

IBM® SPSS® Amos™ 28  
ユーザーズ ガイド

*James L. Arbuckle*



**注：**本書の情報およびサポートされる製品を使用する前に、「通達」に記載されている情報をご一読ください。

新しいエディションに特に記載がない限り、本エディションは IBM® SPSS® Amos™ 28 および以降のすべてのリリースおよび改訂版に適用されます。

Microsoft 製品のスクリーンショットは Microsoft Corporation からの許可を得て複製されています。

ライセンス資料の所有権 - IBM に帰属

© Copyright IBM Corp. 1983, 2021. 米国政府の規制付き権利 - 使用、複製、開示には、IBM との「GSA ADP Schedule Contract」で定められた規制が適用されます。

© Copyright 2021 Amos Development Corporation. All Rights Reserved.

AMOS は、Amos Development Corporation 社の商標です。

---

# 目次

主要な方法	2
チュートリアルについて	3
例について	3
ドキュメントについて	4
その他の情報源	4
謝辞	5
概要	7
データについて	8
Amos Graphics の起動	9
新しいモデルの作成	10
データ ファイルの指定	11
モデルの指定と変数の描画	11
変数の命名	12
矢印の描画	13
パラメータの制約	13
パス図の表示の変更	14
オブジェクトを移動するには	14
オブジェクトや双方向矢印の形を変更するには	14
オブジェクトを削除するには	15
動作を元に戻すには	15
動作をやり直すには	15
オプション出力の設定	15
分析の実行	17
出力の表示	17
テキスト出力を表示するには	17
グラフィックス出力を表示するには	19
パス図の印刷	20
パス図のコピー	20
テキスト出力のコピー	20

概要	21
データについて	21
データの取り込み	22
データの分析	23
モデルを指定する	23
変数に名前を付ける	24
フォントの変更	25
共分散の設定	25
分析の実行	26
グラフィック出力を表示する	26
テキスト出力の表示	27
オプション出力	30
標準化推定値の計算	30
分析の再実行	31
相関推定値のテキスト出力としての表示	31
Amos モデルの分布の仮定	32
VB.NET でのモデル作成	33
追加出力の生成	35
C# によるモデリング	36
その他のプログラム開発ツール	36
概要	37
データについて	37
パラメータ制約条件	37
分散の制約	38
等しいパラメータの指定	39
共分散の制約	39
オブジェクトの移動と書式設定	40
データの入力	41
分析の実行	42
テキスト出力の表示	42
オプション出力	43
分散共分散行列推定値	44
共分散および分散推定値のパス図への表示	46
出力のラベル付け	46
仮説の検定	47
パス図へのカイ2乗統計量の表示	48



VB.NET でモデルを作成する	50
タイミングがすべて	52
概要	53
データについて	53
データの取り込み	53
2つの変数に相関がないという仮説の検定	54
モデルを指定する	54
テキスト出力の表示	56
グラフィック出力の表示	57
VB.NET でのモデル作成	59
概要	61
データについて	61
データの分析	62
モデルを指定する	63
特定	64
係数を固定する	64
テキスト出力を表示する	65
グラフィック出力を表示する	67
その他のテキスト出力を表示する	68
VB.NET でモデルを作成する	70
外生変数間の相関に関する仮定	71
AStructure メソッドの式形式	72
概要	73
データについて	73
モデル A	74
測定モデル	75
構造モデル	75
特定	76
モデルを指定する	76
描画領域の方向を変更する	76
パス図を作成する	77
指標を回転する	78
測定モデルを複製する	78
変数名を入力する	80
構造モデルを完成する	80

