目次

第 1 章　STATWEB による共分散構造分析実施の基礎 1
1. 分析の準備 1
1.1. データベースの作成 1
1.2. モデルの登録 1
2. 分析の実施：具体例①　回帰モデルのみの場合 3
2.1. モデルの決定画面 3
2.2. モデルの登録・修正 3
2.3. 分析メニュー 5
2.4. 結果の出力 5
3. 分析の実施：具体例②　因子モデルの場合 7
3.1. モデルの決定画面 7
3.2. モデルの登録・修正 7
3.3. 分析メニュー 9
3.4. 結果の出力 9
4. 分析方法の詳細 11
4.1. モデルの登録 11
4.2. モデルの登録・修正 14
4.3. 分析メニュー 16
4.4. パス図メニュー 19
4.5. 出力結果の詳細 21

第 2 章　共分散構造分析の様々なモデル 22
1. パス解析 22
1.1. 逐次モデル（Recursive Model） 22
1.2. 非逐次モデル（non-Recursive Model） 25
2. 重回帰分析（Multiple Regression Analysis） 27
3. MIMIC (Multiple Indicator Multiple Cause) 29
4. PLS (Partial Least Squares) 31
5. 2 次因子分析 34
6. 平均共分散構造分析 36
6.1. 平均構造のあるパス解析：観測変数のみ 37
6.2. 平均構造のあるパス解析：構成概念間のパス解析 39
7. 多母集団分析：1 因子の場合 41

7.1. 配置不変モデル 41
7.2. 等値制約に関する他のモデル 43
8. 縦断データ分析 46
8.1. 配置不変モデル 46
8.2. 等値制約に関する他のモデル 48

第１章　STATWEB による共分散構造分析実施の基礎

1. 分析の準備

1.1. データベースの作成

分析対象となるデータベースは、行列形式のデータ形式であるマトリックス型で作成する(詳細は HP のマニュアル参照)。なお、変数名には以下の規則が適用される。

①半角英数の他、全角かなも使用可能。「f1」や「V1」だけでなく、「得点」や「評価」なども使用できる。
②大文字と小文字は区別される。X と x は区別される。
③半角の数字も使用可能だが、変数の最初の文字としては使用できない。「f1」は使用できるが「1f」は使用できない。
④以下にあげる名前は使用できない。

break	else	FALSE	for	function
if	in	Inf	NA	NaN
next	NULL	repeat	TRUE	while

1.2. モデルの登録

1.2.1. 新規登録

初めて分析を行う場合は、新規モデルの登録を行う(Figure 2.1)。

①画面メニューから新規登録を選択する。

②モデルの種類

モデルの種類を選択する。各モデルを選択する際の基準は p.21 を参照のこと。また代表的なモデルの具体例は第 3 章を参照のこと。

③モデル名

モデル名を入力・決定する。

④データベース名

事前に作成・登録したデータベースから、使用するデータベースを選択する。

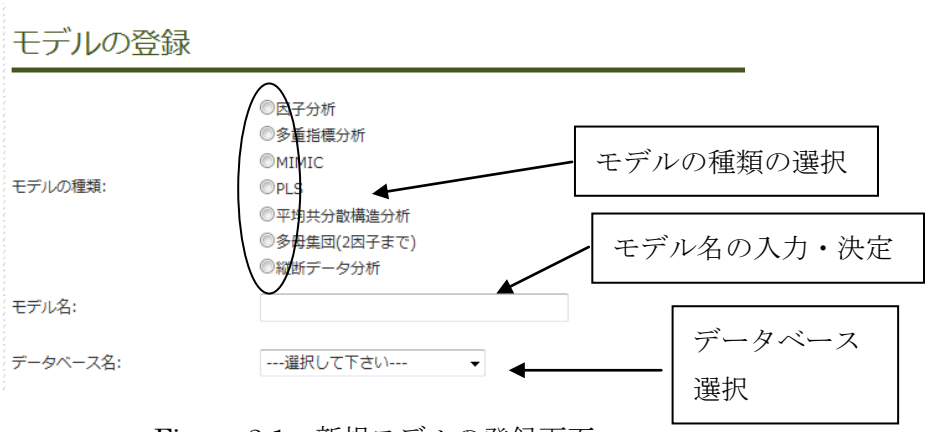

Figure 2.1　新規モデルの登録画面

1.2.2.　登録モデルからの実施

すでにモデルを登録済の場合は、登録済のモデルを選択し実施できる(Figure 2.2)。

①画面メニューから登録モデル一覧を選択する。

②実施するモデルを選択する。

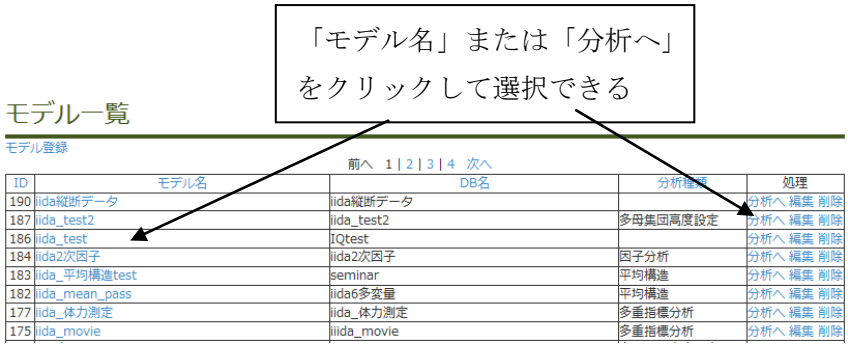

Figure 2.2　登録済のモデル一覧の画面

2. 分析の実施：具体例①　回帰モデルのみの場合

【具体例】第 1 章の回帰モデルの説明であげた、映画への満足度と観客動員の関係

(1) データ概要：ある年の年間興行が 20 億円以上の邦画 31 本を対象に調査をした
(仮想データ、評価は全て 7 件法)

(2) 変数：①映画への満足度(観客 100 による評価の平均)
②主演俳優への好意度(同じく 100 名の平均)
③監督への評価(同じく 100 名の平均)
④製作費(億円)　⑤興行収入(億円)　⑥広告費(億円)

(3) モデル：第 1 章 p.5 の Figure 1.6 で示した以下の多重指標モデル。
「①満足度　←　②俳優　＋　③監督　＋　④製作費」
映画を見た後の満足度は、出演している俳優への好み、監督の力量、製作費の影響を受ける。

「⑥広告費　←　④製作費」
広告費は製作費に含まれ、製作費が多い作品ほど広告にもお金をかける。

「⑤興行収入　←　①満足度　＋　⑥広告費」
映画の興行収入は、宣伝にかけた費用と、口コミなどによる映画への評価の影響を受ける。

2.1. モデルの決定画面

モデルの種類は新規モデル作成時に「多重指標分析」とする。

2.2. モデルの登録・修正

①因子モデル
今回は使用しないのでそのまま。
②回帰モデル
1a) 従属変数に「満足度」を指定する。
1b) 分散の指定は“指定しない”のまま。
1c) 独立変数に「俳優」、「監督」、「製作費」を指定する。クリックすると左の枠から右の枠へ移動する。
1d) “↓↓↓回帰モデルを登録↓↓↓”をクリックする。
1e) 下の式の欄に「満足度←俳優+監督+製作費」が追加される。

2a) 従属変数に「広告費」を指定する。
2b) 分散の指定は“指定しない”のまま。
2c) 独立変数に「製作費」を指定する。
2d) “↓↓↓回帰モデルを登録↓↓↓”をクリックする。
2e) 下の式の欄に「広告費←製作費」が追加される。

3a) 従属変数に「興行収入」を指定する。
3b) 分散の指定は“指定しない”のまま。
3c) 独立変数に「満足度」と「広告費」を指定する。
3d) “↓↓↓回帰モデルを登録↓↓↓”をクリックする。
3e) 下の式の欄に「興行収入←満足度+広告費」が追加される。

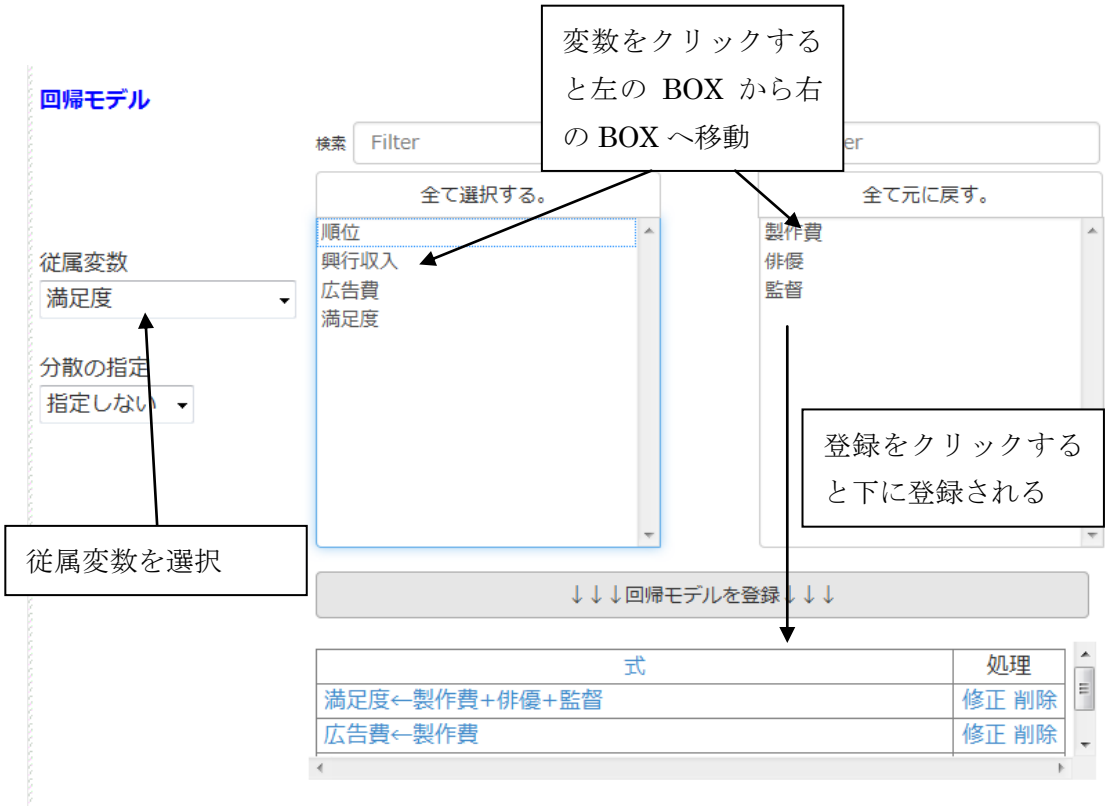

Figure 2.3　回帰モデルの入力画面例

③共分散
　今回は使用しないのでそのまま。
④誤差分散
　今回はそのまま。

⑤分析メニューへ
“分析メニューに進む”をクリックする。

2.3. 分析メニュー

①分析メニュー
分析メニューはすべてそのまま変更なし。各項目の詳細は p.26 を参照。
②パス図メニュー
すべてそのまま変更なし。
③分析の実行
OK をクリックし分析を実行する。

2.4. 結果の出力

モデルの評価における代表的な指標については p.7 を参照のこと。今回の分析結果の解釈にあたって特に重要な点は以下の通り。また、パス図は Figure 2.4 のようになる。

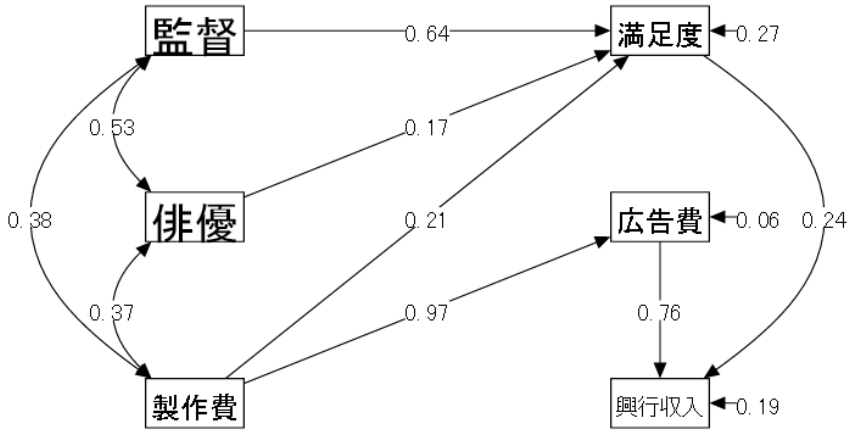

Figure 2.4　映画の満足度を説明するモデルのパス図

①モデル全体の評価
モデルの適合度を示す指標は以下の通りとなる。χ^2 検定は有意でなく、CFI からは 0.95 を超えて適合度は良いと考えられるが、RMSEA では適合度が悪いと判断される。ただし、RMSEA の検定も有意ではなく、90%信頼区間に 0 が含まれている点ではまずまずの適合度と言える。

χ^2=10.301　自由度=6　有意確率=0.113　n=31

CFI=0.975　　TLI=0.951　　RMSEA=0.152

②各係数の評価

母数の標準化推定値は以下の通りになる。俳優と満足度の関係性以外は、パス係数に統計的には有意な関係性が認められる。

Table 2.1　映画の満足度を説明するモデルの標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	満足度	←	製作費	0.211	0.104	2.036	0.042
2	満足度	←	俳優	0.174	0.113	1.549	0.121
3	満足度	←	監督	0.637	0.113	5.620	0.000
4	広告費	←	製作費	0.967	0.046	21.254	0.000
5	興行収入	←	広告費	0.756	0.091	8.276	0.000
6	興行収入	←	満足度	0.236	0.091	2.590	0.010

【結果の解釈】

標準化推定値の比較から、以下の関係性が示唆される。映画への満足度は、必ずしも好きな俳優が主演しているからといって内容に満足するとは限らず、監督への評価が映画への満足度には比較的強く影響すると言える。興行収入は、映画への満足度と広告費の影響を受けているが、口コミなどで観客を増やす効果は相対的には小さく、広告にお金をかけて映画への期待度を増す方が興行収入により直結すると言える。

