

Noter til

Multivariate Statistiske Metoder med SAS

Erling B. Andersen

Juli 2002

Forord.

I dette notesæt er den nødvendige statistiske teori for at kunne benytte SAS-procedurene Proc Factor, Proc Calis og Proc Corresp gennemgået. Desuden er det vist, hvordan man benytter SAS-proceduren Proc IML til mest almindelige matrixberegninger.

Den største vægt er dog lagt på at illustrere anvendelsen af de nævnte SAS-procedurer. Her er for Proc Factor og Proc Calis benyttet den meget store tværnationale database ISSP, der administreres af ZUMA i Köln. For Proc Corresp's vedkommende er der benyttet en række variable fra den store danske Velfærdsundersøgelse, professor Erik Jørgen Hansen gennemførte i 1974, og publicerede resultaterne i 1976.

Notesættet, der første gang blev brugt i foråret 2001, er belvet revideret of udvidet i forbindelse med mit kursus i 'Multivariat Statistik med SAS', som bliver gennemført for polit-studerende i efterårssemestret 2002.

Rungsted. Juli 2002.

Erling B. Andersen

Indhold

1. ISSP databasen.	1
2. Lidt matrixregning.	4
3. Matrixregning i SAS.	7
4. Transformationer af vektorer af stokastiske variable.	12
5. Hotellings T^2 - test.	14
6. Principalkomponentmetoden.	20
6.1 Principalkomponentmetoden.	20
6.2 Forklaret variation. Kommunaliteter.	21
6.3 Rotation.	22
7. Principalkomponentmetoden i SAS.	26
8. Om normeringer.	36
9. Asymptotiske resultater for ML-estimatorer og kvotientteststørrelser.	37
10. Faktoranalyse	42
11. Eksplorativ Faktor Analyse i SAS.	46
11.1. Regulære tilfælde.	46
11.2. Heywood tilfælde.	57
12. Om skaleringer i Linear Structural Models.	67
13. Polyseriale korrelationskoefficienter.	69
14. Principalkomponentanalyse og faktor analyse med polyseriale korrelationskoefficienter.	71
15. Stianalyse	79
16. Stianalyse med manifeste variable	81
17. Kvotienttestteori.	93
17.1 Test af modellen M mod modellen M_1	93
17.2. Test af modellen M_1 mod en simplere model M_2	94
17.3. Test af modellen M_2 mod den oprindelige model M.	95
18. En målingsmodel (Confirmative Factor Analysis).	98

19. Stianalyse med latente variable.	113
20. Sammenligning af målingsmodellen og stimodellerne.	129
21. Simpel correspondance analyse	130
22. Simpel correspondance analyse i SAS	140
23. Multipel correspondance analyse i SAS.	149

1. ISSP databasen.

Gennemgangen af metoderne i disse noter eksemplificeres ved data fra den såkaldte ISSP database. Den omfatter et stort antal spørgsmål, stillet gennem en en årrække fra 1985 og fremefter, i et varierende antal lande.

ISSP 89 - Module - Work Orientations - ZA No. 1840

V3 COUNTRY

Country

		Unweighted	
		Abs.	%
02. West Germany	(D)	1575	10.66
03. Great Britain	(GB)	1297	8.78
04. USA	(USA)	1453	9.84
05. Austria	(A)	1997	13.52
06. Hungary	(H)	1000	6.77
07. Netherlands	(NL)	1690	11.44
08. Italy	(I)	1028	6.96
09. Ireland	(IRL)	972	6.58
10. Northern Ireland	(NIRL)	780	5.28
11. Norway	(N)	1848	12.51
12. Israel	(IL)	1133	7.67
		-----	-----
		14773	100.00

V24 IMPORTANT: JOB SECURITY

Q.6 From the following list, please tick one box for each item to show how important you personally think it is in a job?

Q.6a How important is: Job security?
(Please tick one box on each line)

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all
8. Can't choose, don't know
9. NA

V25 IMPORTANT: HIGH INCOME

Q.6b How important is: High income?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all
8. Can't choose, don't know
9. NA

Der foreligger en kodebog for de variable, der er udtrukket til undervisningsbrug. Ovenstående boks og nedenstående boks viser kodebogen for de variable V3, V24, V25 V26 og V27 for 1989 undersøgelsen, der, sammen med V28 - V32, især benyttes i noterne.

De variable der er vist her er dels V3: De deltagende lande, med antal respondenter og deres procentdel af hele stikprøven, dels de første 4 variable, V24 - V27, der drejer sig om hvilke forhold, respondenterne finder af betydning for deres job.

V26 IMPORTANT: ADVANCEMENT

Q.6c How important is: Good opportunities for advancement?

-
1. Very important
 2. Important
 3. Neither important nor unimportant
 4. Not important
 5. Not important at all

 8. Can't choose, don't know
 9. NA

V27 IMPORTANT: LEISURE TIME

Q.6d How important is: A job that leaves a lot of leisure time?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

8. Can't choose, don't know
9. NA

Den næste boks viser nogle af de baggrundsvariable, vi skal bruge i forbindelse med stianalyserne siden hen.

V90 WORKING HOURS

How many hours a week do you normally work in your main job?

-
- 02. Two hours
 -
 - 95. 95 hours and more
 - 98. Don't know
 - 99. NA, no hours
 - 00. Not applicable
-

V100 EDUCATION

Years in school

- 01. 1 year
 -
 - 22. 22 years
 - 95. Still at school
 - 96. Still at college, university
 - 98. Don't know
 - 99. NA
 - 00. No formal schooling
-

V110 SUBJECTIVE SOCIAL CLASS

Most people see themselves as belonging to a particular class. Please tell me which social you would say you belong to?

- 1. Lower class: Poor
- 2. Working class
- 3. Lower middle/ Upper working class
- 4. Middle class
- 5. Upper middle class
- 6. Upper class
- 8. Don't know
- 9. NA

2. Lidt matrixregning.

En matrix $\mathbf{A}$ af dimension $n \times m$ kan skrives:

$$\begin{bmatrix} a_{11} & \dots & a_{1j} & \dots & a_{1m} \\ \dots & \dots & \dots & \dots & \dots \\ a_{i1} & \dots & a_{ij} & \dots & a_{im} \\ \dots & \dots & \dots & \dots & \dots \\ a_{n1} & \dots & a_{nj} & \dots & a_{nm} \end{bmatrix}$$

Vektorer vil altid i disse noter være søjlevektorer, dvs. matricer af dimension $n \times 1$. For eksempel er vektoren $\mathbf{b}$ lig med

$$\mathbf{b} = \begin{bmatrix} b_1 \\ \dots \\ b_i \\ \dots \\ b_n \end{bmatrix}.$$

Den transponerede matrix $\mathbf{A}^T$ er $\mathbf{A}$, hvor rækker og søjler er byttet om, dvs. matricen

$$\begin{bmatrix} a_{11} & \dots & a_{1j} & \dots & a_{1m} \\ \dots & \dots & \dots & \dots & \dots \\ a_{i1} & \dots & a_{ij} & \dots & a_{im} \\ \dots & \dots & \dots & \dots & \dots \\ a_{n1} & \dots & a_{nj} & \dots & a_{nm} \end{bmatrix}$$

For en ikke-singulær, kvadratisk matrix $\mathbf{A}$ af dimension n er den inverse matrix $\mathbf{A}^{-1}$ en matrix, der opfylder

$$\mathbf{A} \cdot \mathbf{A}^{-1} = \mathbf{I},$$

hvor $\mathbf{I}$ er enhedsmatricen af dimension n . Ikke-singulær betyder, at $\mathbf{A}$ har fuld rang, så

$$\det(\mathbf{A}) \neq 0,$$

hvor $\det(\mathbf{A})$ er $\mathbf{A}$'s determinant.

En matrix af dimension $n \times m$ siges at være ortogonal, hvis

$$\mathbf{A} \cdot \mathbf{A}^T = \mathbf{I},$$

dvs. hvis

$$\sum_{j=1}^m a_{ij}^2 = 1 \quad , \quad \text{for alle rækker } i$$

og

$$\sum_{j=1}^m a_{ij} a_{kj} = 0 \quad , \quad \text{for alle par af rækker } i \text{ og } k \text{ .}$$

Man siger, at to vektorer $\mathbf{a}$ og $\mathbf{b}$ er ortogonale, hvis de begge har længden 1, dvs.

$$\sum_{i=1}^n a_i^2 = 1$$

og

$$\sum_{i=1}^n b_i^2 = 1 \quad ,$$

samtidigt med, at produktsummen af deres elementer er 0, dvs.

$$\sum_{i=1}^n a_i b_i = 0 \quad .$$

For en kvadratisk, symmetrisk og ikke-negativ definit matrix $\mathbf{A}$ af dimension n (sådan som variansmatricer er det), gælder, at der findes en kvadratisk matrix $\mathbf{B}$ af dimension n , så $\mathbf{B}^T$ er ortogonal (dvs. søjlerne i $\mathbf{B}$ er ortogonale), og en diagonal matrix Λ også af dimension n , så $\mathbf{A}$ kan skrives

$$\mathbf{A} = \mathbf{B} \Lambda \mathbf{B}^T.$$

Elementerne i Λ kaldes da egenverdierne, mens søjlerne i $\mathbf{B}$ kaldes egenvektorerne for $\mathbf{A}$. Alle diagonalelementerne $\lambda_1, \dots, \lambda_n$ i Λ er ikke-negative, og antal positive λ 'er er lig med $\mathbf{A}$'s rang.

Denne opspaltning af en kvadratisk matrix går under forskellige navne. På engelsk siges ofte: 'Single value decomposition'. Jeg skal blot referere til resultatet, som en egenverdiopsplætning eller en egenverdi-dekomponering.

I algebraen er resultatet noget bredere. Under visse betingelser kan en ikke kvadratisk matrix $\mathbf{C}$ opspaltes på tilsvarende måde, nemlig som

$$\mathbf{C} = \mathbf{G} \Lambda \mathbf{H}^T \quad ,$$

hvor $\mathbf{G}^T$ og $\mathbf{H}^T$ er ortogonale. Man kan let bestemme $\mathbf{G}$, $\mathbf{H}$ og Λ fra denne ligning. Hvis vi f.eks. ganger bagved med $\mathbf{H}$ og $\mathbf{G}^T$, får man idet $\mathbf{H}^T \mathbf{H} = \mathbf{I}$, hvis $\mathbf{H}^T$ er orthogonal,

$$\mathbf{C} \mathbf{H} \mathbf{G}^T = \mathbf{G} \Lambda \mathbf{G}^T ,$$

hvorfra $\mathbf{G}$ og Λ kan findes ved en egenværdiopspaltning. $\mathbf{H}$ bestemmes ved omvendt at gange foran med $\mathbf{G}^T$ og $\mathbf{H}$, så man får

$$\mathbf{H} \mathbf{G}^T \mathbf{C} = \mathbf{H} \Lambda \mathbf{H}^T .$$

3. Matrixregning i SAS.

Matrixregning i SAS foregår i PROC IML. Her kan man definere en variabel som en matrix. Det foregår således, hvis vi som eksempel tager følgende korrelationsmatrix:

1.000	0.546	0.244	0.149
0.546	1.000	0.398	0.182
0.244	0.398	1.000	0.271
0.149	0.182	0.271	1.000

Kalder vi denne matrix for V , men i SAS-sprog blot for "v", kan man indlæse V , og finde den inverse V^{-1} på følgende simple måde, hvor $\text{inv}(v)$ er lig med V^{-1} :

```
proc iml;
v = {1.000  0.546  0.244  0.149,
      0.546  1.000  0.398  0.182,
      0.244  0.398  1.000  0.271,
      0.149  0.182  0.271  1.000};
vi = inv(v);
vny = v*vi;
print v vi vny;
run;
```

Læg mærke til, hvordan matricer indlæses i SAS. Man skriver blot matrixens rækker adskilt ved et komma, mens hele matricen omkranses med 2 'Tuborg'-paranteser. Husk, som altid i SAS, at afslutte med et semikolon efter hvor ordre. I dette program kontrolleres også, ved at beregne $V \cdot V^{-1}$ som matricen 'vny', at $V \cdot V^{-1}$ rent faktisk er lig med enhedsmatricen I af dimension 4.

SAS-udskriften fra denne programstump bliver:

V				VI			
1	0.546	0.244	0.149	1.4306219	-0.757125	-0.029477	-0.067378
0.546	1	0.398	0.182	-0.757125	1.5973461	-0.434719	-0.060096
0.244	0.398	1	0.271	-0.029477	-0.434719	1.2493311	-0.255058
0.149	0.182	0.271	1	-0.067378	-0.060096	-0.255058	1.0900975

VNY			
1	-2.48E-17	-2.17E-19	-6.48E-18
1.019E-17	1	-2.8E-17	-1.17E-17
-7.08E-18	1.547E-17	1	1.144E-17
1.385E-17	-1.95E-18	1.824E-17	1

Læg mærke til at SAS har en tendens til at skrive 0'er som et tal opløftet til en høj negativ potens (ofte fra 17 til 20).

Matrixmultiplikation i IML foregår sådan: Lad **A** være en matrix, der kan ganges forfra med **V**, f.eks. 2x4 matricen

```
0.7 0.5 0.4 0.3
0.3 0.4 -0.5 -0.7
```

Man danner da produktet **A · V** i IML som:

```
proc iml;
v = {1.000  0.546  0.244  0.149,
      0.546  1.000  0.398  0.182,
      0.436  0.398  1.000  0.271,
      0.149  0.182  0.271  1.000};
a = {0.7 0.5 0.4 0.3,
      0.3 0.4 -0.5 -0.7};
vp = a*v;
print v a vp;
run;
```

Udskriften fra en SAS-kørsel, hvor matricen **A** kaldes 'a', **V** 'v' og **A · V** kaldes 'vp', ser sådan ud:

V				A			
1	0.546	0.244	0.149	0.7	0.5	0.4	0.3
0.546	1	0.398	0.182	0.3	0.4	-0.5	-0.7
0.244	0.398	1	0.271				
0.149	0.182	0.271	1				
VP							
1.1153	1.096	0.8511	0.6037				
0.2921	0.2374	-0.4573	-0.718				

Man transponerer en matrix i PROC IML ved at skrive **AT** som **t(a)**, hvor 'a' er den matrix, der skal transponeres. Følgende programstump viser beregningen af **AT**.

```
proc iml;
v = {1.000  0.546  0.244  0.149,
      0.546  1.000  0.398  0.182,
      0.436  0.398  1.000  0.271,
      0.149  0.182  0.271  1.000};
a = {0.7  0.5  0.4  0.3,
      0.3  0.4 -0.5 -0.7};
at = t(a);
print a at;
run;
quit;
```

Udskriften fra en SAS-kørsel, ser sådan ud

A				AT	
0.7	0.5	0.4	0.3	0.7	0.3
0.3	0.4	-0.5	-0.7	0.5	0.4
				0.4	-0.5
				0.3	-0.7

Hvis man ønsker at undersøge, om rækkerne i **A** er ortogonale, dvs. om $\mathbf{A} \cdot \mathbf{A}^T = \mathbf{I}$, skal man skrive programstumpen, hvor **A A^T** kaldes 'a1'.

```
proc iml;
v = {1.000  0.546  0.244  0.149,
      0.546  1.000  0.398  0.182,
      0.436  0.398  1.000  0.271,
      0.149  0.182  0.271  1.000};
a = {0.7  0.5  0.4  0.3,
      0.3  0.4 -0.5 -0.7};
at = t(a);
a1 = a*t(a);
print a1;
run;
quit;
```

SAS ouput'et fra dette program bliver.

```

      A1
      0.99 -1.36E-20
-1.36E-20      0.99

```

Bemærk igen, at SAS har en tendens til ikke at afrunde fornuftigt, så man får 0.99 i stedet for 1 og -1.36 opløftet til 10^{-20} i stedet for 0.

Man kan også udføre en egenverdidekomponering i SAS. Det sker ved hjælp af kaldet EIGEN. Input til kaldet af EIGEN skal være en være en symmetrisk matrix, her kaldet 'v'. Output er en søjlevektor bestående af egenverdierne i aftagende størrelsesorden, som vi betegner 'lambda', og en matrix, 'e', af samme dimension som 'v', der har egenvektorerne som søjler. Programmet for en egenverdidekomponering af 'v' kan se sådan ud, hvor også størrelsen 'b = e*diag(lambda)*t(e)' beregnes for at kontrollere om SAS udfører sine beregninger rigtigt. Her er 'diag(lambda)' en matrixoperation, der laver lambda om til en diagonalmatrix med egenverdierne i diagonalen og 0'er uden for diagonalen.

```

proc iml;
v = {1.000  0.546  0.244  0.149,
      0.546  1.000  0.398  0.182,
      0.436  0.398  1.000  0.271,
      0.149  0.182  0.271  1.000};
call eigen(lambda,e,v);
print lambda e;
dl = diag(lambda);
b=e*diag(lambda)*t(e);
print v b;
run;

```

Output fra dette program ser sådan ud:

LAMBDA					E				
1.9295776	0.5333939	-0.44712	0.3970508	0.5982689					
0.946497	0.5927437	-0.302554	-0.012485	-0.746298					
0.7014503	0.494584	0.2932501	-0.766266	0.2867543					
0.4224751	0.3457348	0.7890181	0.5050067	-0.053723					

V				B			
1	0.546	0.244	0.149	1	0.546	0.244	0.149
0.546	1	0.398	0.182	0.546	1	0.398	0.182
0.244	0.398	1	0.271	0.244	0.398	1	0.271
0.149	0.182	0.271	1	0.149	0.182	0.271	1

En sammenligning af matricerne 'v' og 'b' = 'e*diag(lambda)*t(e)', der skal være ens, hvis SAS har regnet rigtigt, godkender beregningerne.

4. Transformationer af vektorer af stokastiske variable.

Lad $\mathbf{X}$ være søjlevektoren dannet af de stokastiske variable $X_1, \dots, X_n$ og betragt transformationen

$$\mathbf{Y} = \mathbf{A} \mathbf{X} ,$$

hvor $\mathbf{A}$ er en $n \times n$ matrix af konstanter, så $\mathbf{Y}$ bliver en søjlevektor af dimension n dannet af de stokastiske variable $Y_1, \dots, Y_n$.

Kovariansmatricen $\mathbf{V}_Y$ for $\mathbf{Y}$ bliver da

$$\mathbf{V}_Y = \mathbf{A} \mathbf{V}_X \mathbf{A}^T ,$$

hvor $\mathbf{V}_X$ er kovariansmatricen for $\mathbf{X}$.

Dette variansresultat gælder også, såfremt vektoren af Y -variable er kortere end vektoren af X -variable. Hvis $\mathbf{Y}$ er en søjlevektor af dimension $m < n$, hvor n er dimensionen af søjlevektoren $\mathbf{X}$, og transformationsmatricen $\mathbf{A}$ har dimension $m \times n$, skal ligningen

$$\mathbf{Y} = \mathbf{A} \mathbf{X}$$

derfor opfattes som en transformation, hvor der er færre Y 'er efter, end der var X 'er før transformationen. Altså en projektion på et lavere Euclidisk rum. Men det gælder stadig, at kovariansmatricen $\mathbf{V}_Y$ for $\mathbf{Y}$ er givet ved

$$\mathbf{V}_Y = \mathbf{A} \mathbf{V}_X \mathbf{A}^T ,$$

hvor $\mathbf{V}_X$ er kovariansmatricen for $\mathbf{X}$, idet $\mathbf{A}$ og $\mathbf{A}^T$ bringer dimensionen af $\mathbf{X}$ 'ned fra' n til m .

Disse resultater, og resultaterne fra Kapitel 2, kan kombineres til:

(1) En transformation $\mathbf{Y} = \mathbf{A} \mathbf{X}$ kaldes ortogonal, hvis $\mathbf{A}^T$ er ortogonal, dvs. hvis rækkerne i $\mathbf{A}$ er ortogonale. Hvis således $\mathbf{X}$ af dimension n transformeres til $\mathbf{Y}$ af dimension $m < n$, har $\mathbf{A}$ dimensionen $m \times n$. Ortogonaliteten betyder, at

$$\sum_{j=1}^n a_{ij}^2 = 1 \quad , \quad \text{for alle } i$$

og

$$\sum_{k=1}^n a_{ik} a_{jk} = 0 \quad , \quad \text{for alle } i \text{ og } j .$$

(2) Der findes en ortogonal transformation $\mathbf{Y} = \mathbf{A} \mathbf{X}$ af $\mathbf{X}$, der gør $\mathbf{Y}$ 'erne uafhængige.

Betragt nemlig egenværdiopspaltningen

$$\mathbf{V}_X = \mathbf{A}^T \Lambda \mathbf{A}.$$

Ganger vi foran og bagved med $\mathbf{A}$ og $\mathbf{A}^T$, får vi

$$\mathbf{V}_Y = \Lambda = \mathbf{A} \mathbf{V}_X \mathbf{A}^T.$$

Det betyder, at hvis vi transformerer $\mathbf{X}$ som $\mathbf{Y} = \mathbf{A} \cdot \mathbf{X}$, kan $\mathbf{X}$ 'erne transformeres til uafhængige variable via den ortogonale transformation $\mathbf{A}$. Desuden fremgår det, varianserne for $\mathbf{Y}$ 'erne er egenværdierne for $\mathbf{V}_X$, og at transformationen består i en matrix $\mathbf{A}$ med egenvektorerne for $\mathbf{V}_X$ som rækker.

Disse simple resultater fra matrixalgebraen har haft enorm betydning for den matematisk statistik. Allerede tidligt vurderede ledende statistikere egenværdi-dekomponeringer af kovariansmatricer for centrale statistiske principper. Begreber som 'kanonisk korrelation', 'principalkomponentmetoden' og først og fremmest 'faktoranalyse' er udløbere af denne simple algebraiske teknik. Senest er den "skole" inden for området kategoriserede data, der kaldes deres metoder **korrespondance analyse**, endnu en anvendelse af den for matematikere så gamle, velkendte dekomponering af symmetriske, positivt definite matricer i deres komponenter.

5. Hotellings T^2 - test.

Det simple t-test for middelværdien i en enkelt stikprøve kan generaliseres til et test for middelværdierne i p korrelerede stikprøver.

For $p = 1$, dvs. for én stikprøve, har vi n observationer $x_1, \dots, x_n$, hvor de tilsvarende stokastiske variable $X_1, \dots, X_n$ antages at være uafhængige, ensfordelte med middelværdi μ og varians σ^2 . For at teste hypotesen

$$H_0 : \mu = \mu_0 ,$$

når variansen σ^2 er ukendt, benyttes teststørrelsen

$$t = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s} ,$$

hvor

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

Denne teststørrelse er, som bekendt, t-fordelt med $n - 1$ frihedsgrader, og man kalder testet for et t-test.

For $p > 1$ stikprøver, kan observationerne opstilles i observationsmatricen

$$\mathbf{X} = \begin{bmatrix} x_{11} & \dots & x_{1n} \\ \dots & \dots & \dots \\ x_{p1} & \dots & x_{pn} \end{bmatrix}$$

Det antages nu, at observationerne i den i 'te række er uafhængige, ensfordelte med fælles middelværdi μ_i og varians σ_i^2 . Observationerne i den i 'te række og den j 'te række er derimod korrelerede med korrelationskoefficienten σ_{ij} .

Under hypotesen

$$H_0 : \mu_i = \mu_{i0} ,$$

kan de hypotetiske middelværdier samles i vektoren

$$\mu_0 = \begin{bmatrix} \mu_{10} \\ \dots \\ \mu_{p0} \end{bmatrix}$$

således at μ_0 er en søjlevektor af længden p. Estimatet for μ_0 er søjlevektoren

$$\bar{\mathbf{x}} = \begin{bmatrix} \bar{x}_1 \\ \dots \\ \bar{x}_p \end{bmatrix},$$

mens kovariansmatricen

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \dots & \sigma_{1p} \\ \dots & \dots & \dots \\ \sigma_{p1} & \dots & \sigma_p^2 \end{bmatrix}$$

estimeres ved

$$\mathbf{S} = \begin{bmatrix} s_1^2 & \dots & s_{1p} \\ \dots & \dots & \dots \\ s_{p1} & \dots & s_p^2 \end{bmatrix}.$$

Her er

$$s_i^2 = \frac{1}{n-1} \sum_{k=1}^n (x_{ik} - \bar{x}_i)^2$$

og

$$s_{ij} = \frac{1}{n-1} \sum_{k=1}^n (x_{ik} - \bar{x}_i)(x_{jk} - \bar{x}_j)$$

Hotelling foreslog, at generalisere t-teststørrelsen for én stikprøve til teststørrelsen

$$T^2 = n(\bar{\mathbf{x}} - \mu_0)^T \mathbf{S}^{-1}(\bar{\mathbf{x}} - \mu_0).$$

Hvis man derfor ved hjælp af SAS har beregnet alle gennemsnittene for de p stikprøver og den tilsvarende empiriske p x p kovariansmatrix $\mathbf{S}$, kan man i IML beregne Hotellings T^2 - teststørrelse.

Fordelingen af Hotellings T^2 - teststørrelse kan, viste Hotelling, karakteriseres ved at

$$\frac{(n-1)T^2}{p(n-p)} \sim F(p, n-p)$$

Dette resultat svarer til for én stikprøve, dvs. $p = 1$, at

$$\frac{(n-1)t^2}{1(n-1)} = t^2 \sim F(1, n-1)$$

I SAS proceduren IML er det uhyre nemt at beregne Hotellings teststørrelse og den forbundne F-størrelse. Lad os betragte de variable V27 og v29 til V32 fra ISSP-databasen 1987 for de 377 mænd fra UK, der har fuldtidsarbejde. De variable drejer sig om forskellige forhold, de skal bedømme betydningen af for deres daglige arbejde. Alle 5 spørgsmål har samme svarmuligheder, som vi scorer 1 til 5. Vi skal teste den hypotese, at middelværdien for alle 5 variable er den gennemsnitlige score 3. Her bliver vektoren μ_0 altså lig med

$$\mu_0 = \begin{bmatrix} 3 \\ 3 \\ 3 \\ 3 \\ 3 \end{bmatrix}.$$

Hvis vi kalder denne vektor 'x0', mens 'xbar' og 'x' er vektorerne bestående af differenserne mellem gennemsnittene og de hypotetiske middelværdiergennemsnit, bliver SAS-programmet til beregning af T^2 og F.

```

proc iml;
d={ 0.791523224    0.078580902    0.162353970    0.138509510    0.315854450,
    0.078580902    0.753414414    0.356432361    0.332221062    0.245358090,
    0.162353970    0.356432361    0.807494780    0.577212314    0.313575823,
    0.138509510    0.332221062    0.577212314    0.864354648    0.289914781,
    0.315854450    0.245358090    0.313575823    0.289914781    1.002596083};
x = {2.5411,
     2.2228 ,
     2.4164 ,
     2.3820 ,
     2.8541};
x0 = {3,
      3,
      3,
      3,
      3};
xbar = x - x0;
di = inv(d);
print d xbar di;
t2 = 377*t(xbar)*di*xbar;
f = (377-1)*t2/5/(377-5);
print t2 f;
run;
quit;

```

Endelig er 'd' den empiriske kovariansmatrix. Der er 377 observationer, så $n = 377$.

SAS-udskriften fra dette program bliver:

```

      D
0.7915232 0.0785809 0.162354 0.1385095 0.3158545
0.0785809 0.7534144 0.3564324 0.3322211 0.2453581
0.162354 0.3564324 0.8074948 0.5772123 0.3135758
0.1385095 0.3322211 0.5772123 0.8643546 0.2899148
0.3158545 0.2453581 0.3135758 0.2899148 1.0025961
      XBAR
-0.4589
-0.7772
-0.5836
-0.618
-0.1459

```

```

      DI
550.15738 23.392082 -53.00132 -8.044186 -160.1413
23.392082 659.73529 -191.7469 -102.7288 -79.14462
-53.00132 -191.7469 987.87406 -548.4014 -86.77112
-8.044186 -102.7288 -548.4014 859.72943 -49.40846
-160.1413 -79.14462 -86.77112 -49.40846 487.26869

```

```

      T2      F
441.99675    89.34988

```

Da 95% fraktilen for en F-fordeling med (5,372) frihedsgrader er lig med 2.25, er dette resultat endog meget signifikant.

Hvis vi ændrer de 5 hypotetiske værdier af middelværdierne til 2.5, bliver SAS-programmet:

```
proc iml;
d={ 0.791523224    0.078580902    0.162353970    0.138509510    0.315854450,
    0.078580902    0.753414414    0.356432361    0.332221062    0.245358090,
    0.162353970    0.356432361    0.807494780    0.577212314    0.313575823,
    0.138509510    0.332221062    0.577212314    0.864354648    0.289914781,
    0.315854450    0.245358090    0.313575823    0.289914781    1.002596083};
x = {2.5411,
      2.2228 ,
      2.4164 ,
      2.3820 ,
      2.8541};
x0 = {2.5,
      2.5,
      2.5,
      2.5,
      2.5};
xbar = x - x0;
di = inv(d);
t2 = 377*t(xbar)*di*xbar;
print d xbar di;
f = (377-1)*t2/5/(377-5);
print t2 f;
run;
quit;
```

SAS output fra dette program bliver:

D					XBAR
0.7915232	0.0785809	0.162354	0.1385095	0.3158545	0.0411
0.0785809	0.7534144	0.3564324	0.3322211	0.2453581	-0.2772
0.162354	0.3564324	0.8074948	0.5772123	0.3135758	-0.0836
0.1385095	0.3322211	0.5772123	0.8643546	0.2899148	-0.118
0.3158545	0.2453581	0.3135758	0.2899148	1.0025961	0.3541
DI					
550.15738	23.392082	-53.00132	-8.044186	-160.1413	
23.392082	659.73529	-191.7469	-102.7288	-79.14462	
-53.00132	-191.7469	987.87406	-548.4014	-86.77112	
-8.044186	-102.7288	-548.4014	859.72943	-49.40846	
-160.1413	-79.14462	-86.77112	-49.40846	487.26869	
T2		F			
125.21961	25.313211				

F-teststørrelsen er stadig meget signifikant i forhold til 95% fraktilen, der er 2.25 for en F-fordeling med (5,372) frihedsgrader. Selv hvis vi vælger 99% fraktilen for en F-fordeling med (5,372) frihedsgrader, svarende til en signifikanssandsynlighed mindre end 0.005, får vi 3.09, så resultatet er stadig meget signifikant.

6. Principalkomponentmetoden.

6.1 Principalkomponentmetoden.

Principalkomponentmetoden, som den benyttes i økonometrien for at løse bl.a. multikollinearitetsproblemer, er måske det bedste eksempel både på egenværdidekomponeringens enkelthed og dens styrke som analyseredskab.

Antag, at man i en regressionsanalyse med mange forklarende variable, som af natur er stokastiske, er løbet ind i et tilfælde af rigtig sur multikollinearitet. Hvis antal forklarende variable er n , er problemet jo, at kovariansmatricen mellem de forklarende variable - X 'erne - er singulær eller næsten singulær. Her ville det være af betydning for analysen, hvis man kunne finde et antal forklarende variable: $Y_1, \dots, Y_k$, hvor $k < n$, der dels afhang lineært af X 'erne, dels ikke var korrelerede, så var multikollinearitetsproblemet jo bragt ud af verden. Det man her søger er altså en lineær transformation

$$Y = A X,$$

hvor A er en matrix af dimension $k \times n$, med $k < n$, og hvor Y 'erne er ukorrelerede. Åbenbart er problemet, ifølge Kapitel 2, løst ved at vælge A som k rækker af egenvektorer for $V_X = \text{var}[X]$. Y 'ernes varianser bliver da egenværdierne svarende til de valgte egenvektorer. Så ønsker man, at Y 'erne har så stor variation som muligt, skal man vælge egenvektorerne svarende til de største egenværdier. Denne procedure kaldes principalkomponentmetoden.

Principalkomponentmetoden kan også motiveres ved følgende resultater, der viser at metoden succesivt giver de normerede linearkombinationer af X 'erne, der har størst mulig varians og dermed forklarer mest muligt af variationen i lineære forudsigelser baseret på X 'erne. Det første resultat er:

Koefficienterne $b_{11}, \dots, b_{n1}$, der opfylder

$$\max_{\sum_i b_{i1}^2 = 1} \left(\text{var} \left[\sum_{i=1}^n b_{i1} X_i \right] \right)$$

dvs. maksimaliserer variansen på $\mathbf{b}_1^T X$ fås netop, når søjlevektoren

$$\mathbf{b}_1 = \begin{bmatrix} b_{11} \\ \dots \\ b_{n1} \end{bmatrix}$$

er lig med egenvektoren $\mathbf{a}_1$ for V_X , svarende til den største egenværdi.

Det andet resultat er, at givet $\mathbf{b}_2$ er normeret til længden 1 og ortogonal med $\mathbf{b}_1$, dvs.

$$\sum_{i=1}^n b_{i2}^2 = 1$$

og

$$\sum_{i=1}^n b_{i1} b_{i2} = 0 ,$$

da opnås

$$\max \left(\text{var} \left[\sum_{i=1}^n b_{i2} X_i \right] \right)$$

netop når $\mathbf{b}_2$ er lig med egenvektoren $\mathbf{a}_2$ for $\mathbf{V}_X$, svarende til den næststørste egenværdi.

Sådan fortsættes med, at givet $\mathbf{b}_3$ er normeret til længden 1 og ortogonal med både $\mathbf{b}_1$ og $\mathbf{b}_2$, da opnås

$$\max \left(\text{var} \left[\sum_{i=1}^n b_{i3} X_i \right] \right)$$

når $\mathbf{b}_3$ er lig med egenvektoren $\mathbf{a}_3$ for $\mathbf{V}_X$, svarende til den tredjestørste egenværdi. Etc.

