80

Følg opskriften fra s. 110, men i Model markeres *country* og *lvitdintake* samtidig, der skiftes fra Main Effects til Interaction og klikkes på pilen og Continue.

For at få de enkelte effekter af *lvitdintake* skal denne udelades af Model, medens interaktionen bibeholdes.



Blodtryk vs. fedme

Sammenligning af mænd og kvinder, figurer

Slide 85

Selve figuren laves i Graph/Chart Builder, hvor man vælger Scatter plot (nr. 2 fra venstre), og i den fremkomne boks trækker man $\log_{10}bp$ over på Y-aksen, $\log_{10}obese$ over på X-aksen og sex over i Set Color

For at tegne individuelle regressionslinier dobbeltklikker man efterfølgende på grafen og klikker på ikonet Add Fit Line at Subgroups og derefter i Properties-boksen afkrydse Linear og klikke Apply.

Disse linier vil ikke blive parallelle, og er ikke vist i forelæsningsnoterne.



Blodtryk vs. fedme og køn: Kovariansanalyse

Slide 86

Her benyttes Analyze/General Linear Model/Univariate, hvor vi sætter log10bp over i Dependent Variable, sex i Fixed Factor(s) og log10obese i Covariate(s)

For at undgå at få interaktionen med i modellen, klikkes nu på Model, hvorefter man vælger Custom, markerer begge kovariater, skifter fra Interaction til Main Effects og klikker på pilen og Continue.

Husk også i Options at vælge Parameter Estimates



ANCOVA-plot, med parallelle linier

Slide 87

Her er man nødt til først at gemme de predikterede værdier ved at benytte Save og vælge Predicted Values. De kommer til at hedde PRE_1 i datasættet.

Herefter går man igen ind i Graph/Chart Builder/Scatter, vælger Scatter plot (nr. 2 fra venstre), og i den fremkomne boks udskiftes log10bp med PRE_1.

For at tegne individuelle regressionslinier dobbeltklikker man efterfølgende på grafen og klikker på ikonet Add Fit Line at Subgroups og derefter i Properties-boksen afkrydse Linear og klikke Apply.

Desværre får man ikke samtidig selve observationerne på figuren.....

Og de to lodrette linier er heller ikke forsøgt indtegnet.