3. 分析の実施：具体例②　因子モデルの場合

【具体例】前章の因子モデルの説明にあげた小 4 男子児童の体力測定データ

(1) データ概要：小学 4 年生男子 25 名について以下の調査をした(仮想データ)

(2) 変数：①反復横とび　②走 50m　③立ち幅とび
④ソフトボール投げ　⑤身長　⑥体重

(3) モデル：第 1 章 p.7 の Figure 1.8 で示した以下のような共分散構造モデル。
「⑦運動能力　=
①反復横とび　＋　②走 50m　＋　③立ち幅とび　＋　④ソフトボール投げ」
4 項目の体力測定結果は潜在的な運動能力によってまとめられる。

「⑧体格　=　⑤身長　＋　⑥体重」
身長と体重は成長度を反映した体の大きさとしてまとめられる。

「⑦運動能力　←　⑧体格」
運動能力は体格の影響を受ける。

3.1. モデルの決定画面

モデルの種類は「多重指標分析」とする。

3.2. モデルの登録・修正

①因子モデル

1a) 因子名に「運動能力」と入力。
1b) 分散の指定は“指定しない”のまま。
1c) ラベル付きは“しない”のまま。
1d) 右側の変数の指定欄から「反復横とび」、「走 50m」、「立ち幅とび」、「ソフトボール投げ」を選択する。クリックすると左の枠から右の枠へ移動する。
1e) “↓↓↓因子モデルを登録↓↓↓”をクリックする。
1f) 下の式の欄に式「運動能力→反復横とび+走 50m +立ち幅とび+ソフトボール投げ」が追加される。

2a) 因子名に「体格」と入力。
2b) 分散の指定は“指定しない”のまま。
2c) ラベル付きは“しない”のまま。

2d）右側の変数の指定欄から「身長」、「体重」を選択する。

2e）“↓↓↓因子モデルを登録↓↓↓”をクリックする。

2f）下の式の欄に式「体格→身長+体重」が追加される。

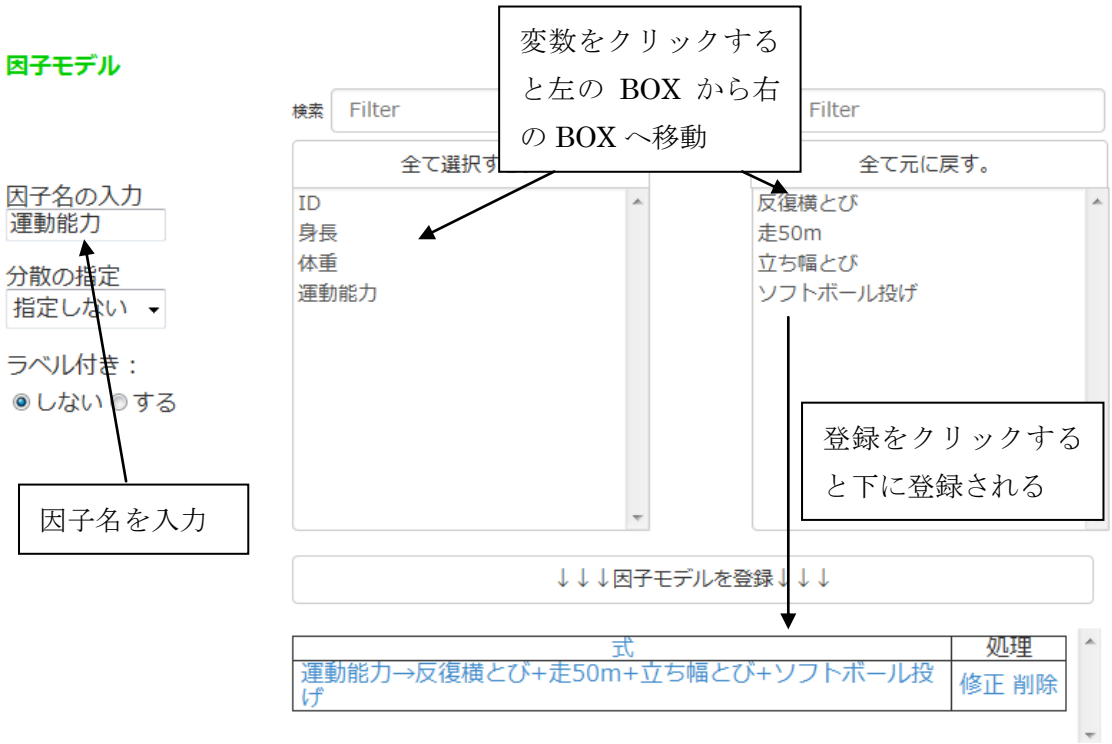

Figure 2.5　因子モデルの入力画面例

②回帰モデル

1a）従属変数に「運動能力」を指定する。

1b）分散の指定は“指定しない”のまま。

1c）独立変数に「体格」を指定する。

1d）“↓↓↓回帰モデルを登録↓↓↓”をクリックする。

1e）下の式の欄に「運動能力←体格」が追加される。

③共分散

今回は使用しないのでそのまま。

④誤差分散

今回はそのまま。

⑤分析メニューへ

“分析メニューに進む”をクリックする。

3.3. 分析メニュー

①分析メニュー

分析メニューはすべてそのまま変更なし。各項目の詳細は p.26 を参照。

②パス図メニュー

すべてそのまま変更なし。

③分析の実行

OK をクリックし分析を実行する。

3.4. 結果の出力

モデルの評価における代表的な指標については p.7 を参照のこと。今回の分析結果の解釈にあたって特に重要な点は以下の通り。また、パス図は Figure 2.6 のようになる。なお、「走 50m」は値が小さいほど成績が良いことになるので、マイナスの推定値になっており、走るのが速い(走破タイムが短い)ほど運動能力は高いと言える。

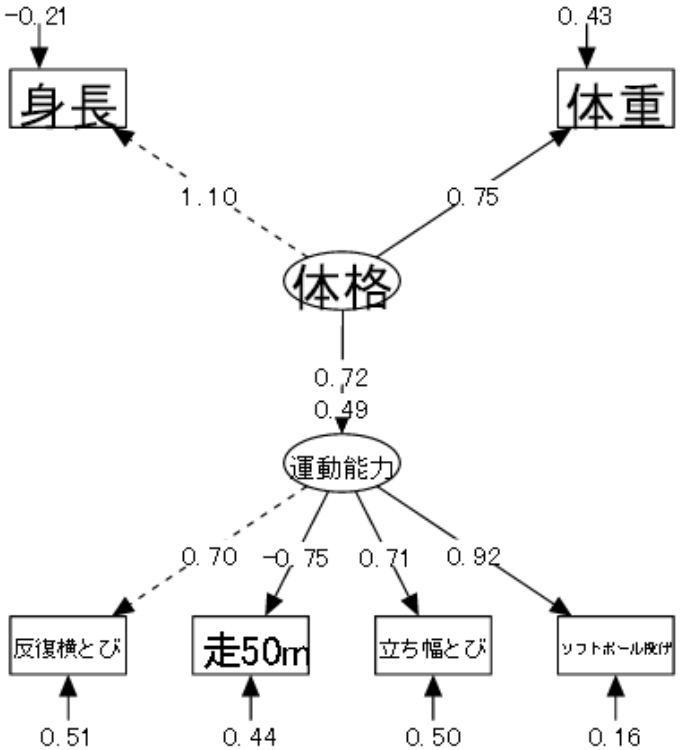

Figure 2.6　小学生の運動能力を説明するモデルのパス図

①モデル全体の評価

モデルの適合度を示す指標は以下の通りとなる。χ^2 検定は有意でなく、CFI からは 0.935 で適合度は良いとは言えない。RMSEA では 0.178 で適合度が悪いと判断される。ただし、

RMSEA の検定は有意ではなく、90%信頼区間に 0 が含まれている点ではまずまずの適合度と言える。

χ^2=14.347　自由度=8　有意確率=0.073　n=25

CFI=0.933　　TLI=0.875　　RMSEA=0.178

②各係数の評価

母数の標準化推定値は以下の通りになる。すべてのパス係数に統計的には有意な関係性が認められる。なお、因子モデルの場合は 1 つ目の係数の負荷量が 1.0 になるよう計算するため、非標準化係数の推定値が 1.0 に固定される。そのため、1 つ目の因子の推定値については誤差や有意確率が表示されない。

Table 2.2　小学生の運動能力を説明するモデルの標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	運動能力	→	反復横とび	0.699			
2	運動能力	→	走50m	−0.747	0.215	−3.480	0.001
3	運動能力	→	立ち幅飛び	0.708	0.214	3.306	0.001
4	運動能力	→	ソフトボール	0.916	0.222	4.120	0.000
5	体格	→	身長	1.101			
6	体格	→	体重	0.754	0.170	4.432	0.000
7	運動能力	←	体格	0.716	0.241	2.966	0.003

【結果の解釈】

標準化推定値の比較から、以下の関係性が示唆される。体格は運動能力に影響を与えており、特に成長過程にある小学生においては、身長の伸びなどの成長度合いが運動能力を決定する一要因になっていると示唆される。

4. 分析方法の詳細

4.1. モデルの登録

モデルの分類を選択する際の基準は以下の通り。3 章で具体例を取り上げる各モデルと分類の一覧を Table 2.3 に示す。

Table 2.3　3 章で取り上げるモデル名と登録時の分類一覧

モデル名(第3章での分類)	登録時のモデルの分類
パス解析:逐次モデル	多重指標分析
パス解析:非逐次モデル	多重指標分析
多変量回帰分析	多重指標分析
MIMIC	MIMIC
PLS	PLS
2次因子分析	因子分析
平均共分散構造分析	平均共分散構造分析
多母集団分析(全ての配置モデル)	多母集団(2因子まで)
縦断データ分析(全ての配置モデル)	縦断データ分析

①因子分析：

従来の因子分析のように、因子モデルのみで表わされる構造式を分析する場合に選択する。回帰モデルや共分散、誤差分散のメニューは表示されない。2 次因子分析の場合もこれを選択する。

②多重指標分析：

従属変数が 1 つ以上あるモデルの場合に選択する。

③MIMIC：

観測変数から仮定される潜在変数(因子)が、他の観測変数からの従属変数になるモデルの場合に選択する。Figure 2.7 に示したように(観測変数→潜在変数→観測変数)という流れの因果連鎖が想定されるモデルである。

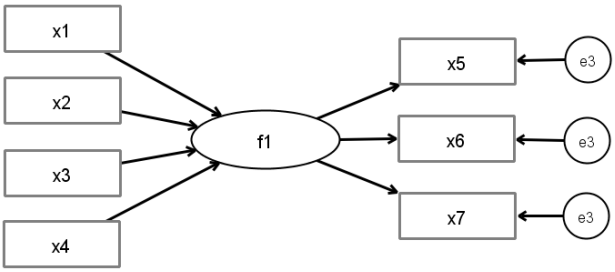

Figure 2.7　MIMIC モデルにおける典型的なパス図(観測変数 x1～x4 間の相関は省略)

④PLS：

MIMIC における潜在変数(構成概念)のところに、2 つ以上の潜在変数間の因果関係を仮定するモデルの場合に選択する。Figure 2.8 に示したように(観測変数→潜在変数→潜在変数→観測変数)という流れの因果連鎖が想定されるモデルである。

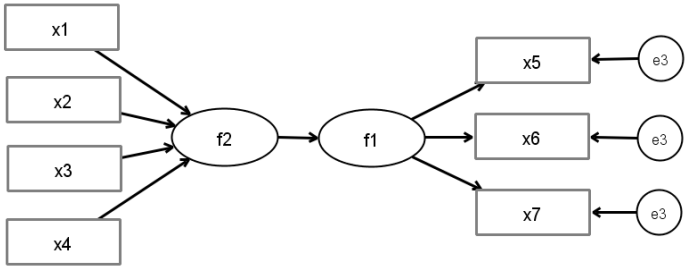

Figure 2.8　PLS モデルにおける典型的なパス図(観測変数 x1～x4 間の相関は省略)

⑤平均共分散構造分析：

平均構造を組み込んだモデルの場合に選択する。これにより、因子分析では平均 0、分散 1 に固定される因子の平均(潜在変数の平均)の比較が可能になる。

⑥多母集団(2 因子まで)：

異なる母集団間で構造方程式モデルを比較する場合に選択する。Figure 2.10 に示した画面でグループ変数を指定する。他のモデルパータンと異なり、母集団間の比較になるため、データがどの母集団に属するものかを指定するグループ変数の指定が必要になる。データ作成時に例えば Figure 2.9 に示したように前もってグループ変数を変数の中に入れておく。なお、データベース作成時に分類変数の指定はしないこと。