Principalkomponentmetoden kan tillige motiveres som en mindste kvadraters løsning. Det gælder nemlig, at hvis vi forsøger for fastholdt værdi af k at minimalisere Q , givet ved

$$Q = \sum_{i=1}^n \sum_{j=1}^n \left(s_{ij} - \sum_{q=1}^k b_{iq} b_{jq} \lambda_q \right)^2 , \quad s_{ii} = s_i^2 ,$$

da er $\lambda_1, \dots, \lambda_k$ de k største egenværdier, og $(b_{1q}, \dots, b_{nq})$ den til λ_q svarende egenværdi. Dette resultat betyder simpelthen, at man får egenværdi-dekomponeringen, hvis man minimaliserer kvadratsumsafvigelsen mellem elementerne i estimatet for $\mathbf{V}_X$ og elementerne i $\mathbf{B} \mathbf{\Lambda} \mathbf{B}^T$.

6.2 Forklaret variation. Kommunaliteter.

Da $\mathbf{A}$ som rækker har de k egenvektorer for $\mathbf{V}_X$, der svarer til de k største egenværdierne for $\mathbf{V}_X$, og disse k egenværdier netop er varianserne for de ukorreleerede Y 'er, dvs. diagonalelementerne i diagonalmatricen $\mathbf{V}_Y$, gælder

$$\mathbf{V}_X \approx \mathbf{V}_X^* = \mathbf{A}^T \mathbf{V}_Y \mathbf{A} .$$

Hvis $k=n$, dvs. vi medtager alle egenvektorer og egenværdier, vil naturligvis gælde et lighedstegn, dvs.

$$\mathbf{V}_X = \mathbf{A}^T \mathbf{V}_Y \mathbf{A} .$$

Med $\text{tr}(\mathbf{M})$ betegner man sporet (Engelsk 'trace'), dvs. summen $m_{11} + \dots + m_{nn}$ af diagonalelementerne i $\mathbf{M}$. Hvis man transformerer ortogonalt, gælder at sporet af kovariansmatricerne er ens. Det vil sige

$$\text{tr}(\mathbf{V}_X^*) = \text{tr}(\mathbf{V}_Y)$$

og hvis alle egenvektorer medtages

$$\text{tr}(\mathbf{V}_X) = \text{tr}(\mathbf{V}_Y) .$$

Man kan derfor altid bedømme, hvor tæt man er på at have forklaret hele variationen ved at summere de egenverdier, der indgår i egenverdi-dekomponeringen. Diagonalelementerne i approksimationen $\mathbf{V}_X^*$ til $\mathbf{V}_X$ kaldes kommunaliteterne. Hvis $\mathbf{V}_X$ er en korrelationsmatrix, er kommunaliteterne alle mindre end 1, og deres indbyrdes størrelsesorden viser hvilke X'er, der kommer nærmest til at forklare hele variationen.

6.3 Rotation.

Lad $\mathbf{x}$ og $\mathbf{y}$ være søjlevektorer af dimension n . En ortogonal transformation af fuld rang, dvs.

$$\mathbf{y} = \mathbf{A} \mathbf{x} ,$$

hvor $\mathbf{A}$ er en $n \times n$ matrix med ortogonale rækker, er en rotation i det n -dimensionale rum. Det betyder, at hvis $\mathbf{x}$ er koordianterne til et punkt, er $\mathbf{y}$ koordianterne til det samme punkt, men i et koordinatsystem, der er drejet vinkelret i forhold til det gamle.

For $n = 2$, tager det sig sådan ud: Punktet med koordinaterne (x_1, x_2) føres ved transformationen

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \cos v & \sin v \\ -\sin v & \cos v \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$


over i punktet (y_1, y_2) . Denne transformation er ortogonal, idet de to rækkevektorer har længder 1 ifølge 'idiotformlen'

$$\cos^2 v + \sin^2 v = 1 ,$$

og produktsummen af deres komponenter er:

$$-\cos v \cdot \sin v + \sin v \cdot \cos v = 0 ,$$

På figuren neden for er vist, hvordan de to punkter (p_1, p_2) og (q_1, q_2) beliggende på enhedscirklen transformeres over i punkterne $(y_1, y_2) = (1, 0)$ og $(0, 1)$.




Som figuren ret tydeligt viser, kan man altid dreje et koordinatsystem, eller som vi her skal sige 'rottere koordinatsystemet', så specielle punkter ligger særlig attraktivt, f.eks. på akserne i det nye koordinatsystem.

Ved principalkomponentmetoden - og senere i faktoranalysen - skal vi benytte os af sådanne ortogonale transformationer.


Principalkomponentmetoden sigter mod at gøre de nye variable ukorrelerede. Men det betyder ikke nødvendigvis, at de nye variable er dem, der bedst forklarer afhængigheden mellem de oprindelige variable (X 'erne) og de nye (Y 'erne). **Varimax-rotation** er en metode, der roterer Y 'ernes kooordinatsystem (der, som vi erindrede, normalt er af lavere dimension end X 'ernes koordiantssystem), så der er flest mulige af de oprindelige X 'er, der korrelerer højt med Y 'erne.

Antag, for at 'skære det ud i pap', at vi skal analysere V24 - V32 fra ISSP 1989. Her er 9 V 'er, og vi kun ønsker 2 Y 'er. Lad os derfor antage, at vi kan rotere Y -koordinatsystemet, så de første 4 V 'er korrelerer med en korrelationskoefficient ret tæt ved 1 med Y_1 , mens de sidste 5 V 'er korrelerer med en korrelationskoefficient ret tæt ved 1 med Y_2 . De to principale komponenter Y_1 og Y_2 er derfor et udtryk for, at en meget stor del af variationen i X 'erne kan forklares ved, at de variable V24, ... ,V27 varierer tæt omkring en y_1 -akse, mens de variable V28, ... ,V32 varierer tæt omkring en y_2 -akse. Eksemplet i næste kapitel illustrerer dette forhold udmærket.


Man kan anskueliggøre matrixoperationerne i dette Kapitel på følgende måde:




$$\mathbf{A} = \mathbf{B}\mathbf{\Lambda}\mathbf{B}^T$$



$$\mathbf{\Lambda} = \mathbf{B}^T \mathbf{A} \mathbf{B}$$



$$\mathbf{A} = \mathbf{B}\mathbf{\Lambda}\mathbf{B}^T$$




$$\mathbf{\Lambda} = \mathbf{B}^T \mathbf{A} \mathbf{B}$$


I tilfældet med kovariansmatricer $\mathbf{V}_Y$ for $\mathbf{Y}$ og $\mathbf{V}_X$ for $\mathbf{X}$ ved transformationen

$$\mathbf{Y} = \mathbf{A}\mathbf{X}$$


bliver billederne




$$\mathbf{V}_X = \mathbf{A}^T \mathbf{\Lambda} \mathbf{A}$$



$$\mathbf{V}_Y = \mathbf{\Lambda} = \mathbf{A} \mathbf{V}_X \mathbf{A}^T$$



$$\mathbf{V}_X \approx \mathbf{A}^T \mathbf{\Lambda} \mathbf{A}$$



$$\mathbf{V}_Y \approx \mathbf{\Lambda} = \mathbf{A} \mathbf{V}_X \mathbf{A}^T$$

7. Principalkomponentmetoden i SAS.

Til illustration af principalkomponentmetoden i SAS betragter vi de variable V24 til V32 fra ISSP 1989, som beskriver hvilke forhold ved jobbet, respondenterne selv anser for betydningsfulde. De enkelte spørgsmål og de mulige svarkategorier fremgår af udsnittet fra kodebogen for 1989-undersøgelsen, der er vist i de to næste bokse.

V24 IMPORTANT: JOB SECURITY

Q.6a How important is: Job security?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V25 IMPORTANT: HIGH INCOME

Q.6b How important is: High income?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V26 IMPORTANT: ADVANCEMENT

Q.6c How important is: Good opportunities for advancement?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all
8. Can't choose, don't know
9. NA

V27 IMPORTANT: LEISURE TIME

Q.6d How important is: A job that leaves a lot of leisure time?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V28 IMPORTANT: INTERESTG JOB

Q.6e How important is: An interesting job?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V29 IMP.: INDEPENDENT WORK

Q.6f How important is: A job that allows someone to work independently?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V30 IMP.: JOB HELPS PEOPLE

Q.6g How important is: A job that allows someone to help other people?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V31 IMP.: JOB USEFUL F. SOC.

Q.6h How important is: A job that is useful to society?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

V32 IMP.:FLEXIBLE WRKG HOURS

Q.6i How important is: A job with flexible working hours?

1. Very important
2. Important
3. Neither important nor unimportant
4. Not important
5. Not important at all

For at udføre en principalkomponentanalyse, inklusive en VARIMAX-rotation, skal man skrive følgende program:

```
1. libname eba 'S:\eba-data';
2. title 'Principal component analysis on ISSP 1989. All countries';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v27>5 then delete;
12. if v28>5 then delete;
13. if v29>5 then delete;
14. if v30>5 then delete;
15. if v31>5 then delete;
16. if v32>5 then delete;
17. proc factor data=b
18.   method = prin
19.   priors = one
20.   mineigen = 1
21.   flag = 0.5;
22. run;
23. quit;
```

Da det er første gang vi viser et eksempel på en større analyse med udgangspunkt i ISSP databasen, skal vi gennemgå SAS-programmet i passende dele. Den første del består af programlinie 1 til 5. De ser sådan ud:

```
1. libname eba 'S:\eba-data';
2. title 'Principal component analysis on ISSP 1989. All countries';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
```

Linie 1 knytter programmet til det område på S-drevet, hvor ISSP databasen ligger. Linie 2 sikrer, at alle sider i output får en overskrift, der fortæller, hvilket dataset og analyseform det handler om. I linie 3 og 4 oprettes dataset 'a', som i første omgang sættes til alle de variable i 1989-delen af ISSP databasen. Linie 5 sørger herefter for, at kun de 9 variable V24 til V32 kommer med i dataset 'a'.

Linie 6 til 16 ser sådan ud.

```
6. data b;  
7. set a;  
8. if v24>5 then delete;  
9. if v25>5 then delete;  
10. if v26>5 then delete;  
11. if v27>5 then delete;  
12. if v28>5 then delete;  
13. if v29>5 then delete;  
14. if v30>5 then delete;  
15. if v31>5 then delete;  
16. if v32>5 then delete;
```

Her sættes i første omgang dataset 'b' lig med de 9 variable i dataset 'a'. Men herefter fjernes alle personer, der har ubesvarede spørgsmål. De 5 svarmuligheder er kodet 1 til 5, som vist oven for, mens ubesvarede er kodet 8 eller 9. Dataset 'b' består derfor nu af svarene på V24 til V32 for alle de personer, der har besvaret alle de 9 spørgsmål med en af de 5 givne svarkategorier.

Den første eksplorative analyse foregår ved hjælp af PROC FACTOR. Denne del består af linie 17 til 21, hvor programmet ser sådan ud:

```
17. proc factor data=b  
18.   method = prin  
19.   priors = one  
20.   mineigen = 1  
21.   flag = 1;  
22. run;  
23. quit;
```

Inden det første semikolon skal vi angive en række 'options' for at sikre, at vi får den analyse, vi ønsker:

'data = b' : Analysen udføres på dataset 'b'.

'method = prin' : Der udføres en principal komponent analyse.

'mineigen = 1': SAS udskriver egenvektorerne svarende til egenværdier med værdier over 1.

'flag = 0.5': Egenvektorer angives ganget med 100 og rundet af, samtidig med at værdier større end 0.5 forsynes med en '**'.
(På engelsk 'to be flaged'.)

Herefter sættes et semikolon og der skrives 'run' og 'quit', så programmet bliver kørt.

De vigtigste dele af output fra en SAS kørsel af dette program ser således ud: (Når jeg skriver 'de vigtigste dele', betyder det, at SAS output'et viser en del flere resultatet, som du i første omgang ikke skal bekymre dig om!)

Initial Factor Method: Principal Components

	1	2	3	4	5
Eigenvalue	2.6688	1.3339	1.1094	0.9521	0.7761
	6	7	8	9	
Eigenvalue	0.6705	0.5970	0.5325	0.3599	

3 factors will be retained by the MINEIGEN criterion.

Factor Pattern

	FACTOR1	FACTOR2	FACTOR3	
V24	38	43	-45	IMPORTANT: JOB SECURITY
V25	41	70 *	2	IMPORTANT: HIGH INCOME
V26	54 *	44	-23	IMPORTANT: ADVANCEMENT
V27	40	21	66 *	IMPORTANT: LEISURE TIME
V28	59 *	-6	-6	IMPORTANT: INTERESTG JOB
V29	62 *	-17	15	IMP.: INDEPENDENT WORK
V30	68 *	-45	-22	IMP.: JOB HELPS PEOPLE
V31	66 *	-42	-25	IMP.: JOB USEFUL F. SOC.
V32	52 *	-8	53 *	IMP.: FLEXIBLE WRKG HOURS

NOTE: Printed values are multiplied by 100 and rounded to the nearest integer.
Values greater than 0.5 have been flagged by an '*'.

Variance explained by each factor

FACTOR1	FACTOR2	FACTOR3
2.668801	1.333858	1.109400

Som det fremgår, er der 3 egenværdier større end 1, nemlig 2.67, 1.33 og 1.11. Egenvektorerne til disse tre egenværdier kaldes her FACTOR1, FACTOR2 og FACTOR3, så FACTOR1 svarer til den største egenværdi 2.67, osv. I output'et noteres også, at antal egenvektorer (faktorer) er baseret på, at den mindste medtagne egenværdi (MINEIGEN) er 1. Det nævnes også, (NOTE:) at egenvektorer angives ganget med 100 og rundet af, samtidig med, at værdier større end 0.5 forsynes med en '*'. Sidste linie er blot de 3 største egenværdier gentaget.

Der er to grunde til, at vi nu vælger kun at medtage 2 faktorer. For det første er den tredje største egenværdi ganske tæt ved 1. For det andet ser billedet lidt rodet ud for FACTOR2 og FACTOR3, hvad angår hvilke variable, der bidrager til forklaringen af variationen i kovariansmatricen. Også efter en VARIMAX-rotation, der ikke er vist her, ser det ikke tilfredsstillende ud.

Hvis der kun skal medtages 2 egenvektorer, kan vi godt bruge MINEIGEN optionen ved at skrive 'MINEIGEN = 1.2'. Men det virker lidt kunstigt. I stedet kan man direkte forlange, at der medtages 2 faktorer ved at skrive 'NFACT = 2'. For at se hvilke egenvektorer, der bidrager mest til at forklare variationen i de variable, må vi rotere koordinatsystemet ved en

ortogonal rotation. Benyttes VARIMAX metoden, skal der stå 'ROTATE = VARIMAX'. Ellers er programmet det samme, så det kommer til at se sådan ud:

```
1. libname eba 'S:\eba-data';
2. title 'Principal component analysis on ISSP 1989. All countries';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v27>5 then delete;
12. if v28>5 then delete;
13. if v29>5 then delete;
14. if v30>5 then delete;
15. if v31>5 then delete;
16. if v32>5 then delete;
17. proc factor data=b
18.   method = prin
19.   priors = one
20.   nfact = 2
21.   rotate = varimax
22.   flag = 0.5;
23. run;
24. quit;
```

Optionen 'priors = one' er rent teknisk, idet den bruges for at starte varimax rotationen.

De vigtigste dele af output fra dette program ser således ud:

2 factors will be retained by the NFACTOR criterion.

Factor Pattern

	FACTOR1	FACTOR2	
V24	38	43	IMPORTANT: JOB SECURITY
V25	41	70 *	IMPORTANT: HIGH INCOME
V26	54 *	44	IMPORTANT: ADVANCEMENT
V27	40	21	IMPORTANT: LEISURE TIME
V28	59 *	-6	IMPORTANT: INTERESTG JOB
V29	62 *	-17	IMP.: INDEPENDENT WORK
V30	68 *	-45	IMP.: JOB HELPS PEOPLE
V31	66 *	-42	IMP.: JOB USEFUL F. SOC.
V32	52 *	-8	IMP.:FLEXIBLE WRKG HOURS

Rotation Method: Varimax

Orthogonal Transformation Matrix

	1	2
1	0.83882	0.54441
2	-0.54441	0.83882

Rotated Factor Pattern


	FACTOR1	FACTOR2	
V24	8	56 *	IMPORTANT: JOB SECURITY
V25	-4	82 *	IMPORTANT: HIGH INCOME
V26	21	66 *	IMPORTANT: ADVANCEMENT
V27	22	40	IMPORTANT: LEISURE TIME
V28	53 *	27	IMPORTANT: INTERESTG JOB
V29	62 *	19	IMP.: INDEPENDENT WORK
V30	82 *	-1	IMP.: JOB HELPS PEOPLE
V31	78 *	1	IMP.: JOB USEFUL F. SOC.
V32	48	22	IMP.:FLEXIBLE WRKG HOURS

Af den første linie output fremgår, at kun 2 faktorer vises ifølge NFACTOR kriteriet ('nfact = 2'). I de næste linie vises egenvektorerne, der altid i SAS kaldes 'FACTOR1', FACTOR2, etc. Herefter noteres det, at man roterer med VARIMAX metoden, og den ortogonale rotations matrix vises. Det fremgår, at den vinkel v , koordinatsystemet drejes er bestemt af $\cos v = 0.839$ og $\sin v = -0.544$. Det svarer til en vinkel på $v = -33^\circ$.

Her skal man lægge mærke til, at SAS definerer vektorer som matricer af dimension $1 \times n$, dvs. rækkevektorer, mens jeg i Kapitel 6, som sædvane er, opfatter vektorer som matricer af orden $n \times 1$, dvs. som søjlevektorer. Det betyder, at den ortogonale transformation, der udskrives af SAS under overskriften 'Orthogonal Transformation Marix' er:

$$\begin{bmatrix} \cos v & -\sin v \\ \sin v & \cos v \end{bmatrix}.$$

På grafisk form ser rotationen sådan ud:



Efter rotationen vises igen de to egenvektorer: FACTOR1 og FACTOR2.

I den sidste del vises faktorerne efter VARIMAX rotationen. Det fremgår ved at betragte de faktorer, der er forsynet med en '*', at V28, V29, V30 og V31 korrelerer højt med FACTOR1. Fortolkningen af denne faktor er oplagt: Der er tale om aspekter ved job'et, der gør det interessant og betydningsfuldt. Omvendt synes FACTOR2 at korrelerer højt med variable, der har at gøre med, hvad job'et gør for dig selv, bl.a. høj løn og gode advancementsmuligheder. Om job'et er betydningsfuldt, fordi det giver dig megen fritid, tenderer mod FACTOR2, lige som dét, at have et job med fleksible arbejdstider tenderer mod at betyde mest for FACTOR1.

Vi kan altså konstatere, at principal komponent metoden her deler de variable op i to 'naturlige grupper', som man måske kunne kalde 'Interessant Job' og 'Godt Job'.

I forbindelse med stianalyserne i Kapitel 14 og 15, skal vi bruge endnu en sammensat variabel fra 1989 undersøgelsen. De variable V68 til V74 drejer sig om forhold vedrørende arbejdsbetingelserne ved jobbet, som respondenterne selv oplever dem, både fysiske og psykiske. Udsnittet, vist i boksen neden for, beskriver spørgsmålene og svarkategorierne. (De 5 svarkategorier er kun vist ved V68, da de er ens for alle 7 spørgsmål.)

V68 HOME FROM WORK EXHAUSTED

Q.17 Now some more questions about your working conditions.
Please tick one box for each item below to show how often
it applies to your work.

Q.17a How often do you come home from work exhausted?

1. Always
2. Often
3. Sometimes
4. Hardly ever
5. Never

V69 HARD PHYSICAL WORK

Q.17b How often do you have to do hard physical work?

V70 STRESSFUL WORK

Q.17b How often do you have to do stressful work?

V71 BORED AT WORK

Q.17d How often are you bored at work?

V72 WRK IN DANGRS CONDITIONS

Q.17e How often do you work in dangerous conditions?

V73 UNHEALTHY CONDITIONS

Q.17f How often do you work in unhealthy conditions?

V74 PHYS. UNPLEASANT COND.

Q.17g How often do you work in physically unpleasant conditions?

En principalkomponentanalyse af disse 7 spørgsmål giver følgende egenvektorer, med NFACT lig med 2, og efter en VARIMAX rotation.

Rotated Factor Pattern

	FACTOR1	FACTOR2	
V68	10	85 *	HOME FROM WORK EXHAUSTED
V69	62 *	30	HARD PHYSICAL WORK
V70	7	80 *	STRESSFUL WORK
V71	30	-2	BORED AT WORK
V72	80 *	11	WRK IN DANGRS CONDITIONS
V73	81 *	11	UNHEALTHY CONDITIONS
V74	73 *	6	PHYS. UNPLEASANT COND.

FACTOR1, som korrelerer højt med V69, V72, V73 og V74, har åbenbart at gøre med jobbet fysiske belastning, mens FACTOR2 har at gøre med jobbet psykiske belastning. Generelt har man erfaring for, at der skal mindst tre variable, helst flere, før man kan tale om en egentlig faktor. Så fra de 7 variable, der vedrører arbejdsmiljøet, kan vi kun bruge FACTOR1, som man kan kalde 'Hard Job' eller 'Dangerous Job'.

8. Om normeringer.

I PROC FACTOR sker der nogle lidt andre normeringer end i mine noter. Det, der vises som FACTOR1, FACTOR2, etc., er således ikke egenvektorerne, der jo er normerede til længden 1, dvs. at kvadratsummen af elementerne er 1. I PROC FACTOR er der normeret så længden er kvadratroden af egenværdien, dvs. kvadratsummen af elementerne er lig med egenværdien. Lidt senere står der "Standardized Scoring Coefficients", som til gengæld har længden 1 divideret med kvadratroden af egenværdien, dvs. kvadratsummen af elementerne er lig med 1 divideret med egenværdien. Det er de sidste, SAS skriver som FACTOR1, FACTOR2, etc. i output-sættet, dvs. med ordren "out=d".

Der er den fordel ved Standardized Scoring Coefficients som faktorer, at de også er uafhængige efter en ortogonal transformation, hvad egenvektorerne ikke nødvendigvis er. Det ser man således:

Hvis transformationen er $\mathbf{Y} = \mathbf{AX}$, og $\mathbf{A}$ er den ortogonale matrix, der optræder i egenværdi-dekomponeringen

$$\mathbf{V}_X = \mathbf{A}^T \mathbf{\Lambda} \mathbf{A} ,$$

har vi

$$\mathbf{V}_Y = \mathbf{A} \mathbf{V}_X \mathbf{A}^T = \mathbf{\Lambda} \text{ (diagonal) } .$$

Men definerer vi transformationen vi som $\mathbf{Z} = \mathbf{\Lambda}^{-1/2} \mathbf{AX}$, hvor $\mathbf{A}$ er den samme ortogonale matrix, som oven for, da gælder

$$\mathbf{V}_Z = \mathbf{\Lambda}^{-1/2} \mathbf{A} \mathbf{V}_X \mathbf{A}^T \mathbf{\Lambda}^{-1/2} = \mathbf{\Lambda}^{-1/2} \mathbf{A} \mathbf{A}^T \mathbf{\Lambda} \mathbf{A} \mathbf{A}^T \mathbf{\Lambda}^{-1/2} = \mathbf{I} .$$

idet $\mathbf{A} \mathbf{A}^T = \mathbf{I}$, når $\mathbf{A}$ er ortogonal. Hvis vi nu transformerer med en ny ortogonal matrix $\mathbf{B}$, dvs. $\mathbf{Q} = \mathbf{BZ}$, får vi

$$\mathbf{V}_Q = \mathbf{B} \mathbf{B}^T = \mathbf{I} ,$$

så Q'erne, ligesom Z'erne er uafhængige, men nu alle har varians 1.

9. Asymptotiske resultater for ML-estimatorer og kvotientteststørrelser.

Resultaterne i dette afsnit bygger på **den centrale grænseværdisætning**. Den siger, at hvis $Y_1, \dots, Y_n$ er uafhængige og ensfordelte stokastiske variable med endelig middelværdi μ og endelig varians σ^2 , da gælder for store værdier af n

$$\sum_{i=1}^n Y_i \sim N(n\mu, n\sigma^2) .$$

Som sådan er resultatet ret meningsløst, idet både middelværdi og varians går mod uendelig. Men det skal opfattes sådan, at hvis summen af Y 'er standardiseres, så nærmer fordelingen sig til den standardiserede normalfordeling, dvs. med

$$S_Y = \sum_{i=1}^n Y_i ,$$

så vil

$$\frac{S_Y - n\mu}{\sqrt{n\sigma^2}} = \frac{\sqrt{n}(\bar{Y} - \mu)}{\sigma} \sim N(0,1) ,$$

ML-estimatoren fås som løsningen til

$$\frac{\partial \ln L(\hat{\theta})}{\partial \theta} = 0 .$$

Hvis der er tale om n uafhængige, ensfordelte stokastiske variable X_i , $i=1, \dots, n$, hvor

$$L(\theta) = \prod_{i=1}^n f(X_i|\theta) ,$$

fås ML-estimatorerne af ligningen

$$(9.1) \quad \frac{\partial \ln L(\hat{\theta})}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(X_i|\hat{\theta})}{\partial \theta} = \sum_{i=1}^n \frac{f'(X_i|\hat{\theta})}{f(X_i|\hat{\theta})} = 0 .$$

Rækkeudvikles den partielt afledede af $\ln L$ mht. til θ i punktet θ_0 , som er den sande værdi af θ , fås approksimationen

$$0 = \frac{\partial \ln L(\hat{\theta})}{\partial \theta} \approx \frac{\partial \ln L(\theta_0)}{\partial \theta} + (\hat{\theta} - \theta_0) \frac{\partial^2 \ln L(\theta_0)}{\partial \theta^2} ,$$

så

$$(9.2) \quad (\hat{\theta} - \theta_0) \approx \frac{\partial \ln L(\theta_0)}{\partial \theta} \cdot \left(- \frac{\partial^2 \ln L(\theta_0)}{\partial \theta^2} \right)^{-1} .$$

Men af (9.1) med

$$Y_i = \frac{\partial \ln f(X_i | \theta_0)}{\partial \theta} = \frac{f'(X_i | \theta_0)}{f(X_i | \theta_0)}$$

følger, at vi kan anvende den centrale grænseværdisætning. Middelværdi og varians af Y_i får man af identiteten

$$\int f(x | \theta_0) dx = 1 ,$$

hvoraf følger, at

$$\int f'(x | \theta_0) dx = \int f''(x | \theta_0) dx = 0 .$$

Først ser man, at

$$E[Y_i] = E\left[\frac{\partial \ln f(X_i | \theta_0)}{\partial \theta} \right] = \int \frac{f'(x | \theta_0)}{f(x | \theta_0)} \cdot f(x | \theta_0) dx = \int f'(x | \theta_0) dx = 0 ,$$

så $E[Y_i] = 0$. For at finde variansen på Y_i , betragtes den anden afledede af $\ln f(x|\theta)$:

$$\frac{\partial^2 \ln f(x|\theta)}{\partial \theta^2} = \frac{\partial}{\partial \theta} \left(\frac{f'(x|\theta)}{f(x|\theta)} \right) = \frac{f''(x|\theta) \cdot f(x|\theta) - (f'(x|\theta))^2}{(f(x|\theta))^2}$$

$$= \frac{f''(x|\theta)}{f(x|\theta)} - \left(\frac{f'(x|\theta)}{f(x|\theta)} \right)^2 .$$

Det betyder, at

$$E\left[\frac{\partial^2 \ln f(X_i|\theta)}{\partial \theta^2}\right] = \int f''(x|\theta) dx - \int \left(\frac{f'(x|\theta)}{f(x|\theta)}\right)^2 f(x|\theta) dx = 0 - \text{var}[Y_i] .$$

Vi tillader os yderligere i (9.2) at erstatte det led, der inverteres, med sin middelværdi, der jo bliver

$$E\left[-\frac{\partial^2 \ln L(\theta_0)}{\partial \theta^2}\right] = \sum_{i=1}^n E\left[-\frac{\partial^2 \ln f(X_i|\theta)}{\partial \theta^2}\right] = n \cdot \text{var}[Y_i] .$$

Den første faktor på højresiden i (9.2) er summen af Y 'erne. Så en anvendelse af den centrale grænseværdisætning giver, at for store værdier af n har vi approximationen

$$(\hat{\theta} - \theta_0) \sim N\left(0, \frac{1}{(n \cdot \text{var}[Y_i])^2} \cdot n \cdot \text{var}[Y_i]\right) = N\left(0, \frac{1}{n \sigma^2}\right) ,$$

hvor

$$\sigma^2 = \left(E\left[-\frac{\partial^2 \ln f(X_i|\theta_0)}{\partial \theta^2}\right]\right)^{-1} .$$

For store værdier af n er ML-estimatoren altså approksimativt normalfordelt med middelværdi θ_0 , dvs. den sande værdi af θ , og en varians, der nemt beregnes ud fra fordelingen af X_i .

Kvotientteststørrelsen for hypotesen $\theta = \theta_0$ er givet som

$$Z = -2 \ln \frac{L(\theta_0)}{L(\hat{\theta})} .$$

Rækkeudvikler man $\ln L(\theta_0)$ omkring $\hat{\theta}$, får man

$$\ln L(\theta_0) \approx \ln L(\hat{\theta}) + (\theta_0 - \hat{\theta}) \frac{\partial \ln L(\hat{\theta})}{\partial \theta} + \frac{1}{2} (\theta_0 - \hat{\theta})^2 \left(\frac{\partial^2 \ln L(\hat{\theta})}{\partial \theta^2} \right) .$$

Da

$$\frac{\partial \ln L(\hat{\theta})}{\partial \theta} = 0 ,$$

får man derfor

For $\hat{\theta}$ tæt ved θ_0 gælder

Om kvotientteststørrelsens asymptotiske fordeling gælder altså

$$Z = -2\ln L(\theta_0) + 2\ln L(\hat{\theta}) \approx (\theta_0 - \hat{\theta})^2 \left(-\frac{\partial^2 \ln L(\hat{\theta})}{\partial \theta^2} \right).$$

$$-\frac{\partial^2 \ln L(\hat{\theta})}{\partial \theta^2} \approx E \left[-\frac{\partial^2 \ln L(\theta_0)}{\partial \theta^2} \right] \approx \frac{1}{\text{var}[\hat{\theta}]}.$$

$$Z \approx \left(\frac{\hat{\theta} - \theta_0}{\sqrt{\text{var}[\hat{\theta}]}} \right)^2 \sim U^2 \sim \chi^2(1)$$

Også hvis θ er en vektor af længde m , og alle de m komponenter er specificerede under hypotesen, vil Z være χ^2 -fordelt, men nu med m frihedsgrader.

Hvis hypotesen - i vektor tilfældet - består af $k < m$ bånd mellem θ 'erne, vil Z være χ^2 -fordelt, men nu med k frihedsgrader. Det er dette tilfælde, man i statistikkens teori kalder sammensatte hypoteser (Engelsk: Composite hypotheses). Men man skal for sammensatte hypoteser være forsigtig med identifikationen af modellens parametre. Meget generelt kan man sige, at hvis de her viste resultater skal holde, skal der være tale om en reparametrisering af $(\theta_1, \dots, \theta_m)$ over i $(\tau_1, \dots, \tau_m)$, så hypotesen består i:

$$\tau_1 = \tau_{10}$$

$$\tau_2 = \tau_{20}$$

...

$$\tau_k = \tau_{k0},$$

mens $\tau_{k+1}, \dots, \tau_m$ ikke er specificerede under hypotesen.

Reparametriseringen kan godt være θ 'erne selv, så hypotesen består i at specificere de k første komponenter af θ -vektoren.

Et typisk eksempel på en reparametrisering er hypotesen

$$\theta_1 + \dots + \theta_m = 0.$$

Her skal man reparametrisere med

$$\tau_1 = \theta_1 + \dots + \theta_m,$$

og $\tau_j = \theta_j$, $j = 2, \dots, m$. Hypotesen er herefter $\tau_1 = 0$, svarende til at der lægges ét bånd mellem θ 'erne, og antal frihedsgrader er dermed lig med 1.

10. Faktoranalyse.

Faktoranalyse er egentlig blot en multipel regressionsanalyse med forklarende variable, der ikke er observerbare. Det vil sige, at man skal estimere både regressionskoefficienterne og de forklarende variable, udover restledsvariansen. Formelt set defineres faktoranalyse ved matrixligningen

$$\mathbf{X} = \mathbf{B} \mathbf{F} + \mathbf{E},$$

Her er $\mathbf{X}$ en søjlevektor af dimension n af stokastiske variable $X_1, \dots, X_n$, $\mathbf{B}$ er en $n \times k$ -dimensional matrix af ukendte konstanter, som man ofte kalder 'factor loadings', $\mathbf{F}$ er en søjlevektor af dimension k af ikke-observerbare stokastiske variable $F_1, \dots, F_k$, mens $\mathbf{E}$ er en søjlevektor af stokastiske restled $E_1, \dots, E_n$. Vi skal senere kalde ikke-observerbare variable for latente variable.