モデル A の結果	80
グラフィック出力を表示する	82
モデル B	83
モデル B の結果	84
モデル A に対するモデル B の検定	86
VB.NET でのモデル作成	88
モデル A	88
モデル B	89
概要	91
データについて	91
Wheaton データ用のモデル A	92
モデルの特定化	93
特定	93
分析の結果	94
棄却の処理	94
修正指数	95
Wheaton データ用のモデル B	97
テキスト出力	97
モデル B のグラフィック出力	99
修正指数の誤用	100
新しい制約の追加によってモデルを改良する	100
Wheaton データ用のモデル C	104
モデル C の結果	104
Model C の検定	105
モデル C のパラメータ推定値	105
単一分析での複数モデルの使用	106
複数モデルによる出力	109
個々のモデルのグラフィック出力を表示する	109
4 つのモデルすべての適合度の統計を表示する	109
オプション出力を取得する	110
間接効果、直接効果、総合効果を取得する	112
VB.NET でのモデル作成	113
モデル A	113
モデル B	114
モデル C	115
複数のモデルを適合する	116
概要	119

データについて . . . . .	119
Felson と Bohrnstedt のモデル . . . . .	120
モデルの特定 . . . . .	121
分析の結果 . . . . .	121
テキスト出力 . . . . .	121
標準化推定値を取得する . . . . .	122
重相関係数の平方を取得する . . . . .	123
グラフィック出力 . . . . .	123
安定指数 . . . . .	124
VB.NET でのモデル作成 . . . . .	125
概要 . . . . .	127
データについて . . . . .	127
共通因子モデル . . . . .	128
特定 . . . . .	129
モデルを指定する . . . . .	130
モデルを作成する . . . . .	130
分析の結果 . . . . .	131
標準化推定値を取得する . . . . .	132
標準化推定値を表示する . . . . .	133
VB.NET でのモデル作成 . . . . .	134
概要 . . . . .	135
共分散分析とその代替分析 . . . . .	135
データについて . . . . .	136
共分散分析 . . . . .	137
Olsson データ用のモデル A . . . . .	137
特定 . . . . .	138
モデル A を指定する . . . . .	138
モデル A の結果 . . . . .	138
より適切なモデルを探す . . . . .	139
修正指数を要求する . . . . .	139
Olsson データ用のモデル B . . . . .	140
モデル B の結果 . . . . .	141
Olsson データ用のモデル C . . . . .	142
モデル C のパス図を作成する . . . . .	143
モデル C の結果 . . . . .	143
すべてのモデルを一度に適合する . . . . .	143

VB.NET でのモデル作成	144
モデル A	144
モデル B	144
モデル C	145
複数のモデルを適合する	145
概要	147
複数グループの分析	147
データについて	147
モデル A	148
グループの相違を指定するための規則	148
モデル A を指定する	149
テキスト出力	152
グラフィック出力	153
モデル B	154
テキスト出力	156
グラフィック出力	156
VB.NET でのモデル作成	157
モデル A	157
モデル B	158
複数モデルの入力	159
概要	161
Felson と Bohrnstedt のモデル	161
データについて	161
女子生徒と男子生徒用のモデル A を指定する	162
図のキャプションを指定する	162
モデル A のテキスト出力	164
モデル A のグラフィック出力	166
パラメータの差に対する検定統計量を取得する	166
女子生徒と男子生徒のモデル B	167
モデル B の結果	169
テキスト出力	169
グラフィックス出力	170
モデル A と B を単一の分析に適合する	171
女子生徒と男子生徒のモデル C	171
モデル C の結果	175

VB.NET でのモデル作成 . . . . .	176
モデル A . . . . .	176
モデル B . . . . .	177
モデル C . . . . .	177
複数のモデルを適合する . . . . .	178
概要 . . . . .	179
データについて . . . . .	179
Holzinger と Swineford の少年少女のモデル A . . . . .	180
グループに名前を付ける . . . . .	180
データの指定 . . . . .	181
モデル A の結果 . . . . .	182
テキスト出力 . . . . .	182
グラフィック出力 . . . . .	182
Holzinger と Swineford の少年少女のモデル B . . . . .	183
モデル B の結果 . . . . .	185
テキスト出力 . . . . .	185
グラフィック出力 . . . . .	185
VB.NET でのモデル作成 . . . . .	188
モデル A . . . . .	188
モデル B . . . . .	189
概要 . . . . .	191
平均値と切片のモデル作成 . . . . .	191
データについて . . . . .	191
若者および老人の被験者のモデル A . . . . .	192
Amos Graphics の平均構造モデル . . . . .	192
モデル A の結果 . . . . .	194
テキスト出力 . . . . .	194
グラフィック出力 . . . . .	196
若者および老人の被験者のモデル B . . . . .	196
モデル B の結果 . . . . .	197
モデル B とモデル A との比較 . . . . .	198
複数のモデル入力 . . . . .	198
VB.NET での平均構造モデル作成 . . . . .	199
モデル A . . . . .	199
モデル B . . . . .	200
複数のモデルを適合する . . . . .	201