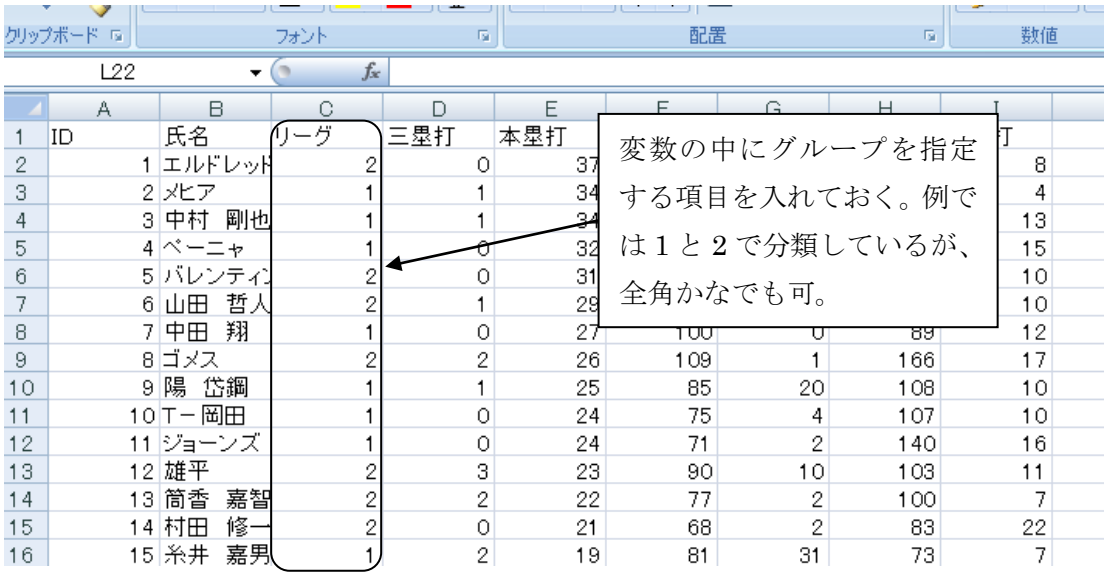

	A	B	C	D	E	F	G	H	I
1	ID	氏名	リーグ	三塁打	本塁打				打
2	1	エルドレッド	2	0	37				8
3	2	メヒア	1	1	34				4
4	3	中村　剛也	1	1	34				13
5	4	ベーニャ	1	0	32				15
6	5	バレンティン	2	0	31				10
7	6	山田　哲人	2	1	28				10
8	7	中田　翔	1	0	27	100	0	89	12
9	8	ゴメス	2	2	26	109	1	166	17
10	9	陽　岱鋼	1	1	25	85	20	108	10
11	10	T－岡田	1	0	24	75	4	107	10
12	11	ジョーンズ	1	0	24	71	2	140	16
13	12	雄平	2	3	23	90	10	103	11
14	13	筒香　嘉智	2	2	22	77	2	100	7
15	14	村田　修一	2	0	21	68	2	83	22
16	15	糸井　嘉男	1	2	19	81	31	73	7

Figure 2.9　多母集団のデータベース作成時のグループ変数の作成：Excel での作成時

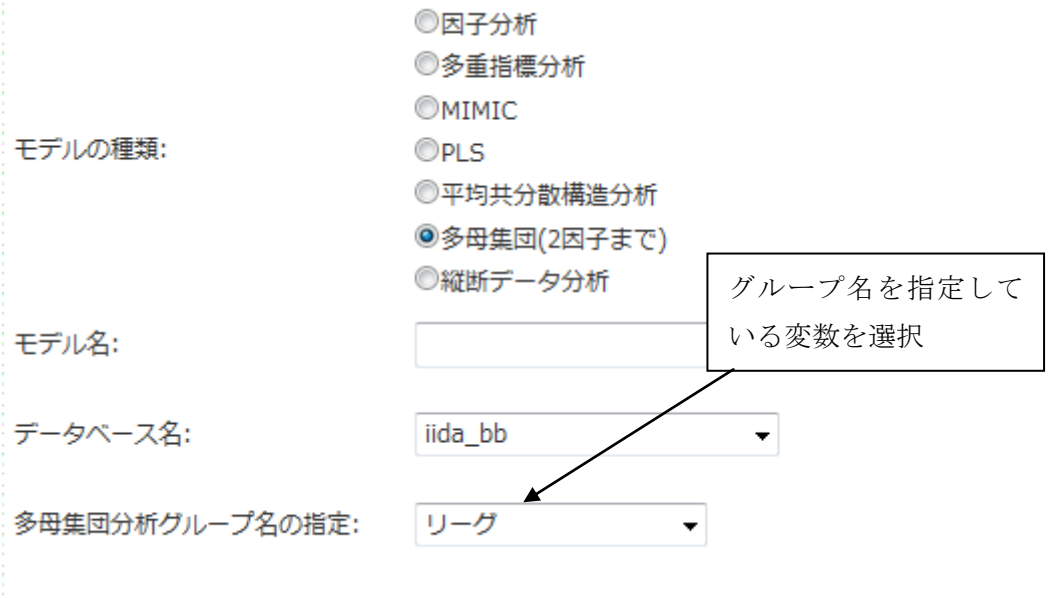

Figure 2.10　多母集団分析グループ変数の指定画面の例

⑦縦断データ分析：

縦断データのデータベースはロー・データではなく、そこから計算される分散共分散行列となる。そのため、対象となるデータの分散共分散行列を Table 2.4 のように作成し、これをデータベースとすること。Table 2.4 の例は第 3 章 p.56 で例示したケースのもの。

Table 2.4　日本代表監督に対する評価の分散共分散行列

項目	人選A	戦術A	内容A	対応A	人選B	戦術B	内容B	対応B
人選A	0.690	0.214	0.062	0.048	−0.166	0.212	0.028	0.032
戦術A	0.214	1.052	−0.321	−0.041	−0.088	−0.163	0.055	0.041
内容A	0.062	−0.321	1.168	0.066	−0.041	−0.038	−0.186	−0.146
対応A	0.048	−0.041	0.066	0.430	−0.101	−0.098	0.062	−0.010
人選B	−0.166	−0.088	−0.041	−0.101	1.052	0.277	0.055	0.021
戦術B	0.212	−0.163	−0.038	−0.098	0.277	1.006	0.070	0.138
内容B	0.028	0.055	−0.186	0.062	0.055	0.070	0.654	0.018
対応B	0.032	0.041	−0.146	−0.010	0.021	0.138	0.018	0.750
標本平均	3.300	3.220	2.460	3.640	3.220	3.560	2.840	3.360
標準偏差	0.831	1.025	1.081	0.656	1.025	1.003	0.809	0.866

以下の項目を指定する(Figure 2.11)。

(1) サンプルサイズ：データのサンプルサイズを入力する。

(2) 行番号(a : b)：データの先頭(a)と最後尾(b)の行数を「a : b」と指定する。Table 2.4 の場合、1 行目はデータベース登録時に変数名としてあるので、「1：8」とする。

(3) 平均値の行番号:標本平均が入力されている行数を指定する。Table 2.4 の場合は「9」。

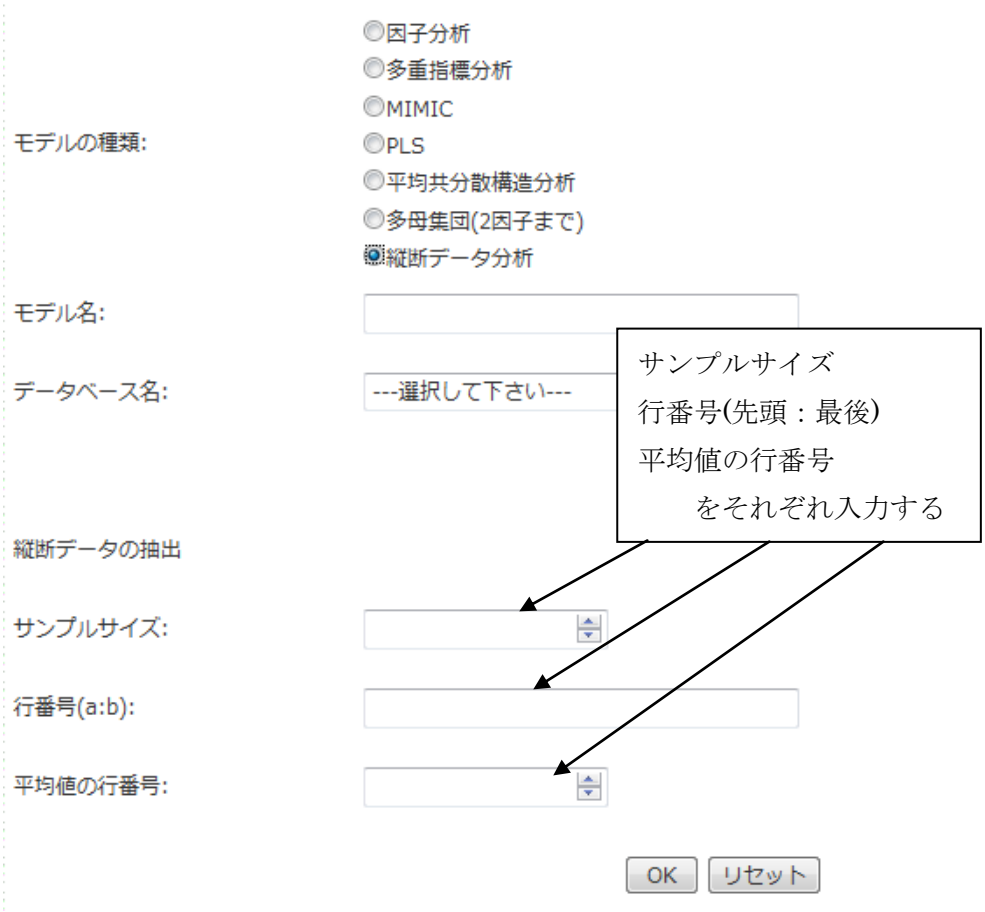

Figure 2.11　縦断データ分析のモデル作成時の例

4.2. モデルの登録・修正

4.2.1. 基本的なメニュー

①因子モデル

潜在変数と観測変数間の関係性のモデルを指定する。

1) 因子名を決定：潜在変数の名前を入力する。

2) 分散の指定：潜在変数の分散を 1 に指定するかしないかを選択する。

3) ラベル付き：任意のラベルをつけることができる。縦断データ分析の等値制約のモデルによって、同じラベルをつける必要がある。

4) 潜在変数と関連する変数を選択する。

5) “↓↓↓因子モデルを登録↓↓↓”に登録をクリックする。

②回帰モデル

1) 従属変数を選択する。

2) 独立変数を指定する。

3) “↓↓↓回帰モデルを登録↓↓↓”をクリックする。

③共分散

2 つの変数間の共変関係について指定する。

(1) 相関／分散の指定なし：

異なる 2 つの変数の共変関係を指定：　「V1←→V2」と表示

1 つの変数に誤差を指定：　「V1←→V1」と表示

因子モデルでは観測変数は独立に計算されるが、モデル外の別の変数の影響を受けるために高い相関関係(共変関係)を示すことをモデルに組み込みたい場合、2 つの変数を選択する。同じ変数を選択した場合には、その変数に誤差を仮定することができる。いずれも相関／分散の指定はしない。

(2) 相関／分散を 0 に指定：

異なる 2 つの変数間の相関を 0 に指定：　「V1←→0*V2」と表示

回帰モデルでは観測変数間の相関関係は全ての組み合わせが考慮される。そこで特に独立した変数で相関関係を考慮しないモデルを組み込む場合、その 2 変数を選択し相関／分散を 0 に指定する。

(3) 相関／分散を 1 に指定：

1 つの変数の分散を 1 に指定：　「V1←→1*V1」と表示

2 つとも同じ変数を選択して相関／分散を 1 にすると、その変数の分散を 1 に指定することができる。

④誤差分散

誤差分散について指定する。個別に指定することができる。「平均共分散分析」、「多母集団分析」、「縦断データ分析」の場合、使用する関数の関係で個別に指定する必要がある。

4.2.2. 特別なモデルのメニュー

①係数の固定

モデル登録時の種類で「平均共分散構造分析」を選択した時に出る。回帰モデルの説明変数の 1 つに係数 1 を固定する際に使用する。

・登録後の表示例・・・変数名：V1

「1*V1」：係数の固定

②平均回帰因子モデル

モデル登録時の種類で「平均共分散構造分析」を選択した時に通常の回帰モデルの代わりに出る。従属変数の定数項として切片 1 の指定が可能になる。

・登録後の表示例・・・従属変数：V1、独立変数：V2 の場合

「V1←V2」：切片指定なし

「V1←1+V2」：切片 1 に指定

③切片

モデル登録時の種類で「平均共分散構造分析」を選択した時に出る。個別に変数の切片を指定できる。

・登録後の表示例・・・変数名：V1

「V1 ~ 1」：平均の制約しない

「V1~ 0*1;」：平均の制約 0 に指定

4.3. 分析メニュー

①測定モデルの指定：

構造方程式モデルにおいて、パラメータが特定の値をとるよう制約する等値制約について設定する。「多母集団分析」、「縦断的データの分析」、「平均共分散構造分析」の場合に使用するので、上記以外の分析モデルの場合は配置のままとする。

配置　：特に等値制約はしない。

弱　　：因子負荷を同じ値にする。

強　　：因子負荷と観測変数の切片を同じ値にする

厳密　：因子負荷、観測変数の切片、観測変数の誤差分散を同じ値にする。

全母数：すべての母数について同じ値にする。

②平均構造：

平均構造を組み込むかを指定する。STATWEB では平均構造はモデルの登録・修正において設定可能なため、本書で説明している範囲内では FALSE のままで良い。

TRUE　：平均構造を組み込む

FALSE：平均構造を組み込まない

③fixed.x：

外生変数の平均、分散、共分散の値を指定する。

TRUE　：外生変数の共分散は固定された変数であるとみなされ、それらの平均、分散、共分散は観測値の値に固定される。

FALSE：ランダムな変数とみなされ、平均、分散、共分散は自由な母数となる。

Default：引数 mimic に基づいて設定される。

④orthogonal：

外生潜在変数間の相関関係について指定する。

TRUE　：相関はないと仮定する場合。

FALSE：相関を仮定する場合。

⑤std.lv：

潜在変数(因子)の因子負荷量を設定する。

TRUE　：潜在変数の分散が 1.0 に固定される。

FALSE：最初の指標の因子負荷量を 1.0 が固定される。

⑥std.ov：

標準化とは変数の平均を 0、標準偏差を 1 とするデータの変換のこと。この標準化を分析前に実施し、標準化されたデータを用いて分析するかを選択する。

TRUE　：標準化する。

FALSE：標準化しない(観測データの値をそのまま使用する)。

⑦推定方法：

パラメータの推定方法を選択する。選択できる方法は以下の通り。

ML：最尤推定法

：共分散構造を用いて尤度を最大にする推定方法。最も一般的に用いられている方法。

GLS：一般化最小二乗法

：分散多変量正規分布を仮定した一般的な最小二乗法。

WLS：重み付き最小二乗法

：誤差に重み付けをした最小二乗法。重みを指定しない場合は、ADF 法と呼ばれる方法で決定される。

ULS：重みなし最小二乗法

：全ての誤差に同じ重みを付けて行う最小二乗法。

DWLS：対角重み付き最小二乗法

：重み行列が対角行列の形を取る最小二乗法。共分散構造分析では多変量正規分布に従わないデータから正しい推定結果が得られるよう意図した重み行列を指すことが一般的。

⑧likelihood：

最尤法における尤度の決定方法を選択する。⑦推定方法で ML： 最尤推定法を選択した場合のみ関係する。

Wishart：ウィシャート尤度による方法。

Normal：通常の尤度法による方法。

Default：R で関数 lavaan を使用している場合、通常の尤度法が使用されるため、normal を選択した場合と同じ結果になる。

⑨information：

母数の標準誤差の計算方法を決定する。

Expectd ：標準誤差の計算に情報行列の期待値が用いられる。

Observed：標準誤差の計算に情報行列の観測値が用いられる。

Default ：Expectd と同じく標準誤差の計算に情報行列の期待値が用いられる。

⑩標準誤差：

係数など標準誤差の計算方法を決定する。

Standard ：従来の標準誤差が計算される。

Firstorder ：一次関数に基づき計算される。

Robust.huber.white：MLR(疑似最尤推定法) に基づき計算される。

None ：計算されない。

⑪検定：

係数などの検定方法を決定する。

Standard ：通常の χ^2 検定が計算される。

Satorra.Bentler ：Satorra.Bentler の尺度化検定統計量が計算される。

Yuan.Bentler ：Yuan.Bentler の尺度化検定統計量が計算される。

Mean.var.adjusted： 平均、分散調整による検定統計量が計算される。

Scaled.shifted ：代替的な平均と分散による検定統計量

4.4. パス図メニュー

①パスのラベル：

パス図に示させるパス係数について、表示形式を選択する。非標準化解の場合は各観測変数の値によって変わってくるため、一般的には標準化した標準化解を選択する。

非標準化解：標準化していない値が表示される。

標準化解　：標準化した値が表示される。

ナンバー　：1 から順にナンバリングされた値が表示される。

表示なし　：何も表示しない。

②スタイル：

共分散構造モデルの表現の形式を指定する。

Lisrel：Lisrel(Linear Structural Relation)形式は Joreskog & Sorbom(1979)によって考案された形式。最初に報告されたこともあり最も一般的に使用されている。