Denne matrixligning kan i form af observerede variable blive skrevet fuldt ud som

$$x_i = \sum_{j=1}^k b_{ij} f_j + e_i$$

sådan, at x_i 'erne ($i = 1, \dots, n$) er de observerede variable, f_j , $j = 1, \dots, k$ er værdierne af ikke-observerbare (latente) faktorer og e_i 'erne ($i = 1, \dots, n$) på sædvanlig vis er restled. I forhold til regressionsanalyse er forskellen, at de forklarende variable her er erstattet af ikke-observerbare 'konstruerede' variable $f_1, \dots, f_k$, mens elementerne i $\mathbf{B}$ er parametre, som de er i vanlig regressionsanalyse.

Det antages at $\mathbf{F}$ 'erne og $\mathbf{E}$ 'erne er ukorreleerede. Normalt antages endvidere, at alle variable er centrerede, så de har middelværdi 0. I så fald bliver kovariansmatricen $\mathbf{V}_X$ for $\mathbf{X}$ lig med

$$\mathbf{V}_X = E[\mathbf{X} \mathbf{X}^T] = \mathbf{B} E[\mathbf{F} \mathbf{F}^T] \mathbf{B}^T + E[\mathbf{E} \mathbf{E}^T],$$

eller

$$\mathbf{V}_X = \mathbf{B} \mathbf{V}_F \mathbf{B}^T + \mathbf{V}_E.$$

Ofte analyseres korrelationsmatricen, dvs. kovariansmatricen omskaleret så matricen har 1-taller i diagonalen, i stedet for selv kovariansmatricen. Men for det følgende spiller dette ikke den store rolle. Forskellen på de to udgangspunkter for analysen, vender vi tilbage til.

Hvis man medtager lige så mange faktorer, som der er X 'er, dvs. $n = k$, kan man nemt finde en løsning, hvor alle fejleddene $\mathbf{E}$ har varians 0, og hvor faktorerne $F_1, \dots, F_k$ er ukorreleerede. Løsningen er, at $\mathbf{V}_F$ er en diagonalmatrix dannet af egenværdierne for $\mathbf{V}_X$ og $\mathbf{B}$ er en matrix med egenvektorerne for $\mathbf{V}_X$ som søjler, idet man blot, jvf. Kapitel 2, skal foretage en egenværdi-dekomponering af $\mathbf{V}_X$.

Hvis $k < n$ er én løsning på faktoranalysen at danne $\mathbf{V}_F$ som en diagonalmatrix af de k største egenværdier, og vælge matricen $\mathbf{B}$ af factor loadings som dannet af de tilsvarende k egenvektorer som søjler.

I dette tilfælde bliver elementerne $\mathbf{V}_E$ således forskellene på diagonalelementerne i $\mathbf{V}_X$ og diagonalelementerne i $\mathbf{B} \mathbf{V}_F \mathbf{B}^T$. Som ved principalkomponentmetoden kaldes diagonalelementerne i $\mathbf{B} \mathbf{V}_F \mathbf{B}^T$ for kommunaliteterne, og beskriver hvor stor en andel af variationen faktormodellen bidrager til hver af X 'erne.

Man kan også vælge nogle initialværdier for kommunaliteterne, dvs. diagonalelementerne i $\mathbf{B} \mathbf{V}_F \mathbf{B}^T$. De øvrige initialparametre fås de ved at 'regne baglæns' i beregningen oven for. Denne metode bruges generelt af SAS.

For at udlede ML-estimatorerne for parametrene i faktor modellen, skal man kan opstille log-likelihoodfunktionen for den empiriske kovariansmatrix $\mathbf{V}_X$ (eller den tilsvarende korrelationsmatrix), som en funktion af de ukendte parametre, og maksimalisere denne funktion.

Her er det vigtigt at bemærke 3 ting.

(1) Matricen $\mathbf{S}_X^2$ af dimension $n \times n$, der som elementer har de empiriske varianser og kovarianser mellem X 'erne er en sufficient stikprøvefunktion for den teoretiske kovariansmatrix $\mathbf{V}_X$. Man kan derfor opstille log-likelihoodfunktionen for estimation af faktor-modellens parametre, ved at betragte den simultane tæthedsfunktion for elementerne i $\mathbf{S}_X^2$. Denne fordeling er kendt som Wishart-fordelingen, jvf. Kapitel 4.

(2) I Faktormodellen

$$\mathbf{V}_X = \mathbf{B} \mathbf{V}_F \mathbf{B}^T + \mathbf{V}_E$$

er alle elementerne på højresiden parametre, så vi kan godt skrive ligningen som

$$\mathbf{V}_X = \mathbf{V}_X(\theta_1, \dots, \theta_m),$$

hvor $\theta_1, \dots, \theta_m$ er modellens parametre. Det er med denne parametrisering, ML-estimationen kan udføres.

(3) Faktormodellen skal være identificerbar, dvs. der må ikke være flere parametre m , end der er datapunkter i den empiriske kovariansmatrix. Optællingen af m er meget lettere, end man skulle tro. Og sker iøvrigt også i PROC FACTOR. Vi får, når der medtages k egenværdier

(i) k egenværdier, dvs. varianser for de ukorrelerede faktorer.

(ii) antal frit varierende elementer i $\mathbf{B}$, som er

$$k \cdot n - k - \frac{k(k-1)}{2},$$

idet der er $k \cdot n$ elementer i $\mathbf{B}$, men det lægger k bånd på egenvektorerne, at de skal have længden 1 og $k(k-1)/2$ bånd på egenvektorerne, at produktsummen af enhver kombination dem skal være 0.

(iii) n varianser af fejlleddene.

Det giver ialt

$$m = k + (k \cdot n - k - \frac{k(k-1)}{2}) + n = n(k+1) - \frac{k(k-1)}{2}.$$

På den anden side er der

$$\frac{n(n-1)}{2} + n = \frac{n(n+1)}{2}$$

frit varierende elementer i en kovariansmatrix $\mathbf{V}_x$ af dimension $n \times n$.

I en korrelationsmatrix er der selvfølgelig n færre parametre end i en kovariansmatrix, idet alle diagonal leddene er lig med 1. Til gengæld skal summen af diagonallementene i $\mathbf{B} \mathbf{V}_F \mathbf{B}^T$ og $\mathbf{V}_E$ være 1, så kriteriet for identificerbarhed er derfor det samme for de to tilfælde.

I begge tilfælde er modellen, som sagt, identificerbar, hvis der er flere 'datapunkter', dvs frit varierende elementer i kovarians/korrelations-matricen, end der er frit varierende parametre i modellen. Vælger vi at betagte tilfældet med en kovariansmatrix, bliver betingelsen

$$\frac{n(n+1)}{2} > n(k+1) - \frac{k(k-1)}{2}.$$

Hvis der er lighedstegn, er modellen lige akkurat identificerbar, så der er tale om en reparametrisering.

Antag for eksempel, at der er 6 variable, dvs. $6 \cdot 7/2 = 21$ datapunkter. Her kan man bestemme $k = 2$ faktorer, idet antal parametre for $k = 2$ er

$$6 \cdot 3 - 2 \cdot 1/2 = 18 - 1 = 17.$$

Men hvis vi forsøger os med $k = 3$, er der tale om en reparametrisering, idet kriteriet her bliver

$$6 \cdot 7/2 = 21 > 6 \cdot 4 - 3 \cdot 2/2 = 24 - 3 = 21,$$

Da der er lighedstegn, er modellen ganske vist identificerbar, men vi kan ikke teste modellens tilpasningsevne, da der jo bliver perfekt tilpasning mellem data og model.

Selve likelihoodligningerne kan ikke løses eksplicit. Man er nødt til at 'gætte' på nogle udgangsværdier for parametrene, og så gradvis forbedre parameterværdierne, indtil de partielt afledede af log-likelihoodligningen er 0, eller - hvad der kommer ud på det samme - indtil log-likelihood ligningen når sin maksimale værdi. Det viser sig, at de vigtigste parametre, som skal sættes til fornuftige udgangsværdier, er kommunaliteterne, dvs. diagonalelementerne i $\mathbf{V}_F$.

Som ved principalkomponentmetoden kan man rotere det koordinatsystem, hvori faktorerne er repræsenteret. Faktormodellen er nemlig kun identificeret, hvis vi forlanger, at faktorerne er ukorrelerede. Dette krav giver ikke nødvendigvis den bedste fortolkning af faktorernes relative indflydelse på X 'erne. Lad således $\mathbf{A}$ være en ortogonal matrix af dimension $k \times k$, dvs. $\mathbf{A} \mathbf{A}^T = \mathbf{I}$. Hvis $\mathbf{F}$ transformeres over i $\mathbf{F}^*$ som $\mathbf{F}^* = \mathbf{A}^T \mathbf{F}$, eller $\mathbf{F} = \mathbf{A} \mathbf{F}^*$, får vi ifølge faktoranalysemodellen

$$\mathbf{X} = \mathbf{B} \mathbf{A} \mathbf{F}^* + \mathbf{E} ,$$

og dermed, når $\mathbf{B}^* = \mathbf{B} \mathbf{A}$

$$\mathbf{V}_X = \mathbf{B}^* \mathbf{V}_F^* \mathbf{B}^{*T} + \mathbf{V}_E .$$

Denne faktormodel er ækvivalent med den første, blot kræver vi ikke længere, at faktorerne $F_1^*, \dots, F_k^*$ er ukorrelerede.

Man kan også rotere F -koordinatsystemet, så de nye akser ikke er vinkelrette på hinanden, dvs. transformationsmatricen $\mathbf{A}$ ikke er ortogonal. Det kaldes på engelsk en 'oblique' (skæv) transformation. SAS-proceduren VARIMAX roterer ortogonalt, mens SAS-optionen CORMAX i PROC FACTOR roterer både ortogonalt og skævt.

11. Eksplorativ Faktor Analyse i SAS.

11.1. Regulære tilfælde.

Vi skal nu se, hvorledes man udfører en faktor analyse i SAS. Det er stadig PROC FACTOR, vi benytter, men med lidt andre options. SAS-programmet eksemplificeres stadig med de variable V24 - V32 fra ISSP 1989. I det første program benytter vi ML-estimation af parametrene og foretager en VARIMAX rotation, dvs. roterer koordinatsystemet ortogonalt. Programmet kan f.eks. se sådan ud:

```
1. libname eba 's:\eba-data';
2. title 'Factor analysis on ISSP 1989. All countries. ML-estimation. Varimax rotation';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v27>5 then delete;
12. if v28>5 then delete;
13. if v29>5 then delete;
14. if v30>5 then delete;
15. if v31>5 then delete;
16. if v32>5 then delete;
17. proc factor data=b
18.   method = ml
19.   priors = smc
20.   nfact = 2
21.   rotate = varimax
22.   flag = 0.5;
23. run;
24. quit;
```

Den første del af programmet, linie 1 - 16, er identisk med programmerne i Kapitel 7. Men i kaldet af PROC FACTOR er optionerne følgende:

(1) Option'en 'data = b', har samme betydning som i Kapitel 7.

(2) Optionen 'method = ml' i linie 18 betyder, at der benyttes ML-estimation. Denne estimationsmetode er iterativ, dvs. med udgangsværdi i nogle beregnede **udgangsværdier**, itererer SAS sig frem til estimerede parameterværdier, der tilfredsstiller likelihood ligningerne.

(3) Optionen 'prior = smc' i linie 19 betyder, at udgangsværdierne fastsættes ved, at udgangsværdierne for kommunaliteter sættes lig med de kvadrerede multiple korrelationskoefficienter mellem de enkelte variable og de øvrige 8 variable. Det har vist sig, at disse udgangsværdier,

bortset fra helt 'skæve' tilfælde, giver en hurtig konvergens til løsningerne af likelihood ligningerne.

(4) Optionen 'nfact = 2' i linie 20 betyder, som før, at antal ønskede faktorer sættes til 2.

(5) Optionen 'rotate = varimax' betyder, at koordinatsystemet roteres ortogonalt for at få så store korrelationer som muligt mellem de variable og den ene eller den anden faktor.

(6) 'flag = 0.5' har samme betydning, som i Kapitel 7, nemlig, at der sættes en '**' ved alle korrelationer større end 0.5. Samtidigt rundes faktorerne (automatisk) op til 100 gange deres størrelse, dvs. skal 'læses' som procenter.

Med optionen 'method = ml', kan man ikke i SAS analysere en kovariansmatrix, så i det følgende er det altid korrelationsmatricen, der analyseres.

De vigtigste dele af SAS-out'et fra dette program ser sådan ud:

```
Factor analysis on ISSP 1989. All countries. ML-estimation. Varimax rotation          Initial
Factor Method: Maximum Likelihood

Prior Communalities Estimates: SMC

      V24      V25      V26      V27      V28      V29      V30      V31      V32
0.117728  0.219241  0.220309  0.134460  0.222785  0.249457  0.439657  0.418069  0.176114
```

I den første boks vises den del af SAS output'et, hvor de valgte udgangsværdier for kommunaliteteterne, betegnet 'Prior Communalities Estimates' er vist.

Den næste boks viser de egenverdier, man får ved en opspaltning af kovariansmatricen baseret på udgangsværdierne for kommunaliteteterne.

```

Eigenvalue      1      2      3      4      5
Difference      2.8883  0.8526  0.3753  0.2472 -0.0674
Proportion      0.9060  0.2674  0.1177  0.0775 -0.0211
Cumulative      0.9060  1.1735  1.2912  1.3687  1.3476

Eigenvalue      6      7      8      9
Difference      0.0337  0.0860  0.0827
Proportion     -0.0590 -0.0696 -0.0965 -0.1225
Cumulative      1.2886  1.2190  1.1225  1.0000

2 factors will be retained by the NFACTOR criterion.
```

De to første egenverdier er klart større end de øvrige, så optionen 'NFACTOR = 2' er ganske velvalgt.

I den sidste del af SAS output'et vises nogle nøgletal fra de nødvendige iterationer for at bestemme ML-estimerne.

Iter	Criterion	Ridge	Change	Communalities
1	0.20755	0.000	0.24780	0.12181 0.40187 0.30749 0.11444 0.22337 0.24893 0.68746 0.52223 0.16570
2	0.20488	0.000	0.03526	0.13812 0.39694 0.32852 0.11435 0.20106 0.22794 0.68968 0.55749 0.15675
3	0.20479	0.000	0.00930	0.13872 0.40559 0.32702 0.11093 0.19964 0.22405 0.69899 0.55337 0.15486
4	0.20478	0.000	0.00282	0.13958 0.40693 0.32769 0.11111 0.19811 0.22330 0.69617 0.55591 0.15442
5	0.20478	0.000	0.00093	0.13975 0.40786 0.32762 0.11097 0.19793 0.22295 0.69707 0.55509 0.15435

Convergence criterion satisfied.

Det som står under 'Criterion' er ikke selve værdien af log-likelihoodfunktion, men et numerisk mål (kriterie) for, hvor tæt man er ved maksimum for likelihood funktionen.

Kriteriet 'Criterion' for, hvor tæt man er ved likelihoodfunktionens maksimum er imidlertid tæt forbundet med selve værdien af likelihoodfunktion.

Tæthedsfunktionen for matricen S af empiriske varianser og kovarianser blev udledt af den amerikanske statistiker Wishart, og bærer derfor for hans navn. Wishart-fordelingens tæthedsfunktion kan skrives

$$f(S) = K \cdot \det(S)^{\frac{1}{2}(n-p-1)} \cdot \exp\left(-\frac{1}{2}\text{tr}(\Sigma^{-1}S)\right) \cdot \det(\Sigma)^{-\frac{1}{2}n},$$

hvor K er en konstant, der er uafhængig af modellens parametre, n er antal variable, p er antal parametre, Σ er kovariansmatricen $\mathbf{V}_x$ med de sande værdier af varianser og kovarianser under modellen indsat og $\text{tr}(A)$ (for en symmetrisk matrix) er summen af leddene i matricens diagonal, kaldet 'sporet' eller 'trace' på engelsk. Jeg har her benyttet betegnelsen $\det(A)$ for determinanten af en matrix A.

Beregner man transformationen $-2 \ln L$ af likelihoodfunktion, hvor $L = f(S)$, får man fra Wishart fordelings tæthedsfunktion

$$-\frac{1}{2} \ln L = -\frac{1}{2} \ln f(S) = \text{tr}(\Sigma^{-1}S) + \ln(\det(\Sigma)) - (n-p-1) \ln(\det(S))$$

Den kriteriefunktion, som SAS benytter er

$$\text{Criterion} = \text{tr}(\Sigma^{-1}S) + \ln(\det(\Sigma)) - \ln(\det(S)) - n.$$

Der er altså tale om en 'omskalering' af $-2 \ln L$, som har det samme minimum som $-2 \ln L$. Faktoren $n - p - 1$ har at gøre med at ML-estimatoren for σ^2 i regressionsanalyse med p forklarende variable har nævneren n , mens den middeltrette estimator har nævneren $n - p - 1$. Grunden til at algoritmen søger efter et minimum for 'Criterion' er, at logaritmen til likelihoodfunktionen er ganget med -2 , så et maksimum bliver til et minimum.

Når SAS bruger en omskaleret værdi af $-2 \ln L$ er det fordi, som man let ser, at SAS-kriteriet 'Criterion' er lig med 0, hvis $S = \Sigma$, idet $\text{tr}(\Sigma^{-1}S)$ i så fald er lig med n .

'Change' viser hvor store ændringerne er i konvergenskriteriet. Desuden vises ændringerne i kommunaliteterne. Det fremgår, at kriteriet nogenlunde svarer til, at kommunaliteterne er bestemt med 3 korrekte decimaler.

I den næste boks vises den del af output, som vedrører testene for modellen og faktorværdierne før og efter en VARIMAX rotation.

Der testes først

$$H_0 : \text{Ingen fælles faktorer}$$

mod

$$H_A : \text{Mindste én fælles faktor.}$$

Her får man en transformeret kvotientteststørrelse på $z = 19953.2$ med 36 frihedsgrader, som selvfølgelig er vildt signifikant. Nul-hypotesen er her, at alle de variable er uafhængige, og alternativet, at der er en vis afhængighed, som kan forklares ved én eller flere faktorer.

Dette test har selvfølgelig ingen betydning i praksis. Desværre er det en svaghed ved SAS, at det all for ofte udskriver disse 'nonsens test'.

Der testes dernæst

$$H_0 : 2 \text{ faktorer er tilstrækkeligt}$$

mod

$$H_A : \text{Flere faktorer er nødvendige.}$$

Her bliver den transformerede kvotientteststørrelse på $z = 2729.3$ med 19 frihedsgrader, som også signifikant, men graden af tilpasning er åbenbart blevet stærkt forbedret. Nul-hypotesen er her, at en faktor model med 2 faktorer beskriver data, mod at der skal flere faktorer til for at beskrive data med en faktor model.

Significance tests based on 13334 observations:

Test of H0: No common factors.
vs HA: At least one common factor.

Chi-square = 19953.154 df = 36 Prob>chi**2 = 0.0001

Test of H0: 2 Factors are sufficient.
vs HA: More factors are needed.

Chi-square = 2729.292 df = 19 Prob>chi**2 = 0.0001

Dernæst vises faktorværdierne svarende til de 2 faktorer med de største egenværdier, både før og efter en VARIMAX-rotation. Her svarer rotationen til $\cos v = 0.937$ og $\sin v = -0.349$, eller $v = -20.4^\circ$, jvf. Kapitel 7.

Factor Pattern

	FACTOR1	FACTOR2	
V24	25	28	IMPORTANT: JOB SECURITY
V25	21	60 *	IMPORTANT: HIGH INCOME
V26	35	45	IMPORTANT: ADVANCEMENT
V27	22	25	IMPORTANT: LEISURE TIME
V28	41	18	IMPORTANT: INTERESTG JOB
V29	45	14	IMP.: INDEPENDENT WORK
V30	81 *	-21	IMP.: JOB HELPS PEOPLE
V31	73 *	-16	IMP.: JOB USEFUL F. SOC.
V32	37	14	IMP.:FLEXIBLE WRKG HOURS

Rotation Method: Varimax

Orthogonal Transformation Matrix

	1	2
1	0.93731	0.34851
2	-0.34851	0.93731

Rotated Factor Pattern

	FACTOR1	FACTOR2	
V24	14	35	IMPORTANT: JOB SECURITY
V25	-1	64 *	IMPORTANT: HIGH INCOME
V26	17	55 *	IMPORTANT: ADVANCEMENT
V27	12	31	IMPORTANT: LEISURE TIME
V28	32	31	IMPORTANT: INTERESTG JOB
V29	38	29	IMP.: INDEPENDENT WORK
V30	83 *	8	IMP.: JOB HELPS PEOPLE
V31	74 *	11	IMP.: JOB USEFUL F. SOC.
V32	30	26	IMP.:FLEXIBLE WRKG HOURS

Lige som ved principal komponent metoden finder også faktor analysen frem til, at spørgsmålene om, hvad jobbet gør for dig: Især V25 og V26, men også til dels V24 og V27 vægter højt med faktoren FACTOR2. På den anden side vægter de spørgsmål, som udtrykker, hvad godt, du kan gøre ved hjælp af dit jobbet, nemlig V30 og V31, højt med FACTOR1. Til gengæld vægter V28, V29 og V32 nogenlunde lige meget på de to faktorer, så disse variable er svære at placere med kun to faktorer i modellen.

Læg mærke til, at vi får et lidt andet resultat, end vi fandt i Kapitel 7, hvor vi analyserede de samme spørgsmål.

Hvis vi i stedet for benytter PROMAX rotations metoden, skal optionerne for PROC FACTOR skrives om på følgende måde:

```
proc factor data=b
  method = ml
  priors = smc
  nfact = 2
  rotate = promax
  flag = 0.5;
run;
```

Her er 'rotate = varimax' byttet ud med 'rotate = promax'. Det giver en lidt længere udskrift for rotationsdelen af output. Den første boks viser igen værdierne af FACTOR1 og FACTOR2 efter VARIMAX rotationen.

Prerotation Method: Varimax

Rotated Factor Pattern

	FACTOR1	FACTOR2	
V24	14	35	IMPORTANT: JOB SECURITY
V25	-1	64 *	IMPORTANT: HIGH INCOME
V26	17	55 *	IMPORTANT: ADVANCEMENT
V27	12	31	IMPORTANT: LEISURE TIME
V28	32	31	IMPORTANT: INTERESTG JOB
V29	38	29	IMP.: INDEPENDENT WORK
V30	83 *	8	IMP.: JOB HELPS PEOPLE
V31	74 *	11	IMP.: JOB USEFUL F. SOC.
V32	30	26	IMP.: FLEXIBLE WRKG HOURS

De 2 næste bokse viser en række tekniske mellemtrin vedr. de forskellige rotationer, f.eks. 'Procrustean Transformation Matrix' og 'Normalized Oblique Transformation Matrix', samt forskellige normaliseringer af faktorvægtene.

Rotation Method: Promax

Procrustean Transformation Matrix

	1	2
1	1.28687	-0.25041
2	-0.13815	1.71708

Normalized Oblique Transformation Matrix

	1	2
1	0.92388	0.21642
2	-0.46110	1.00961

Inter-factor Correlations

	FACTOR1	FACTOR2
FACTOR1	100 *	25
FACTOR2	25	100 *

Rotated Factor Pattern (Std Reg Coefs)

	FACTOR1	FACTOR2	
V24	10	34	IMPORTANT: JOB SECURITY
V25	-8	65 *	IMPORTANT: HIGH INCOME
V26	12	53 *	IMPORTANT: ADVANCEMENT
V27	9	30	IMPORTANT: LEISURE TIME
V28	29	27	IMPORTANT: INTERESTG JOB
V29	35	24	IMP.: INDEPENDENT WORK
V30	84 *	-4	IMP.: JOB HELPS PEOPLE
V31	74 *	0	IMP.: JOB USEFUL F. SOC.
V32	28	22	IMP.:FLEXIBLE WRKG HOURS

Reference Axis Correlations

	FACTOR1	FACTOR2
FACTOR1	100 *	-25
FACTOR2	-25	100 *

Rotation Method: Promax

Reference Structure (Semipartial Correlations)

	FACTOR1	FACTOR2	
V24	10	33	IMPORTANT: JOB SECURITY
V25	-8	63 *	IMPORTANT: HIGH INCOME
V26	11	51 *	IMPORTANT: ADVANCEMENT
V27	9	29	IMPORTANT: LEISURE TIME
V28	28	26	IMPORTANT: INTERESTG JOB
V29	34	23	IMP.: INDEPENDENT WORK
V30	82 *	-4	IMP.: JOB HELPS PEOPLE
V31	72 *	0	IMP.: JOB USEFUL F. SOC.
V32	27	21	IMP.:FLEXIBLE WRKG HOURS

Factor Structure (Correlations)			
	FACTOR1	FACTOR2	
V24	18	36	IMPORTANT: JOB SECURITY
V25	8	63 *	IMPORTANT: HIGH INCOME
V26	25	56 *	IMPORTANT: ADVANCEMENT
V27	17	32	IMPORTANT: LEISURE TIME
V28	36	34	IMPORTANT: INTERESTG JOB
V29	41	32	IMP.: INDEPENDENT WORK
V30	83 *	17	IMP.: JOB HELPS PEOPLE
V31	75 *	19	IMP.: JOB USEFUL F. SOC.
V32	33	29	IMP.: FLEXIBLE WRKG HOURS


De roterede faktorvægte er dog nogenlunde ens, og de afsluttende faktorvægte 'Factor Structure (Correlations)' afviger ikke meget fra, hvad vi fandt ved VARIMAX-rotationsmetoden. Den væsentligste forskel er mellem de egenverdier (FACTOR's), der er vist under overskriften 'Semipartial Correlations' og under overskriften 'Correlations'. Der er tale om en omnormering, hvor vi tager hensyn til variansen på de variable V24 til V32, idet egenverdierne under 'Semipartial Correlations' er næsten identiske med de FACTOR-værdier, der er vist under 'Std Reg Coefs', dvs. standardiserede regressions koefficienter. Disse sidste er simpelthen de koefficienter SAS beregner, når der normeres, så variansen på FACTOR's er 1. De værdier, der vises under 'Correlations' er desuden normeret, så variansen på V'erne alle er 1. Derved bliver de viste værdier af FACTOR1 og FACTOR2 rent faktisk lig med korrelationskoefficienterne mellem V'erne og de to faktorer.

Mest interessant er måske de nye værdier af FACTOR1 og FACTOR2 ved den skæve transformation (Normalized Oblique Transformation). Figuren neden for viser hvor de 9 punkter, svarende til V24 - V32, ligger i forhold til akserne (FACTOR1, FACTOR2) før den skæve transformation og efter den skæve transformation (NY FACTOR1, NY FACTOR2).

Man får de nye koordinater ud fra den 2 x 2 matrix som står under 'Normalized Oblique Transformation Matrix' i SAS output'et, nemlig som

$$\text{NY FACTOR1} = 0.92388 \text{ FACTOR1} + 0.21642 \text{ FACTOR2}$$

$$\text{NY FACTOR2} = -0.46110 \text{ FACTOR1} + 1.00961 \text{ FACTOR2}$$



Som det fremgår af figuren, kan man få den endnu bedre samling omkring akserne, dvs. en højere korrelation mellem de observerede variable og faktorerne, ved at rotere til akser, der ikke står vinkelret (ortogonalt) på hinanden. Husk her, at der allerede (ved en VARIMAX rotation) er roteret ortogonalt, så de to akser FACTOR1 og FACTOR2 giver en så god vinkelret tilpasning til datapunkterne, som muligt. Så den endnu bedre tilpasning til akserne NY FACTOR1 og NY FACTOR2, skyldes alene, at vi tillader en ikke-ortogonal rotering.

Man kan også prøve at medtage 3 faktorer, så skal programmet med PROMAX-rotation skrives:

```
proc factor data=b
  method = ml
  priors = smc
  nfact = 3
  rotate = promax
  flag = 0.5;
run;
```

I SAS-output'et neden for er vist den del, der vedrører teststørrelserne. Der er sket en væsentlig forbedring af modeltilpasningen, men modellen er stadig ikke i stand til at beskrive data tilfredsstillende.

```

Significance tests based on 13334 observations:

Test of H0: No common factors.
vs HA: At least one common factor.

Chi-square = 19953.154    df = 36    Prob>chi**2 = 0.0001


Test of H0: 3 Factors are sufficient.
vs HA: More factors are needed.

Chi-square = 1134.183    df = 12    Prob>chi**2 = 0.0001


```

Af denne boks fremgår det, at medtagelse af tre faktorer udvælger 3 sæt á 2 variable (hvis V26 regnes til FACTOR2), der korrelerer højt med hver sin factor. V25 og V26, der beskriver de egoistiske aspekter af jobbet. V28 og V29 beskriver de interessante aspekter ved jobbet, mens V30 og V31 beskriver de altruistiske aspekter.

Skal man beskrive resultatet af en faktor analyse af spørgsmål V24 til V32 grafisk, får man følgende graf, hvis vi betragter 2 faktorer og alt korrelerer med alt:




Hvis vi kun medtager de sammenhænge mellem de 9 observerede variable og de 2 signifikante faktorer, SAS-programmet peger på, dvs. hvor korrelationen er større end 0.5, får man det lidt mere enkle billede, vist i den næste graf.



På denne graf kan man se, at den latente variabel F1 har at gøre med, hvad jobbet kan gøre for dig, dvs. høj indkomst og gode advancementsforhold, mens den latente variable F2 beskriver hvad respondenterne ønsker at opnå via sit job, nemlig at hjælpe andre mennesker og at være nyttig for samfundet.

Hvis man medtager 3 faktorer, får man følgende graf, med den fortolkning, vi gav oven for:



11.2. Heywood tilfælde.

I visse ekstreme tilfælde, vil ML-estimerne for faktormodellens parametre ikke ligge inden for de specificerede parameterområder. Sædvanligvis er det kommunaliteterne - og dermed varianterne på restleddene - der falder uden for parameterområdet. Disse tilfælde kaldes Heywood-tilfælde efter den amerikanske statistiker, der første gang observerede og studerede fænomenet. For teorien for ML-estimer betyder det, at nogle ML-estimer falder på randen af det parameterområde, modellen foreskriver. Hermed er alle resultater vedr. ML-estimater og kvotienttests asymptotiske egenskaber ikke længere gyldige, så vi kan ikke vurdere en models tilpasningsevne til data, eller standard fejlen på ML-estimerne udfra de sædvanlige formler.

For at belyse, hvordan man i praksis identificerer et Heywood-tilfælde, betragter vi variabel V40 til V48 fra ISSP-undersøgelsen i 1985. Disse spørgsmål drejer sig om, hvilke emner de adspurgte mener er væsentlige for deres skoleuddannelse. Et uddrag af kodebogen er vist i den næste boks.

V40 School: Read with math

Q.15 And now a few questions about education. Here are some things that might be taught i school. How important is it that schools teach each of theses to 15 years old?

Q.15a Importance of things taught in school: Reading, writing and mathematics.

1. Essential, must be taught
2. Very important
3. Fairly important
4. Not very important
5. Not needed, should not be taught

V41 School: Sex education

Q.15b Importance of things taught in school: Sex education.

V42 School: Respect authority.

Q.15c Importance of things taught in school: Respect authority.

V43 School: History, literature, art.

Q.15d Importance of things taught in school: History, literature and the arts.

V44 School: Good justment.

Q.15e Importance of things taught in school: Ability to make one's own judgements.

V45 School: Job training

Q.15f Importance of things taught in school: Job training.

V46 School: Technology

Q.15g Importance of things taught in school: Science and technology.

V47 School: Concern for others

Q.15h Importance of things taught in school: Concern for minorities and the poor.

V48 School: Disciplin, order

Q.15i Importance of things taught in school: Disciplin and orderliness.

SAS-programmet for en faktoranalyse af disse 9 variable ser sådan ud:

```
libname eba 's:\eba-date';
title 'ISSP 1885 data faktoranalyse på variabel v40 til v48';
data a;
keep v40-v48;
data b;
set a;
if v40>5 then delete;
if v41>5 then delete;
if v42>5 then delete;
if v43>5 then delete;
if v44>5 then delete;
if v45>5 then delete;
if v46>5 then delete;
if v47>5 then delete;
if v48>5 then delete;
if v40=0 then delete;
if v41=0 then delete;
if v42=0 then delete;
if v43=0 then delete;
if v44=0 then delete;
if v45=0 then delete;
if v46=0 then delete;
if v47=0 then delete;
if v48=0 then delete;
proc factor data=b
  method = ml
  priors = smc
  nfact = 2
  rotate = varimax
  round
  flag = 0.5
;
var v40-v48;
run;
quit;
```

Det væsentlige SAS-output fra denne SAS-kørsel bliver

Initial Factor Method: Maximum Likelihood

Prior Communalities Estimates: SMC

v40	v41	v42	v43	v44	v45	v46
0.06336876	0.08598355	0.45092857	0.26429743	0.23169534	0.19495692	0.25860247
v47	v48					
0.27575655	0.47225748					

Preliminary Eigenvalues: Total = 3.5103851 Average = 0.39004279

	Eigenvalue	Difference	Proportion	Cumulative
1	3.13829840	2.03851395	0.8940	0.8940
2	1.09978444	0.90726152	0.3133	1.2073
3	0.19252292	0.06655921	0.0548	1.2621
4	0.12596371	0.17095506	0.0359	1.2980
5	-.04499135	0.04233448	-0.0128	1.2852
6	-.08732583	0.09705310	-0.0249	1.2603
7	-.18437893	0.11077581	-0.0525	1.2078
8	-.29515475	0.13917876	-0.0841	1.1237
9	-.43433351		-0.1237	1.0000

2 factors will be retained by the NFACTOR criterion.

