


観測変数が2個の場合を考える．因子分析のモデル式表現とパス図表現は，

$$x_1 = \lambda_1 F_1 + e_1$$


$$x_2 = \lambda_2 F_1 + e_2$$



主成分分析のモデル式表現は，

$$Z_1 = a_1 x_1 + a_2 x_2$$

だから，そのパス図表現は，



で良さそうな気がする．

Amos のようにパス図から共分散構造分析を実行できるソフトウェアで実際に上図のようなパス図を描いてもエラーとなって解を求めることはできない．共分散構造分析モデルの枠組みでは上図には従属変数 Z_1 に誤差変数を要求し，仮に誤差分散を 0 に固定しても自由度が負となってモデルを識別できない．


主成分分析と因子分析は似ているといわれるのだが，観測変数の線形結合である主成分分析をあえて因子分析モデル（共分散構造モデル）の枠組みで表現するならば，以下のような方程式表現となる．

$$x_1 = \lambda_1 F_1 + 0$$


$$x_2 = \lambda_2 F_1 + 0$$

つまり誤差項のない (=0) ような因子分析モデルとなる．

このモデルは観測変数と同じ個数まで因子を抽出すれば正確に相関行列を分解できるけれど、次元縮小という多変量解析の目標からみれば、それは単なる数学的変換に過ぎない。そこで因子分析の主成分分解とは、最初の少数個の成分だけを採り、残りをひとまとめに独自因子とみなして因子分析モデルを近似しようとする方法であった。主成分の分散を固有値ではなく1とし、独自因子に直交仮定を置かないモデルが因子分析の主成分分解である。主成分分析（因子分析の主成分分解）をパス図で描くと以下のようなになる¹。



主成分（因子）Z1 の分散を1とし、誤差分散を0に固定している。このモデルを最小2乗法で第1主成分を求めると、以下の推定値が得られる。



パス係数に表示されているのは因子負荷量であり固有ベクトルの値ではない。ここで使用した数値例の相関行列は2変数の相関係数が0.5の場合である。

$$\begin{bmatrix} 1.0 & 0.5 \\ 0.5 & 1.0 \end{bmatrix}$$

2変数だけの相関行列の主成分は、奥野他(1981)『多変量解析法《改定版》』にあるように、幾何学的には座標を45°回転した結果であり、固有値 λ は²相関係数 r との関係で、

$$\begin{aligned} \lambda_1 &= 1 + |r| = 1.5 \\ \lambda_2 &= 1 - |r| = 0.5 \end{aligned}$$

となる。固有ベクトルの2つの要素は等しい値で、相関係数と関係なく常に、

$$a_1 = 1 / \sqrt{2} = 0.707$$

¹ 主成分分析をSEMで表現する詳細は豊田(1992)SASによる共分散構造分析(東大出版)を参照。

² この記号 λ は固有値として使用。先の文脈で因子負荷として使用した a とは別。

従って、固有値の平方根を乗じた因子負荷量（構造係数）も等しくて常に、

$$l_1 = 0.707 * 1.5 = 0.866$$

となる。これが先のパス図に示されたパス係数（因子負荷）である。このパス図は Amos4 による結果で、小数点以下第 2 位に誤差があつて「0.86」と表示されているが、正しくは「0.87」である。

参考までに SAS による主成分分析（因子分析の主成分分解）のプログラムと出力を掲載する。

```
data x( type = corr ) ;
  input _type_ $ _name_ $ x1 x2 ;
cards ;
N      .   100 100
MEAN   .   0.0 0.0
CORR   x1  1.0 0.5
CORR   x2  0.5 1.0
;
run ;
proc factor data = x ;
run ;
```

Prior Communality Estimates: ONE		
Eigenvalues of the Correlation Matrix: Total = 2 Average = 1		
	1	2
Eigenvalue	1.5000	0.5000
Difference	1.0000	
Proportion	0.7500	0.2500
Cumulative	0.7500	1.0000
1 factors will be retained by the MINEIGEN criterion.		
Factor Pattern		
	FACTOR1	
X1	0.86603	
X2	0.86603	

SAS の CALIS プロシジャの lineqs ステートメント（EQS モデル）の書法と出力結果は以下のようなになる。

```
proc calis data = x method = uls ;
  var x1 x2 ;
  lineqs
    x1 = a1 f1 + e1 ,
    x2 = a2 f1 + e2 ;
  std f1 = 1 , e1 = 0 , e2 = 0 ;
run ;
```

Covariance Structure Analysis: **Least-Squares Estimation**

Levenberg-Marquardt Optimization
 Scaling Update of More (1978)
 Number of Parameter Estimates 2
 Number of Functions (Observations) 3

Optimization Start: Active Constraints= 0 Criterion= 0.878
 Maximum Gradient Element= 0.923 Radius= 1.164

Iter	rest	nfun	act	optcrit	difcrit	maxgrad	lambda	rho
1	0	3	0	0.1668	0.7113	0.473	1.347	1.280
2	0	4	0	0.1252	0.0416	0.0406	0	1.002
3	0	5	0	0.1250	0.000196	0.00382	0	1.075
4	0	6	0	0.1250	6.302E-6	0.00126	0	1.333
5	0	7	0	0.1250	7.002E-7	0.00042	0	1.333
6	0	8	0	0.1250	7.78E-8	0.00014	0	1.333
7	0	9	0	0.1250	8.645E-9	0.00005	0	1.333
8	0	10	0	0.1250	9.61E-10	0.00002	0	1.333
9	0	11	0	0.1250	1.07E-10	5.17E-6	0	1.333

Optimization Results: Iterations= 9 Function Calls= 12 Jacobian Calls= 10
 Active Constraints= 0 Criterion= 0.125 Maximum Gradient Element= 5.16539E-6
 Lambda= 0 Rho= 1.333 Radius= 0.00003116

NOTE: GCONV convergence criterion satisfied.

Covariance Structure Analysis: Least-Squares Estimation

Fit criterion	0.1250
Goodness of Fit Index (GFI)	0.9000
GFI Adjusted for Degrees of Freedom (AGFI)	0.7000
Root Mean Square Residual (RMR)	0.2500
Parsimonious GFI (Mulaik, 1989)	0.9000

Covariance Structure Analysis: Least-Squares Estimation

Manifest Variable Equations

$$X1 = 0.8660 \cdot F1 + 1.0000 \cdot E1$$

$$X2 = 0.8660 \cdot F1 + 1.0000 \cdot E2$$

Variances of Exogenous Variables

Variable	Parameter	Estimate
F1		1.000000

Covariance Structure Analysis: Least-Squares Estimation

Equations with Standardized Coefficients

$$X1 = 1.0000 \cdot F1 + 0.0000 \cdot E1$$

$$X2 = 1.0000 \cdot F1 + 0.0000 \cdot E2$$

Squared Multiple Correlations

Variable	Error Variance	Total Variance	R-squared
1 X1	0	0.749996	1.000000
2 X2	0	0.750004	1.000000