概要	203
Amos が行う仮定	203
データについて	203
モデルを指定する	204
分析の結果	205
テキスト出力	205
グラフィック出力	206
VB.NET でのモデル作成	207
概要	209
因子平均	209
データについて	210
少年と少女のモデル A	210
モデルを指定する	210
グループ間の制約条件について	212
モデル A の結果	212
テキスト出力	212
グラフィック出力	213
少年と少女のモデル B	215
モデル B の結果	217
モデル A およびモデル B の比較	217
VB.NET でのモデル作成	218
モデル A	218
モデル B	219
複数のモデルの当てはめ	220
概要	221
前提条件	221
データについて	222
デフォルトの動作の変更	223
モデル A	224
モデルを指定する	224
モデル A の結果	225
テキスト出力	225
モデル B	227
モデル B の結果	229
モデル C	230
モデル C の結果	230

モデル D	232
モデル D の結果	233
モデル E	235
モデル E の結果	235
モデル A からモデル E を単一の分析で当てはめる	235
Sörbom の方法と例 9 の方法の比較	235
モデル X	236
Amos Graphics のモデル作成	236
モデル X の結果	237
モデル Y	237
モデル Y の結果	238
モデル Z	240
モデル Z の結果	241
VB.NET でのモデル作成	242
モデル A	242
モデル B	243
モデル C	244
モデル D	245
モデル E	246
複数のモデルを適合する	247
モデル X、モデル Y、モデル Z	247
概要	249
不完全なデータ	249
データについて	250
モデルを指定する	251
飽和モデルおよび独立モデル	252
分析の結果	252
テキスト出力	252
グラフィック出力	254
VB.NET でのモデル作成	255
因子モデルの適合 (モデル A)	255
飽和モデルの適合 (モデル B)	256
尤度比カイ 2 乗統計量とその p 値の計算	259
単一プログラムでの全手順の実行	260
概要	261
欠損データ	261

データについて	262
モデル A	263
モデル A の	結果 264
グラフィックス出力	264
テキスト出力	265
モデル B	267
モデル A およびモデル B からの出力	268
VB.NET でのモデル作成	269
モデル A	269
モデル B	270
概要	271
ブートストラップ法	271
データについて	272
因子分析モデル	272
ブートストラップの進行状況の監視	273
分析の結果	273
VB.NET でのモデル作成	276
概要	277
モデル比較におけるブートストラップ手法	277
データについて	278
5 つのモデル	278
テキスト出力	282
要約	284
VB.NET でのモデル作成	284
概要	285
推定方法	285
データについて	285
モデルについて	286
テキスト出力	288
VB.NET でのモデル作成	291
概要	293
データについて	293
モデルについて	293



オプション矢印が少数の探索的モデル特定化	294
モデルの特定化	294
プログラムのオプションの選択	296
探索的モデル特定化の実行	297
生成されたモデルの表示	298
モデルのパラメータ推定値の表示	299
BCC を使用したモデル比較	299
赤池ウェイトの表示	300
BIC を使用したモデル比較	302
Bayes 因子を使用したモデル比較	303
Bayes 因子の再調整	305
モデルの短いリストについての調査	306
適合度と複雑度についての散布図の表示	307
定数の適合度を表す線の調整	309
定数 C-df を表す線の表示	310
定数 C-df を表す線の調整	311
定数の適合度を表すその他の線の表示	312
C における最善の適合グラフの表示	312
その他の適合度に対する最善の適合グラフの表示	314
C のスクリープロットの表示	315
その他の適合度に対するスクリープロットの表示	316
オプション矢印が多数の探索的モデル特定化	318
モデルの特定化	319
矢印のオプション指定	319
オプション設定のデフォルトへのリセット	320
探索的モデル特定化の実行	320
BIC を使用したモデル比較	321
スクリープロットの表示	322
制限	322
概要	323
データについて	323
モデルについて	323
モデルの特定化	324
[ 探索的モデル特定化 ] ウィンドウを開く	324
すべての係数のオプション指定	325
オプション設定のデフォルトへのリセット	325
探索的モデル特定化の実行	327