Iteration	Criterion	Ridge	Change	Communalities
1	0.1281866	0.0000	0.3884	0.05848 0.07951 0.44675 0.35650 0.31479 0.22508
0.34111	0.34220	0.86069		
2	0.1206839	0.0000	0.2189	0.05773 0.08570 0.38828 0.35598 0.31132 0.21675
.34198	0.34044	1.07958		

ERROR: Communalities greater than 1.0.

Som det fremgår er estimeret for den sidste Kommunalitet over 1 så SAS stopper her, idet vi har identificeret et Heywood-tilfælde.

I SAS har man nu to options. Den første består i at anvende optionen 'Heywood', som vist i den næste program stump. Ved denne option begrænser man kommunaliteterne til højst at have værdien 1. Det svarer til, at vi søger et maximum for log-likelihood funktionen på randen af det tilladte parameterområde. I programmet, vist neden for, er således tilføjet ordet 'heywood' blandt optionerne i kaldet af Proc Factor.

```
libname eba 's:\eba-date';
title 'ISSP 1885 data faktoranalyse på variabel v40 til v48';
data a;
keep v40-v48;
data b;
set a;
if v40>5 then delete;
if v41>5 then delete;
if v42>5 then delete;
if v43>5 then delete;
if v44>5 then delete;
if v45>5 then delete;
if v46>5 then delete;
if v47>5 then delete;
if v48>5 then delete;
if v40=0 then delete;
if v41=0 then delete;
if v42=0 then delete;
if v43=0 then delete;
if v44=0 then delete;
if v45=0 then delete;
if v46=0 then delete;
if v47=0 then delete;
if v48=0 then delete;
proc factor data=b
  method = ml
  priors = smc
  nfact = 2
  heywood
  rotate = varimax
  round
  flag = 0.5
;
var v40-v48;
run;
quit;
```

Dette giver SAS-outputtet, vist i de to næste bokse:

2 factors will be retained by the NFACTOR criterion.

Iteration	Criterion	Ridge	Change	Communalities					
1	0.1281866	0.0000	0.3884	0.05848	0.07951	0.44675	0.35650	0.31479	0.22508
				0.34111	0.34220	0.86069			
2	0.1224055	0.0000	0.1393	0.05800	0.08345	0.40953	0.35617	0.31258	0.21978
				0.34166	0.34108	1.00000			
3	0.1211278	0.0000	0.0292	0.05805	0.09099	0.43872	0.35649	0.31285	0.21757
				0.34031	0.34065	1.00000			
4	0.1211272	0.0000	0.0006	0.05823	0.09140	0.43877	0.35631	0.31314	0.21774
				0.34011	0.34002	1.00000			

Convergence criterion satisfied.

Initial Factor Method: Maximum Likelihood

Significance Tests Based on 5848 Observations

Test	DF	Chi-Square	Pr > ChiSq
H0: No common factors	36	9390.9273	<.0001
HA: At least one common factor			
H0: 2 Factors are sufficient	19	707.6051	<.0001
HA: More factors are needed			

Initial Factor Method: Maximum Likelihood

Factor Pattern

	Factor1	Factor2
v40	13	20
v41	3	30
v42	65 *	11
v43	13	58 *
v44	20	52 *
v45	28	37
v46	18	55 *
v47	29	51 *
v48	100 *	0

```

Orthogonal Transformation Matrix

              1              2
1      0.10533      0.99444
2      0.99444     -0.10533

```

Rotated Factor Pattern

	Factor1	Factor2
v40	22	11
v41	30	0
v42	18	64 *
v43	59 *	6
v44	54 *	14
v45	40	24
v46	57 *	12
v47	53 *	23
v48	11	99 *

Vi kan også bruge optionen 'ultra', som vist i næste programstump. Her lægges ingen begrænsninger på værdien af kommunaliteterne. Det svarer til at bestemme maximum for log-likelihood funktionen, selv om maximum ligger uden for det tilladte parameter område. Det giver nogle mærkelige egenværdier og desuden én eller flere negative varianser på restleddene. Og dette er jo en hel del for viderekommende at fortolke.

```
libname eba 's:\eba-date';
title 'ISSP 1885 data faktoranalyse på variabel v40 til v48';
data a;
keep v40-v48;
data b;
set a;
if v40>5 then delete;
if v41>5 then delete;
if v42>5 then delete;
if v43>5 then delete;
if v44>5 then delete;
if v45>5 then delete;
if v46>5 then delete;
if v47>5 then delete;
if v48>5 then delete;
if v40=0 then delete;
if v41=0 then delete;
if v42=0 then delete;
if v43=0 then delete;
if v44=0 then delete;
if v45=0 then delete;
if v46=0 then delete;
if v47=0 then delete;
if v48=0 then delete;
proc factor data=b
  method = ml
  priors = smc
  nfact = 2
  ultra
  rotate = varimax
  round
  flag = 0.5
;
var v40-v48;
run;
quit;
```

Dette program giver følgende SAS-output.

2 factors will be retained by the NFACTOR criterion.

Iteration	Criterion	Ridge	Change	Communalities					
1	0.1281866	0.0000	0.3884	0.05848	0.07951	0.44675	0.35650	0.31479	0.22508
				0.34111	0.34220	0.86069			
2	0.1206839	0.0000	0.2189	0.05773	0.08570	0.38828	0.35598	0.31132	0.21675
				0.34198	0.34044	1.07958			
3	0.1178987	0.0000	0.2234	0.05778	0.08986	0.34156	0.34783	0.31445	0.21365
				0.33868	0.33982	1.30297			
4	0.1165473	0.0000	0.2471	0.05785	0.09187	0.30472	0.34073	0.31751	0.21367
				0.33429	0.34018	1.55007			
5	0.1158802	0.0000	0.2663	0.05784	0.09260	0.27713	0.33535	0.31977	0.21467
				0.33090	0.34062	1.81632			
6	0.1155707	0.0000	0.2680	0.05782	0.09276	0.25722	0.33163	0.32126	0.21583
				0.32850	0.34092	2.08428			
7	0.1154385	0.0000	0.2457	0.05780	0.09269	0.24331	0.32913	0.32220	0.21681
				0.32688	0.34111	2.32994			
8	0.1153867	0.0000	0.2024	0.05778	0.09256	0.23393	0.32748	0.32278	0.21755
				0.32581	0.34122	2.53230			
9	0.1153679	0.0000	0.1497	0.05777	0.09245	0.22784	0.32643	0.32314	0.21806
				0.32513	0.34129	2.68202			
10	0.1153615	0.0000	0.1007	0.05776	0.09237	0.22404	0.32578	0.32336	0.21839
				0.32470	0.34134	2.78276			
11	0.1153594	0.0000	0.0630	0.05775	0.09231	0.22176	0.32538	0.32349	0.21859
				0.32445	0.34137	2.84572			
12	0.1153587	0.0000	0.0374	0.05775	0.09228	0.22043	0.32516	0.32357	0.21871
				0.32429	0.34139	2.88311			
13	0.1153585	0.0000	0.0215	0.05774	0.09226	0.21968	0.32503	0.32361	0.21878
				0.32421	0.34140	2.90461			
14	0.1153584	0.0000	0.0121	0.05774	0.09225	0.21925	0.32495	0.32364	0.21882
				0.32416	0.34141	2.91674			
15	0.1153584	0.0000	0.0068	0.05774	0.09224	0.21902	0.32491	0.32365	0.21884
				0.32413	0.34141	2.92350			
16	0.1153584	0.0000	0.0037	0.05774	0.09224	0.21889	0.32489	0.32366	0.21885
				0.32411	0.34142	2.92725			
17	0.1153584	0.0000	0.0021	0.05774	0.09224	0.21881	0.32488	0.32367	0.21886
				0.32411	0.34142	2.92932			
18	0.1153584	0.0000	0.0011	0.05774	0.09224	0.21877	0.32487	0.32367	0.21886
				0.32410	0.34142	2.93046			
19	0.1153584	0.0000	0.0006	0.05774	0.09224	0.21875	0.32486	0.32367	0.21886
				0.32410	0.34142	2.93109			

Convergence criterion satisfied.

Significance Tests Based on 5848 Observations

Test	DF	Chi-Square	Pr > ChiSq
H0: No common factors	36	9390.9273	<.0001
HA: At least one common factor			
H0: 2 Factors are sufficient	19	673.9044	<.0001
HA: More factors are needed			

Factor Pattern

	Factor1	Factor2
v40	1	24
v41	-2	30
v42	16	33
v43	-1	57 *
v44	1	57 *
v45	3	46
v46	1	57 *
v47	4	58 *
v48	83 *	29

Rotation Method: Varimax

Orthogonal Transformation Matrix

	1	2
1	-0.19707	0.98039
2	0.98039	0.19707

Rotated Factor Pattern

	Factor1	Factor2
v40	23	6
v41	30	3
v42	29	22
v43	56 *	11
v44	56 *	12
v45	45	12
v46	56 *	12
v47	56 *	15
v48	12	87 *

Fortolkningen af resultater ved at bruge optionerne: 'heywood' og 'ultra' kræver megen erfaring med analyser af factor analyse output. Dette ligger derfor uden for rammerne af dette kursus.

12. Om skaleringer i Linear Structural Models.

En ligning i PROC FACTOR eller i PROC CALIS kan f.eks. se sådan ud:

$$V1 = 0.871 \cdot F1 + E1 .$$

Det betyder i SAS-sprog, at den observerbare eller manifeste variabel V1 er knyttet sammen med den latente variabel F1 som en lineær sammenhæng, mens den del af variationen i V1, der ikke forklares af F1, betegnes restledsvariablen E1. Hvis F1 og E1 er ukorrelerede, og alle variable har middelværdi 0, (som man i reglen antager, eller **kan** antage), kan man direkte beregne denne del af kovariansstrukturen som

$$\text{var}[V1] = (0.871)^2 \text{var}[F1] + \text{var}[E1] ,$$

idet $\text{cov}(F1, E1) = 0$. Variansen af V1 er således ganske enkelt opdelt i $\text{var}[F1]$ ganget med kvadratet på koefficienten i den lineære ligning, og restledsvariansen $\text{var}[E1]$.

Koefficienten i den lineære ligning kan fortolkes på følgende vis. Gentager vi ligningen oven for med en vilkårlig konstant b, dvs.

$$V1 = b \cdot F1 + E1 ,$$

er det spørgsmålet om b kan fortolkes i en covarians-sammenhæng. Ved direkte beregning får man

$$\text{cov}(V1, F1) = \text{cov}(bF1 + E1, F1) = b\text{var}[F1] + 0 ,$$

da F1 og E1 er ukorrelerede. Heraf følger, at

$$b = \frac{\text{cov}(V1, F1)}{\text{var}[F1]} .$$

Skal dette udtrykkes ved en korrelationskoefficient, får man

$$b = \frac{\text{cov}(V1, F1)}{\sqrt{\text{var}[F1] \cdot \text{var}[V1]}} \cdot \frac{\sqrt{\text{var}[V1]}}{\sqrt{\text{var}[F1]}} ,$$

eller

Koefficienten b i den strukturelle ligning er altså en skaleret udgave af korrelationskoefficienten mellem de to variable V1 og F1. Skaleringen skal naturligvis blot tage højde for, hvordan den observerbare variabel V1 er skaleret, og hvordan

$$b = \rho_{V1F1} \frac{\sigma_{V1}}{\sigma_{F1}} .$$

vi har valgt at skalere den latente variabel F1. Hvis man skalerer den latente variabel sådan, at $\text{var}[F1] = 1$, får vi

$$b = \rho_{V1F1} \cdot \sigma_{V1} .$$

I målingsmodellen i Kapitel 18 er det denne skalering, der benyttes. Hvis man skalerer så $\text{var}[V1] = 1$ bliver $\sigma_{V1} = 1$, og koefficienten b ændres til koefficienten b^* , defineret som

$$b^* = \rho_{V1F1} ,$$

dvs. korrelationskoefficienten mellem den manifeste og den latente variable.

I SAS-output fra PROC CALIS benævnes koefficienterne b^* 'Standardized Coefficients'.

Det er vigtigt at bemærke, at hvis man standardiserer så variansen på de manifeste variable bliver 1, skal koefficienten til restleddet E ganges med en konstant, svarende til at ligningen 'ganges igennem' med $1/\sigma_{V1}$ i eksemplet her.

Man kan sammenligne dette med en almindelig lineær regressionsanalyse, hvor både den forklarende variabel X og responsvariablen Y er stokastiske. Det svarer til modellen

$$Y = \beta X + e , \quad e \sim N(0, \sigma^2) ,$$

hvor regressionskoefficienten β har formen

$$\beta = \rho_{XY} \frac{\sigma_Y}{\sigma_X} .$$

Så det forekommer ret klart, hvordan en koefficient i en strukturel SAS-ligning skal fortolkes, nemlig enten som regressionsparameteren i den tilsvarende regressionsmodel mellem de variable $V1$ og $F1$, eller som en skaleret korrelationskoefficient, på samme måde, som β i regressionsanalysen er en skaleret version af korrelationskoefficienten. Til gengæld vises selve korrelationskoefficienten (b^*) også i SAS-output'et.

Det er vigtigt at holde rede på disse skaleringer. Korrelationskoefficienter er tal mellem 0 og 1, dvs. i princippet skalauafhængige. Regressionskoefficienter er udtryk for én variabels relative ændring i forhold til en anden, og afhænger derfor på afgørende vis af skaleringen af de indgående variable.


13. Polyseriale korrelationskoefficienter.

Mange variable har som responskategorier tallene fra 1 til 4, eller fra 1 til 5, svarende til f.eks. svarmulighederne:

1. Meget enig.
2. Enig.
3. Hverken eller.
4. Uenig.
5. Meget uenig.

Her kan man så blot benytte de hele tal, svarende til svarkategorierne, til at danne korrelationer. Ofte får man imidlertid et bedre resultat, hvis man forestiller sig, at de 5 svar er udtryk for, at en latent variabel u , der udtrykker ens holdning til spørgsmålet, overskrider visse tærskelværdier t_1 , t_2 , t_3 og t_4 . Da korrelationskoefficienter jo mest meningsfyldt er knyttet til normalfordelte stokastiske variable, skal vi antage, at u er standardiseret normalfordelt. Svaret 5 gives derfor, hvis $u < t_1$, svaret 4, hvis $t_1 < u < t_2$, osv op til $u > t_4$, der giver svaret 1. Man kunne derfor måske få en bedre scoring af svarkategorierne ved at referere til en sådan bagvedliggende standardiseret normalfordeling.

Hvis h_1 , h_2 , h_3 , h_4 og h_5 er de marginale hyppigheder af 5, 4, 3, 2 og 1 svar i datamaterialet, og $H_1 = h_1$, $H_2 = h_1 + h_2$, $H_3 = h_1 + h_2 + h_3$, $H_4 = h_1 + h_2 + h_3 + h_4$ og $H_5 = 1$, de tilsvarende kumulerede hyppigheder, kan man lave tegningen



Det fremgår, at en rimelig måde at score svarmulighederne på som

$$u_5 = \Phi^{-1}\left(\frac{h_1}{2}\right),$$

$$u_4 = \Phi^{-1}\left(H_1 + \frac{h_2}{2}\right),$$

$$u_3 = \Phi^{-1}\left(H_2 + \frac{h_3}{2}\right),$$

$$u_2 = \Phi^{-1}\left(H_3 + \frac{h_4}{2}\right)$$

og

$$u_1 = \Phi^{-1}\left(H_4 + \frac{h_5}{2}\right)$$

Korrelationskoefficienter, dannet ud fra de således konstruerede u 'er, kaldes polyseriale korrelationskoefficienter.

Metoden, vist oven for, er egentlig ikke den helt rigtige. Men den kommer dels tæt på det rigtige resultat, og viser i det mindste grundidéen. For at danne de rigtige polyseriale korrelationskoefficienter for to variable skal man opstille hele likelihoodfunktionen for den kontingenstabel, der dannes af de fem svarkategorier, dvs. hvor antallet a_{ij} i celle (i,j) er dem, der har svaret i på det første spørgsmål og j på det andet spørgsmål. Denne skal så udtrykkes ved den to-dimensionale normalfordeling for de latente u 'er for de to variable, og herfra kan så de polyseriale korrelationskoefficienter bestemmes ved ML-estimation i multinomialfordelingen for kontingenstabellen.

14. Principalkomponentanalyse og faktor analyse med polyseriale korrelationskoefficienter.

PROC FACTOR i SAS kan ikke direkte beregne de polyseriale korrelationskoefficienter i forbindelse med kaldet af proceduren. Man kan imidlertid lave denne, ganske vist lidt omstændelige, men dog praktisk mulige, beregningsmåde i SAS. Følger vi metoden, foreslået i Kapitel 13, skal man skrive programmet, vist i boksen neden for.

```

1. libname eba 'S:\eba-data';
2. title 'ISSP 1989. Polyseriale koefficienter. Principal component analyse.';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v27>5 then delete;
12. if v28>5 then delete;
13. if v29>5 then delete;
14. if v30>5 then delete;
15. if v31>5 then delete;
16. if v32>5 then delete;
17. proc freq data=b noprint;
18. table v24/out=d24;
19. data dn24;
20. set d24;
21. kum+percent/100;
22. if v24=1 then kum1=kum/2;
23. kum2=(kum+lag(kum))/2;
24. k=sum(kum1,kum2);
25. u=probit(k);
26. proc print data=dn24;

.....

27. proc freq data=b noprint;
28. table v32/out=d32;
29. data dn32;
30. set d32;
31. kum+percent/100;
32. if v32=1 then kum1=kum/2;
33. kum2=(kum+lag(kum))/2;
34. k=sum(kum1,kum2);
35. u=probit(k);
36. proc print data=dn32;
37. run;
38. quit;

```

Data set 'a', baseret på ISSP-databasen for 1989, indlæses, som vist i Kapitel 1, i programlinierne 1 til 5. I linierne 6 til 16 renses data på sædvanligvis for ubesvarede spørgsmål. Det rensede data set kaldes 'b'.

I programlinierne 17 og 18 dannes et output sæt, kaldet 'd24'. Dette dataset indeholder, gennem kaldet af PROC FREQ og optionen 'out = d24' antal procenter, kumulerede antal og kumulerede procenter for hver af de 5 svarkategorier på spørgsmål V24. I de næste programlinier, linie 19 til 23 beregnes de kumulerede andele 'kum+percent/100' og midtpunkterne mellem de kumulerede andele: 'kum1=kum/2' for V24 = 1 og 'kum2=(kum+lag(kum))/2' for V24 = 2 til V24 = 5. (De tilsvarende beregninger for V32 sker i linierne 29 til 33.) Endelig

beregnes i programlinie 24 (34) for den værdi k , som den inverse af Φ skal beregnes af. Den inverse af den normerede normalfordelings fordelingskurve, dvs. transformationen Φ^{-1} , betegnes i reglen i matematisk statistik som 'probit', så i SAS-sprog skal vi blot skrive 'u = probit(k)'. Dette sker i linie 25 for V24 og i linie 35 for V32. De beregnede størrelser udskrives i linie 26 for V24 og i linie 36 for V34.

SAS output fra dette program ser sådan ud:

ISSP 1989. Polyseriale koefficienter. Principal component analyse.								
OBS	V24	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	7894	59.2020	0.59202	0.29601	.	0.29601	-0.53591
2	2	4575	34.3108	0.93513	.	0.76357	0.76357	0.71785
3	3	590	4.4248	0.97938	.	0.95725	0.95725	1.71965
4	4	214	1.6049	0.99543	.	0.98740	0.98740	2.23834
5	5	61	0.4575	1.00000	.	0.99771	0.99771	2.83554
OBS	V25	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	3458	25.9337	0.25934	0.12967	.	0.12967	-1.12796
2	2	7321	54.9048	0.80838	.	0.53386	0.53386	0.08498
3	3	2003	15.0217	0.95860	.	0.88349	0.88349	1.19263
4	4	505	3.7873	0.99648	.	0.97754	0.97754	2.00538
5	5	47	0.3525	1.00000	.	0.99824	0.99824	2.91782
OBS	V26	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	4299	32.2409	0.32241	0.16120	.	0.16120	-0.98952
2	2	6651	49.8800	0.82121	.	0.57181	0.57181	0.18098
3	3	1650	12.3744	0.94495	.	0.88308	0.88308	1.19053
4	4	634	4.7548	0.99250	.	0.96873	0.96873	1.86240
5	5	100	0.7500	1.00000	.	0.99625	0.99625	2.67380
OBS	V27	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	1585	11.8869	0.11887	0.059435	.	0.05943	-1.55954
2	2	4930	36.9732	0.48860	.	0.30373	0.30373	-0.51369
3	3	4116	30.8685	0.79729	.	0.64294	0.64294	0.36634
4	4	2377	17.8266	0.97555	.	0.88642	0.88642	1.20770
5	5	326	2.4449	1.00000	.	0.98778	0.98778	2.25000
OBS	V28	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	6565	49.2350	0.49235	0.24618	.	0.24618	-0.68658
2	2	5952	44.6378	0.93873	.	0.71554	0.71554	0.56964
3	3	609	4.5673	0.98440	.	0.96156	0.96156	1.76914
4	4	178	1.3349	0.99775	.	0.99108	0.99108	2.36873
5	5	30	0.2250	1.00000	.	0.99888	0.99888	3.05510
OBS	V29	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	4445	33.3358	0.33336	0.16668	.	0.16668	-0.96737
2	2	6106	45.7927	0.79129	.	0.56232	0.56232	0.15686
3	3	1954	14.6543	0.93783	.	0.86456	0.86456	1.10102
4	4	750	5.6247	0.99408	.	0.96595	0.96595	1.82437
5	5	79	0.5925	1.00000	.	0.99704	0.99704	2.75192

ISSP 1989. Polyseriale koefficienter. Principal component analyse.

OBS	V30	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	3084	23.1288	0.23129	0.11564	.	0.11564	-1.19705
2	2	6384	47.8776	0.71006	.	0.47068	0.47068	-0.07357
3	3	2856	21.4189	0.92425	.	0.81716	0.81716	0.90459
4	4	850	6.3747	0.98800	.	0.95613	0.95613	1.70741
5	5	160	1.1999	1.00000	.	0.99400	0.99400	2.51216
OBS	V31	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	3419	25.6412	0.25641	0.12821	.	0.12821	-1.13491
2	2	6408	48.0576	0.73699	.	0.49670	0.49670	-0.00827
3	3	2576	19.3190	0.93018	.	0.83358	0.83358	0.96842
4	4	767	5.7522	0.98770	.	0.95894	0.95894	1.73851
5	5	164	1.2299	1.00000	.	0.99385	0.99385	2.50344
OBS	V32	COUNT	PERCENT	KUM	KUM1	KUM2	K	U
1	1	2385	17.8866	0.17887	0.089433	.	0.08943	-1.34425
2	2	4922	36.9132	0.54800	.	0.36343	0.36343	-0.34930
3	3	3464	25.9787	0.80778	.	0.67789	0.67789	0.46181
4	4	2145	16.0867	0.96865	.	0.88822	0.88822	1.21711
5	5	418	3.1348	1.00000	.	0.98433	0.98433	2.15262

Søjlerne 'KUM' og 'K' viser for hver af de 5 mulige svarkategorier 'KUM' = den kumulerede andel af svar i denne kategori, og 'K' lig med værdierne af de ved formlerne

$$h_1/2, H_1 + h_2/2, \dots, H_4 + h_5/2,$$

beregnete værdier. I søjlen 'U' er vist værdierne af $\Phi(K)$, dvs. de værdier de polyseriale korrelationskoefficienter skal beregnes ud fra.

Desværre er man nødt til at kopiere de fundne u-værdier 'i hånden' til et nyt data sæt, hvis man ønsker en principal komponentanalyse af de 'nye' variable, u'erne. Man skal her skrive programmet:

```

1. libname eba 'S:\eba-data';
2. title 'ISSP 1989. Polyseriale koefficienter. Principal komponent metode.';
3. data a;
4. set eba.d89um;
5. keep v24-v32;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v27>5 then delete;
12. if v28>5 then delete;
13. if v29>5 then delete;
14. if v30>5 then delete;
15. if v31>5 then delete;
16. if v32>5 then delete;
17. data bb;
18. set b;
19. if v24=1 then u24=-0.536;
20. if v24=2 then u24=0.718;
21. if v24=3 then u24=1.720;
22. if v24=4 then u24=2.238;
23. if v24=5 then u24=2.836;
24. if v25=1 then u25=-0.128;
25. if v25=2 then u25=0.085;
26. if v25=3 then u25=1.192;
27. if v25=4 then u25=2.005;
28. if v25=5 then u25=2.918;

.....

29. if v32=1 then u32=-1.344;
30. if v32=2 then u32=-0.349;
31. if v32=3 then u32=0.462;
32. if v32=4 then u32=1.217;
33. if v32=5 then u32=2.153;
34. proc factor data=bb
35.  method = prin
36.  priors = one
37.  nfact = 2
38.  rotate = varimax
39.  flag= 0.5;
40. var u24-u32;
41. run;
42. quit;

```

I programlinierne 19 til 33 omdannes værdierne af V24 til V32 til de u-værdier, vi fandt i det forrige program.

I programlinie 40 får SAS ordre til at bruge u-værdierne, defineret i programlinierne 19 til 33, til egenværdi-dekomponeringen af korrelationsmatricen.

Output fra kørslen af dette program ser således ud:

```
ISSP 1989. Polyseriale koefficienter. Principal komponent metode.

1          2          3          4          5
Eigenvalue      2.6821      1.3259      1.0991      0.9474      0.7637

2 factors will be retained by the NFACTOR criterion.

Rotation Method: Varimax

Orthogonal Transformation Matrix

          1          2
1      0.87197    0.48956
2     -0.48956    0.87197

Rotated Factor Pattern

          FACTOR1    FACTOR2
U24          9        59 *
U25         -8        80 *
U26         25        65 *
U27         26        34
U28         55 *       25
U29         63 *       18
U30         80 *       -1
U31         77 *        1
U32         51 *       16

Variance explained by each factor

          FACTOR1    FACTOR2
2.357061    1.650944

Final Communalities Estimates: Total = 4.008004

          U24          U25          U26          U27          U28          U29          U30          U31          U32
0.354253    0.654101    0.481343    0.187233    0.365662    0.432521    0.647573    0.595310    0.290009
```

Hvis man sammenligner med resultatet af at bruge de direkte korrelationskoefficienter, som beskrevet i Kapitel 7, kan man se, at resultaterne ikke har ændret sig mærkbart. Ved en 5-punkts svarskala kan man altså i mange tilfælde nå fornuftige resultater, uden at benytte polyserielle korrelationskoefficienter. Det svarer nogenlunde til almindelige erfaringer. Men det er vigtigt at huske på, at de 5 svarkategorier skal være konstrueret verbalt, så de danner en skala fra det meget positive/enige til det meget negative/uenige alternativ. Desuden skal respondenterne naturligvis også opfatte de 5 svarkategorier som en skala.

Også for en eksplorativ faktor analyse, får man tilsvarende omtrent ens resultater ved at en analyse udført direkte på korrelationsmatricen mellem de oprindelige variable og ved at analysere matricen af polyserielle korrelationskoefficienter. Her ser programmet således ud:

```
libname eba 'S:\eba-data';
title 'ISSP 1989. Polyseriale koefficienter. Principal komponent metode.';
data a;
set eba.d89um;
keep v24-v32;
data b;
set a;
if v24>5 then delete;

.....

data bb;
set b;
if v24=1 then u24=-0.536;
if v24=2 then u24=0.718;
if v24=3 then u24=1.720;
if v24=4 then u24=2.238;
if v24=5 then u24=2.836;

.....

if v32=1 then u32=-1.344;
if v32=2 then u32=-0.349;
if v32=3 then u32=0.462;
if v32=4 then u32=1.217;
if v32=5 then u32=2.153;
proc factor data=bb
  method = ml
  priors = smc
  nfact = 2
  rotate = promax
  flag= 0.5
;
var u24-u32;
run;
quit;
```

De vigtigste dele af SAS-output'et bliver

Significance tests based on 13334 observations:

Test of H0: No common factors.
vs HA: At least one common factor.

Chi-square = 19932.709 df = 36 Prob>chi**2 = 0.0001

Test of H0: 2 Factors are sufficient.
vs HA: More factors are needed.

Chi-square = 2703.916 df = 19 Prob>chi**2 = 0.0001

Rotation Method: Promax

Factor Structure (Correlations)

	FACTOR1	FACTOR2
U24	19	35
U25	4	51 *
U26	26	57 *
U27	18	31
U28	37	41
U29	43	39
U30	84 *	20
U31	75 *	22
U32	34	30


Også her får vi stort set de samme resultater som ved at regne direkte på de observerede variable.

15. Stianalyse


Stianalyse er en statistisk metode, hvor man forsøger at fortolke korrelationerne, dvs. afhængighederne mellem en række variable, ved hjælp af et stidiagram, hvor nogle variable antages at have indflydelse fremad i diagrammet på andre variable. Jvf. diagrammet neden for.

Det er ikke usædvanligt, at man fortolker disse sammenhænge fremad, specielt hvor de variable, fremad i diagrammet, er observeret til senere tidspunkter, end de første, som en **kausal** sammenhæng, dvs en årsagssammenhæng. Begrebet kausalitet er imidlertid et meget kompliceret begreb, som man skal være uhyre varsom med at anvende. Der er utallige eksempler i statistikkens brogede historie, hvor korrelationer er blevet fortolket som årsagssammenhænge. Det mest berømte eksempel er fra starten af dette århundrede, hvor man fandt en overraskende stærk korrelation mellem antal børnefødsler og antal observerede storke i Skåne. Nu er der jo mere mellem himmel og jord, end man går og tror, men alligevel

For at gøre det hele mere konkret: Antag at vi har fundet en række statistisk signifikante korrelationer mellem de nogle typiske 'baggrundsvariable' V3 til V6, som køn, alder, urbanisering (dvs. om man bor i København, Københavns forstæder, de tre store byer - Odense, Århus, Aalborg -, Byer iøvrigt eller på Landet) og uddannelse. V1 og V2 er på den anden siden 'afledte' variable, som f.eks. Holdning til EU eller Miljøbevisthed. Hvis der er korrelationer/afhængighed mellem alle de 6 variable, ville et diagram til beskrivelse af afhængighederne se således ud.



Man kunne også tænke sig, at korrelationer mellem V3 og V1, V5 og V1 samt mellem V6 og V1 er insignifikante. Det ville give stidiagrammet vist den næste figur.



Læg mærke til, at der er linier mellem alle de fire baggrundsvariable. Det betyder, at vi ikke interesserer os for, om der evt. er sammenhænge mellem disse 4 variable. Den væsentligste oplysning, man kan aflæse af diagrammet, er, at V3, V5 og V6 kun påvirker V1 via V2, mens V4 både påvirker V1 via V2 og desuden direkte.

Det er denne type stidiagrammer, vi skal interessere os for i det næste kapitel og i Kapitel 19.

16. Stianalyse med manifeste variable

Vi skal anvende stianalyse på nogle af de variabelgrupper, vi allerede har arbejdet med samt nogle spørgsmål fra gruppen V68 til V74, der drejer sig om respondenternes arbejdsbetingelser.

Fra spørgsmålene vedrørende respondenternes vurdering af de forskellige aspekter af deres job, fandt vi to faktorer 'Good Job' og 'Interesting Job', der var baseret på henholdsvis V24 til V26 og V28 til V32. I denne omgang giver vi alle de variable, som bidrager til en faktor samme vægt. Det betyder, at vi kan konstruere den manifeste variabel

$$V1 = \text{'Good Job'} = V24 + V25 + V26,$$

dvs. for hver person summen af scoreværdien på de tre spørgsmål. Den maksimale scoreværdi bliver 15 - med 5 svarkategorier, scoret 1 til 5 - , mens den mindste scoreværdi bliver 3. En score på 15 betyder, at man har svaret 3 gange 'Not important at all', svarende til en person, der mener hans eller hendes job er meget lidt 'væsentligt'. En score på 3 betyder på den anden side, at den pågældende respondent har svaret 'Very important' på alle 3 spørgsmål, og således mener, at hans eller hendes job er særdeles væsentligt. Tilsvarende kan vi konstruere den manifeste variabel

$$V2 = \text{'Interesting Job'} = V28 + V29 + V30 + V31,$$

som på tilsvarende måde bliver et mål for hvor interessant jobbet er. Fra analysen af de 7 spørgsmål vedrørende arbejdsmiljøet kan vi danne en manifest variabel, der beskriver, hvor hårdt arbejdet er ('Dangerous Job'), som

$$V3 = \text{'Dangerous Job'} = V69 + V72 + V73 + V74.$$

Her betyder en lav score, at arbejdet er fysisk meget belastende, mens en høj score betyder, at arbejdet ikke er særligt fysisk belastende.

Desuden inddrages i analysen baggrundsvariablene V4, der er opgivne antal timer, respondenten arbejder om ugen, her kaldet 'Hours a Week', V5, der er social klasse ('Social Class') med 6 sociale klasser, og V6, der er antal år, respondentens har gået i skole, her benævnt 'School Years'. Baggrundsvariablene er altså


$$V4 = \text{'Hours a Week'} = V90,$$

$$V5 = \text{'Social Class'} = V110$$

og

$$V6 = \text{'School Years'} = V100.$$

Med disse variable, starter vi med stidiagrammet, vist i nedenstående figur.



Hvorfor der står E1 og E2 ved 'Good Job' og 'Interesting Job', vender jeg tilbage til.

Dette stidiagram analyseres ved SAS-programmet vist i de to næste bokse.