Ram：Ram(Reticular Action Model)は McArdle & McDonald (1984)による方法。Lisrel との主な違いは外生変数と構造変数の誤差分散の扱い方にあり、誤差分散の矢印が Lisrel では片方向になるが、Ram では全ての構造変数の誤差分散が両方向の矢印で表現される。

③レイアウト：

パス図のレイアウトを選択する。

Tree　：樹状のようなレイアウト。外生変数の配置を指定しない場合、外生変数を上に、内生変数を下に配置する。

Circle　：水平方向に配置される変数が円形に配置される。それ以外は Tree と同じ。比較的多くの顕在変数と、少数の潜在変数から成るモデルの時に適している。

Spring：Fruchterman-Reingold アルゴリズムを使用する。

④残差変数の表示：

パス図に誤差変数を表示するか指定する。

TRUE　：誤差変数を表示する。

FALSE：誤差変数を表示しない。

⑤因子間相関の表示：

潜在変数間の相関を表示するかを選択する。

TRUE　：因子間相関を表示する。

FALSE：因子間相関を表示しない。

⑥外生変数の配置：

外生潜在変数をパス図上のどこに配置するかを決定する。上側、左側、下側、右側から選択する。

⑦矢印曲率(-5～5)：

パス図における矢印の曲率(曲線のなめらかさ)を指定する。

⑧変数名の表示字数(0～10)：

パス図中に表示される変数名の字数を指定する。0 の場合は省略されず表示される。

⑨パスラベルの表示字数（0～10）：

パス図中に表示されるパスラベルの字数を指定する。0 の場合は省略されず表示される。

⑩観測変数の四角の大きさ(3～15)：

パス図中に表示される観測変数を囲む四角の大きさを、幅と高さ毎に指定する。

⑪潜在変数の丸の大きさ(5～20)：

パス図中に表示される潜在変数を囲む楕円の大きさを、幅と高さ毎に指定する。

⑫余白の大きさ(0～20)：

パス図の余白を、上下左右毎に指定する。

⑬パス推定値の文字(0.3～2)：

パス図に表示されるパス係数の文字サイズを指定する。

⑭係数の文字の間の距離(0.10～0.90)：

パス図に表示されるパス係数の位置を指定する。0.5 で矢印の中央になり、0.5 以下で中央より左側または下側に、0.5 以上で中央より右側または上側に配置される。

⑮構造モデルのみの表示：

パス図において観測変数の表示をするかしないかを選択する。

TRUE ：観測変数を表示せず、潜在変数のみを表示する。構造モデル(構成概念のつながり)のみが表示される。

FALSE：観測変数も表示する。

4.5. 出力結果の詳細

①使用データベース名

分析に使用したデータベースの名前。

②観測数

分析対象となったデータの数(サンプルサイズ)

③推定方法

使用した推定方法。分析メニューで選択した推定方法が表示される。

④カイ二乗値

解析モデルのχ^2値、自由度、有意確率が表示される。

⑤ベースラインモデル

変数間にパスを引かない場合のχ^2値、自由度、有意確率が表示される。

⑥ベースラインモデル 対 ユーザーモデル

④カイ二乗値と⑤ベースラインモデルのχ^2値の比較から、CFI と TLI の 2 つの適合度の指標が表示される。

⑦ログ尤度・情報量基準

情報量基準の指標(AIC、BIC、SABIC の 3 つ)と、非心度に基づく指標(RMSEA)、モデルの推定精度に基づく指標(SRMR)が表示される。RMSEA では 90%信頼区間と有意確率も表示される。

⑧母数の推定

分析メニューの information と標準誤差で選択した計算方法が表示される。

⑨非標準化推定値（係数）

標準化していない各係数の推定値に関する情報(推定値、標準誤差、z 値、有意確率)がモデル(係数)毎に表示される。実際の観測変数の単位や数値の影響を受けるため、各係数の大小関係は比較できないが、具体的な値の関係性を判断するのに使用される。

⑩標準化推定値

標準化した各係数の推定値に関する情報(推定値、標準誤差、z 値、有意確率)がモデル(係数)毎に表示される。標準化されているため、各係数の大小関係を比較するのに使用される。

第 2 章　共分散構造分析の様々なモデル

この章では、様々なパターンのモデルの解析方法を解説する。あくまで STATWEB での分析方法の解説に主眼を置くため、必ずしも適合度の高い例とは限らない。なお、表記を簡略化するため、分析方法での入力方法は以下のように表記する。

(1) 回帰モデル：「従属変数←独立変数」の向きに矢印でつなぐ
　　例：「従属変数←独立変数 A＋独立変数 B＋独立変数 C」
(2) 因子モデル：「＝」でつなぐ
　　例：「因子＝変数 A＋変数 B＋変数 C」
(3) 共分散：「←→」でつなぐ
　　例：「変数 A←→1*変数 A」(分散を 1 に指定した場合)

1. パス解析

既に述べたように、共分散構造分析では構成概念を扱うモデルだけではなく、回帰モデルだけで観測変数のみによってモデルが構成される場合もある。従属変数が 1 つに限定される重回帰分析に対し、複数の説明変数(独立変数)から複数の従属変数を説明する分析手法をパス解析と言う。

パス解析は、逐次モデル(Recursive Model)と非逐次モデル(non-Recursive Model)に大きく分類される。両者の違いはパス図の矢印を道順のようにたどってみるとわかりやすい。矢印の方向にだけたどって、ある変数から出発し同じ変数に戻ってくることができる変数が 1 つでもあれば非逐次モデル、同じ変数に戻ってくることができる変数が 1 つもなければ逐次モデルとなる。

1.1. 逐次モデル (Recursive Model)

【具体例】加齢による動脈硬化リスクについて

(1) データ概要：ある会社の健康診断を受けた男性 10 名の結果(仮想データ)

(2) 変数：①年齢　　②血糖値(空腹時)　　③血圧(最高値)
　　④危険度(医者による診断、5 段階評価)

(3) モデル：以下のようなモデルを考える。
「④危険度　←　②血糖値　＋　③血圧」
　　慢性的な高血糖と高血圧により動脈硬化リスクが高まると考えられる。

「②血糖値　←　①年齢　　③血圧　←　①年齢」
　　血糖値、血圧共に加齢による影響を受ける。

「③血圧　←　②血糖値」
　　高血糖は血液がドロドロなので血圧に影響する。

【分析方法】
①モデルの分類：「多重指標分析」とする。
②モデルの登録・修正
(1) 回帰モデルに以下の 3 つを指定。
　　「危険度←血糖値+血圧」
　　「血糖値←年齢」
　　「血圧←年齢+血糖値」
(2) それ以外はそのまま。
③分析メニュー
すべてそのまま変更なし。

【分析結果】
分析結果の要点は以下の通り。パス図は Figure3.1 のようになる。

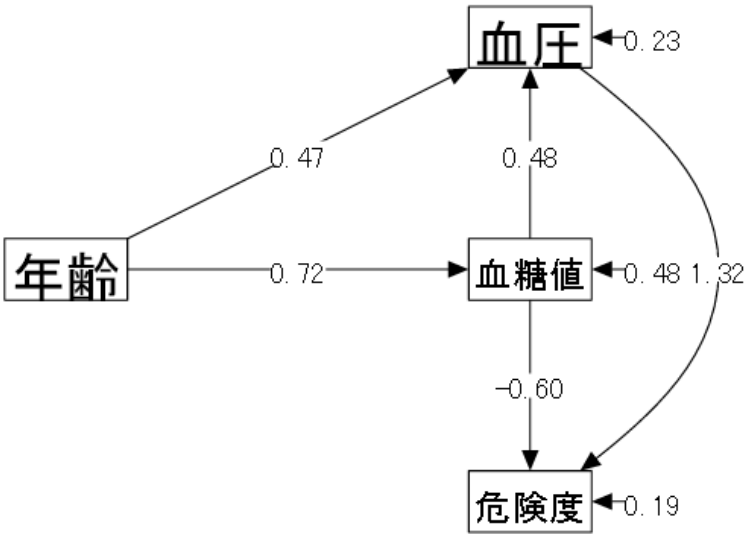

Figure 3.1　加齢による動脈硬化リスクのパス図

①モデル全体の評価
モデル全体の評価は以下の通りとなる。χ^2 値は有意でなく、CFI では適合度が良いと判断されるが、RMSEA からは適合度は悪いと判断される。

χ^2=1.609　自由度=1　有意確率=0.205　n=10

CFI=0.982　　TLI=0.893　　RMSEA=0.247

②各係数の評価

母数の標準化推定値(Table 3.1) と非標準化推定値(Table 3.2)は以下の通りになる。いずれのパス係数も統計的には有意な関係性である。

Table 3.1　加齢による動脈硬化リスクの標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	血糖値	←	年齢	0.723	0.219	3.307	0.001
2	血圧	←	年齢	0.470	0.219	2.140	0.032
3	危険度	←	血糖値	−0.602	0.241	−2.496	0.013
4	危険度	←	血圧	1.318	0.241	5.467	0.000
5	血圧	←	血糖値	0.476	0.219	2.170	0.030

Table 3.2　加齢による動脈硬化リスクの非標準化推定値(誤差分散は省略)

	モデル			推定値	誤差	z値	有意確率
1	血圧	←	年齢	1.070	0.500	2.140	0.032
2	血圧	←	血糖値	0.385	0.178	2.170	0.030
3	危険度	←	血糖値	−0.040	0.016	−2.496	0.013
4	危険度	←	血圧	0.108	0.020	5.467	0.000
5	血糖値	←	年齢	2.034	0.615	3.307	0.001

【結果の解釈】

非標準化推定値からは、以下の関係性が示される。

(1) 年齢が 1 歳あがると、血糖値は 2.03 程度あがる。

(2) 年齢が 1 歳あがると、血圧は 1.07 程度あがる。

(3) 血糖値が 1 あがると、危険度は 0.04 程度さがる。

(4) 血圧が 1 あがると、危険度は 0.11 程度あがる。

(5) 血糖値が 1 あがると、血圧は 0.39 程度あがる。

血糖値は直接的には危険度をあげる影響はみられないが、血糖値の上昇は血圧に悪影響し、結果として、間接的には動脈硬化リスクはマイナスの影響を与えていると言える。

1.2. 非逐次モデル（non-Recursive Model）

【具体例】高校生のスマホ利用状況について

(1) データ概要：高校生 100 名に対して以下の調査を行った(仮想データ)

(2) 変数：①利用時間(1 日の平均的な利用時間：時間)
②SNS 友人(SNS でつながっている友人の数)
③会話(1 日の家庭での会話時間の平均：分)
④学校友人(学校で親しくしている友人の数)

(3) モデル：以下のようなモデルを考える。
「①利用時間　←　②SNS 友人　＋　③会話」
スマホ利用時間はネット上での交友関係と家庭での家族との会話の影響を受ける

「②SNS 友人　←　①利用時間　＋　④学校友人」
ネット上の友人は、ネット利用時間と実生活での交友関係の影響を受ける

※①利用時間と②SNS 友人は共に互いの従属変数と説明変数になっており、矢印がループするので非逐次モデルに該当する。

【分析方法】
①モデルの分類：「多重指標分析」とする。
②モデルの登録・修正
(1) 回帰モデルに以下の 2 つを指定
「利用時間←SNS 友人+会話」
「SNS 友人←利用時間＋学校友人」
(2) それ以外はそのまま
③分析メニュー
すべてそのまま変更なし。

【分析結果】
分析結果の要点は以下の通り。パス図は Figure 3.2 のようになる。

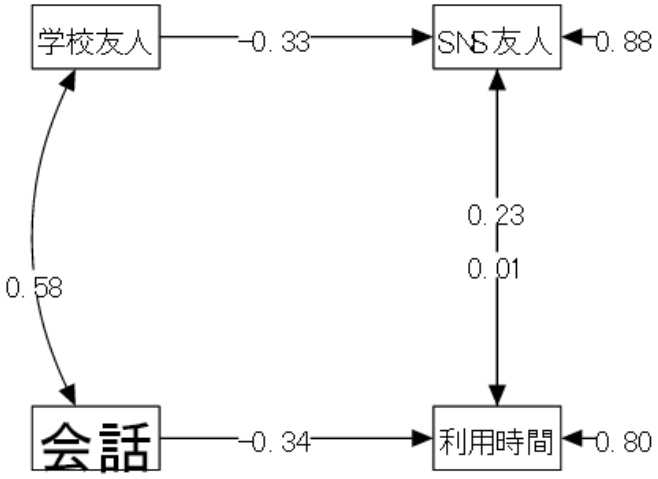

Figure 3.2　高校生のスマホ利用状況のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2値は有意でなく、CFI、RMSEA 共に適合度が良いと判断される。