BCC を使用したモデル比較	327
スクリープロットの表示	331
モデルの短いリストの表示	331
発見的な探索的モデル特定化	332
ステップワイズ検索の実行	333
スクリープロットの表示	334
発見的な探索的モデル特定化における制限	335
概要	337
データについて	337
モデル 24a: 平均値と切片項を使用しないモデル作成	337
モデルの特定化	338
[複数グループの分析] ダイアログ ボックスを開く	338
パラメータ部分集合の表示	340
生成されたモデルの表示	341
すべてのモデルの適合と、出力の表示	342
分析のカスタマイズ	343
モデル 24b: 因子の平均値の比較	343
モデルの特定化	343
制約条件の削除	344
グループ間制約の生成	345
モデルの適合	346
出力の表示	346
概要	349
データについて	349
モデルについて	350
モデルの特定化	350
潜在変数の平均値と切片項の制限	350
グループ間制約の生成	351
モデルの適合	352
テキスト出力を表示する	353
修正指数の調査	354
モデルの変更と分析の繰り返し	355
概要	357

ベイズ推定 . . . . .	357
事前分布の選択 . . . . .	358
Amos Graphics によるベイズ推定の実行 . . . . .	359
共分散の推定 . . . . .	359
最尤法解析の結果 . . . . .	360
ベイズ解析 . . . . .	361
ベイズ解析とデータ代入の結果の複製 . . . . .	362
現行シードの調査 . . . . .	363
現行シードの変更 . . . . .	363
リフレッシュ オプションの変更 . . . . .	366
収束の評価 . . . . .	366
診断の作図 . . . . .	368
2 変量相関の周辺事後分布図 . . . . .	373
ベイズの信頼区間 . . . . .	375
信頼係数の変更 . . . . .	375
ベイズ推定に関する参考資料 . . . . .	376
概要 . . . . .	377
例について . . . . .	377
ベイズ推定についてのその他の情報 . . . . .	377
ベイズ解析と不適解 . . . . .	378
データについて . . . . .	378
最尤法によるモデルの適合 . . . . .	379
無情報 ( 拡散 ) 事前分布によるベイズ推定 . . . . .	379
バーンイン オブザベーション数の変更 . . . . .	380
概要 . . . . .	389
例について . . . . .	389
Wheaton のデータの再考 . . . . .	390
間接効果 . . . . .	390
間接効果の推定 . . . . .	390
モデル C のベイズ解析 . . . . .	394
追加推定値 . . . . .	395
間接効果に関する推論 . . . . .	397
概要 . . . . .	403
例について . . . . .	403
疎外感モデルの安定性 . . . . .	403