Den første boks, på næste side, viser i linierne 1 til 5 indlæsning af de nødvendige variable fra ISSP-databasen. Herefter etableres dataset 'b', hvor de variable renses for ubesvarede spørgsmål i linierne 6 til 28, mens de 6 variable, der skal indgå i stianalysen, defineres i linierne 29 til 34. I linierne 35 til 41 sættes der labels på de 6 manifeste variable V1 til V6 af hensyn til læsningen af SAS-output'et.

```
1. libname eba 's:\eba-data';
2. title 'Path analyse with manifest variables. ISSP 1989';
3. data a;
4. set eba.d89um;
5. keep v24-v26 v28-v31 v69 v72-v74 v90 v110 v100 ;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v28>5 then delete;
12. if v29>5 then delete;
13. if v30>5 then delete;
14. if v31>5 then delete;
15. if v69>5 then delete;
16. if v72>5 then delete;
17. if v73>5 then delete;
18. if v74>5 then delete;
19. if v69=0 then delete;
20. if v72=0 then delete;
21. if v73=0 then delete;
22. if v74=0 then delete;
23. if v90>70 then delete;
24. if v90=0 then delete;
25. if v100>14 then delete;
26. if v100=0 then delete;
27. if v110>6 then delete;
28. if v110=0 then delete;
29. v1=v24+v25+v26;
30. v2=v28+v29+v30+v31;
31. v3=v69+v72+v73+v74;
32. v4=v90;
33. v5=v110;
34. v6=v100;
35. label
36. v1='Good job'
37. v2='Interesting job'
38. v3='Dangerous job'
39. v4='Hours per week'
40. v5='Social class'
41. v6='Years in school';
```

```
1. proc calis corr residual;
2. lineqs
3.  v2 = pv2v1 v1 + pv2v3 v3 + pv2v4 v4 + e2,
4.  v1 = pv1v3 v3 + pv1v4 v4 + pv1v5 v5 + pv1v6 v6 + e1;
5. std
6.  e1 = vare1,
7.  e2 = vare2,
8.  v3 = varv3,
9.  v4 = varv4,
10. v5 = varv5,
11. v6 = varv6;
12. cov
13. v3 v4 = cv3v4,
14. v3 v5 = cv3v5,
15. v3 v6 = cv3v6,
16. v4 v5 = cv4v5,
17. v4 v6 = cv4v6,
18. v5 v6 = cv5v6;
19. var v1-v6;
20. run;
21. quit;
```

I denne boks er kaldet af PROC CALIS vist. I linie 1 er anført SAS-optionerne: 'corr', der betyder, at alle estimerede korrelationskoefficienter udskrives, og 'residual', der medfører, at differensen mellem de observerede korrelationer og de af stimodellen estimerede korrelationer udskrives. Disse differenser kaldes **residualer**, og der er altså én residual for hver observeret korrelation.

Linie 3 og 4 er definitionsligningerne for V2 og V1, som vist på figuren. Linie 5-11 er alle de varianser, der indgår som parametre i modellen. Bemærk, at varianserne på V2 og V1 kaldes E2 og E1, idet de har en lidt anden status end de andre varianser på grund af definitionsligningerne for V2 og V1 i linie 3 og 4. Endelig står i linie 12-18 de korrelationer, der indgår i modellen som parametre. Bemærk her, at der ingen korrelationer er mellem V1, V2 og de øvrige 4 variable.

SAS output'et fra dette program er vist i de følgende bokse.

Manifest Variable Equations

```

V1      =      .      *V3      +      .      *V4      +      .      *V5      +      .      *V6      + 1.0000 E1
              PV1V3      +      PV1V4      +      PV1V5      +      PV1V6

V2      =      .      *V1      +      .      *V3      +      .      *V4      + 1.0000 E2
              PV2V1      +      PV2V3      +      PV2V4

3834 Observations      Model Terms      1
   6 Variables      Model Matrices      4
  21 Informations      Parameters      19

```

I denne første boks vises de to definitions-ligninger, linie 3 og 4, for de 'afledte' variable V1 og V2 på symbolsk form, så man kan checke, at ligningerne er korrekt skrevet op i SAS-programmet. Desuden vises 6 nøgletal fra datasættet og modellen, bl.a. at der er 3834 observationer, som indgår i beregningen af korrelationerne, at der er 6 variable og 21 elementer i korrelationsmatricen, nemlig $7 \cdot 6/2$. Endelig ser vi, at der 19 parametre, der skal estimeres i modellen.

I den næste boks vises en lang række teststørrelser og tilpasningsmål. De to tal, vi har brug for er fremhævet.

```

Fit criterion . . . . . 0.0077
Goodness of Fit Index (GFI) . . . . . 0.9975
GFI Adjusted for Degrees of Freedom (AGFI) . . . . . 0.9733
Root Mean Square Residual (RMR) . . . . . 0.0176
Parsimonious GFI (Mulaik, 1989) . . . . . 0.1330

Chi-square = 29.4095      df = 2      Prob>chi**2 = 0.0001
Null Model Chi-square:      df = 15      721.1757

RMSEA Estimate . . . . . 0.0598  90%C.I.[0.0419, 0.0798]
Probability of Close Fit . . . . . 0.1731
ECVI Estimate . . . . . 0.0176  90%C.I.[0.0140, 0.0232]
Bentler's Comparative Fit Index . . . . . 0.9612
Normal Theory Reweighted LS Chi-square . . . . . 29.2969
Akaike's Information Criterion. . . . . 25.4095
Bozdogan's (1987) CAIC. . . . . 10.9061
Schwarz's Bayesian Criterion. . . . . 12.9061
McDonald's (1989) Centrality. . . . . 0.9964
Bentler & Bonett's (1980) Non-normed Index. . . . . 0.7089
Bentler & Bonett's (1980) NFI . . . . . 0.9592
James, Mulaik, & Brett (1982) Parsimonious NFI. . . . . 0.1279
Z-Test of Wilson & Hilferty (1931). . . . . 4.6831
Bollen (1986) Normed Index Rho1 . . . . . 0.6942
Bollen (1988) Non-normed Index Delta2 . . . . . 0.9619
Hoelter's (1983) Critical N . . . . . 782

```

Kvotientteststørrelsen for modeltilpasningen, som vi i det følgende vil kalde q-teststørrelsen, er på $q = 29.41$ med 2 frihedsgrader, som er klart signifikant. Det betyder, at modellens tilpasning til data kan forbedres, men udelukker ikke, at nogle af korrelationerne er insignifikante, svarende til, at de tilsvarende stier på grafen kan udelades. De næste bokse belyser dette.

Bemærk, at SAS output'et altid viser q-teststørrelsen for den såkaldte 'Null Model', hvor der overhovedet ingen korrelationer er mellem de variable. Det vil sige, at modellen kun har 6 parametre, svarende til de 6 restledsvarianser. Frihedsgraderne for dette test er derfor $21 - 6 = 15$. Hvorfor dette test, totalt uden informationsværdi, vises af SAS, er mig en gåde.

I den næste boks vises de standardiserede residualer. Da de asymptotiske standardfejl på residualerne beregnes af SAS-programmet, kan der også beregnes en 'Asymptotic Standardized Residual Matrix', der viser residualerne divideret med deres standard fejl. Elementerne i 'Asymptotic Standardized Residual Matrix' kan sammenholdes med tallet 2 for at se, om de er signifikante. Denne tabel skal, som sagt, inspiceres for værdier, der er klart større end 2. Alle 0'erne i tabellen svarer til korrelationer, der estimeres af modellen.

Asymptotically Standardized Residual Matrix

	V1	V2	V3	V4	V5	V6	
V1	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	Good job
V2	0.0000	0.0000	0.0000	0.0000	-5.1623	1.2626	Interest. job
V3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	Dangerous job
V4	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	Hours a week
V5	0.0000	-5.1623	0.0000	0.0000	0.0000	0.0000	Social class
V6	0.0000	1.2626	0.0000	0.0000	0.0000	0.0000	School Years

Average Standardized Residual = 0.3059

Average Off-diagonal Standardized Residual = 0.4283

Rank Order of 2 Largest Asymptotically Standardized Residuals

V5, V2	V6, V2
-5.1623	1.2626

Som det fremgår er der én signifikant modelafvigelse, svarende til korrelationen mellem V2 og V5. Vi venter lidt med at forfølge denne oplysning.

Først betragter vi definitionsligningerne for V1 og V2, hvor regressionskoefficienterne såvel som deres standardfejl og 't Values' er vist. En 't-Value' er den estimerede regressionskoefficient divideret med sin standardfejl. Disse størrelser er signifikante, hvis deres værdier er større end ca. 2. Benyttes denne 'regel' fremgår det, at hele 4 koefficienter er insignifikante, nemlig den mellem V1 og V3, den mellem V1 og V5, den mellem V2 og V3 og den mellem V2 og V4.

Manifest Variable Equations

V1	=	0.0148*V3	-	0.0543*V4	+	0.0158*V5	+	0.0731*V6	+	1.0000 E1
Std Err		0.0168 PV1V3		0.0163 PV1V4		0.0165 PV1V5		0.0162 PV1V6		
t Value		0.8797		-3.3238		0.9536		4.5051		
V2	=	0.2658*V1	-	0.0048*V3	+	0.0098*V4	+	1.0000 E2		
Std Err		0.0156 PV2V1		0.0158 PV2V3		0.0158 PV2V4				
t Value		17.0301		-0.3048		0.6230				

Disse informationer fra SAS output'et fortæller os, som vi skal se om et øjeblik, at grafen for stimodellen kan forenkles betydeligt uden at væsentligt forringe modeltilpasningen.


Endelig viser den næste boks korrelationerne mellem 'baggrundvariablene' V3, V4 og V5.

Covariances among Exogenous Variables

Parameter			Estimate	Standard Error	t Value
V4	V3	CV3V4	-0.159551	0.016356	-9.755
V5	V3	CV3V5	0.210387	0.016506	12.746
V5	V4	CV4V5	0.044621	0.016168	2.760
V6	V3	CV3V6	0.121825	0.016272	7.487
V6	V4	CV4V6	-0.026603	0.016158	-1.646
V6	V5	CV5V6	0.093889	0.016223	5.787

Det fremgår heraf, at der er en enkelt insignifikant korrelation, nemlig mellem V4 og V6. I modsætning til de andre signifikante størrelser, hvor modelmodifikationer klart må overvejes, er det knap så væsentligt at modificere modellen ved at fjerne sammenhængen mellem V4 og V6. Dette skyldes, at den væsentlige del af modelfortolkningen består i at fortolke de signifikante sammenhænge mellem 'baggrundvariablene' V3 til V6 og de 'afledte' variable V1 og V2.

Hvis vi starter modelmodifikationer med at fjerne de sammenhænge, der svarer til insignifikante regressionskoefficienter i definitions-ligningerne for V1 og V2, får vi den forenkede graf:



Modellen svarende til denne graf analyseres ved følgende kald af PROC CALIS, hvor leddene

pv2v3 v3 , pv2v4 v4

i linie 5 og

pv1v3 v3 , pv1v5 v5

i linie 6 er udeladt, mens resten af SAS programmet er uændret.

```
1. proc calis
2. corr
3. residual;
4. lineqs
5. v2 = pv2v1 v1 + e2,
6. v1 = pv1v4 v4 + pv1v6 v6 + e1;
7. std
8. e1 = vare1,
9. e2 = vare2,
10. v3 = varv3,
11. v4 = varv4,
12. v5 = varv5,
13. v6 = varv6;
14. cov
15. v3 v4 = cv3v4,
16. v3 v5 = cv3v5,
17. v3 v6 = cv3v6,
18. v4 v5 = cv4v5,
19. v4 v6 = cv4v6,
20. v5 v6 = cv5v6;
21. var v1-v6;
22. run;
23. quit;
```

I det næste - korte - uddrag af SAS output'et, ses, at data stadig ikke beskriver modellen godt nok, idet $q = 32.10$ med 6 frihedsgrader er klart signifikant. Til gengæld er modellens tilpasningsevne ikke blevet forringet. Differensen mellem q -værdien for denne model og den forrige er nemlig

$$Q(\text{differens}) = 32.10 - 29.41 = 2.69 ,$$

som med $df = 6 - 2 = 4$ har en signifikanssandsynlighed på 0.611, jvf. Kapitel 17.


Samtidig ser vi, at alle de tilbageværende korrelationer i definitionsligningerne for $V1$ og $V2$ har signifikante koefficienter.

Chi-square = 32.0976 df = 6 Prob>chi**2 = 0.0001

Manifest Variable Equations

V1	=	-	0.0559*V4	+	0.0764*V6	+	1.0000 E1
Std Err			0.0161 PV1V4		0.0161 PV1V6		
t Value			-3.4735		4.7490		
V2	=		0.2650*V1	+	1.0000 E2		
Std Err			0.0156 PV2V1				
t Value			17.0160				

Der er endnu en måde, vi kan forbedre modellen på, nemlig ved at inddrage den signifikante sammenhæng mellem V2 og V5, som vi 'opdagede' i forbindelse med inspektionen af de standardiserede residualer. Denne nye modificerede model har grafen



Kaldet af PROC CALIS, svarende til denne graf, ser sådan ud, idet vi har tilføjet

pv2v5 v5

i ligningen for V2.

```
proc calis
  corr
  residual;
  lineqs
    v2 = pv2v1 v1 + pv2v5 v5 + e2,
    v1 = pv1v4 v4 + pv1v6 v6 + e1;
  std
    e1 = vare1,
    e2 = vare2,
    v3 = varv3,
    v4 = varv4,
    v5 = varv5,
    v6 = varv6;
  cov
    v3 v4 = cv3v4,
    v3 v5 = cv3v5,
    v3 v6 = cv3v6,
    v4 v5 = cv4v5,
    v4 v6 = cv4v6,
    v5 v6 = cv5v6;
  var v1-v6;
run;
```

Nøgletallene i SAS-output'et for denne model ser sådan ud:

Chi-square = 6.3494 df = 5 Prob>chi**2 = 0.2737

Manifest Variable Equations

V1	=	-	0.0559*V4	+	0.0764*V6	+	1.0000	E1
Std Err			0.0161		0.0161			
t Value			-3.4735		4.7490			
V2	=		0.2669*V1	-	0.0789*V5	+	1.0000	E2
Std Err			0.0155		0.0155			
t Value			17.1916		-5.0842			

Sammenligner man q-teststørrelserne mellem de to sidste modeller, ser man, at

$$q \text{ (differens)} = 32.10 - 6.35 = 25.75 .$$

Med $6 - 5 = 1$ frihedsgrad er dette resultat klart signifikant, så at inddrage sammenhængen mellem V2 og V5 er en klar forbedring af modellens tilpasning til data. Ja, endda så meget, at signifikanssandsynligheden er 0.274, svarende til et meget smukt fit til data. Modellen kan derfor accepteres som en tilfredsstillende beskrivelse af variationen i den observerede korrelationsmatrix.

Vi kan således lade dette være vores endelige model. I næste boks er vist de standardiserede koefficienter til stjerne fra 'baggrundsvARIABLE' til 'afledte' variable og korrelationer mellem 'baggrundsvARIABLE', dvs. de tal vi skal bruge til den graf, der belyser styrken at sammenhængene mellem de variable.


Equations with Standardized Coefficients

V1	=	-	0.0559*V4	+	0.0764*V6	+	0.9954	E1
			PV1V4		PV1V6			
V2	=		0.2668*V1	-	0.0789*V5	+	0.9606	E2
			PV2V1		PV2V5			

Correlations among Exogenous Variables

Parameter			Estimate
V4	V3	CV3V4	-0.159551
V5	V3	CV3V5	0.210387
V5	V4	CV4V5	0.044621
V6	V3	CV3V6	0.121825
V6	V4	CV4V6	-0.026603
V6	V5	CV5V6	0.093889

De standardiserede regressionskoefficienter er fremkommet ved at normere så alle indgående variable har varians 1, dvs. der er tale om korrelationskoefficienter. På denne måde er alle de viste koefficienter på den næste figur sammenlignelige.



17. Kvotienttestteori.

17.1 Test af modellen M mod modellen M_1 .

Betragt en model M med m parametre $(\theta_1, \dots, \theta_m)$ og likelihoodfunktion

$$M : L(\theta_1, \dots, \theta_m) .$$

Betragt dernæst modellen M under hypotesen

$$H_1 : \theta_{k+1} = \dots = \theta_m = 0 ,$$

dvs. modellen M_1 med parametre $(\theta_1, \dots, \theta_k, 0, \dots, 0)$ og likelihoodfunktion

$$M_1 : L(\theta_1, \dots, \theta_k, 0, \dots, 0) .$$

Spørgsmålet er, om modellen M_1 beskriver data lige så godt som modellen M.

Tænker man i hypoteseprøvningsterminologi, svarer det til, om H_1 kan accepteres. Vurderingen bygger derfor på **kvotientteststørrelsen** Q_1 , defineret som

$$Q_1 = -2 \ln \frac{L(\tilde{\theta}_1, \dots, \tilde{\theta}_k, 0, \dots, 0)}{L(\hat{\theta}_1, \dots, \hat{\theta}_m)} ,$$

hvor

$$(\hat{\theta}_1, \dots, \hat{\theta}_m)$$

er ML-estimatorerne under M, og

$$(\tilde{\theta}_1, \dots, \tilde{\theta}_k)$$

er ML-estimatorerne under M_1 , dvs. de værdier, der maksimaliserer

$$M_1 : L(\theta_1, \dots, \theta_k, 0, \dots, 0)$$

Testet Q_1 har ifølge den generelle teori for kvotientteststørrelser en approksimativ χ^2 -fordeling med m-k frihedsgrader, jvf. Kapitel 9.

Dette skriver vi som

$$Q_1 \sim \chi^2(m-k) .$$

Vi forkaster derfor hypotesen, dvs. at modellen M_1 beskriver data lige så godt som M, på niveau α , hvis det for den observerede værdi q_1 af Q_1 gælder, at eller man bestemmer signifikanssandsynligheden

$$q_1 > \chi^2_{1-\alpha}(m-k) ,$$

$$p = P(Q_1 \geq q_1) ,$$

hvor $Q_1 \sim \chi^2(m-k)$. Hvis p er lille, beskriver M_1 ikke data lige så godt som M , mens en stor værdi (f.eks. større end 0.05) betyder, at M_1 beskriver data lige så godt som M .

17.2. Test af modellen M_1 mod en simplere model M_2 .

Hvis M_1 beskriver data lige så godt som M , kan man gå videre og teste om en endnu simplere model M_2 kan beskrive data lige så godt som M_1 . En simplere model betyder, at der er flere parametre - end i M_1 -, der sættes lig med 0. Det vil sige en model, hvor p flere end k parametre er sat til 0. Det svarer til hypotesen

$$H_2 : \theta_{k-p+1} = \dots = \theta_k = \theta_{k+1} = \dots = \theta_m = 0 .$$

Her bliver kvotientteststørrelsen

$$Q_2^* = -2 \ln \frac{L(\tilde{\theta}_1, \dots, \tilde{\theta}_{k-p}, 0, \dots, 0)}{L(\hat{\theta}_1, \dots, \hat{\theta}_k, 0, \dots, 0)} ,$$

hvor nu

$$(\hat{\theta}_1, \dots, \hat{\theta}_k)$$

er ML-estimatorerne for $(\theta_1, \dots, \theta_k)$ under M_1 , og

$$(\tilde{\theta}_1, \dots, \tilde{\theta}_{k-p})$$

er ML-estimatorerne for $(\theta_1, \dots, \theta_{k-p})$ under M_2 . (Hvorfor jeg skriver Q_2^* , vil fremgå af det følgende.)

Da vi ønsker at vurdere om modellen M_2 , der svarer til hypotesen

$$H_2 : \theta_{k-p+1} = \dots = \theta_m = 0 ,$$

beskriver data lige så godt som modellen M_1 , dvs. **givet at** hypotesen

$$H_1 : \theta_{k+1} = \dots = \theta_m = 0$$

allerede er opfyldt, er der, som sagt, p flere θ 'er, der sættes lig med 0 under H_2 end under H_1 .

Det betyder, at

$$Q_2^* \sim \chi^2(p) .$$

17.3. Test af modellen M_2 mod den oprindelige model M .

Man kan selvfølgelig også teste modellen M_2 mod den oprindelige model M . Da modellen M_2 er en model af samme type som M_1 , blot med færre parametre, vil kvotientteststørrelsen for M_2 mod M være

$$Q_2 = -2 \ln \frac{L(\tilde{\theta}_1, \dots, \tilde{\theta}_{k-p}, 0, \dots, 0)}{L(\hat{\theta}_1, \dots, \hat{\theta}_m)} .$$

I forhold til M er antallet af θ 'er, der er 0 under M_2 , lig med $m - (k - p) = m - k + p$. Derfor gælder

$$Q_2 \sim \chi^2(m - k + p) .$$

17.4. Sekventiel testning.

Sekventiel testning bygger på følgende resultat

$$Q_2 = Q_2^* + Q_1 .$$

Bevis: Vi får

$$Q_2 = -2 \ln L(\tilde{\theta}_1, \dots, \tilde{\theta}_{k-p}, 0, \dots, 0) + 2 \ln L(\hat{\theta}_1, \dots, \hat{\theta}_m) =$$

$$- 2 \ln L(\tilde{\theta}_1, \dots, \tilde{\theta}_{k-p}, 0, \dots, 0) + 2 \ln L(\hat{\theta}_1, \dots, \hat{\theta}_k, 0, \dots, 0) + \left(-2 \ln L(\tilde{\theta}_1, \dots, \tilde{\theta}_k, 0 \dots 0) + 2 \ln L(\hat{\theta}_1, \dots, \theta_m) \right) ,$$

eller

$$Q_2 = Q_2^* + Q_1 .$$

Læg mærke til, at det passer med frihedsgraderne. Hvis vi kalder frihedsgraderne for M_2 mod M for df_2 , frihedsgraderne for M_2 mod M_1 df_2^* og frihedsgraderne for M_1 mod M for df_1 , gælder

$$df_2 = m - k + p = p + (m - k) = df_2^* + df_1 .$$

Resultatet skrives ofte som:

$$Q_2^* = Q_2 - Q_1 = \chi_2^2 (df_2 - df_1) ,$$

Og testet med Q_2^* , som q-teststørrelse kaldes et sekventielt q-test.

Man kalder modellerne M , M_1 , M_2 **hierakiske**, fordi de succesivt er indeholdt i hinanden.

Dette skrives ofte som

$$M_2 \subset M_1 \subset M .$$

For hierakiske modeller kan en model, f.eks. M_2 , der indeholdt i en anden model, f.eks. M_1 , dvs. at i M_2 er én eller flere af parametrene i M_1 sat lig med 0, testes mod M_1 ved et kvotienttest. I eksemplet her ved kvotientteststørrelsen $Q_2^* = Q_2 - Q_1$. Brugen af differenser mellem q-teststørrelser kaldes **sekventiel testning**.

For at opstille resultaterne, når der testes sekventielt, i en overskuelig tabel, er det nyttigt at indføre betegnelsen **den mættede model** (Eng. 'saturated model') for den model, hvor ingen af parametrene er sat lig med 0. (Dén, der hidtil har heddet M). Det betyder, at kvotientteststørrelserne for M_1 og M_2 mod den mættede model er Q_2 og Q_1 , mens q-teststørrelsen Q_2^* for M_2 mod M_1 er differensen mellem q-teststørrelserne for de to hypotester mod den mættede model.

Det kan være praktisk at opstille skemaet:

Model	Q-størrelse mod mættet model	Antal fri- hedsgrader	Sekventiel teststørrelse	Antal fri- hedsgrader
M_1	Q_1	df_1	-	
M_2	Q_2	df_2	$Q_2 - Q_1$	$df_2 - df_1$

Skemaet kan naturligvis fortsættes. Hvis vi tester 5 modeller både direkte og sekventielt mod den mættede model, får man skemaet:

Model	Q-størrelse mod mættet model	Antal fri- hedsgrader	Sekventiel teststørrelse	Antal fri- hedsgrader
M_1	Q_1	df_1	-	
M_2	Q_2	df_2	$Q_2 - Q_1$	$df_2 - df_1$
M_3	Q_3	df_3	$Q_3 - Q_2$	$df_3 - df_2$
M_4	Q_4	df_4	$Q_4 - Q_3$	$df_4 - df_3$
M_5	Q_5	df_5	$Q_5 - Q_4$	$df_5 - df_4$


Her vurderes modellerne M_1 til M_5 mod den mættede model ved q-teststørrelserne Q_1 til Q_5 , mens de forenklede modeller M_2 til M_5 vurderes mod den forrige model ved differenserne mellem de respektive q-teststørrelser.

Vigtig bemærkning: En kvotientteststørrelses værdi forøges altid, hvis man simplificerer modellen, idet en model med færre parametre naturligvis ikke kan beskrive en model lige så godt som den oprindelige model. Det er derfor ikke nødvendigt at spekulere over, hvilke kvotientteststørrelser, der skal trækkes fra hinanden. En differens mellem to Q-værdier må nemlig ikke blive negativ. (At kvotientteststørrelsen ikke forøger sin værdi, når modellen simplificeres, men er lig med den forrige, sker ikke i praksis.)

18. En målingsmodel (Confirmative Factor Analysis).

Vi har tidligere analyseret de tre variabelgrupper (1) V24 - V26, (2) V28 - V31 og (3) V69 plus V72 - V74, der i stianalysen med manifeste variable optrådte som repræsentanter for de afledede variable (1) 'Good job', (2) 'Interesting job' og (3) 'Dangerous Job'. Vi skal nu tilføje variabelgrupperne (4) V63 - V66 og (5) V59 - V61. Der er tale om de samme spørgsmål, som i grupperne (1) og (2), men hvor man i (1) og (2) spurgte om, hvorvidt de forskellige forhold ved jobbet var væsentlige ('important') efter respondentens opfattelse, spurgte man i grupperne (4) og (5) om forholdene ved arbejdet rent faktisk var, som påstanden var formuleret ('Statement'). Så vi må omdøbe de afledede variable (1) og (2) til 'Impt: Good Job' og 'Impt: Interesting Job'. Herved bliver de 2 afledede variable svarende til (1) og (2), men nu relateret til de faktiske forhold, til (4) 'Fakt: Interesting Job' og (5) 'Fakt: Good Job'. Her har jeg, af uransagelige grunde, byttet om på rækkefølgen og skrevet ordet 'fact' med k på engelsk!

En målingsmodel er en model, der grafisk kan illustreres således:



I formler ser modellen sådan ud.

$$x_1 = b_{11} f_1 + e_1$$

$$x_2 = b_{21} f_1 + e_2$$

$$x_3 = b_{31} f_1 + e_3$$

$$x_4 = b_{12} f_2 + e_4$$

$$x_5 = b_{22} f_2 + e_5$$

$$x_6 = b_{32} f_2 + e_6$$

$$x_7 = b_{42} f_2 + e_7$$

$$x_8 = b_{13} f_3 + e_8$$

$$x_9 = b_{23} f_3 + e_9$$

$$x_{10} = b_{33} f_3 + e_{10}$$

$$x_{11} = b_{43} f_3 + e_{11}$$

$$x_{12} = b_{14} f_4 + e_{12}$$

$$x_{13} = b_{24} f_4 + e_{13}$$

$$x_{14} = b_{34} f_4 + e_{14}$$

$$x_{15} = b_{44} f_4 + e_{15}$$

$$x_{16} = b_{15} f_5 + e_{16}$$

$$x_{17} = b_{25} f_5 + e_{17}$$

$$x_{18} = b_{35} f_5 + e_{18}$$

Her er x 'erne de observerbare eller **manifeste** variable, mens f_1 til f_5 er de 5 ikke-observerbare eller **latente** variable. Restledene, e 'erne, er uafhængige normalfordelte stokastiske variable, mens b 'erne er de koefficienter, der knytter de latente variable sammen med de observerede variable. Som det fremgår af figuren, er det yderligere en antagelse, at de V 'er, der indgår i definitionen af en latent variabel er uafhængige givet den latente variabel.

Idet kovariansmatricen for V 'erne danner udgangspunkt for estimationen af modellens parametre, kan man godt opskrive de 18 ligninger ovenfor på matrix form, som

$$\mathbf{V}_X = \mathbf{B} \mathbf{V}_F \mathbf{B}^T + \mathbf{E} ,$$

hvor $\mathbf{V}_x$ er en 18x18 matrix, dannet af x 'ernes varianser og kovarianser. $\mathbf{B}$ er en 18x5 matrix bestående af b 'koefficienterne, $\mathbf{V}_F$ er kovariansmatricen for de 5 latente variable $F_1, \dots, F_5$. $\mathbf{E}$ er en diagonalmatrix af varianser for restleddene $E_1, \dots, E_{18}$. Men det er en del besværligt, idet der er mange 0'er i $\mathbf{B}$ som følge af, at de kun er bestemt af de x 'er, der er funktioner af en bestemt latent variabel. Heldigvis behøver vi ikke at studere denne matrix relation. For at estimere modellens parametre, skal vi blot i SAS-programmet skrive de 18 ligninger op, stort set som de står oven for.

Men først må vi identificere modellens parametre. Det sker lettest ud fra figuren for modellen, idet hver forbindelseslinie svarer til en parameter. Der er således:

- (1) 18 restledsvarianser, svarende til pilene fra restleddene til de observerede variable, dvs. fra et 'E' til et 'V'.
- (2) $3 + 4 + 4 + 4 + 3 = 18$ koefficienter til de latente variable, svarende til linierne fra V 'erne til F 'erne.
- (3) 10 kovarianser mellem de 5 latente variable, idet der kan trækkes

$$\binom{5}{2} = \frac{5 \cdot 4}{2} = 10$$

linier mellem de 5 ovaler, svarende til F_1 til F_5 .

Der er altså ialt $18 + 18 + 10 = 46$ parametre, der skal estimeres i denne **målingsmodel**. Til gengæld er der $19 \times 18 / 2 = 171$ datapunkter i form af kovarianserne mellem de 18 observerede variable, der indgår i modellen. Der er derfor $171 - 46 = 125$ frihedsgrader til rådighed til at teste, om modellen, med de estimerede parametre, kan beskrive variationen i de observerede data.

Vi skal til senere brug kalde denne målingsmodel M_m .

De første 32 linier af SAS-programmet til analyse af målingsmodellen, vist neden for, er data-delen, hvor de 18 variable, der indgår i analyse bliver udtrukket af databasen og bliver rensat for ubesvarede spørgsmål. Denne del svarer helt til de tidligere viste programmer.

```

1. libname eba 'S:\eba-data';
2. title 'ISSP89: All countries';
3. data a;
4. set eba.d89um;
5. keep v24-v26 v28-v31 v69 v72-v74 v59-v61 v63-v66;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
10. if v26>5 then delete;
11. if v28>5 then delete;
12. if v29>5 then delete;
13. if v30>5 then delete;
14. if v31>5 then delete;
15. if v69>5 then delete;
16. if v72>5 then delete;
17. if v73>5 then delete;
18. if v74>5 then delete;
19. if v59>5 then delete;
20. if v60>5 then delete;
21. if v61>5 then delete;
22. if v63>5 then delete;
23. if v64>5 then delete;
24. if v65>5 then delete;
25. if v66>5 then delete;
26. if v59=0 then delete;
27. if v60=0 then delete;
28. if v61=0 then delete;
29. if v63=0 then delete;
30. if v64=0 then delete;
31. if v65=0 then delete;
32. if v66=0 then delete;

```

Den næste del af programmet er kaldet af SAS proceduren PROC CALIS, som udfører analysen af de 18 variable som funktioner af 5 latente variable.

Linie 33 er selve kaldet af PROC CALIS, hvor man kan vælge mellem forskellige optioner. Her er valgt 'covariance', der betyder, at det er kovariansmatricen $\mathbf{V}_x$, der bliver analyseret, 'corr', der betyder, at alle korrelationer bliver vist, samt 'residual', der betyder, at residualer og standardiserede residualer mellem den observerede kovariansmatrix $\mathbf{V}_x$ og den - udfra de estimerede parametre - beregnede, bliver vist. Man kan godt udelade optionen 'residual', da den, som i eksemplet her, sjældent yder noget væsentligt bidrag til fortolkningen af resultaterne.

Linie 34 til 52, med overskriften 'lineqs', er de 19 linier, der definerer de 5 latente variable, svarende til ligningerne oven for, så f.eks. $x_1 = b_{11} f_1 + e_1$ svarer til linie 35

$$v24 = lv24f1 f1 + e1 .$$

```

33. proc calis covariance corr residual;
34. lineqs
35. v24 = lv24f1 f1 +e1,
36. v25 = lv25f1 f1 +e2,
37. v26 = lv26f1 f1 +e3,
38. v28 = lv28f2 f2 +e4,
39. v29 = lv29f2 f2 +e5,
40. v30 = lv30f2 f2 +e6,
41. v31 = lv31f2 f2 +e7,
42. v69 = lv69f3 f3 +e8,
43. v72 = lv72f3 f3 +e9,
44. v73 = lv73f3 f3 +e10,
45. v74 = lv74f3 f3 +e11,
46. v63 = lv63f4 f4 +e12,
47. v64 = lv64f4 f4 +e13,
48. v65 = lv65f4 f4 +e14,
49. v66 = lv66f4 f4 +e15,
50. v59 = lv59f5 f5 +e16,
51. v60 = lv60f5 f5 +e17,
52. v61 = lv61f5 f5 +e18;
53. std
54. f1=1,
55. f2=1,
56. f3=1,
57. f4=1,
58. f5=1,
59. e1-e18 = vare1-vare18;
60. cov
61. f1 f2 = cf1f2,
62. f1 f3 = cf1f3,
63. f1 f4 = cf1f4,
64. f1 f5 = cf1f5,
64. f2 f3 = cf2f3,
65. f2 f4 = cf2f4,
66. f2 f5 = cf2f5,
67. f3 f4 = cf3f4,
68. f3 f5 = cf3f5,
69. f4 f5 = cf4f5;
70. var v24-v26 v28-v31 v69 v72-v74 v63-v66 v59-v61;
71. run;
72. quit.