χ^2=0.008　自由度=1　有意確率=0.929　n=100

CFI=1.000　　TLI=1.167　　RMSEA=0.000

②各係数の評価

母数の標準化推定値は Table 3.3 の通りになる。利用時間と SNS 友人間を結ぶパス係数はいずれも有意ではなく、他のパス係数は統計的に有意である。

Table 3.3　高校生のスマホ利用状況の標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	利用時間	←	SNS友人	0.230	0.231	0.999	0.318
2	利用時間	←	家族会話	−0.341	0.100	−3.404	0.001
3	SNS友人	←	利用時間	0.011	0.255	0.045	0.964
4	SNS友人	←	学校友人	−0.329	0.117	−2.804	0.005

【結果の解釈】

母数の標準化推定値からは、家族の会話が少ないほどネット利用時間が増え、学校での友人関係が少ないほどネットでの友人関係が多くなる傾向にある。ネット利用時間と SNS 友人数の関係は統計的に有意でなく、必ずしもネット上でつながっている人数と利用時間に強い関係性はないと考えられ、人数よりは関係性の質が重要なのかもしれないと言える。

2. 重回帰分析（Multiple Regression Analysis）

重回帰分析は、複数の説明変数(独立変数)から複数の従属変数を説明するモデルである。上記のパス解析の例では、いずれも従属変数が１つである点が異なる。

【具体例】ある町におけるアパートの条件と賃貸料の関係

(1) データ概要：ある駅を最寄り駅とするアパート(間取りはほぼ同じ条件）の各種条件と問い合わせ件数(仮想データ)

(2) 変数：①賃貸料(月の賃貸料、万円)　②距離(駅からの徒歩による所要時間、分)
③築年数(年)　④問い合わせ(最近１カ月の問い合わせ件数)

(3) モデル：以下のようなモデルを考える。この例では賃貸料と問い合わせが従属変数となっているため、重回帰分析に該当する。

「①賃貸料　←　②距離　＋　③築年数」
駅からの距離と築年数によって賃貸料は変わってくる。

「④問い合わせ　←　①賃貸料　＋　②距離　＋　③築年数」
問い合わせの多さは、賃貸料と駅からの距離と築年数

②距離と③築年数は関係ないので無相関を仮定する。

【分析方法】
①モデルの分類：「多重指標分析」とする。
②モデルの登録・修正
(1) 回帰モデルに以下の２つを指定
「賃貸料←距離+築年数」
「問い合わせ←賃貸料+距離+築年数」
(2) 共分散で距離と築年数の間の相関／分散を０に指定
「距離←→0*築年数」
(3) それ以外はそのまま
③分析メニュー
すべてそのまま変更なし。

【分析結果】
分析結果の要点は以下の通り。パス図は Figure 3.3 のようになる。

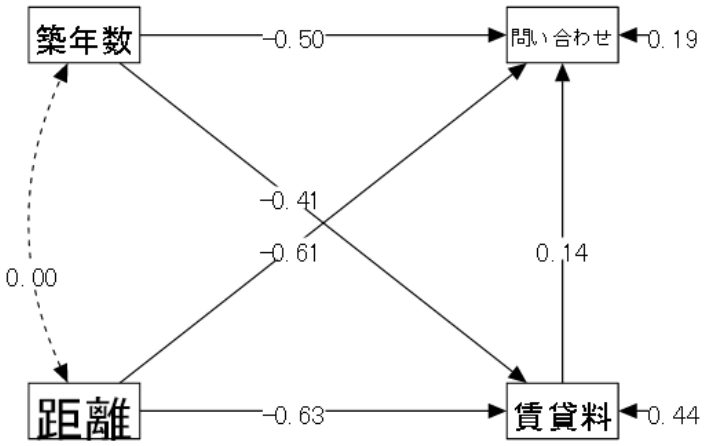

Figure 3.3　アパートの条件と賃貸料、問い合わせ件数のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2値は有意でなく、CFI 、RMSEA 共に適合度が良いと判断される。

χ^2=0.251　自由度=1　有意確率=0.617　n=16

CFI=1.000　　TLI=1.145　　RMSEA=0.000

②各係数の評価

母数の標準化推定値(Table 3.4) と非標準化推定値(Table 3.5)は以下の通りになる。パス係数は賃貸料と問い合わせの関係のみ、統計的には有意な結果ではない。

Table 3.4　アパートの条件と賃貸料、問い合わせ件数の標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	賃貸料	←	距離	−0.633	0.165	−3.834	0.000
2	賃貸料	←	築年数	−0.405	0.165	−2.457	0.014
3	問い合わせ	←	賃貸料	0.141	0.167	0.844	0.399
4	問い合わせ	←	距離	−0.605	0.153	−3.959	0.000
5	問い合わせ	←	築年数	−0.503	0.130	−3.883	0.000

Table 3.5　アパートの条件と賃貸料、問い合わせ件数の非標準化推定値(誤差分散は省略)

	モデル			推定値	誤差	z値	有意確率
1	賃貸料	←	距離	−0.503	0.131	−3.834	0.000
2	賃貸料	←	築年数	−0.138	0.056	−2.457	0.014
3	問い合わせ	←	賃貸料	0.105	0.125	0.844	0.399
4	問い合わせ	←	距離	−0.359	0.091	−3.959	0.000
5	問い合わせ	←	築年数	−0.128	0.033	−3.883	0.000

【結果の解釈】

非標準化推定値からは、以下の関係性が示される。

(1) 距離が 1 分長くなると、賃貸料は 0.50 万円程度安くなる。

(2) 築年数が 1 年長くなると、賃貸料は 0.14 万円程度安くなる。

(3) 距離が 1 分長くなると、問い合わせは 0.36 件程度少なくなる。

(4) 築年数が 1 年長くなると、問い合わせは 0.13 件程度少なくなる。

(5) 問い合わせ件数と賃貸料の関係性については統計的に有意とは言えず、関係性については特に結論は言えない。

3. MIMIC (Multiple Indicator Multiple Cause)

複数の観測変数から 1 つの構成概念が規定されて、その構成概念が規定したものとは別の観測変数に影響を与えているモデルのこと。つまり、複数の観測変数→潜在変数→複数の観測変数、という流れの因果連鎖が想定されるモデルである。多重指標モデルでは複数の観測変数から構成概念に矢印が向いているが、MIMIC ではその構成概念から更に別の観測変数に向けて矢印が出ている(潜在変数→複数の観測変数の部分)ことが異なる。

【具体例】中学生の活字離れと学業成績

(1) データ概要：中学生 25 名を対象に以下の調査をした(仮想データ)

(2) 変数：①読書量(最近 1 ケ月の間に読んだ本の冊数)
②新聞を読む頻度(1 日に新聞を読む平均時間)
③雑誌を読む頻度(1 日に雑誌を読む平均時間)
④国語の成績　⑤数学の成績　⑥英語の成績

(3) モデル：3 科目の成績から⑦学力という潜在変数を仮定し、3 種の活字にふれる頻度が学力に与える影響を確認するようなモデルを立てて検証を行う。

「⑦学力 ＝ ④国語 ＋ ⑤数学 ＋ ⑥英語」
各科目の成績から潜在変数としての学力が仮定される

「⑦学力 ← ①読書量 ＋ ②新聞 ＋ ③雑誌」
学力はそれぞれの活字にふれる頻度の影響を受ける

【分析方法】

①モデルの分類：「MIMIC」とする。

②モデルの登録・修正

(1) 因子モデルに以下の 1 つを指定

因子名：学力

「学力=国語＋数学＋英語」

(2) 回帰モデルに以下の 1 つを指定

「学力←読書量+新聞＋雑誌」

(3) それ以外はそのまま

③分析メニュー

すべてそのまま変更なし。

【分析結果】

分析結果の要点は以下の通り。パス図は Figure 3.4 のようになる。

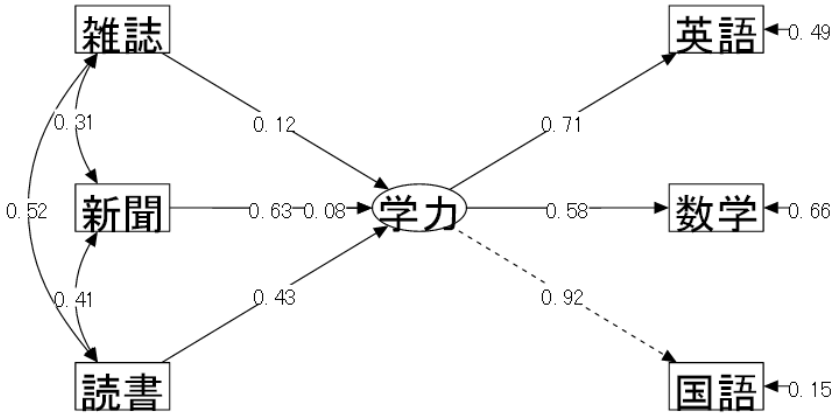

Figure 3.4　MIMIC モデルによる活字離れと学業成績のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2 値は有意でなく、CFI では適合度が良いと判断される。

χ^2=6.77　自由度=6　有意確率=0.343　n=25

CFI=0.987　　TLI=0.974　　RMSEA=0.072

②各係数の評価

母数の標準化推定値は Table 3.6 の通りになる。潜在変数(因子)の因子負荷量を 1.0 に固定するため、潜在変数と結ぶ 1 つ目のパスには推定値以外の値は表示されない。雑誌を読む頻度と学力の関係のみ有意ではない。

Table 3.6　MIMIC モデルによる活字離れと学業成績の関連の
標準化推定値(誤差分散と説明変数間の相関は省略)。

	モデル			標準化推定値	誤差	z値	有意確率
1	学力	→	国語	0.923			
2	学力	→	数学	0.583	0.175	3.325	0.001
3	学力	→	英語	0.713	0.158	4.513	0.000
4	学力	←	読書量	0.435	0.116	3.742	0.000
5	学力	←	新聞	0.629	0.106	5.937	0.000
6	学力	←	雑誌	0.115	0.110	1.044	0.296

【結果の解釈】

標準化推定値からは、雑誌を読む頻度と学力の関係性には統計的に有意な関係は見られなかった。読書量と新聞を読む頻度は学力に影響し、各科目の成績に影響すると言える。特に学力と国語の関係性が高いことから、ここでの学力は特に文章に関する能力と考えられる。

4. PLS (Partial Least Squares)

MIMIC における潜在変数(構成概念)のところに、2 つ以上の潜在変数間の因果関係を仮定するモデルである。つまり、複数の観測変数→潜在変数→潜在変数→複数の観測変数、という流れの因果連鎖が想定されるモデルである。

PLS モデルの注意点として、1 つ目の潜在変数には分散に 0 を固定し、誤差を仮定しないことがある。このように特定の値を取るよう指定された母数を固定母数(fixed parameter)と言う。1 つ目の潜在変数は観測変数から矢印を受けていて、従属変数でもあるが誤差を仮定しないのは、矢印の元になっている観測変数の重み付け和で表現される変数と考えるからである。しかし観測変数の重み付け和も直接観察できないので潜在変数として扱われる。また、2 つ目の潜在変数は矢印を受ける従属変数にもなるので、誤差を仮定する必要がある。

【具体例】 中学生の活字離れと学業成績(仮想データ)

(1) データ概要：中学生 25 名を対象に以下の調査をした(仮想データ)

(2) 変数：①読書量(最近 1 ケ月の間に読んだ本の冊数)
②新聞を読む頻度(1 日に新聞を読む平均時間)
③雑誌を読む頻度(1 日に雑誌を読む平均時間)
④国語の成績　⑤数学の成績　⑥英語の成績

(3) モデル : MIMIC の時は潜在変数を「学力」1 つとし、その分析結果から仮定された「学力」は文章に関する能力と関連性が強いと想定された。そこで、もう 1 つ“学力"と活字にふれる頻度の間に⑧文章理解力という潜在変数を想定し、3 科目の成績から⑦学力という潜在変数を仮定し、3 種の活字にふれる頻度が学力に与える影響を確認するようなモデルを立てて検証を行う。

「⑦学力　=　④国語　＋　⑤数学　＋　⑥英語」
各科目の成績から潜在変数としての「学力」が仮定される

「⑧文章理解力　= ⑦学力」
「文章理解力」は「学力」と関係がある

「⑧文章理解力　←　①読書量　＋　②新聞　＋　③雑誌」
「文章理解力」はそれぞれの活字にふれる頻度の影響を受ける

⑧文章理解力の分散を 0 に指定する。
「文章理解力」は矢印を受ける従属変数ではあるが、もう 1 つの潜在変数である「学力」とは異なる変数であり、モデル上では、3 つの活字にふれる頻度の変数のみから表現されるものとして扱う。

【分析方法】
①モデルの分類 :「PLS」とする。
②モデルの登録・修正
(1) 因子モデルに以下の 2 つを指定
因子名：学力
「学力=国語＋数学＋英語」
因子名：文章理解
「文章理解=学力」
(2) 回帰モデルに以下の 1 つを指定
「文章理解←読書量+新聞＋雑誌」
(3) 共分散の指定で以下の 2 つを指定
「学力←→学力」
「文章理解←→0*文章理解」: 相関／分散は“0 に指定”
(4) それ以外はそのまま
④分析メニュー
すべてそのまま変更なし。