数値カスタム推定値 . . . . .	409
ドラッグアンドドロップ . . . . .	412
二値カスタム推定値 . . . . .	420
二値推定値の定義 . . . . .	421
概要 . . . . .	425
例について . . . . .	425
多重代入 . . . . .	426
モデルベースの代入 . . . . .	426
Amos Graphics を使用した多重データ代入の実行 . . . . .	426
概要 . . . . .	433
SPSS Statistics を使用した代入データ ファイルの分析 . . . . .	433
手順 2: 10 個の個別分析 . . . . .	434
手順 3: 多重代入データ ファイルの結果の結合 . . . . .	435
参考文献 . . . . .	436
概要 . . . . .	437
データについて . . . . .	437
データの再コード化 . . . . .	439
データの分析 . . . . .	440
回帰分析の実行 . . . . .	440
事後予測分布 . . . . .	443
代入 . . . . .	446
データ値に対する一般的な不等式制約 . . . . .	449
概要 . . . . .	451
データについて . . . . .	451
データ ファイルの指定 . . . . .	453
Amos 内でのデータの再コード化 . . . . .	454
モデルの特定化 . . . . .	463
モデルの適合 . . . . .	463
MCMC 診断 . . . . .	466
事後予測分布 . . . . .	468
潜在変数の事後予測分布 . . . . .	472
代入 . . . . .	476
概要 . . . . .	481
データについて . . . . .	482
分析の実行 . . . . .	484
データ ファイルの指定 . . . . .	485

モデルの特定化 . . . . .	489
モデルの適合 . . . . .	491
個々のクラスの分類 . . . . .	493
潜在構造分析 . . . . .	494
概要 . . . . .	495
データについて . . . . .	495
分析の実行 . . . . .	496
データ ファイルの指定 . . . . .	498
モデルの特定化 . . . . .	500
パラメータの制約 . . . . .	501
モデルの適合 . . . . .	503
個々のクラスの分類 . . . . .	506
潜在構造分析 . . . . .	507
ラベルスイッチング . . . . .	508
概要 . . . . .	511
データについて . . . . .	511
1つ目のデータセット . . . . .	511
2つ目のデータセット . . . . .	513
データセットのグループ変数 . . . . .	514
分析の実行 . . . . .	515
データ ファイルの指定 . . . . .	516
モデルの特定化 . . . . .	518
モデルの適合 . . . . .	520
個々のクラスの分類 . . . . .	523
パラメータ推定値の向上 . . . . .	524
グループ比率の事前分布 . . . . .	526
ラベルスイッチング . . . . .	526
はじめに . . . . .	527
データについて . . . . .	528
共通因子モデル . . . . .	528
モデルを指定するプラグインの作成 . . . . .	528
元に戻す機能の制御 . . . . .	532
プラグインのコンパイルと保存 . . . . .	534
プラグインの使用方法 . . . . .	536

モデル指定以外のその他の分析機能	537
モデル変数に対応するプログラム変数の定義	537
はじめに	539
Wheaton のデータの再考	540
間接効果の推定	540
パラメータに名前を付けない間接効果の推定	548
はじめに	551
データについて	551
Markov モデル	551
儉約性の測度	564
NPAR	564
DF	564
PRATIO	565
最小標本乖離度	565
CMIN	565
P	565
CMIN/DF	566
FMIN	567
母集団の乖離度に基づく測度	567
NCP	568
F0	568
RMSEA	569
PCLOSE	570
情報理論的測度	570
AIC	570
BCC	571
BIC	571
CAIC	571
ECVI	572
MECVI	572
ベースライン モデルとの比較	573
NFI	573
RFI	574
IFI	575
TLI	575
CFI	575

儉約性修正済み測度 . . . . .	576
PNFI . . . . .	576
PCFI . . . . .	576
GFI および関連測度 . . . . .	577
GFI . . . . .	577
AGFI . . . . .	577
PGFI . . . . .	578
その他の測度 . . . . .	578
HI 90 . . . . .	578
HOELTER . . . . .	578
LO 90 . . . . .	579
RMR . . . . .	579
選択された適合度のリスト . . . . .	580
ゼロ ベースの再調整 . . . . .	589
赤池ウェイト / Bayes 因子 (合計 = 1) . . . . .	590
赤池ウェイト / Bayes 因子 (max = 1) . . . . .	591