```

Bemærk, at b-koefficienterne her er skrevet som et 'l', der står for 'lineær' efterfulgt af navnet på både x-variablen og f-variablen. Størrelserne 'lv24f1' til 'lv61f5' er altså de 18 b-parametre. Dernæst følger i linie 53 til 59 definitionen af de variansparametre, der indgår i modellen. De 18 restledsvarianser kaldes 'e1' til 'e18'. Varianserne til de 5 latente variable 'f1' til 'f5' sættes i linierne 54 til 58 lig med 1. Dette skyldes det, at man i produktled, som $b_{ij} f_j$ enten må normere b'erne eller f'erne, ellers er modellen ikke identificerbar. Her bliver f'erne normeret ved at sætte f'ernes varianser til 1. I linie 60 til 69 defineres de 10 kovarianser i modellen, nemlig alle kovarianser mellem de 5 latente variable. Her bruges navnene 'cf1f2'

til 'cf4f5', hvor 'c' står for kovarians og efterfølges af navnene på de indgående variable. Endelig i linie 70 står hvilke 18 variable, der indgår i analysen.

Man behøver ikke i SAS at bruge så 'lange' koefficientnavne som f.eks. 'LV24F1', men det har den fordel, at man kan holde rede på, hvilke to variable, der er tale om. Dog er 'l'-et obligatorisk, så SAS véd, at der er tale om en lineær regressionskoefficient. Hvis man kan holde rede på, hvad der er hvad, kan man godt blot skrive 'L1' til 'L18', så 'L1' svarer til 'LV24F1', osv.

Den første boks neden for viser den del af SAS-output'et, hvor de 18 definitions ligninger er angivet på symbolsk form, så man kan checke, at alt er med. At der skrives et 1-tal foran fejlleddet er blot et udtryk for, at PROC CALIS skal kunne håndtere mange forskellige modeller med strukturelle ligninger. I målingsmodellen, og i stimodellerne i næste kapitel, er koefficienterne til fejledene lig med 1, men det betyder ikke at E'ernes varianser er ens. Tværtimod optræder kan man se af 'std'-afsnittet i SAS-programmet, at alle varianser på restled optræder som parametre i modellen, benævnt 'vare1' til 'vare18'.

Endelig vises i de 3 sidste linier af output-boksen, at der 6776 observationer, 18 variable, 171 elementer i V_x og 46 parametre.

Manifest Variable Equations

V24	=	.	*F1	+	1.0000	E1
			LV24F1			
V25	=	.	*F1	+	1.0000	E2
			LV25F1			
V26	=	.	*F1	+	1.0000	E3
			LV26F1			
V28	=	.	*F2	+	1.0000	E4
			LV28F2			
V29	=	.	*F2	+	1.0000	E5
			LV29F2			
V30	=	.	*F2	+	1.0000	E6
			LV30F2			
V31	=	.	*F2	+	1.0000	E7
			LV31F2			
V69	=	.	*F3	+	1.0000	E8
			LV69F3			
V72	=	.	*F3	+	1.0000	E9
			LV72F3			
V73	=	.	*F3	+	1.0000	E10
			LV73F3			
V74	=	.	*F3	+	1.0000	E11
			LV74F3			
V63	=	.	*F4	+	1.0000	E12
			LV63F4			
V64	=	.	*F4	+	1.0000	E13
			LV64F4			
V65	=	.	*F4	+	1.0000	E14
			LV65F4			
V66	=	.	*F4	+	1.0000	E15
			LV66F4			
V59	=	.	*F5	+	1.0000	E16
			LV59F5			
V60	=	.	*F5	+	1.0000	E17
			LV60F5			
V61	=	.	*F5	+	1.0000	E18
			LV61F5			

6776 Observations	Model Terms	1
18 Variables	Model Matrices	4
171 Informations	Parameters	46

```

Dual Quasi-Newton Optimization
Dual Broyden - Fletcher - Goldfarb - Shanno Update (DBFGS)
Number of Parameter Estimates 46
Number of Functions (Observations) 171

Optimization Start: Active Constraints= 0 Criterion= 1.010 Maximum Gradient Element= 0.302

  Iter rest nfun act   optcrit   difcrit maxgrad   alpha   slope
    1    0    4    0   0.9202   0.0902   0.477  0.0402  -7.167
    2    0    6    0   0.8133   0.1069   0.183  0.803  -0.239
    3    0    8    0   0.7796   0.0337   0.139  0.372  -0.138
    4    0    9    0   0.7539   0.0257   0.0715  0.745 -0.0681
    5    0   10    0   0.7461   0.00786  0.0886  1.000 -0.0160
    6    0   11    0   0.7418   0.00426  0.0646  1.000 -0.0134
    7    0   12    0   0.7402   0.00166  0.0548  1.000 -0.0066
    8    0   13    0   0.7391   0.00103  0.0257  1.000 -0.003
    9    0   14    0   0.7389  0.000217  0.0169  1.000 -0.0008
   10    0   15    0   0.7389  0.000035  0.0174  1.000 -0.0003
   11    0   16    0   0.7388  0.000042  0.00847  1.000 -0.0002
   12    0   17    0   0.7388  0.000043  0.00532  1.000 -0.0001
   13    0   18    0   0.7388  4.125E-6  0.00486  1.000 -263E-7
   14    0   19    0   0.7388  4.529E-6  0.00188  1.000 -158E-7
   15    0   20    0   0.7388  2.129E-6  0.0009  1.000 -538E-8
   16    0   21    0   0.7388  5.406E-7  0.00029  1.000 -107E-8
   17    0   22    0   0.7388  2.397E-7  0.00036  1.000 -442E-9
   18    0   23    0   0.7388  1.297E-7  0.00017  1.000 -235E-9
   19    0   24    0   0.7388  2.608E-8  0.00008  1.000 -54E-9
   20    0   26    0   0.7388  1.687E-8  0.00011  2.000 -19E-9
   21    0   27    0   0.7388  9.746E-9  0.00003  1.000 -18E-9
   22    0   28    0   0.7388  2.394E-9  0.00001  1.000 -43E-10

Optimization Results: Iterations= 22 Function Calls= 29 Gradient Calls= 26
Active Constraints= 0 Criterion= 0.73877962 Maximum Gradient Element= 0.000014872
Slope= -4.29007E-9

NOTE: GCONV convergence criterion satisfied.

```

I denne boks fra SAS output'et er vist en række tekniske detaljer fra den iterative løsning af likelihoodligningerne. De første 4 linier viser, hvilken iterationsmetode, der er benyttet. Som man kan se, er det en tillempet Newton iterationsmetode, som der åbenbart har været flere om at tillempe. Dernæst er der en række, ligeledes tekniske, detaljer vedrørende de 22 iterationer, der er nødvendige. Den eneste størrelse, der her har en vis interesse er 'optcrit', som - på nær et par konstanter - er lig med -2 gange log-likelihoodfunktionen. Kriteriet er derfor minimum, hvis likelihoodfunktionen er maksimum og 0 hvis der er fuldstændig overensstemmelse mellem den observerede og den estimerede kovariansmatrix. Denne fortolkning af 'optcrit' er nærmere gennemgået i Kapitel 11. De øvrige oplysninger har kun interesse for specialister, og især i de tilfælde, hvor proceduren ikke konvergerer.

I dette tilfælde er der konvergens, hvilket noteres med 'NOTE: GCONV convergence criterion satisfied.'

```

Fit criterion . . . . . 0.7388
Goodness of Fit Index (GFI) . . . . . 0.9144
GFI Adjusted for Degrees of Freedom (AGFI) . . . . . 0.8829
Root Mean Square Residual (RMR) . . . . . 0.0551
Parsimonious GFI (Mulaik, 1989) . . . . . 0.7470

Chi-square = 5005.2319      df = 125      Prob>chi**2 = 0.0001
Null Model Chi-square:      df = 153      25973.7793

RMSEA Estimate . . . . . 0.0759  90%C.I.[0.0741, 0.0777]
Probability of Close Fit . . . . . .
ECVI Estimate . . . . . 0.7524  90%C.I.[0.7188, 0.7871]
Bentler's Comparative Fit Index . . . . . 0.8110
Normal Theory Reweighted LS Chi-square . . . . . 5709.2068
Akaike's Information Criterion . . . . . 4755.2319
Bozdogan's (1987) CAIC . . . . . 3777.5892
Schwarz's Bayesian Criterion . . . . . 3902.5892
McDonald's (1989) Centrality . . . . . 0.6976
Bentler & Bonett's (1980) Non-normed Index . . . . . 0.7687
Bentler & Bonett's (1980) NFI . . . . . 0.8073
James, Mulaik, & Brett (1982) Parsimonious NFI . . . . . 0.6596
Z-Test of Wilson & Hilferty (1931) . . . . . 57.4646
Bollen (1986) Normed Index Rho1 . . . . . 0.7641
Bollen (1988) Non-normed Index Delta2 . . . . . 0.8112
Hoelter's (1983) Critical N . . . . . 207

```

I denne boks vises en lang række mål for, hvor god tilpasningen mellem model og data er, startende med 'Fit criterion', som er identisk med 'optcrit' fra den forrige boks. SAS-programmer har den tradition, at man hellere angiver for mange, end for få, statistiske størrelser. Her har det taget en hel del overhånd. Vi skal koncentrere os om de 2 linier, der er fremhævet [af mig] i output'et. Størrelsen 5005.2319 med $df = 125$ er det transformerede kvotienttestskøn for sammenligningen af den mættede model, hvor parametrene er alle de 171 kovarianser i V_X og målingsmodellen med 46 parametre. Antal frihedsgrader 'df' er altså $df = 171 - 46 = 125$. Den viste q-teststørrelse er klart signifikant. SAS skriver '= 0.0001' både hvis signifikanssandsynligheden er lig 0.0001 efter afrunding, og når signifikanssandsynligheden er < 0.00005 .

Den model, der kaldes 'Null Model', er en model, hvor der ingen korrelationer er, hverken mellem latente, mellem manifeste eller mellem latente og manifeste variable. Denne model har $171 - 153 = 18$ frihedsgrader, da det alene er de 18 restledsvarsianser, der er parametre i modellen. Hvorfor SAS insisterer på at gengive q-teststørrelsen for denne model i alle output er mig en gåde. Det må vist høre til de helt store sjældenheder, at man kan få brug for at sammenligne en model med denne trivielle model. Men det er nok typisk for programmørerne i SAS, at de har en svaghed for at inkludere en række mere eller mindre trivielle nøgletal for modellerne, selv om disse nøgletal sjældent vil blive brugt i praksis.

I den næste boks vises alle de estimerede lineære koefficienter - b'erne - sammen med deres standardfejl og kvotienten mellem estimatet og standardfejlen. Denne kvotient 't Value' er approksimativt normeret normalfordelt i store stikprøver. Dvs. at estimatet for en b-parameter, eller L - parameter, er signifikant forskellig fra 0, hvis værdien af 't Value' er større end ca. 2. Det er en del misvisende, at SAS altid skriver 't Value' også hvis størrelse, som det er tilfældet her, ikke er t-fordelt. Men sådan gør man altså! Tallene i boksen viser, at alle koefficienter er signifikante, dvs. at alle de latente variable bidrager signifikant til at forklare de manifesterede variables variation. Det er naturligvis betryggende, da en ikke-signifikant koefficient jo ville betyde, at den pågældende variabel ikke skulle medtages i modellen.

```

V24      =      0.2476*F1      +  1.0000 E1
Std Err      0.0110 LV24F1
t Value      22.5496

V25      =      0.3858*F1      +  1.0000 E2
Std Err      0.0130 LV25F1
t Value      29.7263

V26      =      0.5474*F1      +  1.0000 E3
Std Err      0.0166 LV26F1
t Value      32.9705

V28      =      0.2355*F2      +  1.0000 E4
Std Err      0.0085 LV28F2
t Value      27.5853

V29      =      0.3201*F2      +  1.0000 E5
Std Err      0.0110 LV29F2
t Value      29.1305

V30      =      0.7155*F2      +  1.0000 E6
Std Err      0.0113 LV30F2
t Value      63.0401

V31      =      0.6742*F2      +  1.0000 E7
Std Err      0.0112 LV31F2
t Value      60.3099

V69      =      0.6926*F3      +  1.0000 E8
Std Err      0.0159 LV69F3
t Value      43.4694

V72      =      0.8716*F3      +  1.0000 E9
Std Err      0.0142 LV72F3
t Value      61.2299

V73      =      0.8906*F3      +  1.0000 E10
Std Err      0.0138 LV73F3
t Value      64.4274

V74      =      0.7501*F3      +  1.0000 E11
Std Err      0.0149 LV74F3
t Value      50.4350

V63      =      0.5187*F4      +  1.0000 E12
Std Err      0.0122 LV63F4
t Value      42.4859

V64      =      0.4218*F4      +  1.0000 E13
Std Err      0.0135 LV64F4
t Value      31.3003

V65      =      0.7612*F4      +  1.0000 E14
Std Err      0.0136 LV65F4
t Value      55.9705

V66      =      0.6757*F4      +  1.0000 E15
Std Err      0.0127 LV66F4
t Value      53.2188

V59      =      0.4654*F5      +  1.0000 E16
Std Err      0.0159 LV59F5
t Value      29.3291

V60      =      0.6690*F5      +  1.0000 E17
Std Err      0.0166 LV60F5
t Value      40.3543

V61      =      0.7164*F5      +  1.0000 E18
Std Err      0.0179 LV61F5
t Value      40.0005

```

Covariances among Exogenous Variables					
Parameter			Estimate	Standard Error	t Value
F2	F1	CF1F2	0.321473	0.017606	18.259
F3	F1	CF1F3	0.028704	0.018305	1.568
F3	F2	CF2F3	0.011339	0.015531	0.730
F4	F1	CF1F4	0.073583	0.019086	3.855
F4	F2	CF2F4	0.488811	0.013579	35.998
F4	F3	CF3F4	-0.025022	0.016056	-1.558
F5	F1	CF1F5	0.199822	0.020139	9.922
F5	F2	CF2F5	0.082211	0.017288	4.755
F5	F3	CF3F5	-0.130227	0.017001	-7.660
F5	F4	CF4F5	0.313064	0.016933	18.488

I denne boks er de estimerede kovarianser CF1F2 til CF4F5 mellem de latente variable F1 til F5 vist. Også standardfejlene og de standardiserede estimater, dvs. 't Value' er vist. Som nævnt er et estimat signifikant forskelligt fra 0, hvis 't Value' er større end ca. 2. At et estimat ikke er signifikant forskelligt fra 0 betyder, at korrelationen mellem de to pågældende variable kan sættes til 0 uden at forringe modellens forklaringsevne. Her gælder det alle de tre korrelationer, hvor F3 indgår.

I den næste boks er vist de standardiserede koefficienter, som man vanligvis indskriver på grafen for at vise størrelsesordenen af den pågældende sammenhæng. For estimerne af de lineære parametre (L - parametrene) er estimerne standardiserede så variansen på alle de variable både de manifeste (V'erne) og de latente (F'erne) er lig med 1. Det betyder, ifølge Kapitel 12 at de er lig med korrelationskoefficienterne mellem V'erne og F'erne. De standardiserede koefficienter er altså sammenlignelige. Bemærk, at da både V'erne og F'erne standardiseres til varians 1, vil varianserne på E'erne naturligvis også ændre sig.

Equations with Standardized Coefficients


V24	=	0.3629*F1 LV24F1	+ 0.9318 E1
V25	=	0.5269*F1 LV25F1	+ 0.8499 E2
V26	=	0.6473*F1 LV26F1	+ 0.7622 E3
V28	=	0.3650*F2 LV28F2	+ 0.9310 E4
V29	=	0.3841*F2 LV29F2	+ 0.9233 E5
V30	=	0.7958*F2 LV30F2	+ 0.6055 E6
V31	=	0.7608*F2 LV31F2	+ 0.6489 E7
V69	=	0.5489*F3 LV69F3	+ 0.8359 E8
V72	=	0.7395*F3 LV72F3	+ 0.6732 E9
V73	=	0.7741*F3 LV73F3	+ 0.6331 E10
V74	=	0.6233*F3 LV74F3	+ 0.7820 E11
V63	=	0.5566*F4 LV63F4	+ 0.8308 E12
V64	=	0.4220*F4 LV64F4	+ 0.9066 E13
V65	=	0.7192*F4 LV65F4	+ 0.6948 E14
V66	=	0.6852*F4 LV66F4	+ 0.7284 E15
V59	=	0.4332*F5 LV59F5	+ 0.9013 E16
V60	=	0.6581*F5 LV60F5	+ 0.7529 E17
V61	=	0.6488*F5	+ 0.7609 E18

I den sidste boks er korrelationskoefficienterne mellem de 5 latente variable vist. Også her af hensyn til en grafisk fremstilling, hvor man kan skrive disse korrelationer ind.

Correlations among Exogenous Variables

Parameter			Estimate
F2	F1	CF1F2	0.311122
F3	F1	CF1F3	0.054118
F3	F2	CF2F3	0.008131
F4	F1	CF1F4	0.047377
F4	F2	CF2F4	0.492078
F4	F3	CF3F4	-0.018468
F5	F1	CF1F5	0.192202
F5	F2	CF2F5	0.001949
F5	F3	CF3F5	0.070247
F5	F4	CF3F5	0.070247

I figuren neden for er alle de standardiserede lineære koefficienter og alle korrelationerne indtegnet på stifiguren, baseret på tallene i de to sidste output-bokse.




Figuren skal læses på den måde, at høje korrelationer tyder på en stærk sammenhæng, mens små korrelationer tyder på små (men dog signifikante) sammenhænge.

19. Stianalyse med latente variable.

Ved en stianalyse med latente variable specificeres både de lineære ligninger, som binder de latente og de manifeste variable sammen, men også ligninger, der lader nogle af de latente variable være funktioner af nogle af de øvrige. Navnet 'stianalyse' skal illustrere, at nogle af sammenhængene 'peger fremad' fra nogle variable til andre 'afledte' variable. Det er ikke ualmindeligt, at sådanne relationer opfattes som kausale sammenhænge, men det behøver ikke at være tilfældet. Man skal under alle omstændigheder være omhyggelig med at fortolke sammenhænge som kausale - alene udfra statistiske analyser af relationer mellem variable.

Grafen neden for viser en stimodel, der bygger på de samme variable, som målingsmodellen i Kapitel 18. Vi skal somme tider kalde en sådan graf et **stidiagram**.



Her er det de to spørgsmål vedrørende (F1), hvor væsentligt man synes ens job er med hensyn til løn, advancementsmuligheder mv. ('Good Job'), og (F2), hvor væsentligt man synes ens job er, med hensyn til at være til gavn for samfundet, hjælpe andre mennesker, mv. ('Interesting Job'), der opfattes som 'afledte' variable. Vi skal forsøge at forklare disse variable som afledte af de 3 andre latente variable (F3), hvor farligt jobbet er (Dangerous Job), F4 hvordan ens job rent faktisk er med hensyn til at være til gavn for samfundet, hjælpe andre mennesker, mv. ('Fakt. Interesting Job') og (F5) med hensyn til løn, advancementsmuligheder, mv. ('Fakt. Good Job').

Læg mærke til, at linierne fra de 3 'baggrundvariable' F3, F4 og F5 til de 'afledte' variable F2 og F1 nu kun har en pil i den ene ende, nemlig den, der viser fremad fra 'baggrundsvARIABLEN' til den 'afledte variabel'.

SAS-programmet til analyse af denne model ser således ud:

```

1. libname eba 's:\eba-data';
2. title 'ISSP89: All countries';
3. data a;
4. set eba.d89um;
5. keep v24-v26 v28-v31 v69 v72-v74 v59-v61 v63-v66;
6. data b;
7. set a;
8. if v24>5 then delete;
9. if v25>5 then delete;
.....

10. if v66=0 then delete;
11. proc calis covariance corr residual;
12.   lineqs
13.     v24 = lv24f1 f1 + e1,
14.     v25 = lv25f1 f1 + e2,
15.     v26 = f1 + e3,
16.     v28 = lv28f2 f2 + e4,
17.     v29 = lv29f2 f2 + e5,
18.     v30 = lv30f2 f2 + e6,
19.     v31 = f2 + e7,
20.     v69 = lv69f3 f3 + e8,
21.     v72 = lv72f3 f3 + e9,
22.     v73 = lv73f3 f3 + e10,
23.     v74 = f3 + e11,
24.     v63 = lv63f4 f4 + e12,
25.     v64 = lv64f4 f4 + e13,
26.     v65 = lv65f4 f4 + e14,
27.     v66 = f4 + e15,
28.     v59 = lv59f5 f5 + e16,
29.     v60 = lv60f5 f5 + e17,
30.     v61 = f5 + e18,
31.     f1 = pf1f2 f2 + d1,
32.     f2 = pf2f3 f3 + pf2f4 f4 + pf2f5 f5 + d2;
33.   std
34.     f3 - f5 = varf3 - varf5,
35.     d1-d2 = vard1 - vard2,
36.     e1-e18 = vare1-vare18;
37.   cov
38.     f3 f4 = cf3f4,
39.     f3 f5 = cf3f5,
40.     f4 f5 = cf4f5;
41.   var v24-v26 v28-v31 v69 v72-v74 v63-v66 v59-v61;
42. run;
43. quit;

```

Linie 1-10 svarer til de tidligere programmer, hvor data indlæses fra databasen og renses for ubesvarede spørgsmål. I linie 11-41 følger så selve PROC CALIS-kaldet. Det adskiller sig fra det tilsvarende program for målingsmodellen på flere måder.

For det første er der kommet to nye ligninger til, nemlig linie 31 og linie 32, hvor de to lineære relationer mellem 'baggrundsvariablene' F3 til F5 og de afledte variable F1 og F2 står. De lineære koefficienter betegnes her ved forbogstavet 'p' for 'path' og de to restled kaldes D1 og D2 for at adskille dem fra restleddene i ligningerne linie 13 - 30.

Det er nødvendigt at lave en ny normering af de manifeste variable. Dette skyldes at to af de latente variable F1 og F2 optræder både i ligningerne linie 13 til 30 og i de to ligninger, der definerer F1 og F2. Man vælger derfor at normere F'erne, så L-koefficienten for den sidste af V-variablene i hver gruppe, omfattende de samme latente variable, er lig med 1. Det betyder, at ligningerne for f.eks. V26 og V31 bliver

$$v26 = f1 + e3,$$

$$v31 = f2 + e7,$$

Til gengæld må vi indføre varianserne for de 3 latente 'baggrundsvariable' som parametre i modellen. Det sker i 'std'-afsnittet som linie 34, hvor de navngives 'varf3' til 'varf5'.

Varianserne af de to 'afledte' latente variable bestemmes af de nye restled D1 og D2 i linie 31 og 32, så vi må også i 'std'-afsnittet linie 35 definere D1 og D2's varianser som parametre med navnene 'vard1' og 'vard2'.

Vi skal kalde denne '**basis**' **stimodel** for M_{p0} .

Den første vigtige del af output viser de indgående ligninger på symbolsk form plus nogle grundlæggende tal, f.eks. at der er 18 variable, 171 datapunkter og 43 parametre. Ligesom ved målingsmodellen skrives der '1.000' foran alle restled.

Manifest Variable Equations

V24	=	.	*F1	+	1.0000	E1	
			LV24F1				
V25	=	.	*F1	+	1.0000	E2	
			LV25F1				
V26	=	1.0000	F1	+	1.0000	E3	
V28	=	.	*F2	+	1.0000	E4	
			LV28F2				
V29	=	.	*F2	+	1.0000	E5	
			LV29F2				
V30	=	.	*F2	+	1.0000	E6	
			LV30F2				
V31	=	1.0000	F2	+	1.0000	E7	
V69	=	.	*F3	+	1.0000	E8	
			LV69F3				
V72	=	.	*F3	+	1.0000	E9	
			LV72F3				
V73	=	.	*F3	+	1.0000	E10	
			LV73F3				
V74	=	1.0000	F3	+	1.0000	E11	
V63	=	.	*F4	+	1.0000	E12	
			LV63F4				
V64	=	.	*F4	+	1.0000	E13	
			LV64F4				
V65	=	.	*F4	+	1.0000	E14	
			LV65F4				
V66	=	1.0000	F4	+	1.0000	E15	
V59	=	.	*F5	+	1.0000	E16	
			LV59F5				
V60	=	.	*F5	+	1.0000	E17	
			LV60F5				
V61	=	1.0000	F5	+	1.0000	E18	
F1	=	.	*F2	+	1.0000	D1	
			PF1F2				
F2	=	.	*F3	+	.	*F4	+
			PF2F3			PF2F4	+
					.	*F5	+
						PF2F5	+
							1.0000
							D2
6776	Observations		Model Terms				1
18	Variables		Model Matrices				4
171	Informations		Parameters				43

```

Fit criterion . . . . . 0.7559
Goodness of Fit Index (GFI) . . . . . 0.9131
GFI Adjusted for Degrees of Freedom (AGFI) . . . . . 0.8840
Root Mean Square Residual (RMR) . . . . . 0.0567
Parsimonious GFI (Mulaik, 1989) . . . . . 0.7639

Chi-square = 5121.0244      df = 128      Prob>chi**2 = 0.0001
Null Model Chi-square:      df = 153      25973.7793

RMSEA Estimate . . . . . 0.0759  90%C.I.[0.0741, 0.0777]
Probability of Close Fit . . . . . .
ECVI Estimate . . . . . 0.7686  90%C.I.[0.7346, 0.8037]
Bentler's Comparative Fit Index . . . . . 0.8066
Normal Theory Reweighted LS Chi-square . . . . . 5799.5037
Akaike's Information Criterion . . . . . 4865.0244
Bozdogan's (1987) CAIC . . . . . 3863.9182
Schwarz's Bayesian Criterion . . . . . 3991.9182
McDonald's (1989) Centrality . . . . . 0.6918
Bentler & Bonett's (1980) Non-normed Index . . . . . 0.7689
Bentler & Bonett's (1980) NFI . . . . . 0.8028
James, Mulaik, & Brett (1982) Parsimonious NFI . . . . . 0.6717
Z-Test of Wilson & Hilferty (1931) . . . . . 58.1260
Bollen (1986) Normed Index Rho1 . . . . . 0.7643
Bollen (1988) Non-normed Index Delta2 . . . . . 0.8068
Hoelter's (1983) Critical N . . . . . 207

```

Her er vist alle de mange teststørrelser og indeks for modeltilpasning. Igen har jeg fremhævet de to linier, vi skal bruge. Vi ser at modeltilpasningen ved et Q-test er beskrevet af $q = 5121.02$ med 128 frihedsgrader, som er endog meget signifikant. Bemærk, at SAS skriver signifikanssandsynligheden som $p = 0.0001$, selv om den faktiske værdi er langt mindre end 0.00005.

I næste boks er vist alle de estimerede ligninger med 't Value' for alle lineære koefficienter. Alle L-koefficienter for de manifeste variable er signifikante, som vi skulle forvente. Men bemærk, at fordi vi har omnormeret de latente variable, får vi intet signifikanstest for koefficienterne til V26, V31, V74, V61 og V66. Til gengæld ser vi, at P-koefficienten til F3 i ligningen for F2 ikke er signifikant. Dette betyder, at én af de modelmodificeringer, der bør overvejes, er at fjerne F3 fra ligningen, der definerer F2.

```

Manifest Variable Equations

V24      =      0.5296*F1      +  1.0000 E1
Std Err      0.0289 LV24F1
t Value      18.3273

```

Den næste boks viser de estimerede korrelationer mellem de 3 latente 'baggrundsvariable' F3 til F5, sammen med værdierne af 't Values'. Tallene viser en ikke signifikant korrelation mellem F3 og F4.

Den næste modelmodifikation, der bør overvejes, er derfor at fjerne denne korrelation, svarende til den dobbelte pil mellem F3 og F4 på stidiagrammet.

Covariances among Exogenous Variables					
Parameter			Estimate	Standard Error	t Value
F4	F3	CF3F4	-0.012483	0.008161	-1.530
F5	F3	CF3F5	-0.068911	0.009271	-7.433
F5	F4	CF4F5	0.145906	0.009519	15.328

Den næste boks viser de standardiserede koefficienter.

Equations with Standardized Coefficients

V24	=	0.3938*F1 LV24F1	+ 0.9192	E1	
V25	=	0.5565*F1 LV25F1	+ 0.8309	E2	
V26	=	0.5999 F1	+ 0.8000	E3	
V28	=	0.3615*F2 LV28F2	+ 0.9324	E4	
V29	=	0.3828*F2 LV29F2	+ 0.9238	E5	
V30	=	0.7993*F2 LV30F2	+ 0.6009	E6	
V31	=	0.7611 F2	+ 0.6487	E7	
V69	=	0.5485*F3 LV69F3	+ 0.8362	E8	
V72	=	0.7393*F3 LV72F3	+ 0.6734	E9	
V73	=	0.7742*F3 LV73F3	+ 0.6330	E10	
V74	=	0.6237 F3	+ 0.7816	E11	
V63	=	0.5550*F4 LV63F4	+ 0.8319	E12	
V64	=	0.4199*F4 LV64F4	+ 0.9076	E13	
V65	=	0.7207*F4 LV65F4	+ 0.6932	E14	
V66	=	0.6861 F4	+ 0.7275	E15	
V59	=	0.4317*F5 LV59F5	+ 0.9020	E16	
V60	=	0.6744*F5 LV60F5	+ 0.7384	E17	
V61	=	0.6351 F5	+ 0.7724	E18	
F1	=	0.3033*F2 PF1F2	+ 0.9529	D1	
F2	=	0.0173*F3 PF2F3	+ 0.5042*F4 PF2F4	- 0.0652*F5 PF2F5	+ 0.8727 D2

I Kapitel 12 diskuterede vi definitionen og betydningen af denne omskalering af L- og P- koefficienterne. De viste koefficienter skal således nu opfattes som korrelationer og er derfor sammenlignelige i størrelsesforhold. Sammenhængen mellem f.eks. V30 og F2 er altså - alt andet lige - meget stærkere end sammenhængen mellem V24 og F1.

Correlations among Exogenous Variables

Parameter			Estimate
F4	F3	CF3F4	-0.024579
F5	F3	CF3F5	-0.130897
F5	F4	CF4F5	0.307511

I denne sidste boks vises korrelationerne mellem de latente 'baggrundsvARIABLE'. Som for målingsmodellen bruges disse først og fremmest til at skrive ind i en graf, hvis man ønsker, at den skal vise 'styrken' af de forskellige sammenhænge målt ved korrelationskoefficienter. Den insignifikante sammenhæng mellem F3 og F4 afspejles dog klart ved den meget lille korrelation på -0.025 mellem de to variable.

Hele PROC CALIS - programdelen får derfor udseendet:

```
proc calis covariance corr residual;
  lineqs
    v24 = lv24f1 f1 + e1,
    .....


    v61 = f5 + e18,
    f1 = pf1f2 f2 + d1,
    f2 = pf2f4 f4 + pf2f5 f5 + d2;
  std
    f3-f5 = varf3 - varf5,
    d1-d2 = vard1 - vard2,
    e1-e18 = vare1 - vare18;
  cov
    f3 f4 = cf3f4,
    f3 f5 = cf3f5,
    f4 f5 = cf4f5;
  var v24-v26 v28-v31 v69 v72-v74 v63-v66 v59-v61;
run;
quit;
```

Den første modelmodifikation, den valgte stimodel pegede på, var at fjerne den lineære relation mellem F2 og F3. Det betyder, at ligningen, der beskriver sammenhængen mellem F2 og F3 til F5, skal omformes, så de to ligninger, der definerer de latente variable F1 og F2, får udseendet

```
f1 = pf1f2 f2 + d1,
f2 = pf2f4 f4 + pf2f5 f5 + d2;
```

Vi har her udeladt de fleste af definitionsligningerne for de manifeste variable.

Derved får den modificerede stimodel, som vi skal kalde M_{p1} , det grafiske udseende:



De dele af SAS-output'et, der ændres, vises i de følgende bokse.

På symbolsk form viser SAS de nye ligninger for F1 og F2 som:

Latent Variable Equations

$$F1 = . *F2 + 1.0000 D1$$

$$F2 = . *F4 + . *F5 + 1.0000 D2$$

6776 Observations	Model Terms	1
18 Variables	Model Matrices	4
171 Informations	Parameters	42

Chi-square = 5122.3772	df = 129	Prob>chi**2 = 0.0001
Null Model Chi-square:	df = 153	25973.7793

Det fremgår samtidigt, at der nu kun er 42 parametre, sammenlignet med de 43 parametre i M_{p0} . Og at q-teststørrelsen for modellen er $q = 5122.38$ med 129 frihedsgrader.

I den næste boks er de nye estimater for de lineære parametre vist, sammen med deres standardfejl og 't Value'. Det fremgår, som forventet, at der ikke længere optræder insignifikante koefficienter.

Latent Variable Equations					
F1	=	0.2282*	F2	+	1.0000 D1
Std Err		0.0152	PF1F2		
t Value		15.0211			
F2	=	0.5028*	F4	-	0.0659*
Std Err		0.0195	PF2F4		0.0171
t Value		25.7255			-3.8513

Som det fremgår af den næste output-boks, er der imidlertid stadig en insignifikant korrelation mellem de 2 latente 'baggrundsvariable' F3 og F4.