【分析結果】

分析結果の要点は以下の通り。パス図は Figure 3.5 のようになる。

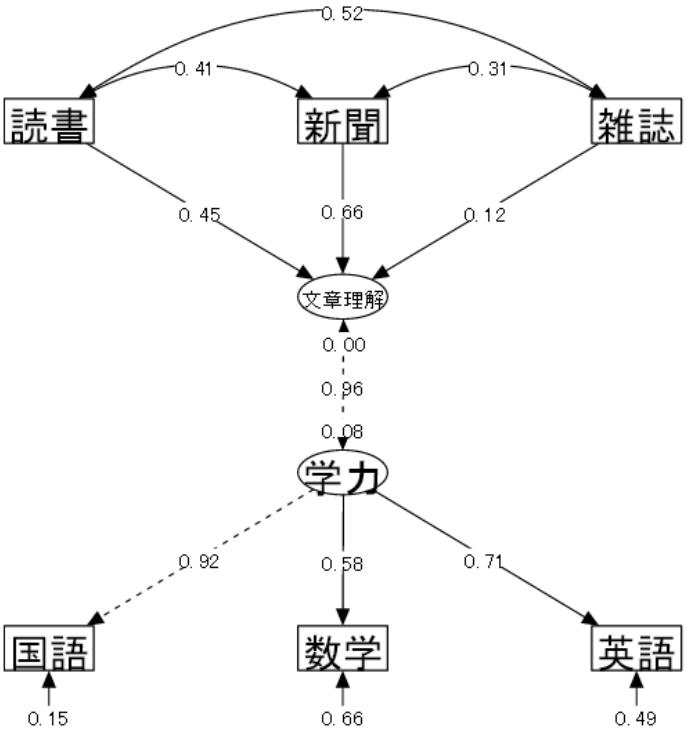

Figure 3.5　PLS モデルによる活字離れと学業成績のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2 値は有意でなく、CFI では適合度が良いと判断される。また、読書量、新聞、雑誌と潜在変数との関係が MIMIC モデルと異なっていることがわかる。

χ^2=6.770　自由度=6　有意確率=0.343　n=25

CFI=0.987　　TLI=0.974　　RMSEA=0.072

②各係数の評価

母数の標準化推定値は Table 3.7 の通りになる。潜在変数(因子)の因子負荷量を 1.0 に固定するため、潜在変数と結ぶ 1 つ目のパスには推定値以外の値は表示されない。MIMIC モデル同様、雑誌を読む頻度と学力の関係のみ有意ではない。

Table 3.7　PLS モデルによる活字離れと学業成績の関連の
標準化推定値(誤差分散と説明変数間の相関は省略)。

	モデル			標準化推定値	誤差	z値	有意確率
1	文章理解	→	学力	0.958			
2	学力	→	国語	0.923			
3	学力	→	数学	0.583	0.175	3.325	0.001
4	学力	→	英語	0.713	0.158	4.513	0.000
6	文章理解	←	読書	0.453	0.121	3.742	0.000
7	文章理解	←	新聞	0.657	0.111	5.937	0.000
8	文章理解	←	雑誌	0.120	0.115	1.044	0.296

【結果の解釈】

結果は MIMIC モデルと大きく違いはない。文章理解力には読書量と新聞を読む頻度がより強く関係し、文章理解力は学力に強く影響する。今回の学力は特に国語との関連が深いため、ただ学力とするよりも文系学力と理解したほうが良いかもしれない。

5. 2 次因子分析

因子分析では、潜在的な変数として因子が抽出され、この因子によって複数の観測変数が説明される。この複数の因子がさらにその裏にある少数の因子で説明される場合、このようなモデルを 2 次因子分析と言う。言わば、因子分析によって得られた因子に対する因子分析、というイメージを持つとわかりやすいだろう。

【具体例】環境問題への意識調査

(1) データ概要：100 名を対象に以下の項目についての知識度を測定、7 段階で評価した(仮想データ)。

(2) 変数：①温暖化　②光化学スモッグ　③酸性雨
④レッドデータ　⑤特定外来生物　⑥生態系
⑦リユース　⑧リサイクル　⑨ゴミ分別

(3) モデル：大気汚染、生物多様性、ゴミの 3 つの問題に対する意識の高さを潜在変数として仮定し、この 3 潜在変数から更に 2 次的な潜在変数として環境問題への意識を仮定する。

「⑩大気汚染　＝　①温暖化　＋　②光化学スモッグ　＋　③酸性雨」
「⑪生物多様性　＝　④レッドデータ　＋　⑤特定外来生物　＋　⑥生態系」
「⑫ゴミ問題　＝　⑦リユース　＋　⑧リサイクル　＋　⑨ゴミ分別」
「⑬環境意識　＝　⑩大気汚染　＋　⑪生物多様性　＋　⑫ゴミ問題」

【分析方法】

①モデルの分類：「因子分析」とする。

②モデルの登録・修正

(1) 因子モデルに以下の 4 つを指定

因子名：大気汚染

「大気汚染=温暖化＋光化学スモッグ＋酸性雨」

因子名：生物多様性

「生物多様性=レッドデータ＋特定外来生物＋生態系」

因子名：ゴミ問題

「ゴミ問題=リユース＋リサイクル＋ゴミ分別」

因子名：環境意識

「環境意識=大気汚染＋生物多様性＋ゴミ問題」

③分析メニュー

すべてそのまま変更なし。

【分析結果】

分析結果の要点は以下の通り。パス図は Figure3.6 のようになる。

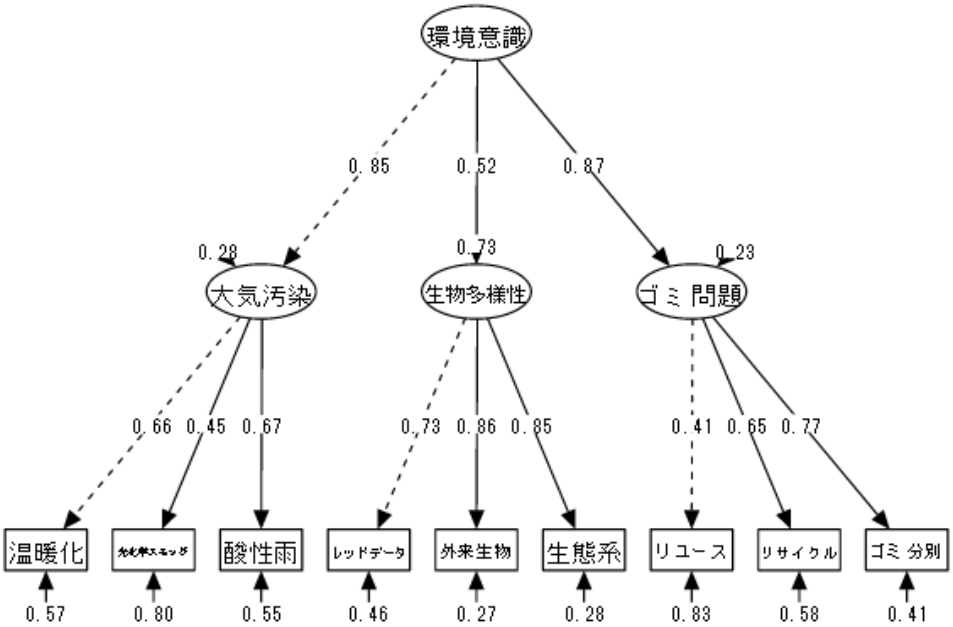

Figure 3.6　2 次因子分析による環境問題への意識のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2値は有意ではなく、CFI では適合度が良いと判断される。

χ^2=31.870　自由度=24　有意確率=0.130　n=100

CFI=0.969　　TLI=0.953　　RMSEA=0.057

②各係数の評価

母数の標準化推定値は Table 3.8 の通りになる。潜在変数(因子)の因子負荷量を 1.0 に固定するため、潜在変数と結ぶ 1 つ目のパスには推定値以外の値は表示されない。

Table 3.8　2 次因子分析による環境問題への意識の標準化推定値(誤差分散は省略)

	モデル			標準化推定値	誤差	z値	有意確率
1	環境	→	大気汚染	0.850			
2	環境	→	生物多様性	0.521	0.169	3.081	0.002
3	環境	→	ゴミ問題	0.875	0.354	2.474	0.013
4	ゴミ問題	→	リユース	0.415			
5	ゴミ問題	→	リサイクル	0.648	0.193	3.364	0.001
6	ゴミ問題	→	ゴミ分別	0.769	0.223	3.441	0.001
7	大気汚染	→	温暖化	0.657			
8	大気汚染	→	光化学S	0.446	0.130	3.436	0.001
9	大気汚染	→	酸性雨	0.668	0.151	4.429	0.000
10	生物多様性	→	レッドデータ	0.732			
11	生物多様性	→	特定外来種	0.856	0.110	7.766	0.000
12	生物多様性	→	生態系	0.850	0.110	7.750	0.000

【結果の解釈】

環境問題全般の意識の高さには、大気汚染やゴミ問題への意識が比較的強く関係し、生物多様性への意識は、関係はあると言えるが他の 2 因子と比較すると影響度は低いと言える。大気汚染への意識には、温暖化と酸性雨についての知識が比較的強く関係している。生物多様性への意識には、他の 2 因子と比較すると 3 項目とも関係性が強いが、特に特殊外来生物と生態系への知識が強く関係している。ゴミ問題への意識には、ゴミ分別の知識が最も関係性が強く、次いでリサイクル、最後にリユースとなっている。

6. 平均共分散構造分析

因子分析では仮説的な構成概念が潜在変数として扱われるが、仮説的な構成概念のため特に単位はなく、平均は 0、分散は 1 に固定される。潜在変数間の関係などを複雑に扱える共分散構造分析では、潜在変数の変化などに関心が向けられるケースも考えられる。しかし、潜在変数間の比較に関心がある場合、平均は 0、分散は 1 に固定されると比較ができな

い。このような場合に潜在変数の平均の情報を扱う必要がある。このような場合に用いられるのが平均共分散構造分析である。

ここでいう平均構造とは回帰分析における切片に該当し、他の変数の影響を全て取り除いた値と考えることができる。潜在変数には、切片項として元になる観測変数の 1 つに定数 1 を仮定する。また、全ての観測変数の切片は 0 に制約する。これにより観測変数からの影響度をそろえることができ、潜在変数の切片が因子平均として表現される。平均共分散構造分析では以下の注意点があげられる。

(1) 全ての観測変数に切片 0 の制約をつけること。
(2) 潜在変数の切片項として定数 1 を入れること(係数の固定により実施)。
(3) 全ての観測変数は単位が同じであり、同じ尺度であること。この場合に限り、切片 0 の制約が有効となり、平均構造の比較が可能となる。
(4) 標準化係数ではなく、非標準化係数を確認すること。

6.1. 平均構造のあるパス解析：観測変数のみ

【具体例】ビールの新製品に対する評価の調査

(1) データ概要：50 名のモニターに対し、以下の項目を 5 件法により調査した。

(2) 変数：①味満足度　②コク　③キレ
④のどごし　⑤価格　⑥商品満足度

(3) モデル：以下の 2 つのモデルを仮定する。
「①味満足度　＝　②コク　＋　③キレ　＋　④のどごし」
「⑥商品満足度　＝　①味満足度　＋　⑤価格」

【分析方法】
①モデルの分類：「平均共分散構造分析」とする。
②モデルの登録・修正
(1) 平均回帰モデルに以下の 2 つを指定
「味←1＋コク＋キレ＋のどごし」平均構造の指定を“1 に指定”
「満足度←1＋味＋価格」平均構造の指定を“1 に指定”
(2) 共分散で以下の 2 つを指定
「味←→味」
「満足度←→満足度」
(3) それ以外はそのまま

③分析メニュー

非標準化解に指定。それ以外はそのまま。

【分析結果】

分析結果の要点は以下の通り。パス図は Figure 3.7 のようになる。

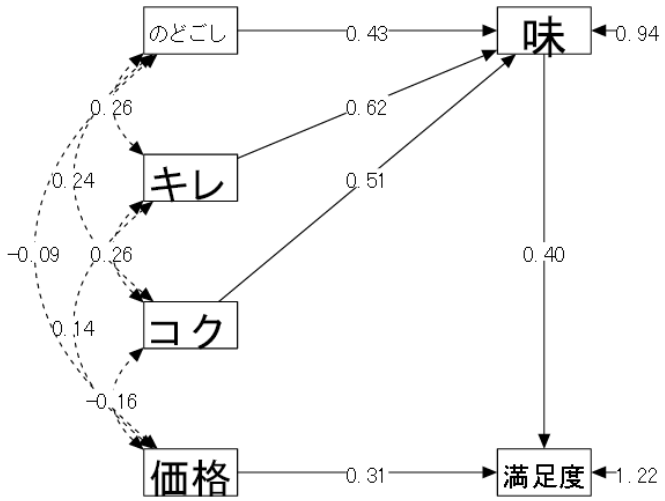

Figure 3.7　ビールの新製品に対する評価のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2値は有意ではないが、他の指標では適合度は悪い。

χ^2=8.407　自由度=4　有意確率=0.078　n=50

CFI=0.923　　TLI=0.826　　RMSEA=0.148

②各係数の評価

母数の非標準化推定値はTable 3.9の通りになる。係数と切片は全て統計的に有意である。

Table 3.9　ビールの新製品に対する評価の調査の非標準化推定値

		モデル			推定値	誤差	z値	有意確率
係数	1	味満足度	←	コク	0.514	0.152	3.383	0.001
	2	味満足度	←	キレ	0.621	0.137	4.542	0.000
	3	味満足度	←	のどごし	0.431	0.175	2.470	0.014
	4	商品満足度	←	味満足度	0.396	0.106	3.727	0.000
	5	商品満足度	←	価格	0.313	0.160	1.957	0.050
切片	1	味満足度			-2.342	0.736	-3.182	0.001
	2	商品満足度			1.503	0.457	3.289	0.001
分散	1	商品満足度			1.218	0.244	1.218	0.742
	2	味満足度			0.936	0.187	0.936	0.433