<b>通達</b>	<b>593</b>
-----------	------------

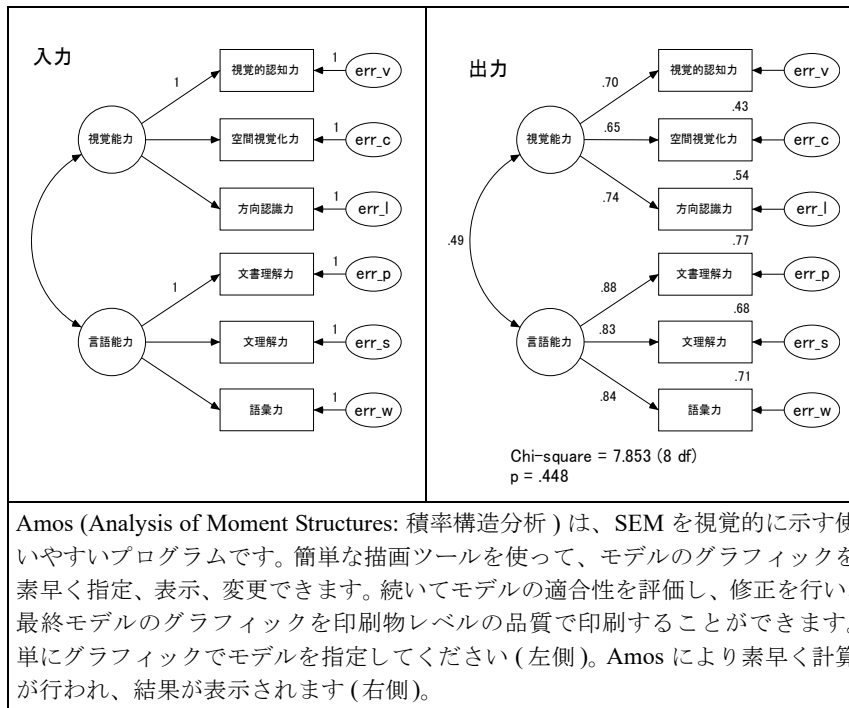
<b>参考文献</b>	<b>597</b>
-------------	------------





# 概要

IBM® SPSS® Amos™ は、構造方程式モデリング (SEM) または共分散構造分析や因子モデリングとも呼ばれる一般的なデータ分析手法を備えています。この手法には、特別なケースとして、一般線型モデルや共通因子分析など広く行われている従来の方法が含まれています。



構造方程式モデリング (SEM) はしばしば、難解で習得して使用するのが難しいと考えられています。これは大きな間違いです。実際、データ分析で SEM の重要性が増しているのは、使いやすさによるところが大きいのです。以前は統計の専門家が必要だった推定や仮説の検定に関する問題が、SEM によって専門家でなくても処理できるようになってきました。

Amos はもともと、強力で基本的には単純なこの方法を教授するためのツールとして設計されました。このため、この方法の使いやすさを示すことに力が注がれています。Amos は、使いやすいグラフィカル インターフェイスに SEM 用の高度な計算エンジンを統合させています。印刷物レベルの品質を持つ Amos のパス図は、学生や同僚の研究者に対してモデルを明確に示します。Amos に備わっている数値化方法は、最も効果的で信頼性の高い方法です。

## 主要な方法

構造方程式モデルを推定するために、Amos には以下の方法が備わっています。

- 最尤法
- 重み付けのない最小 2 乗法
- 一般化した最小 2 乗法
- Browne の漸近的分布非依存法
- 尺度不変最小 2 乗法
- ベイジアン推定

欠損データがある場合、Amos は、リストごとやペアごとの削除や中間補完のようなアドホックな方法に頼るのではなく、全情報の最尤を使った最新の方法によって推定を実行します。プログラムは、複数の母集団のデータを一度に分析することができます。また、回帰方程式で外因性の変数と切片の平均を推定することができます。

プログラムは、ブーストラップ標準誤差と信頼区間を全てのパラメータ推定、有効推定、標本平均、分散、共分散、および相関で使用可能にします。また、百分位数の区間と偏位修正された百分位数の区間 (Stine, 1989)、およびモデル検定に対するブーストラップ手法 (Bollen - Stine, 1992) も備えています。

1 つの分析で複数のモデルが適合することがあります。Amos はモデルのペアごとに、他のパラメータに制限を加えることによって 1 つのモデルを取得します。プログラムは、こうしたモデルの比較に適したいくつかの統計をレポートします。プログラムは、観測される各変数に対する変量の正規分布の検定と多変量の正規分布の検定を備え、外れ値の検出を試みます。