Covariances among Exogenous Variables					
Parameter			Estimate	Standard Error	t Value
F4	F3	CF3F4	-0.010950	0.008071	-1.357
F5	F3	CF3F5	-0.069200	0.009268	-7.466
F5	F4	CF4F5	0.145948	0.009523	15.325

Så det betaler sig måske at fjerne sammenhængen mellem de latente 'baggrundsvariable' F3 og F4.

Dette gør man ved at sætte korrelationen mellem F3 og F4 lig med 0, eller simpelthen at skrive

$$f3\ f4 = 0$$

i 'cov'-afsnittet af PROC CALIS programmet.

De væsentlige del af SAS-programmet skal derfor ændres som følger.


Grafen eller stidiagrammet for denne model, som vi skal kalde M_{p2} , ser sådan ud, idet dobbelpilen mellem F3 og F4 er fjernet:

```

proc calis covariance corr;
  lineqs
  .....

  f1 = pf1f2 f2 + d1,
  f2 = pf2f4 f4 + pf2f5 f5 + d2;
  std
  f3-f5 = varf3 - varf5,
  d1-d2 = vard1 - vard2,
  e1-e18 = vare1 - vare18;
  cov
  f3 f4 = 0,
  f3 f5 = cf3f5,
  f4 f5 = cf4f5;
  var v24-v26 v28-v31 v69 v72-v74 v63-v66 v59-v61;
run;
quit;

```



Det første SAS-output viser, at der nu kun er 41 parametre i modellen, og at den relevante q-teststørrelse nu er 5124.17 med 130 frihedsgrader. Dette resultat er stadig kraftigt signifikant.

Latent Variable Equations				
F1	=	.	*F2 PF1F2	+ 1.0000 D1
F2	=	.	*F4 PF2F4	+ . *F5 PF2F5 + 1.0000 D2
6776 Observations		Model Terms		1
18 Variables		Model Matrices		4
171 Informations		Parameters		41
Chi-square = 5124.1684	df = 130	Prob>chi**2 = 0.0001		
Null Model Chi-square:	df = 153	25973.7793		

Vi venter imidlertid til Kapitel 20 med at sammenligne de forskellige modeller. Her skal vi se, at det ikke så meget er den absolutte værdi af q-teststørrelsen, der er afgørende, som differenserne mellem q-teststørrelserne. Disse er nemlig et mål for, hvor godt én model beskriver data i forhold til en anden model med flere estimerede parametre.

Den næste boks viser de to ligninger, der definerer de latente variable, sammen med de estimerede L-koefficienter, deres standardafvigelser og 't Value'. Det fremgår, at alle koefficienter er signifikant forskellige fra 0. Fjernelsen af korrelationen mellem F3 og F4 har altså ikke ændret på dette forhold.

Latent Variable Equations				
F1	=	0.2282*	F2	+ 1.0000 D1
Std Err		0.0152	PF1F2	
t Value		15.0225		
F2	=	0.5016*	F4	- 0.0649*
Std Err		0.0195	PF2F4	0.0171 PF2F5
t Value		25.7803		-3.7995

Derimod viser den næste boks, at der kun er 2 estimerede korrelationer mellem de latente 'baggrundsvariable ' tilbage, nu hvor korrelationen mellem F3 og F4 er udeladt af modellen. Til gengæld er begge disse C-koefficienter signifikant forskellige fra 0.

Covariances among Exogenous Variables					
Parameter			Estimate	Standard Error	t Value
F5	F3	CF3F5	-0.066589	0.009040	-7.366
F5	F4	CF4F5	0.144706	0.009486	15.254

I den sidste boks er de standardiserede L- og C-koefficienter vist, hvis man har lyst til at sætte estimerede korrelationer på grafen for denne model.

$$\begin{aligned}
 F1 &= 0.3032 \cdot F2 + 0.9529 \cdot D1 \\
 &\quad \text{PF1F2} \\
 F2 &= 0.5047 \cdot F4 - 0.0675 \cdot F5 + 0.8726 \cdot D2 \\
 &\quad \text{PF2F4} \quad \text{PF2F5}
 \end{aligned}$$

Correlations among Exogenous Variables

Parameter			Estimate
F5	F3	CF3F5	-0.123663
F5	F4	CF4F5	0.299410

Vi mangler en enkelt model, som bør overvejes. Hvis man ser tilbage på målingsmodellen i Kapitel 18, fremgik det, at der var signifikante korrelationer mellem F1 og F4 og mellem F1 og F3. Dog var 't-value' for korrelationen mellem F1 og F3 kun lidt over 3. Denne sammenhæng var mellem om jobbet rent faktisk var et 'Good Job' og om respondenter mente at det var væsentligt, at jobbet var et 'Interesting Job'. Man kunne måske håbe på, at denne sammenhæng kunne 'opsluges' af sammenhængen mellem F5 og F2, nemlig at jobbet er et 'Good Job' både rent faktisk, og bliver anset som sådan af respondenter.

Derimod kan vi ikke ignorere sammenhængen mellem F5 og F1, som udtrykker at jobbet er et 'Interesting Job' både rent faktisk, og bliver anset som sådan af respondenter. Så vi bør prøve at indføje en sammenhæng mellem F5 og F1 i modellen. De relevante linier i PROC CALIS programmet ændres derfor til:


```

proc calis covariance corr residual;
  lineqs
    v24 = lv24f1 f1 + e1,
    .....

    f1 = pf1f2 f2 + pf1f5 f5 + d1,
    f2 = pf2f4 f4 + pf2f5 f5 + d2;
  std
    f3-f5 = varf3 - varf5,
    d1-d2 = vard1 - vard2,
    e1-e18 = vare1 - vare18;
  cov
    f3 f4 = 0,
    f3 f5 = cf3f5,
    f4 f5 = cf4f5;
  var v24-v26 v28-v31 v69 v72-v74 v63-v66 v59-v61;
run;

```

Denne model, som vi skal kalde M_{p3} , har grafen:



Den første output-boks vises de symbolske ligninger, så vi kan checke, at modellen er korrekt skrevet op i SAS-programmet. Desuden fremgår det, at der er 42 parametre i modellen, så antal frihedsgrader til rådighed for at teste modellen er $171 - 42 = 129$.

Latent Variable Equations

F1 = . *F2 + . *F5 + 1.0000 D1
PF1F2 PF1F5

F2 = . *F4 + . *F5 + 1.0000 D2
PF2F4 PF2F5

6776 Observations	Model Terms	1
18 Variables	Model Matrices	4
171 Informations	Parameters	42

Lidt længere nede i output finder vi listen over teststørrelser og mål for modeltilpasningen.

I boksen neden for er kun vist de 2 linier med q-teststørrelser. Det fremgår, at modellen er signifikant med en observeret q-værdi på 5071.96 med - som beregnet ovenfor - 129 frihedsgrader. Men igen her henviser jeg til Kapitel 20, hvor de forskellige modeller sammenlignes ud fra **differenser** mellem observerede q-teststørrelser.

```
Chi-square = 5071.9582      df = 129      Prob>chi**2 = 0.0001
Null Model Chi-square:      df = 153      25973.7793
```

Boksen neden for viser definitionsligningerne for de latente 'afledte' variable, med standard fejl og tilhørende 't-Value'. Værdierne af 't-value' for sammenhængene mellem F1 og F2, F2 og F4, samt F2 og F5, har stort set ikke ændret sig, men P-koefficienten svarende til sammenhængen mellem F1 og F5 er klart signifikant med en 't-value' på 7.74.

Latent Variable Equations

```
F1      =      0.2422*F2      +      0.1233*F5      +      1.0000 D1
Std Err      0.0159 PF1F2      0.0159 PF1F5
t Value      15.2222      7.7407

F2      =      0.4994*F4      -      0.0660*F5      +      1.0000 D2
Std Err      0.0194 PF2F4      0.0168 PF2F5
t Value      25.7801      -3.9345
```

Hvis man ønsker at tegne modellens graf med de estimerede korrelationer, viser de 2 næste bokse de dele af SAS-output'et, som skal benyttes.

Equations with Standardized Coefficients


```
F1      =      0.2942*F2      +      0.1584*F5      +      0.9385 D1
              PF1F2              PF1F5

F2      =      0.5029*F4      -      0.0697*F5      +      0.8736 D2
              PF2F4              PF2F5
```

Correlations among Exogenous Variables

Parameter			Estimate
F5	F3	CF3F5	-0.123663
F5	F4	CF4F5	0.299410

Grafen eller stidiagrammet for den 'endelige' model med styrken af de enkelte sammenhænge udtrykt ved korrelationer ser sådan ud:



20. Sammenligning af målingsmodellen og stimodellerne.

Vi skal bruge resultaterne i Kapitel 17 til at sammenligne de forskellige modeller, der blev analyseret i Kapitel 18 og 19. De modeller, der er tale om, er M_m , M_{p0} , M_{p1} , M_{p2} og M_{p3} .

De af SAS beregnede q-teststørrelserne og de tilhørende frihedsgrader (df) er vist i tabellen nedenfor. Jeg har ikke vist signifikanssandsynlighederne for disse q-værdier, idet de alle er vildt signifikante.

Derimod er der, for hver af de 4 sidste linier, vist differensen mellem q-størrelserne, antal frihedsgrader for q-differensen og de tilhørende signifikanssandsynligheder.

Model	q	df	q-differens	df	Sign.ssh.
M_m	5005.23	125	-	-	-
M_{p0}	5121.02	128	115.79	3	< 0.0005
M_{p1}	5121.38	129	1.36	1	0.244
M_{p2}	5124.17	130	1.79	1	0.181
M_{p3}	5071.96	129	52.21	1	< 0.0005

Her får man overblik over situationen, som kan samles i følgende resultater:

(a) Målingsmodellen (M_m) kan ikke beskrive materialet. Det kan derfor heller ikke nogle af de 4 stimodeller (M_{p0} til M_{p3}), der jo er enklere modeller end målingsmodellen. Så egentlig burde man stoppe her. Men de følgende kommentarer viser, at det behøver man ikke.

(b) Da q-differensen mellem målingsmodellen (M_m) og den første stimodel (M_{p0}) er signifikant, kan vi konstatere, at vi i basis stimodellen har udeladt signifikante sammenhænge mellem de latente variable.

(c) q-differensen mellem M_{p1} og M_{p0} er ikke signifikant. Det betyder, at de to modeller har en lige god (omend generelt meget dårlig) tilpasning til data. Så korrelationen mellem F3 og F2 kan altså udelades uden at forringe modellens tilpasningsevne.

(d) På samme måde er q-differensen mellem M_{p2} og M_{p1} ikke signifikant. Det betyder, at de to modeller har en lige god tilpasning til data. Korrelationen mellem F3 og F4 kan altså også udelades uden at forringe modellens tilpasningsevne.

(e) Her skal vi være opmærksom på at M_{p3} er en **forbedring** af modellen i forhold til M_{p2} , dvs. M_{p3} har **flere** parametre end M_{p2} . Det betyder, at vi nu skal trække det nederste tal fra **dét lige over**, hvor vi i de andre linier har gjort det modsatte. Her er resultatet klart signifikant, så vi får en markant forbedring af modellens tilpasning til data ved at tilføje en korrelation mellem F5 og F1.

21. Simpel correspondance analyse

Den observerede værdi af Pearsons Q-teststørrelse

$$q = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(x_{ij} - \frac{x_{i.} x_{.j}}{n} \right)^2}{\frac{x_{i.} x_{.j}}{n}}$$

er et mål for hvor meget de observerede antal i en kontingenstabel $\{x_{ij}\}$ afviger fra de forventede antal

$$\frac{x_{i.} x_{.j}}{n}$$

under en hypotese om uafhængighed. Idéen i correspondance analyse er at beskrive forskellene mellem de observerede og forventede værdier ved hjælp af passende størrelser, der kan afbildes i en graf. Det er traditionen i correspondance analyse, at man arbejder med hyppigheder og ikke antal. Man omskriver derfor Pearsons Q-teststørrelse til

$$q = n \sum_{i=1}^I \sum_{j=1}^J \frac{(f_{ij} - f_{i.} f_{.j})^2}{f_{i.} f_{.j}},$$

hvor $f_{ij} = x_{ij}/n$, $f_{i.} = x_{i.}/n$ og $f_{.j} = x_{.j}/n$, så

$$q = n \sum_{i=1}^I \sum_{j=1}^J \left(\frac{f_{ij}}{f_{i.} f_{.j}} - 1 \right)^2 f_{i.} f_{.j},$$

Jo større leddene

$$r_{ij} = \frac{f_{ij}}{f_{i.} f_{.j}} - 1$$

derfor er, jo mere afviger de observerede data fra uafhængighedsantagelsen.

I correspondance analyse dekomponerer man matricen $\mathbf{R}$ af residualled r_{ij} i egenvektorer og egenværdier, dvs.

$$\mathbf{R} = \Phi \Lambda \Psi^T$$

Hvor Λ , som sædvanligt, er en diagonal matrix med egenværdierne i diagonalen. Hvad Φ 'erne og Ψ 'erne, dvs elementerne i Φ og Ψ , betyder, vender vi tilbage til.

Der er en mest teknisk detalje af stor betydning for anvendelserne, man skal kende til. I modsætning til en almindelig egenværdidekomponering af en matrix, hvor søjlerne i Φ og Ψ er ortogonale, anvendes i correspondance analyse matrixer, der er ortogonale med en lidt anden definition. Man kræver nemlig, at kvadratsummerne af søjlerne i Φ skal være 1, **vægtet med rækkefrekvenserne**, og at produktsummerne af søjlerne i Φ skal være 0, **vægtet med rækkefrekvenserne**. Det tilsvarende gælder for matrixen Ψ . Normeringerne af ϕ 'erne og ψ 'erne får derfor formen:

$$\sum_{i=1}^I \phi_{im}^2 f_{i\cdot} = \sum_{j=1}^J \psi_{jm}^2 f_{\cdot j} = 1 \quad , \quad \text{for alle } m \quad ,$$

mens kravet om, at produktsummerne skal være 0, erstattes af

$$\sum_{i=1}^I \phi_{im} \phi_{i\mu} f_{i\cdot} = \sum_{j=1}^J \psi_{jm} \psi_{j\mu} f_{\cdot j} = 0 \quad , \quad \text{for alle } m \neq \mu \quad .$$

Ligningen

$$\mathbf{R} = \Phi \Lambda \Psi^T$$

giver en 'fuldstændig løsning' i den forstand, at alle afvigelser fra uafhængighed er beskrevet.

Af hensyn til det følgende skriver vi denne matrix ligning fuldt ud:

$$r_{ij} = \sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} \quad , \quad i=1, \dots, I, \quad j=1, \dots, J \quad .$$

Matrixen $\mathbf{R}$ har rang $\min\{I-1, J-1\}$, idet

$$\sum_i f_{i\cdot} r_{ij} = 0 \quad \text{og} \quad \sum_j f_{\cdot j} r_{ij} = 0 \quad .$$

Dvs. rangen af $\mathbf{R}$ er lig med $\min\{I-1, J-1\}$, så selv for kontingenstabeller af moderat orden, f.eks. 3x4 eller 5x5, kan der blive mange parametre at holde rede på.

Man vælger derfor i correspondance analyse at beskrive residualmatrixen, dvs. afvigelserne mellem det observerede og det forventede under uafhængighed, ved en egenværdi/egenvektor dekomponering af mindre dimension end den maksimale. I den franske tradition, som SAS følger, vælges altid to dimensioner.

Det betyder ganske vist, at man kun får en approksimation til residualerne, idet vi nu har

$$\mathbf{R} \approx \Phi_0 \Lambda_0 \Psi_0^T$$

eller

hvor Λ_0 betegner Λ med kun de M_0 største λ 'er, Φ_0 består af de første M_0 søjler i Ψ og Ψ_0 består af de første M_0 søjler i Ψ . Denne approksimation bliver naturligvis bedre, større dimension M_0 vi vælger, dvs. hvor tæt M_0 kommer på M .

$$r_{ij} = \sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} \approx \sum_{m=1}^{M_0} \lambda_m \phi_{im} \psi_{jm} ,$$

Lige som for principalkomponentmetoden kan correspondance analyse med M_0 dimensioner begrundes ved et mindste kvadraters resultat.

SÆTNING: Hvis kvadratsummen $Q(M_0)$ er defineret som

$$Q(M_0) = \sum_{i=1}^I \sum_{j=1}^J \left(r_{ij} - \sum_{m=1}^{M_0} \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i \cdot} f_{\cdot j} ,$$

da antager $Q(M_0)$ sit minimum, hvis

$$\lambda_1, \lambda_2, \dots, \lambda_{M_0}$$

er de M_0 største egenverdier, mens ϕ_{im} , $i=1, \dots, I$, $m=1, \dots, M_0$ er de søjler i Φ , der svarer til de M_0 største egenverdier og ψ_{jm} , $j=1, \dots, J$, $m=1, \dots, M_0$ er de søjler i Ψ , der svarer til de M_0 største egenverdier.

Approximationen

$$\mathbf{R} \approx \Phi_0 \Lambda_0 \Psi_0^T ,$$

som vi også udledte oven for, kan således tillige begrundes som en mindste kvadraters løsning.

I correspondance analyse tegner man altid det såkaldte 'correspondance analyse diagram' med $M_0 = 2$. I et sådant diagram er der ét punkt for hver rækkekategori og ét punkt for hver søjlekategori. x-koordinater for de punkter, der svarer til rækkekatégorierne, er

$$(\lambda_1 \phi_{11}, \dots, \lambda_1 \phi_{I1}) ,$$

mens y-koordinaterne er

$$(\lambda_2 \phi_{12}, \dots, \lambda_2 \phi_{I2}) .$$

På tilsvarende måde bliver x-koordinaterne for de punkter, der svarer til søjlekatégorierne

$$(\lambda_1 \psi_{11}, \dots, \lambda_1 \psi_{J1}) ,$$

og y-koordinaterne

For at vise, hvordan et correspondance analyse diagram ser ud, betragter vi følgende eksempel.


$$(\lambda_2 \psi_{12}, \dots, \lambda_2 \psi_{J_2}) .$$

Tabellen neden for viser hvordan et tilfældigt udvalg af danskere mellem 40 og 59 år gamle i 1974 fordelte sig på Social Gruppe og hvor ofte de deltog i møder uden for arbejdstiden.

Social Gruppe	Hyppighed af møder uden for arbejdstiden				
	Én eller to gange om ugen	Èn eller to gange om måneden	Ca. én gang hver anden måned	Nogle få gange om året	Aldrig
I	17	27	13	24	25
II	25	57	17	49	55
III	38	91	41	217	213
IV	22	33	21	133	222
V	9	21	17	87	305

Det er også denne tabel, der bliver analyseret i forbindelse med correspondance analyse med SAS i næste kapitel.

Foretager vi en egenverdi/egenvektor dekomponering af residual matricen $\mathbf{R}$, som gennemgået oven for og taster de viste x- og y-koordinater for både rækker og søjler ind i et regneark, får vi grafen på næste side. Det fremgår, at de to højeste socialgrupper ligner hinanden, og at det er dem, der oftest går til møder. Socialgruppe III ligger i midten og går kun af og til til møder. Endelig går personer i de to laveste socialgruppe næsten aldrig til møder uden for arbejdstiden. For den laveste socialgruppe, ser det endda ud til, at de aldrig går til møder.



Den observerede værdi af Pearsons Q-teststørrelse

$$q = \sum_{i=1}^I \sum_{j=1}^J \frac{\left(x_{ij} - \frac{x_{i.} x_{.j}}{n} \right)^2}{\frac{x_{i.} x_{.j}}{n}}$$

kan også skrives

$$q = \sum_{i=1}^I \sum_{j=1}^J \left(\frac{x_{ij}}{x_{i.}} - \frac{x_{.j}}{n} \right)^2 \left(\frac{n x_{i.}}{x_{.j}} \right),$$

eller

$$q = n \sum_{i=1}^I f_{i.} \sum_{j=1}^J \left(\frac{f_{ij}}{f_{i.}} - f_{.j} \right)^2 \left(\frac{1}{f_{.j}} \right).$$

Ved at bytte om på i og j, får man det analoge resultat

$$q = n \sum_{j=1}^J f_{\cdot j} \sum_{i=1}^I \left(\frac{f_{ij}}{f_{\cdot j}} - f_{i\cdot} \right)^2 \left(\frac{1}{f_{i\cdot}} \right).$$

Man kalder i correspondance analyse vektoren

$$\frac{f_{ij}}{f_{i\cdot}}, \quad j = 1, \dots, J$$

for rækkeprofilerne, idet disse størrelser er de relative hyppigheder for tallene i række i. Under uafhængighedshypotesen skal disse være ens bortset fra tilfældige afvigelser. På samme måde defineres søjleprofilerne som

$$\frac{f_{ij}}{f_{\cdot j}}, \quad i = 1, \dots, I.$$

Også disse skal under uafhængighedshypotesen være ens bortset fra tilfældige afvigelser.

Pearsons Q-teststatistic kan derfor fortolkes enten som en vejet sum af afstandene mellem søjleprofilerne og de estimerede søjleprofiler under hypotesen om uafhængighed, eller som en vejet sum af afstandene mellem rækkeprofilerne og de estimerede rækkeprofiler under hypotesen om uafhængighed.

Der er en meget vigtig omskrivning af Pearsons Q-teststørrelse, som spiller en stor rolle ved fortolkningen af correspondance analysens resultater.

Da q kan skrives

$$q = n \sum_{i=1}^I \sum_{j=1}^J \left(\frac{f_{ij}}{f_{i\cdot} f_{\cdot j}} - 1 \right)^2 f_{i\cdot} f_{\cdot j}$$

og

$$\frac{f_{ij}}{f_{i\cdot} f_{\cdot j}} - 1 = \sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm},$$

får vi

$$\begin{aligned} q &= n \sum_{i=1}^I \sum_{j=1}^J \left(\sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i\cdot} f_{\cdot j} \\ &= n \sum_{m=1}^M \sum_{\mu=1}^M \lambda_m \lambda_{\mu} \sum_{i=1}^I \phi_{im} \phi_{i\mu} f_{i\cdot} \sum_{j=1}^J \psi_{jm} \psi_{j\mu} f_{\cdot j}, \end{aligned}$$

Men da de to sidste summer (over i og j) er lig 0, undtagen for $m = \mu$, får vi udtrykket

$$q = n \sum_{m=1}^M \lambda_m^2.$$

På den anden side er q_0 , defineret som

$$q_0 = n \sum_{i=1}^I \sum_{j=1}^J \left(\frac{f_{ij}}{f_{i \cdot} f_{\cdot j}} - 1 - \sum_{m=1}^{M_0} \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i \cdot} f_{\cdot j} ,$$

et mål for hvor godt data er beskrevet, efter vi har indført en correspondance analyse model med $M = M_0$.

Benytter vi

$$r_{ij} = \left(\frac{f_{ij}}{f_{i \cdot} f_{\cdot j}} - 1 \right) = \sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm}$$

kan ovenstående ligning omskrives til

$$\begin{aligned} q_0 &= n \sum_{i=1}^I \sum_{j=1}^J \left(\sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} - \sum_{m=1}^{M_0} \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i \cdot} f_{\cdot j} \\ &= n \sum_{i=1}^I \sum_{j=1}^J \left(\sum_{m=M_0+1}^M \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i \cdot} f_{\cdot j} , \end{aligned}$$

der let omskrives til

$$q_0 = n \sum_{m=M_0+1}^M \lambda_m^2$$

jvf. reduktionen af q til n gange en sum af alle λ 'erne oven for.

Værdien af q_0 er lille, hvis næsten al variation i data er forklaret af correspondance analyse modellen, og stor, hvis kun en lille del af variationen er forklaret.

Man kan derfor benytte

som et mål for hvor meget af variationen i data, der er forklaret af en correspondance analyse model med M_0 dimensioner.

$$q - q_0 = n \sum_{m=1}^{M_0} \lambda_m^2$$

Et relativt mål for den forklarede del bliver herefter

$$r^2(M_0) = \frac{n \sum_{m=1}^{M_0} \lambda_m^2}{n \sum_{m=1}^M \lambda_m^2} = \frac{q - q_0}{q} .$$

For vores eksempel får vi tallene

	Dimension			
	m / M ₀ = 1	2	3	4
λ_m	0.354	0.139	0.048	0.021
$r^2(M_0)$	0.850	0.981	0.997	1.000

Ud fra udtrykket

$$q = n \sum_{i=1}^I \sum_{j=1}^J \left(\sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i\cdot} f_{\cdot j} .$$

for Pearsons Q-teststatistic kan man danne sig et indtryk af, hvor meget rækkevariablen i bedrager til beskrivelsen af afvigelserne mellem data og model. Vi behøver blot at fastholde indeks i, dvs.

$$q_i = n \sum_{j=1}^J \left(\sum_{m=1}^M \lambda_m \phi_{im} \psi_{jm} \right)^2 f_{i\cdot} f_{\cdot j} .$$

Lidt omformninger af dette udtryk giver:

$$q_i = n f_{i\cdot} \sum_{j=1}^J \sum_{m=1}^M \sum_{\mu=1}^M \lambda_m \lambda_{\mu} \phi_{im} \psi_{jm} \phi_{i\mu} \psi_{j\mu} f_{\cdot j} .$$

eller

$$q_i = n f_{i\cdot} \sum_{m=1}^M \sum_{\mu=1}^M \lambda_m \lambda_{\mu} \phi_{im} \phi_{i\mu} \sum_{j=1}^J \psi_{jm} \psi_{j\mu} f_{\cdot j} .$$

Men da summen over j i dette udtryk på grund af ψ -matricens ortogonalitet, vejet med $f_{\cdot j}$, er 1 for $m = \mu$ og 0 for $m \neq \mu$, får vi

$$q_i = n f_{i\cdot} \sum_{m=1}^M \lambda_m^2 \phi_{im}^2 .$$

Det **relative bidrag fra række i til dimension m**, bliver altså

$$D_{im}^A = \frac{n f_{i\cdot} \lambda_m^2 \phi_{im}^2}{\sum_{i=1}^I n f_{i\cdot} \lambda_m^2 \phi_{im}^2} .$$

Men igen på grund af Φ -maricens vejede ortogonalitet, dvs.

$$\sum_{i=1}^I f_{i\cdot} \cdot \phi_{im}^2 = 1 ,$$

har $D_{i\cdot m}^A$ den simple form

$$D_{i\cdot m}^A = f_{i\cdot} \cdot \phi_{im}^2 .$$

På samme måde defineres det **relative bidrag fra søjle j til dimension m** som

$$D_{jm}^B = f_{\cdot j} \psi_{jm}^2 .$$

Hvis man i stedet sammenligner det (i,m) 'te led i q_i med summen over m ved at dividere med summen over m , får man det **relative bidrag til række i fra dimension m** som

$$d_{i\cdot m}^A = \frac{n f_{i\cdot} \lambda_m^2 \phi_{im}^2}{\sum_{m=1}^M n f_{i\cdot} \lambda_m^2 \phi_{im}^2} = \frac{\lambda_m^2 \phi_{im}^2}{\sum_{m=1}^M \lambda_m^2 \phi_{im}^2}$$

Tilsvarende bliver det **relative bidrag til søjle j fra dimension m**

$$d_{jm}^B = \frac{\lambda_m^2 \psi_{jm}^2}{\sum_{m=1}^M \lambda_m^2 \psi_{jm}^2}$$

22. Simpel correspondance analyse i SAS

For eksemplet i Kapitel 21, hvor 'Social Gruppe' er krydset med 'Hyppigheden af at deltage i møder uden for arbejdstiden', udføres en correspondance analyse ved hjælp af SAS proceduren PROC CORRESP. SAS-programmet kan udformes forskelligt.

Dette SAS program er en version, der er sat op, så man får et simpelt plot.

```
1 title 'Meeting data';
2 data meet;
3 input socgr $ w m s y n;
4 label w = 'Week'
5       m = 'Month'
6       s = 'Second Month'
7       y = 'Year'
8       n = 'Never';
9 cards;
10 1 17 27 13 24 25
11 2 25 57 17 49 55
12 3 38 91 41 217 213
13 4 22 33 21 133 222
14 5 9 21 17 87 305
15 proc corresp all data = meet out = results;
16 var w m s y n;
17 id socgr;
18 proc plot data = results;
19 plot dim2*dim1 = socgr;
20 run;
21 quit;
```

Linie 1 angiver en overskrift til hver side.

Linie 2-14 viser hvordan datasættet 'meet' sættes op.

```

2 data meet;
3 input socgr $ w m s y n;
4   label w = 'Week'
5         m = 'Month'
6         s = 'Second Month'
7         y = 'Year'
8         n = 'Never';
9 cards;
10 1 17 27 13 24 25
11 2 25 57 17 49 55
12 3 38 91 41 217 213
13 4 22 33 21 133 222
14 5 9 21 17 87 305

```

I linie 3 kaldes rækkevariablen 'socgr', der står for Social Gruppe, mens søjlevariablene kaldes w, m, s, y og n. Det er af hensyn til grafen, jeg har valgt disse fem bogstaver. I linie 4 til 8 tildeles de labels. Jeg har her, igen af hensyn til grafen, forkortet sådan:

```

'Week' = 'Once a week'
'Month' = 'Once a month'
'Second month' = 'Once every second month'
'Year' = 'Once a year'
'Never' = 'Never'

```

Pointen er, at alle labels starter med et forskelligt første bogstav.

Fra linie 9 til 14 står selve data. Her er socialgrupperne I, II, III, IV og V navngivet '1', '2', '3', '4' og '5' - igen af hensyn til grafen. Bemærk, at man stadig skal skrive 'cards' (i linie 9) som en nostalgisk påmindelse om hulkortenes tidsalder fra 1960 til 1975.

Kaldet af PROC CORRESP står i linie 15 - 17.

```

15 proc corresp all data = meet out = results;
16   var w m s y n;
17   id socgr;

```

Her er valgt optionen 'all', der giver en række grundtal, mens 'data = meet' betyder, at der analyseres på datasættet 'meet'. Endelig angiver 'out = results', at der laves et output datasæt, hvor bl.a. koordinaterne til correspondance analyse diagrammet står. De fem variable, der skal analyseres står i linie 16. Som det ses, er det søjlevariablene. At rækkevariablene skal være de 5 socialgrupper markeres i linie 17 med 'id socgr'.

Selve grafen laves i linie 18 og 19:

```
18 proc plot data = results;
19 plot dim2*dim1 = socgr;
```

Læg mærke til, at i output datasættet 'results' fra PROC CORRESP er plotkoordinaterne gemt som 'dim1' og 'dim2', derfor skal Proc Plot anvendes på SAS-datasættet 'results'. Man skal skrive 'plot dim2*dim1 = socgr', idet 'dim1' og 'dim2', som sagt er plotkoordinaterne, og vi ønsker et punkt for hver værdi af 'socgr'.

Endelig skal der, som altid stå 'run' og 'quit' i de to sidste linier, linie 20 og 21.

SAS leverer en del output, hvor noget er relateret til den korte teoretiske gennemgang i Kapitel 21, andet ikke. Correspondance analyse, som den blev lanceret af franskmænd i midten af 60'erne var baseret på en geometrisk beskrivelse af sammenhænge mellem kategoriserede data, hvorfor mange af betegnelserne - som er overtaget af SAS-programmørerne -, stadig refererer til de franske geometriske betegnelser. Imidlertid viser SAS-output'et alle de væsentlige størrelser.

Så i det følgende, skal vi koncentrere os om de dele af SAS output'et, der har interesse i forbindelse med gennemgangen af correspondance analyse i Kapitel 21. Output'et i uddrag ser sådan ud:

De første 3 SAS-output bokse viser de resultater, man får ved at bruge optionen 'all' i kaldet af PROC CORRESP. I boksen neden for står de observerede antal med række- og søjlesummer, de forventede antal man får under uafhængighedshypotesen

$$n\hat{\pi}_{ij} = \frac{x_{i.} x_{.j}}{x_{..}},$$

samt forskellene mellem observerede og de forventede antal under uafhængighedshypotesen.

Contingency Table						
	Week	Month	Second Month	Year	Never	Sum
1	17	27	13	24	25	106
2	25	57	17	49	55	203
3	38	91	41	217	213	600
4	22	33	21	133	222	431
5	9	21	17	87	305	439
Sum	111	229	109	510	820	1779

Chi-Square Statistic Expected Values						
	Week	Month	Second Month	Year	Never	
1	6.614	13.645	6.495	30.388	48.859	
2	12.666	26.131	12.438	58.196	93.569	
3	37.437	77.234	36.762	172.007	276.560	
4	26.892	55.480	26.408	123.558	198.662	
5	27.391	56.510	26.898	125.852	202.350	

Observed Minus Expected Values						
	Week	Month	Second Month	Year	Never	
1	10.386	13.355	6.505	-6.388	-23.859	
2	12.334	30.869	4.562	-9.196	-38.569	
3	0.563	13.766	4.238	44.993	-63.560	
4	-4.892	-22.480	-5.408	9.442	23.338	
5	-18.391	-35.510	-9.898	-38.852	102.650	

Den næste boks viser de individuelle bidrag til Pearsons Q-teststørrelse. Den samlede værdi af Q-teststørrelsen er $q = 262.66$, der med 16 frihedsgrader klart forkaster uafhængighedshypotesen.