【結果の解釈】

非標準化解のパス係数からは「味満足度」「商品満足度」の平均値は以下の計算式で表せる。

「味満足度」=－2.341＋0.514×「コク」＋0.621×「キレ」＋0.431×「のどごし」

「商品満足度」＝1.503＋0.396×「味満足度」＋0.313×「価格」

「味満足度」「商品満足度」の平均値は、上記式の「コク」「キレ」「のどごし」「価格」の平均値を代入することによって計算される。

6.2. 平均構造のあるパス解析：構成概念間のパス解析

【具体例】2 次因子分析で取り上げた環境意識の調査

(1) データ概要：環境意識の知識の調査、全て 7 件法により評価。なお分析を簡略化するため以下の 6 変数に限定し、2 つの因子の平均を比較する。

(2) 変数：①温暖化　②光化学スモッグ　③酸性雨
④レッドデータ　⑤特定外来生物　⑥生態系

(3) モデル：以下の 2 つの因子の比較をする。
「⑩大気汚染　＝　①温暖化　＋　②光化学スモッグ　＋　③酸性雨」
「⑪生物多様性　＝　④レッドデータ　＋　⑤特定外来生物　＋　⑥生態系」

【分析方法】

①モデルの分類：「平均共分散構造分析」とする。

②モデルの登録・修正

(1) 係数の固定

「酸性雨」と「生態系」の 2 つを選択。

(2) 因子モデルで以下の 2 つを登録

因子名：大気汚染

「大気汚染=温暖化＋光化学スモッグ＋1*酸性雨」

因子名：生物多様性

「生物多様性=レッドデータ＋外来生物＋1*生態系」

(係数の固定により、変数リストに 1*酸性雨と 1*生態系が加わるので、これを選択する)

(3) 切片で以下の 4 つを指定

「大気汚染」

「生物多様性」

「温暖化＋光化学スモッグ＋酸性雨」

平均の制約を“0 に制約する”

「レッドデータ＋外来生物＋生態系」

平均の制約を“0 に制約する”

(1*酸性雨と 1*生態系は選択しないこと)

(4) 共分散で以下の 2 つを登録

「大気汚染←→大気汚染」

「生物多様性←→生物多様性」

(5) 誤差分散で以下を個別に指定

「温暖化＋光化学スモッグ＋酸性雨」

「レッドデータ＋特定外来生物＋生態系」

(1*酸性雨と 1*生態系は選択しないこと)

④分析メニュー

非標準化解に指定。それ以外はそのまま。

【分析結果】

分析結果の要点は以下の通り。パス図は Figure 3.8 のようになる。

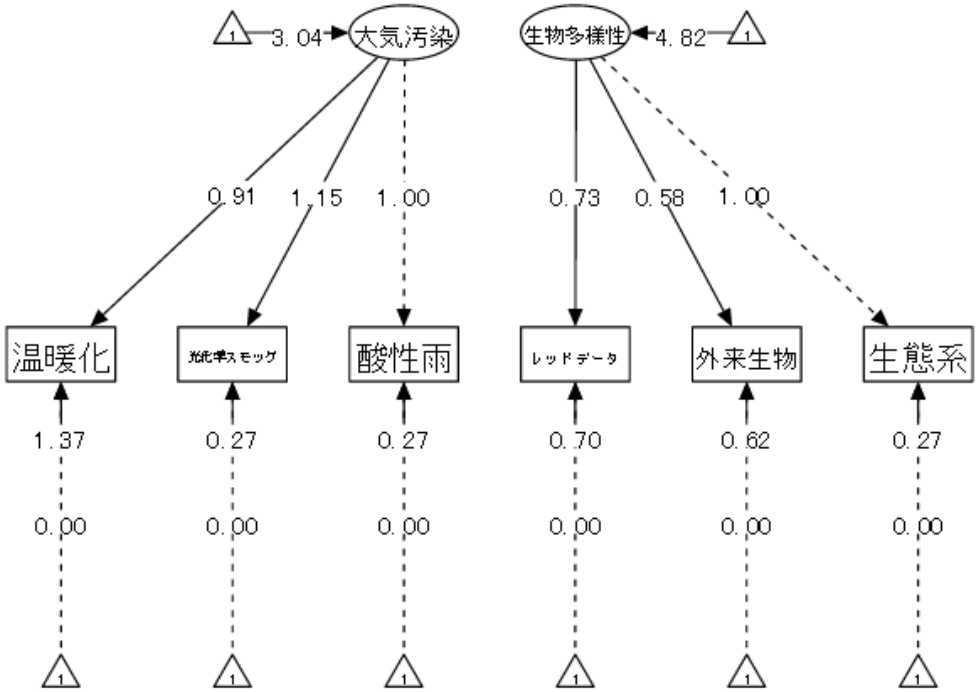

Figure 3.8　温暖化と生物多様性についての共分散構造分析のパス図

①モデル全体の評価

モデル全体の評価は以下の通りとなる。χ^2値は有意であり、全ての指標で適合度は悪い。

χ^2=44.815　自由度=13　有意確率=0.000　n=100

CFI=0.817　　TLI=0.789　　RMSEA=0.156

②各係数の評価

母数の非標準化推定値は Table 3.10 の通りになる。係数と切片は全て統計的に有意である。なお、係数の固定に指定した酸性雨と生態系の推定値は 1.0 に固定されるため、有意確率は算出されない。

Table 3.10　温暖化と生物多様性についての評価の調査の非標準化推定値(誤差は省略)

		モデル	推定値	誤差	z値	有意確率
係数	1	大気汚染 → 温暖化	0.914	0.041	22.111	0.000
	2	大気汚染 → 光化学S	1.154	0.026	44.438	0.000
	3	大気汚染 → 酸性雨	1.000	0.373	0.587	
	4	生物多様性 → レッドデータ	0.734	0.019	39.081	0.000
	5	生物多様性 → 特定外来種	0.577	0.017	33.705	0.000
	6	生物多様性 → 生態系	1.000	1.244	0.923	
切片	1	大気汚染	3.039	0.064	47.806	0.000
	2	商品満足度	4.822	0.135	35.816	0.000

【結果の解釈】

適合度は悪いが、切片の推定値から以下のように読み取ることができる。「温暖化」の平均は 3.04、「生物多様性」は 4.82 で、「生物多様性」の理解度の方が高いと言える。

7. 多母集団分析：1 因子の場合

これまでの分析は母集団が 1 つであることが前提であった。しかし、例えば男女毎に構造方程式モデルを作成し比較したいというように、複数の母集団を同時に分析するケースもあり得る。このような分析を多母集団分析、または多母集団同時分析と呼ばれる。平均共分散構造分析同様、非標準化解を確認すること。

7.1. 配置不変モデル

複数の母集団間で構造方程式モデルが同じである場合のモデル。母集団間で変数の関係性が同質かを比較するのに使用される。このモデルでは識別条件を満たすために、因子の平均を 0、因子の分散を 1 に指定する。また、平均共分散構造分析で説明したように切片項は定数 1 の影響力として表わされるため、切片項として各変数を指定する必要がある。

【具体例】プロ野球の打撃成績に関する因子モデルを、パ・リーグとセ・リーグ間で比較する。モデルを簡略化するため、今回は長打力の 1 因子に限定し、死球の成績も追加する。

(1) データ概要：2014 年のプロ野球の打撃成績(規定打席以上)

(2) 変数：①本塁打　②打点　③三振　④死球

(3) モデル：4 つの成績に影響する構成概念として長打力という能力を仮定し、以下のモデルをリーグ間で比較する。

「⑤長打力 ＝ ①本塁打 ＋ ②打点 ＋ ③三振 ＋ ④死球」

【分析方法】

①モデルの分類：「多母集団(2 因子まで)」とする。

②グループ変数：2 つの母集団を指定する変数として「リーグ」を選択する。

③モデルの登録・修正

(1) 因子モデルに以下を指定

因子名：長打力

「長打力=本塁打＋打点＋三振＋死球」

(2) 各母集団の分散と平均の指定

母集団 1 の平均 fm11、母集団 2 の平均 fm21 は共に“0 に指定”。

母集団 1 の分散 fv11、母集団 2 の分散 fv21 は共に“1 に指定”。

(3) 切片で以下を指定

「本塁打＋打点＋三振＋死球」

(4) 誤差分散で以下を個別に指定

「本塁打＋打点＋三振＋死球」

④分析メニュー

非標準化解に指定。それ以外はそのまま。

【分析結果】

分析結果の要点とパス図(Figure 3.9)、非標準化係数(Table 3.11)は以下の通り。モデルの評価と結果の解釈は、他のモデルとの比較の上で最も適切と思われるモデルを選択の上行う。

χ^2=5.713　自由度=4　有意確率=0.222　n=31, n=27

CFI=0.982　TLI=0.947　RMSEA=0.122

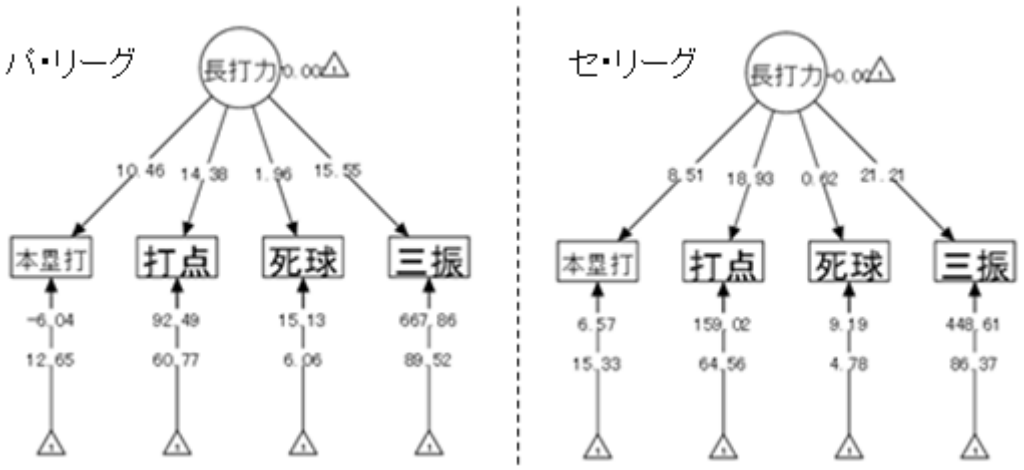

Figure 3.9　打撃成績の因子モデルをリーグ間比較したパス図

Table 3.11　打撃成績の因子モデルをリーグ間比較した非標準化係数
(因子である長打力の切片と分散は 1 に固定されるため省略)

	パ・リーグ					セ・リーグ				
		推定値	誤差	z値	有意確率		推定値	誤差	z値	有意確率
パス	本塁打	10.458	1.436	7.284	0.000	本塁打	8.513	1.397	6.093	0.000
	打点	14.376	2.690	5.345	0.000	打点	18.930	3.787	4.998	0.000
	三振	1.958	0.742	2.641	0.008	三振	0.623	0.610	1.021	0.307
	死球	15.552	5.099	3.050	0.002	死球	21.209	5.222	4.062	0.000
切片	本塁打	12.645	1.826	6.926	0.000	本塁打	15.333	1.711	8.962	0.000
	打点	60.774	3.106	19.564	0.000	打点	64.556	4.377	14.748	0.000
	三振	6.065	0.782	7.754	0.000	三振	4.778	0.596	8.021	0.000
	死球	89.516	5.417	16.524	0.000	死球	86.370	5.769	14.973	0.000
誤差	本塁打	-6.035	14.752	-6.035	0.058	本塁打	6.574	10.461	6.574	0.083
	打点	92.486	36.206	92.486	0.309	打点	159.022	66.940	159.022	0.307
	三振	15.128	3.843	15.128	0.798	三振	9.192	2.509	9.192	0.960
	死球	667.864	171.225	667.864	0.734	死球	448.615	138.146	448.615	0.499

7.2. 等値制約に関する他のモデル

【具体例】配置不変モデルで用いた 2014 年のプロ野球の打撃成績。

①弱測定不変モデル

複数の母集団間で因子負荷が同じ値になるように等値制約をしたモデル。潜在変数と観測変数間の関係を比較するではなく、その関係性は同じであるとして、潜在変数の平均値を比較することが可能となる。配置不変モデルと比較して対応する変数と因子間のパスを

それぞれイコールとする(具体的にはセ・リーグの本塁打とパ・リーグの本塁打をイコールとする)制約が加わる(STATWEB では配置の選択により自動で登録)。そのため、2 つ目の因子の分散の指定はしなくても良くなる。

【手順】以下の点を除いては、配置不変モデルの例と同じ。

(1) 母集団の平均と分散の指定

母集団 1 の平均 fm11、母集団 2 の平均 fm21 は共に“0 に指定”。

母集団 1 の分散 fv11 を“1 に指定“。

(配置不変モデルから母集団 2 の分散の指定を除去)

(2) 分析メニューの測定モデルの指定を“弱”に指定

②強測定不変

因子負荷だけでなく、観測変数の切片も等しくしたモデル。切片はその変数に対する外生変数の影響を除いた時の値であるので、その値も等しいと仮定した場合の因子間の平均を比較することができる。弱測定不変モデルと比較して、対応する切片の係数(具体的にはセ・リーグとパ・リーグの本塁打の切片項)がイコールであるという制約が加わる。そのため、2 つ目の因子の平均を指定しなくても良くなる。

【手順】以下の点を除いては、配置不変モデルの例と同じ。

(1) 母集団の平均と分散の指定

母集団 1 の平均 fm11 を“0 に指定”。

母集団 1 の分散 fv11 を“1 に指定“。

(弱測定不変モデルから母集団 2 の平均の指定を除去)

(2) 分析メニューの測定モデルの指定を“強”に指定

③厳密測定不変

因子負荷、観測変数の切片に加え、観測変数の誤差分散も等しいと考えるモデル。異なる母集団であっても、因子構造が同じであれば誤差も違いがないと仮定することも可能であり、このような場合の因子間の平均を比較することができる。

【手順】以下の点を除いては、配置不変モデルの例と同じ。

(1) 母集団の平均と分散の指定

母集団 1 の平均 fm11 を“0 に指定”。

母集団 1 の分散 fv11 を“1 に指定”。

(2) 分析メニューの測定モデルの指定を“厳密”に指定

④全母数等しいモデル

厳密測定不変モデルの制約に加え、因子の平均も等しいと仮定するモデル。このモデルでは異なる母集団間で因子に違いがないことを確認できる。

【手順】以下の点を除いては、配置不変モデルの例と同じ。

(1) 母集団の平均と分散の指定

母集団 1 の分散 fv11 を“1 に指定”。

(強測定不変モデル・厳密測定不変モデルから母集団 1 の平均の指定を除去)