Contributions to the Total Chi-Square Statistic						
	Week	Month	Second Month	Year	Never	Sum
1	16.310	13.072	6.516	1.343	11.651	48.892
2	12.010	36.466	1.673	1.453	15.898	67.501
3	0.008	2.453	0.489	11.769	14.608	29.327
4	0.890	9.109	1.107	0.722	2.742	14.569
5	12.348	22.314	3.642	11.994	52.074	102.372
Sum	41.567	83.414	13.427	27.280	96.972	262.661

De sidste tabeller viser, hvad man i correspondance analyse kalder 'rækkeprofiler' og 'søjleprofiler'. Der er blot tale om, at man i den første tabel kalder de relative hyppigheder i hver række 'Row Profiles'. F.eks. er $0.160 = 17/106$. I tabellen med søjleprofiler kaldes omvendt de relative hyppigheder i hver søjle 'Column Profiles'. F.eks. er $0.153 = 17/111$.

Row Profiles					
	Week	Month	Second Month	Year	Never
1	0.160377	0.254717	0.122642	0.226415	0.235849
2	0.123153	0.280788	0.083744	0.241379	0.270936
3	0.063333	0.151667	0.068333	0.361667	0.355000
4	0.051044	0.076566	0.048724	0.308585	0.515081
5	0.020501	0.047836	0.038724	0.198178	0.694761
Column Profiles					
	Week	Month	Second Month	Year	Never
1	0.153153	0.117904	0.119266	0.047059	0.030488
2	0.225225	0.248908	0.155963	0.096078	0.067073
3	0.342342	0.397380	0.376147	0.425490	0.259756
4	0.198198	0.144105	0.192661	0.260784	0.270732
5	0.081081	0.091703	0.155963	0.170588	0.371951

I det næste output står selve resultaterne fra correspondance analysen. Den første boks ser sådan ud:

Inertia and Chi-Square Decomposition					
Singular Values	Principal Inertias	Chi-Squares	Percents	17	34
0.35420	0.12546	223.188	84.97%	51	68
0.13946	0.01945	34.602	13.17%	85	
0.04798	0.00230	4.096	1.56%		
0.02087	0.00044	0.775	0.30%		
	0.14765	262.661	(Degrees of Freedom = 16)		

Se bort fra 'Singular Values'. 'Principal Inertias' (lydskrift for 'inertias': 'i-nø-tjas' med tryk på første stavelse) er egenverdierne λ_1 til λ_4 .

'Chi-Squares' er fordelingen af den samlede Pearson Q-teststørrelse på de 4 dimensioner, dvs. med betegnelserne i Kapitel 21: Tallet 223.188 i linie 1 er $q - q_0$ for $M_0 = 1$, mens summen $223.188 + 34.602 = 257.790$ af de to første tal er $q - q_0$ for $M_0 = 2$. Således fortsættes, så summen af de tre første tal $223.188 + 34.602 + 4.096 = 261.886$ er $q - q_0$ for $M_0 = 3$. Summen af alle 'Chi-Squares' er lig med den samlede Pearson Q-teststørrelse 262.661, idet rangen af den matrix, der dekomponeres, er $M_0 = 4$.

'Percents' er 'Chi-Squares' procentvis fordeling på dimensionerne. Skal man bruge $q - q_0$ divideret med q for hver dimension, skal man danne de kumulative procenter i 'Percent'-søjlen.

Den næste del af SAS-output'et ser således ud:

Row Coordinates		
	Dim1	Dim2
1	0.623811	0.228697
2	0.540517	0.185881
3	0.164169	-.146287
4	-.162536	-.069750
5	-.465369	0.127241

Summary Statistics for the Row Points			
	Quality	Mass	Inertia
1	0.957071	0.059584	0.186140
2	0.982533	0.114109	0.256990
3	0.989210	0.337268	0.111654
4	0.925454	0.242271	0.055467
5	0.998137	0.246768	0.389749

'Row coordinates' i søjlen under 'Dim1' er de punkter, der skal bruges i correspondance analyse diagrammet som x-koordinater for socialgruppe I til V, her 1 til 5. Tallene 'Column coordinates' i søjlen under 'Dim2' er y-koordinaterne for socialgruppe I til V i correspondance analyse diagrammet. Disse tal kan, hvis man ønsker en bedre graf, overføres til et regneark, f.eks. EXCEL eller QUATTRO PRO, hvor grafen så laves.

Dernæst i dette SAS-output står en række nøgletal, som man i den franske geometriske tradition lægger stor vægt på.

Søjlen med 'Quality' skal du blot se bort fra. Søjlen betegnet 'Mass' er sådan set triviell, idet den blot viser den relative fordeling af rækkemarginalerne i den observerede tabel. Tallet 0.059584 er således $106/1779$ fra den observerede kontingenstabel. Dvs. søjlerne i 'Mass' viser blot $f_{i.}$ for $i = 1, \dots, 5$.

I den sidste søjle 'inertia' [i -nø - tja] vises de størrelser, vi i Kapitel 21 kaldte q_i , dvs. hvor meget af værdien af Pearsons Q-teststørrelse q , der skyldes et bidrag fra række i , dvs. med

$$q_i = \sum_{j=1}^J \frac{\left(x_{ij} - \frac{x_{i.} x_{.j}}{n} \right)^2}{\frac{x_{i.} x_{.j}}{n}}$$

er 'inertia' q_i/q , f.eks. $0.186 = 48.89/626.66$.

I den næste del af SAS-output'et står bidragene **fra række kategori i til dimension m**, dvs. D_{im}^A med notationen i Kapitel 21, men i SAS-sprog benævnt 'Partial Contribution to Inertia

from the Row Points', samt størrelserne d_{im}^A , i Kapitel 21 benævnt **bidragene fra dimension til kategori m**, men i SAS-sprog benævnt 'Squared Cosines for the Row Points'.

Partial Contributions to Inertia for the Row Points

	Dim1	Dim2
1	0.184817	0.160222
2	0.265732	0.202704
3	0.072454	0.371071
4	0.051016	0.060599
5	0.425981	0.205405

Squared Cosines for the Row Points

	Dim1	Dim2
1	0.843677	0.113394
2	0.878623	0.103910
3	0.551395	0.437815
4	0.781530	0.143924
5	0.928709	0.069428

Man ser at det er socialgruppe V, der bidrager mest til dimension 1, og socialgruppe III, der bidrager mest til dimension 2. På den anden side bidrager dimension 1 mest til at forklare socialgruppe I, II, IV og V, mens dimension 1 og dimension 2 bidrager lige meget til at forklare socialgruppe III.

For søjlevariablene ser SAS-output'et, svarende til output for rækkerne, således ud:

Column Coordinates

	Dim1	Dim2
Week	0.574625	0.167089
Month	0.585062	0.119867
Second Month	0.329072	0.054837
Year	0.082910	- .215870
Never	-.336483	0.070878

Summary Statistics for the Column Points

	Quality	Mass	Inertia
Week	0.956292	0.062395	0.158255
Month	0.979169	0.128724	0.317573
Second Month	0.903474	0.061270	0.051120
Year	0.999677	0.286678	0.103862
Never	0.999878	0.460933	0.369191

'Column coordinates' er de punkter, der skal bruges i correspondance analyse diagrammet som x-koordinater for de 5 'meeting' grupper w, m, s, y og n, i søjlen under 'Dim1', og y-koordinaterne for de 5 'meeting' grupper w, m, s, y og n, i søjlen under 'Dim2'. Også disse tal kan, hvis man ønsker en bedre graf, overføres til et regneark, f.eks. EXCEL eller QUATTRO PRO, hvor grafen så laves.

Dernæst i dette SAS-output står, som for rækkerne, en række nøgletal, som man i den franske geometriske tradition lægger stor vægt på.

Søjlen med 'Quality' skal du igen blot se bort fra. Søjlen betegnet 'Mass' viser blot den relative fordeling af søjlemarginalerne i den observerede tabel. Dvs. med betegnelserne i Kapitel 21, $f_{.j}$ for $j = 1, \dots, 5$.

I den sidste søjle, 'inertia', vises størrelserne q_j/q , hvor q_j svarer til q_j i Kapitel 21, dvs. hvor meget af værdien af Pearsons Q-teststørrelse q , der skyldes et bidrag fra søjle j , dvs.

$$q_j = \frac{\sum_{i=1}^I \left(x_{ij} - \frac{x_{i.} x_{.j}}{n} \right)^2}{\frac{x_{i.} x_{.j}}{n}} .$$

I den næste del af SAS-output'et står bidragene **fra søjle kategori j til dimension m**, dvs. D_{jm}^B med notationen i Kapitel 21, men i SAS-sprog benævnt 'Partial contribution to Inertia from the Column Points', samt størrelserne d_{jm}^B , i Kapitel 21 benævnt bidragene **til søjle kategori j fra dimension m**, men i SAS-sprog benævnt 'Squared Cosines for the Column Points'.

Partial Contributions to Inertia for the Column Points


	Dim1	Dim2
Week	0.164218	0.089560
Month	0.351212	0.095089
Second Month	0.052886	0.009473
Year	0.015708	0.686828
Never	0.415976	0.119050

Squared Cosines for the Column Points

	Dim1	Dim2
Week	0.881739	0.074553
Month	0.939723	0.039445
Second Month	0.879063	0.024411
Year	0.128509	0.871168
Never	0.957397	0.042480

Man ser at det er 'Month' og 'Never', der bidrager mest til dimension 1, og 'Year', der bidrager mest til dimension 2. På den anden side bidrager dimension 1 mest til at forklare de

3 første og den sidste søjle, mens dimension 2 kun bidrager væsentligt til at forklare søjle 4: 'Year'. Det correspondance analyse diagram denne version af SAS-programmet frembringer, ser det sådan ud:



Det er det samme correspondance analyse diagram som figuren i Kapitel 21, men i en lidt mere primitiv udgave.

23. Multipel correspondance analyse i SAS.

Desværre er der flere måder at lave correspondance analyse for kontingenstabeller med flere end to variable. Den mest udbredte kaldes Multiple Correspondance Analyse, eller blot 'MCA'. Denne metode bygger på den såkaldte 'Burt matrix'. Vi skal her udelukkende betragte tilfældet med 3 variable. I eksemplet bliver det Indkomst, Formue og om man ejer eller lejer sin bolig. Kaldet vi disse tre variable 'Indk', 'Form' og 'Ejer/Lejer' dannes Burt matrixen ved at stille alle kategorierne for de tre variable op på rad og række, dvs. med 5 indkomst intervaller, 5 formueintervaller og de to kategorier 'Ejer' og 'Lejer', bliver det 12 kategorier i alt. Disse 12 kategorier lader man da være både rækkerne og søjlerne i kontingenstabellen. Dermed får man 9 dele af kontingenstabellen som anskueliggjort i følgende skema:

Datamatricer	Indk	Form	Ejer/Lejer
Indk	D_I	C_{IF}	C_{IE}
Form	$C_{FI} = C_{IF}^T$	D_F	C_{FE}
Ejer/Lejer	$C_{EI} = C_{IE}^T$	$C_{EF} = C_{FE}^T$	D_E

Her er C-matricerne de to-dimensionale kontingenstabeller, der er dannet af de to variable vist i indekset. F.eks. er C_{IF} 5X5 kontingenstabellen dannet af Indkomst og Formue, og C_{IE} 5x2 kontingenstabellen dannet af Indkomst og Ejer/Lejer.

D-matricerne er diagonal matricer, dvs. med nuller uden for diagonalen. I diagonalen står marginalerne for den pågældende variabel. F.eks. er diagonalleddene i D_I de marginale antal for hver af variabel 'Indk's 5 kategorier.

Selve Burt matrixen for dette eksempel står i det første SAS-output efter programmet for en MCA-analyse.

SAS-programmet for en MCA-analyse er således ud:

```

1 title 'Indkomst Formue data. Burt-matrix';
2 data a;
3 input v1 $ g h i j k a b c d f e l;
4   label g = '0 kr'
5         h = 'lav formue'
6         i = 'mellem formue'
7         j = 'høj formue'
8         k = 'meget høj formue'
9         a = 'lav indkomst'
10        b = 'ret lav indkomst'
11        c = 'mellem indkomst'
12        d = 'ret høj indkomst'
13        f = 'høj indkomst'
14        e = 'ejer'
15        l = 'lejer';
16 cards;
17 1   1391   0   0   0   0 360 283 269 286 193 347 348
18 2     0 961   0   0   0 196 196 197 220 151 400 366
19 3     0   0 831   0   0 120 134 193 209 174 489 358
20 4     0   0   0 578   0  80  94 127 122 155 533 361
21 5     0   0   0   0 414  39  59  63  77 176 571 278
22 a   360 196 120  80  39 795   0   0   0   0 448 843
23 b   283 196 134  94  59   0 766   0   0   0 374 586
24 c   269 197 193 127  63   0   0 850   0   0 641 189
25 d   286 220 209 122  77   0   0   0 915   0 528  50
26 f   193 151 174 155 176   0   0   0   0 849 369  43
27 e   347 400 489 553 571 448 374 641 528 369 2360  0
28 l   348 366 358 361 278 843 586 189  50  43  0 1711
29 ;
30 proc corresp all data=a out= results;
31   var g h i j k a b c d f e l;
32   id v1;
33 proc plot data= results;
34 plot dim2*dim1 = v1;
35 run;
36 quit;

```

Den eneste måde, dette program adskiller sig fra de andre SAS-programmer til correspondence analyse, er ved (1) variabelnavnene og (2) den indlæste datamatrix.

I programlinjerne, vist i næste SAS output boks, skal der tages hensyn til at rækkevariablene er lig med søjlevariablene

```

1 input v1 $ g h i j k a b c d f e l;
2 label g = '0 kr'
3       h = 'lav formue'
4       i = 'mellem formue'
5       j = 'høj formue'
6       k = 'meget høj formue'
7       a = 'lav indkmst'
8       b = 'ret lav indkomst'
9       c = 'mellem indkomst'
10      d = 'ret høj indkomst'
11      f = 'høj indkomst'
12      e = 'ejer'
13      l = 'lejer';
14 cards;
15 1   1391   0   0   0   0 360 283 269 286 193 347 348
16 2     0 961   0   0   0 196 196 197 220 151 400 366
17 3     0   0 831   0   0 120 134 193 209 174 489 358
18 4     0   0   0 578   0  80  94 127 122 155 533 361
19 5     0   0   0   0 414  39  59  63  77 176 571 278
20 a   360 196 120  80  39 795   0   0   0   0 448 843
21 b   283 196 134  94  59   0 766   0   0   0 374 586
22 c   269 197 193 127  63   0   0 850   0   0 641 189
23 d   286 220 209 122  77   0   0   0 915   0 528  50
24 f   193 151 174 155 176   0   0   0   0 849 369  43
25 e   347 400 489 553 571 448 374 641 528 369 2360  0
26 l   348 366 358 361 278 843 586 189  50  43 0 1711

```

Som det fremgår, sker det ved at variabel betegnelserne i linie 1 er de samme som første tegn i de 12 datalinier, linie 15 - 26. Når g, h, i, j og k er ændret til tallene 1 - 5 i linie 15 - 19, skyldes det, at variabelnavnene i 'input'-linien ikke kan være tal. Men på den simple graf senere, benytter SAS de 12 værdier af variabel 'v1' i linie 15 - 26 som betegnelser på punkterne. Hvis man ikke ønsker en simpel graf, kan man benytte de samme bogstaver - eller andre - i 'input'-linien, linie 1, og i starten af de 12 data linier efter 'cards', dvs. linie 15 - 26.

Den 12x12 matrix, der står i linierne 15 - 26, bortset fra linie nummereringen og værdien af 'v1', er Burt matricen.

De 12 linier med labels i linierne 2 til 13 sørger for informative overskrifter på output.

Selve programmet for PROC CORRESP ser således ud:

```
proc corresp data = a out = results;
  var g h i j k a b c d f e l;
  id v1;
proc plot data = results;
  plot dim2*dim1 = v1;
run;
quit;
```

Det svarer til de tidligere kald af PROC CORRESP, men naturligvis med alle 12 involverede variable deklareret i 'var'-linien.

Den første del af output ser lidt anderledes ud for en MCA analyse end for en simpel correspondance analyse.

```
Indkomst Formue data. Burt-matrix
```

Singular Values	Principal Inertias	Chi- Squares	Percents	5	10	15	20	25
0.51706	0.26735	9900.24	23.65%	-----+-----+-----+-----+-----	*****			
0.41712	0.17399	6442.95	15.39%	*****				
0.38998	0.15208	5631.74	13.45%	*****				
0.35910	0.12895	4775.27	11.41%	*****				
0.34132	0.11650	4314.12	10.31%	*****				
0.31312	0.09804	3630.57	8.67%	*****				
0.29658	0.08796	3257.18	7.78%	*****				
0.26495	0.07020	2599.55	6.21%	*****				
0.16883	0.02850	1055.53	2.52%	***				
0.08261	0.00682	252.72	0.60%	*				
0.00016	0.00000	0.00	0.00%					
	1.13040	41859.9	(Degrees of Freedom = 121)					

Når man analyserer en Burt matrix, skal egenværdierne, 'Principal Inertias', og bidragene til Pearsons Q-teststørrelse 'Chi Squares' fortolkes noget anderledes end ved en simpel correspondance analyse. Det er lidt kompliceret, og jeg undlader detaljer. Det er dog værd at bemærke, at selv om 2 dimensioner - skulle man tro udfra 'Percents'-søjlen - kun beskriver ca. 39% af den samlede variation, er det ikke tilfældet. SAS-programmet fortsætter da også ufortøvet med kun at analysere de to første dimensioner.

De koordinater, der skal bruges i correspondance analyse diagrammet bliver nu ens for søjler og rækker. Det fremgår også af SAS output'et - bortset fra nogle mindre beregningsnøjagtigheder - i den næste output boks.

Row Coordinates

	Dim1	Dim2
1	-.309701	-.588644
2	-.096359	-.047709
3	0.228350	0.052766
4	0.192229	0.314509
5	0.422224	0.492901
a	-.721117	0.066072
b	-.581778	0.095500
c	0.295464	-.244177
d	0.576445	-.976775
f	0.829469	0.931470
e	0.441247	-.013471
l	-.744341	0.241864

Column Coordinates

	Dim1	Dim2
0 kr	-.309558	-.588673
lav formue	-.096179	-.047634
mellem formue	0.228559	0.052936
høj formue	0.196627	0.312835
meget høj formue	0.422513	0.493437
lav indkomst	-.721125	0.066435
ret lav indkomst	-.581875	0.095844
mellem indkomst	0.295261	-.243663
ret høj indkomst	0.576206	-.976355
høj indkomst	0.829106	0.931823
ejer	0.440969	-.014764
lejer	-.744737	0.241795

Også bidragene fra de 12 række kategorier til dimension 1 og dimension 2 og bidragene fra dimension 1 og dimension 2 til de 12 række kategorier bliver de samme som bidragene fra de 12 søjle kategorier til dimension 1 og dimension 2 og bidragene fra dimension 1 og dimension 2 til de 12 søjle kategorier. Dette fremgår af den næste output boks.

Partial Contributions to Inertia for the Row Points

	Dim1	Dim2
1	0.033686	0.186993
2	0.002520	0.000949
3	0.013209	0.001084
4	0.007651	0.031473
5	0.030198	0.063237
a	0.151325	0.001952
b	0.085196	0.003528
c	0.022300	0.023403
d	0.080788	0.356435
f	0.146635	0.284143
e	0.139236	0.000199
l	0.287256	0.046604

Squared Cosines for the Row Points

	Dim1	Dim2
1	0.073157	0.264287
2	0.006643	0.001629
3	0.039585	0.002114
4	0.029274	0.078363
5	0.125205	0.170631
a	0.521683	0.004380
b	0.276470	0.007450
c	0.063248	0.043197
d	0.172700	0.495868
f	0.273556	0.344973
e	0.605099	0.000564
l	0.781898	0.082556


Partial Contributions to Inertia for the Column Points

	Dim1	Dim2
0 kr	0.033654	0.187011
lav formue	0.002511	0.000946
mellem formue	0.013234	0.001091
høj formue	0.008084	0.031443
meget høj formue	0.030239	0.063374
lav indkomst	0.151328	0.001974
ret lav indkomst	0.085224	0.003553
mellem indkomst	0.022270	0.023305
ret høj indkomst	0.080721	0.356129
høj indkomst	0.146506	0.284358
ejer	0.138667	0.000239
lejer	0.287562	0.046578

Squared Cosines for the Column Points

	Dim1	Dim2
0 kr	0.073098	0.264343
lav formue	0.006620	0.001624
mellem formue	0.039674	0.002128
høj formue	0.030735	0.077801
meget høj formue	0.125528	0.171208
lav indkomst	0.521810	0.004429
ret lav indkomst	0.276581	0.007504
mellem indkomst	0.063185	0.043031
ret høj indkomst	0.172581	0.495510
høj indkomst	0.273264	0.345167
ejer	0.606139	0.000679
lejer	0.781778	0.082408

Det simple correspondance analyse diagram for en MCA analyse af de tre variable 'Indk', 'Form' og 'Ejer/Lejer' ser sådan ud.




Det dobbelte '1', skyldes de regneunøjagtigheder, som vi bemærkede oven for, vedr. plot-værdierne for rækker og søjler. Bortset fra dette viser figuren, at de 5 punkter for Indkomst, benævnt 1 til 5, følger de 5 punkter for Formue, benævnt a til e, meget godt, men dog med en snævrere variation for Indkomst, især på dimension 1. Samtidig fremgår det, at punktet 'e' for 'Ejere' så klart ligger tæt ved de højeste formuer, men ikke rigtigt placerer sig i forhold til indkomster. Vi vender tilbage til dette forhold. Punktet for 'Lejere' (dobbelpunktet '11')

befinder sig tydeligvis nær de laveste formuer. Dette er der intet overraskende i. For langt de fleste danskere er formuen jo bundet i ejerboligen, hvis man har en sådan.

Disse kommentarer bliver tydeligere ved at se på følgende figur tegnet i regnearket Quattro Pro.

Correspondance diagram: Burt Matrix




Laver man en simpel correspondance analyse på 'Indk' mod 'Form', skal man benytte følgende SAS program:

```
title 'Indkomst Formue data. Alle';
data a;
input indkomst $ a b c d e;
  label a = 'a=0 kr'
        b = 'b=lav formue'
        c = 'c=mellem formue'
        d = 'd=høj formue'
        e = 'e=meget høj formue' ;


cards;
1  360 283 269 286 193
2  196 196 197 220 151
3  120 134 193 209 174
4   80  94 127 122 155
5   39  59  63  77 176
;
proc corresp all data = a out = results;
  var a b c d e;
  id indkomst;
proc plot data= results;
plot dim2*dim1 = indkomst;
run;
```

Grunden til, at 'labels' sektionen er skrevet på denne måde, er, at den simple SAS-graf benytter det første bogstav i 'labels'-linierne, og det første tegn i 'cards'-linierne til at skrive ind på grafen. Man får derfor - med dette program - grafen vist neden for.



Tegnet i Quattro Pro bliver tegningen en del pænere:

Correspondance diagram: Alle



Her ser vi, at Indkomst, punkterne 1 til 5, følges meget pænt med Formue, punkterne a til e.


Ét af kritikpunkterne ved at benytte MCA, dvs. en analyse af Burt matricen, er, at man egentlig slet ikke laver en multidimensional analyse. I Burt matricen indgår nemlig kun de marginale kontingenstabeller mellem de variable, og ikke den fler-dimensionale kontingenstabel mellem alle de variable. For at illustrere dette, skal vi se på to correspondance analyser, der bygger på den 3-dimensionale kontingenstabel mellem 'Indk', 'Form' og 'Ejer/Lejer'. Man kan således dele den 3-dimensionale tabel op i 2 dele. Den første er kontingenstabellen mellem 'Indk' og 'Form' alene for Ejere. Den anden er kontingenstabellen mellem 'Indk' og 'Form' alene for Lejere. Det giver et ganske overraskende resultat i forhold til MCA-analysen. De to programmer ser sådan ud:

Kun for ejere:

```
title 'Indkomst Formue data. Kun ejere';
data a;
input indkomst $ a b c d e;
  label a = 'a=0 kr'
        b = 'b=lav formue'
        c = 'c=mellem formue'
        d = 'd=høj formue'
        e = 'e=meget høj formue' ;


cards;
1  69 70 98 75 35
2  68 76 113 87 56
3  98 64 153 120 54
4  110 100 155 115 73
5  103 64 122 131 151
;
proc corresp all data=a out= results;
  var a b c d e;
  id indkomst;
proc plot data= results;
plot dim2*dim1 = indkomst;
run;
```

Med correspondance analyse diagram:



Eller tegnet i Quattro Pro.

Correspondance diagram: Ejere




Som man ser, følges Indkomst og Formue slet ikke ad. Grunden er den oplagte, at de mange ældre boligejere, for hvilke formuen især står i deres bolig, ved deres tilbagetrækning fra arbejdsmarkedet generelt går kraftigt ned i indtægt, mens formuen stadig er relativt høj, idet den er bundet i ejendommen. Kun det laveste indkomst punkt, punktet '5', ligger tæt ved punktet 'e' for den laveste formue.

For kun lejere bliver SAS programmet for en correspondance analyse:

```
title 'Indkomst Formue data. Kun lejere';
data a;
input indkomst $ a b c d e;
  label a = 'a=0 kr'
        b = 'b=lav formue'
        c = 'c=mellem formue'
        d = 'd=høj formue'
        e = 'e=meget høj formue' ;


cards;
1  291 126 22  5  4
2  215 120 21  7  3
3  171 133 40  7  7
4  176 120 54  7  4
5   90  87 52 24 25
;
proc corresp all data=a out= results;
  var a b c d e;
  id indkomst;
proc plot data= results;
plot dim2*dim1 = indkomst;
run;
```

For denne gruppe bliver correspondance analyse diagrammet:



Eller tegnet i Quattro Pro.

Correspondance diagram: Lejere



Nu er billedet til gengæld nogenlunde svarende til det generelle billede. Her gælder fænomenet med at formuen - efter pensionering - forbliver stor, mens indkomsten går ned, jo ikke.

Stikordsregister.

Approksimation til residualerne i correspondance analyse 131 arbejdsbetingelser for respondenter 81 Asymptotic Standardized Residual Ma- trix 85 baggrundsvariable 2, 79, 120 basis stimodel 115 Bidragene fra dimension til kategori m 146 Bidragene fra række kategori i til dimen- sion m 145 Bidragene fra søjle kategori j til dimen- sion m 147 Bidragene til søjle kategori j fra dimen- sion m 147 Burt matrix 149 centrale grænseværdisætning 37 Chi-Squares 144 Column coordinates 147 Column coordinates' 145 Confirmative Factor Analysis 98 CORMAX option 45 correlations output i PROC FACTOR 53 Correspondance analyse 130 Correspondance analyse diagram 132 Criterion 48 criterion option i PROC FACTOR 49 Dangerous Job 81 definitionsligninger på symbolsk form 103 diag matrixoperation i IML 10 Egenvektor 130 egenvektorer 5, 13 Egenværdi 130 egenværdi-dekomponering 5, 13, 20 egenværdi-dekomponering i SAS 10 Egenværdi/egenvektor dekomponering 131 egenværdier 5, 13 egenværdiopspaltning 5, 13 eksplorativ faktor analyse 76 eksplorative analyse for principalkomponentmeto- den 29 EXCEL 145 Fact: Interesting Job 98 factor loadings 42 Fakt: Good Job 98 Fakt: Interesting Job 98 faktoranalyse 13, 42 flag option 29	Franske geometriske betegnelser 142 fysisk belastende arbejde 81 Geometrisk beskrivelse af correspondance analyse 142 Good Job 81 graf for stimodel 113 Heywood-tilfælde 57 hierakiske hypoteser 96 hierakiske modeller 96 Hotellings T2 - test 14 Hotellings T2 - teststørrelse 16 Hours a Week 81 hypoteseprøvning 93 ikke-negativ definit matrix 5 ikke-singulær matrix 4 Impt: Good Job 98 Impt: Interesting Job 98 Inertia 145, 147 initialværdier for kommunaliteter 43 insignifikante regressionskoefficienter 87 Interesting Job 81 invers af normeret normalfordelings- kurve 73 invers matrix 4 ISSP databasen 1, 28 kanonisk korrelation 13 kategoriserede data 13 kausal sammenhæng 79, 113 kommunaliteter 21, 43, 57 initialværdier for 43 Koordinater til correspondance analyse diagram 141 korrelationskoefficienterne mellem variable og faktorer i faktor analyse 53 korrelationskoefficient i en lineær strukturel ligning 67 korrelationskoefficient 68 korrelationsmatrix 7, 42 korrespondance analyse 13 kovariansmatrix 42 kriteriefunktion for ML løsning 48 kvotientteststørrelse 93 kvotientteststørrelse for modeltilpasning 85 kvotientteststørrelsen asymptotisk fordeling af 39 Labels for correspondance analyse di- gram 141 latente baggrundsvariable 120, 122
--	---

- latente variable 42, 99, 113
- likelihoodfunktion 93
- for Wishart fordeling 48
- manifeste variable 99, 113
- Mass 145
- matrix 4
- Matrix af residualled 130
- matrixmultiplikation 8
- matrixregning 4
- matrixregning i SAS 7
- MCA-analyse 149
- method = prin option 29
- mindste kvadraters løsning 21
- Mindste kvadraters resultat
- i correspondance analyse 132
- MINEIGEN option 29
- ML-estimation i faktoranalyse 43
- ML-estimator
- asymptotisk fordeling af 37
- modelmodifikation 120
- modificeret stimodel 121
- multikollinearitetsproblemer 20
- multipl regressionanalyse 42
- Multiple Correspondance Analyse 149
- mættet model 96
- Mål for hvor godt data er beskrevet
- ved en correspondance analyse
- model 136
- Målingmodel 129
- målingsmodel 98, 100
- NFACT option 30
- nonsens test 49
- Normalized Oblique Transformation 53
- Normering
- af ψ 'erne 131
- Normering af ϕ 'erne 131
- oblique rotation 45
- oblique transformation 51, 53
- omskalering af $-2 \ln L$ 49
- option 'flag= 0.5' 28
- option 'heywood' 60
- option 'method=ml' 47
- option 'method=prin' 28
- option 'mineigen=1' 28
- option 'prior=smc' 46
- option 'priors=one' 28, 32
- option 'rotate= varimax' 31
- option 'rotate= promax' 51
- option 'ultra' 63
- ortogonal matrix 5
- ortogonal transformation 12
- Ortogonal transformation 13
- Ortogonalitet
- i correspondance analyse 131
- Parameterrummet 57
- Partial contribution to Inertia 147
- Partial Contribution to Inertia from the
- Row Points 145
- Pearsons Q-teststatistic
- fortolkning af i correspondance analyse 135
- Pearsons Q-teststørrelse
- i correspondance analyse 130
- Percents 144
- polyseriale korrelationskoefficienter 70, 71
- Principal Inertias 144
- principalkomponentmetoden 13, 20, 21
- principalkomponentmetoden i SAS 26
- Prior Communality Estimates 47
- probit 73
- PROC CALIS 67, 84, 87, 101
- PROC CORRESP 140, 142
- for multipl correspondance
- analyse 151
- PROC FACTOR 29, 67, 71
- PROC FREQ 72
- PROC IML 7
- procrustean transformation 51
- projektion 12
- PROMAX rotation 51
- Q-differens mellem målingsmodeller 129
- q-teststørrelse 85
- for sekventielt test 96
- Quality 145
- QUATTRO PRO 145
- regressionskoefficient 86
- regressionskoefficient 68
- Relative bidrag fra række i til dimension
- m 138
- Relative bidrag fra søjle j til dimension
- m 139
- Relative bidrag til række i fra dimension
- m 139
- Relative bidrag til søjle j fra dimension
- m 139
- Relativt mål for den forklarede del 137
- reparametrisering
- ved sammensatte hypoteser 40
- residual 84
- responskategorier 69
- restled i faktoranalysemodel 42
- restledsvariabel 67
- restledsvarsians 67
- Row coordinates 145
- Row Profiles 143
- Rækkeprofiler 135, 143
- sammenligning af modeller 129
- sammensatte hypoteser 40
- saturated model 96
- School Years 81
- sekventiel testning 96

sekventielt q-test	96
semipartial correlations	
output i PROC FACTOR	53
Simpel correspondance analyse	130
Simpel correspondance analyse i SAS	140
single value decomposition	5
skaleret udgave af korrelationskoefficien-	
ten	68
skalering af latent vairabel	68
skaleringer i Linear Structural Models	67
Skoleuddannelse	57
skæv transformation	45
Social Class	81
social klasse	81
spor af matrix	48
sporet for en symmetrisk matrix	22
Squared Cosines for the Column Points	147
Squared Cosines for the Row Points	146
standardiserede regressions koefficienter	
i PROC FACTOR	53
standardiserede residualer	85
Standardized Coefficients	68
Std Reg Coefs	53
stianalyse	79, 113
stianalyse med latente variable	113
stianalyse med manifeste variable	81
stidiagram	79, 81, 113, 122
symbolsk form	
for definitionsligninger	103
Søjleprofiler	135, 143
t-fordelt	14
t-test	14
trace af matrix	48
transformationer af vektorer af stokasti-	
ske variable	12
transformationsmatrix	12
transformeret kvotientteststørrelse	
i faktor analyse	49
transponeret matrix	4
Tuborg paranteser	7
Variation i data forklaret af	
correspondance analyse mo-	
dellen	137
VARIMAX metoden	31
VARIMAX rotation	46, 49
vektor	4
Wishart fordeling	48
Wishart-fordeling	48
X-koordinater	
for correspondance analyse	
diagram	132
Y-koordinater	
for correspondance analyse	
diagram	132
årsagssammenhæng	79