(2) 分析メニューの測定モデルの指定を“全母数”に指定

【分析結果】

各パターンにおける適合度の指標をまとめると Table 3.12 のようになる。

Table 3.12　1 因子の多母集団因子分析における各モデルの比較結果

モデル	χ2値	自由度	有意確率	CFI	TLI	AIC	BIC	SABIC	RMSEA
配置不変	5.713	4	0.222	0.982	0.947	1756.855	1806.306	1730.846	0.122
弱	11.17	7	0.131	0.957	0.927	1756.312	1799.682	1733.554	0.143
強	15.545	10	0.113	0.943	0.932	1754.688	1791.776	1735.181	0.138
厳密	24.072	14	0.045	0.897	0.911	1755.215	1784.061	1740.043	0.158
全母数	25.494	15	0.044	0.892	0.914	1754.636	1781.422	1740.548	0.155

【結果の解釈】

各モデルを比較すると、以下のようにまとめられる。

χ^2 検定：配置不変、弱、強の 3 つのモデルは有意ではない

CFI　　：配置不変と弱の 2 モデルで適合度良

AIC　　：強＜全母数＜厳密＜弱＜配置不変 の順

BIC　　：全母数＜厳密＜強＜弱＜配置不変 の順

SABIC　：配置不変＜弱＜強＜厳密＜全母数 の順

RMSEA：全てにおいて適合度は悪い

総合的に判断して、ここでは配置不変モデルを選択する。この場合、両リーグ間で因子構造はある程度共通するが、その間の関係性は多少異なると考えられる。

配置不変モデルから結果の解釈を行うと、推定値の有意差検定ではセ・リーグの「長打力→三振」の関係のみ有意ではなく、この点が両リーグの因子構造での違いと解釈できる。三振との関係性が認められないということは、セ・リーグの方が、三振かホームランかという勝負がパ・リーグより少ないと言えるかもしれない。

8. 縦断データ分析

多母集団分析では異なる 2 つの母集団の比較を行えるが、縦断的データ分析では、同一の調査対象を時系列的に異なる時点で調査し比較することが行える。例えばあるクラスのデータを 1 年後にも測定し、時間経過による変化を比較する場合がこれにあたる。平均共分散構造分析同様、非標準化解を確認すること。

8.1. 配置不変モデル

【具体例】サッカー日本代表の前監督 A と現監督 B に対する評価

(1) データ概要：日本代表サポーター50 名に、以下の項目の調査を 5 段階評価で行った(仮想データ）。回答者は同一なため、縦断データに該当する。

(2) 変数：①人選 A(前監督 A の選手選考に対する評価)
②戦術 A(前監督 A の戦術に対する評価)
③内容 A(前監督 A の試合内容に対する評価)
④対応 A(前監督 A のマスコミ対応などの評価)
⑤人選 B(現監督 B の選手選考に対する評価)
⑥戦術 B(現監督 B の戦術に対する評価)
⑦内容 B(現監督 B の試合内容に対する評価)
⑧対応 B(現監督 B のマスコミ対応などの評価)

(3) モデル：以下のモデルを、前監督と現監督間で比較する。
「監督の総合的能力 ＝ 人選 ＋ 戦術 ＋ 内容 ＋ 対応」

【データベース作成】
縦断データ分析を行う際には、Table 3.13 のような分散共分散行列を作成し、これをデータベースとすること。また、行列の下に各変数の標本平均を加えること。

Table 3.13　サッカー日本代表監督に対する評価の分散共分散行列

項目	人選A	戦術A	内容A	対応A	人選B	戦術B	内容B	対応B
人選A	0.690	0.214	0.062	0.048	−0.166	0.212	0.028	0.032
戦術A	0.214	1.052	−0.321	−0.041	−0.088	−0.163	0.055	0.041
内容A	0.062	−0.321	1.168	0.066	−0.041	−0.038	−0.186	−0.146
対応A	0.048	−0.041	0.066	0.430	−0.101	−0.098	0.062	−0.010
人選B	−0.166	−0.088	−0.041	−0.101	1.052	0.277	0.055	0.021
戦術B	0.212	−0.163	−0.038	−0.098	0.277	1.006	0.070	0.138
内容B	0.028	0.055	−0.186	0.062	0.055	0.070	0.654	0.018
対応B	0.032	0.041	−0.146	−0.010	0.021	0.138	0.018	0.750
標本平均	3.300	3.220	2.460	3.640	3.220	3.560	2.840	3.360
標準偏差	0.831	1.025	1.081	0.656	1.025	1.003	0.809	0.866

【分析方法】

①モデルのパターン：「縦断データ分析」とする。

②縦断データの抽出

(1) サンプルサイズ：データのサンプルサイズを指定する。今回は 50 と入力。

(2) 行番号(a：b)：分散共分散データの行の先頭と最後を指定する。今回 1：8 と入力。

(3) 平均値の行番号：標本平均の行を指定する。今回は 9 と入力。

③因子モデルに以下の 2 つを指定

因子名：監督 A

「監督 A =人選 A＋戦術 A＋内容 A＋対応 A」

因子名：監督 B

「監督 B =人選 B＋戦術 B＋内容 B＋対応 B」

④切片の指定

「監督 A」：平均の制約を“0 に制約する”

「監督 B」：平均の制約を“0 に制約する”

「人選 A＋戦術 A＋内容 A＋対応 A」

「人選 B＋戦術 B＋内容 B＋対応 B」

⑤共分散

「監督 A←→1*監督 A」：相関／分散を“1 に指定”

「監督 B←→1*監督 B」：相関／分散を“1 に指定”

「監督 A←→監督 B」

「人選 A←→人選 B」

「戦術 A←→戦術 B」

「内容 A←→内容 B」

「対応 A←→対応 B」

⑥誤差分散

「人選 A＋戦術 A＋内容 A＋対応 A」: “個別に指定”

「人選 B＋戦術 B＋内容 B＋対応 B」: “個別に指定”

⑦分析メニュー

非標準化解に指定。それ以外はそのまま。

【分析結果】

①モデル全体の評価

分析結果の要点は以下の通り。モデルの評価と結果の解釈は、他のモデルとの比較の上で最も適切と思われるモデルを選択のうえ行う。

χ^2=10.189　自由度=15　有意確率=0.808　n=50

CFI=1.000　　TLI=2.472　　RMSEA=0.000

8.2. 等値制約に関する他のモデル

各モデルの分析時において、配置不変モデルと手順の異なる点を以下にまとめる(分析メニューの配置は省略)。

①弱測定不変モデル

(1) 因子モデルに以下の 2 つを指定

因子名：監督 A

「監督 A =人選 A＋戦術 A＋内容 A＋対応 A」分散の指定しない、ラベル付きする

因子名：監督 B

「監督 B =人選 B＋戦術 B＋内容 B＋対応 B」分散の指定しない、ラベル付きする

(配置不変モデルから、因子モデルの指定時に“ラベルをつける”に変更)

(2) 共分散の指定

「監督 B←→監督 B」: 相関／分散指定しない、ラベル付きしない

(配置不変モデルから、共分散の指定時に「監督 B」の分散を“指定しない”に変更)

②強測定不変

(1) 切片の指定

「人選 A と人選 B」: 平均の制約はしない、ラベル付きする

「戦術 A と戦術 B」: 平均の制約はしない、ラベル付きする

「内容 A と内容 B」: 平均の制約はしない、ラベル付きする

「対応 A と対応 B」: 平均の制約はしない、ラベル付きする

(弱モデルから、縦断データで対応する観測変数同士をペアにして切片の指定時に“ラベルをつける”に変更)

③厳密測定不変

(1) 誤差分散の指定

「人選 A＋戦術 A＋内容 A＋対応 A」: 個別に指定、ラベル付きする

「人選 B＋戦術 B＋内容 B＋対応 B」: 個別に指定、ラベル付きする

(強モデルから、誤差分散の指定のラベル付きを変更。縦断データで対応する観測変数同士に同じラベルがつくように、選択する順番を一緒にする。)

④全母数等しいモデル

(1) 共分散の指定

「監督 B←→1*監督 B」: 相関／分散 1 に指定する、ラベル付きしない

(厳密測定不変モデルから、共分散の指定時に「監督 B」の分散を“1 に指定する”に変更)

【分析結果】

各パターンにおける適合度の指標をまとめると Table 3.14 のようになる。

Table 3.14　2 因子の多母集団因子分析における各モデルの比較結果

モデル	χ2値	自由度	有意確率	CFI	TLI	AIC	BIC	SABIC	RMSEA
配置不変	10.189	15	0.808	1.000	2.472	1078.024	1133.472	1042.446	0.000
弱	15.657	18	0.616	1.000	1.597	1077.492	1127.205	1045.595	0.000
強	24.950	22	0.299	0.517	0.385	1078.785	1120.829	1051.795	0.052
厳密	36.298	26	0.086	0.000	−0.817	1082.133	1116.550	1060.051	0.089
全母数	36.377	27	0.107	0.000	−0.594	1080.212	1112.717	1059.356	0.083

【結果の解釈】

各モデルを比較すると、以下のようにまとめられる。

χ^2 検定：いずれのモデルも有意ではない

CFI　　：配置不変と弱の 2 モデルの適合度は良い

AIC　　：弱＜配置不変＜強＜全母数＜厳密、の順

BIC　　：全母数＜厳密＜強＜弱＜配置不変、の順

SABIC　：配置不変＜弱＜強＜全母数＜厳密、の順

RMSEA：全てにおいて適合度は悪い

CFI で良い適合度を示す配置不変モデルと弱測定不変モデルのうち、情報量基準の 2 つで値の低い弱測定不変モデルを採用する。このことから、前監督と現監督で因子構造は同じだが、潜在変数の平均値は異なるといえる。弱測定不変モデルにおけるパス図(Figure 3.10)と非標準化係数(Table 3.15)を以下に示す。前監督 A の能力の平均値が 1.00 に対し、現監督 B は 0.927 で下回っていることがわかる。

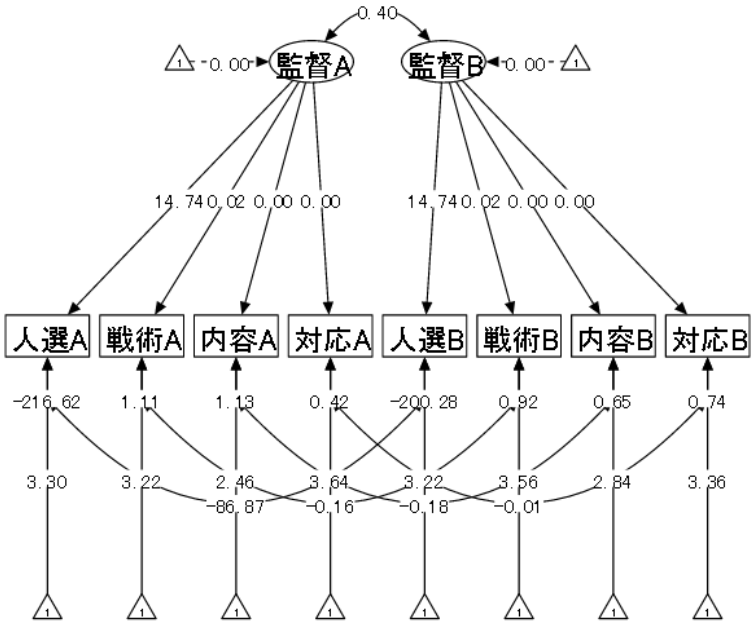

Figure 3.10　弱測定不変モデルによる監督の能力評価のパス図

Table 3.15　弱測定不変モデルによる監督の能力評価の非標準化解

		監督A				監督B		
		推定値	誤差	z値		推定値	誤差	z値
パス	人選	14.740	14.740	18.277	人選	14.740	14.190	13.667
	戦術	0.017	0.017	0.016	戦術	0.017	0.017	0.017
	内容	0.005	0.005	0.005	内容	0.005	0.005	0.006
	対応	0.001	0.001	0.002	対応	0.001	0.001	0.001
共分散	監督	0.399	0.415	0.415				
	人選	−86.869	−86.869					
	戦術	−0.162	−0.162	−0.160				
	内容	−0.181	−0.181	−0.211				
	対応	−0.009	−0.009	−0.016				
切片	監督	0.000			監督	0.000		
	人選	3.300	3.300	4.092	人選	3.220	3.220	3.101
	戦術	3.220	3.220	3.061	戦術	3.560	3.560	3.705
	内容	2.460	2.460	2.319	内容	2.840	2.840	3.517
	対応	3.640	3.640	5.610	対応	3.360	3.360	3.914
誤差	監督	1.000	1.000	1.000	監督	0.927	1.000	1.000
	人選	−216.622	−216.622	−333.063	人選	−200.280	−200.280	−185.787
	戦術	1.107	1.107	1.000	戦術	0.923	0.923	1.000
	内容	1.126	1.126	1.000	内容	0.652	0.652	1.000
	対応	0.421	0.421	1.000	対応	0.737	0.737	1.000

【著者略歴】

飯田成敏

早稲田大学文学学術院　非常勤講師

文教大学、白鴎大学、桜美林大学、健康科学大学で非常勤講師を歴任。

専門分野は実験心理学、学習心理学、行動分析学、動物心理学。

大学では心理統計法、心理情報処理などの科目でデータ解析や統計手法の講義を担当。

【分析に用いたソフトウェア】

クラウド型統計分析ソフトウェア　STATWEB　Advanced

http：//www.statweb.jp/

共分散構造分析

2016 年 5 月 1 日 初版第 1 刷

著者　飯田成敏

発行者　伊藤嘉朗

発行所　株式会社データサイエンス研究所

〒162-0824 東京都千代田区平河町 2-5-5　全国旅館会館 3F

Tel　03-3265-3908　Fax 03-3221-3904

http://datascience.co.jp　info@datascience.co.jp

本書内容の一部、全体を問わず、株式会社データサイエンス研究所の文書による承諾なく引用複製することを禁じます。