Amos はパス図をモデル仕様として受け入れ、パラメータ推定値をパス図にグラフィックで表示します。モデル仕様に使われるパス図やパラメータ推定値を表示するパス図は、プレゼンテーション レベルの品質です。直接印刷することもできますし、ワープロや DTP プログラム、汎用のグラフィック プログラムなどのアプリケーションにインポートすることもできます。

## チュートリアルについて

チュートリアルは、Amos Graphics を起動して実行できるように設計されています。基本的な機能をカバーしてあり、初めての Amos 分析をガイドします。

チュートリアルをひと通り実行したら、より高度な機能についてはオンラインヘルプで知ることができます。あるいは、用意されている例を引き続き実行して、Amos を使った構造モデリングについてさらに学ぶことができます。

## 例について

多くの人は、実際に操作しながら学びたいと思っています。これを踏まえて、Amos の使用方法を実践的に示す多数の例を用意しました。最初の数例では、単一の問題に対応できる Amos の基本機能を紹介します。どのボタンをクリックするのか、サポートされている各種データ形式にどうやってアクセスするのか、出力をどのように操作するのか、といったことを学びます。その後の例では、プログラム インターフェイスの問題よりも、モデリングの問題を詳しく扱います。

例1から例4では、従来の分析、つまり標準的な統計パッケージを使って実行できる分析を Amos を使って行う方法を示します。これらの例では、よくある問題に対して新しい手法を示しながら、Amos の基本機能を網羅しています。平均や相関を推定するとか、2つの平均が同じであるという仮説を検定するといった単純なことを行うのにも、Amos を使うと便利な場合があります。理由の1つとして、Amos の欠損データ処理機能を使用できるということが挙げられます。あるいは、Amos のブートストラップ機能は、特に信頼区間を取得するのに役立ちます。

例5から例8は、今日の構造モデリングで一般的に使われている基本的な方法を示します。

例9以降は、利用価値がありながら現時点ではまだそれほど使用されていない高度な方法を示します。こうした方法として、たとえば以下のものがあります。

- 複数の母集団のデータの同時分析。
- 回帰方程式における平均値と切片項の推定。
- 欠損データがある場合の最尤推定。
- 標準誤差の推定値を取得するためのブートストラップ。Amos ではこれらの方法を特に使いやすくしていますので、より普及することが期待されます。
- 探索的モデル特定化。
- ベイジアン推定。
- 欠損値の代入。
- 打ち切りデータの分析。
- 順序-カテゴリカルデータの分析。
- 混在モデル。

ヒント: Amos の特定の機能について質問がある場合はいつでも、プログラムで提供している広範なオンライン ヘルプを参照できます。

## ドキュメントについて

Amos 28 には、広範なドキュメントが付属しています。オンライン ヘルプ、ユーザーズガイド (本書)、および Visual Basic または C# と Amos API (Application Programming Interface) の詳細な参考資料などがあります。標準的なインストールを実行する場合は、%amosprogram%\Documentation\Programming Reference.pdf ファイルにある『Amos 24 Programming Reference Guide』を参考にしてください。

## その他の情報源

このユーザーズ ガイドには有益な解説が記載されていますが、構造モデリングの正しく効果的な使い方の完全なガイドブックというわけではありません。多くの優れた SEM 解説文書が入手可能です。

- 『Structural Equation Modeling: A Multidisciplinary Journal』には、構造モデリングの方法論的な記事および適用例が記載されています。発行元は Taylor and Francis (<http://www.tandf.co.uk>) です。
- Carl Ferguson と Edward Rigdon は、Semnet という電子メーリング リストを設定し、構造モデリングに関連する議論のフォーラムを提供しています。Semnet 購読に関する情報は、[www.gsu.edu/~mkteer/semnet.html](http://www.gsu.edu/~mkteer/semnet.html) で得られます。

## 謝辞

Amos の以前のバージョンと現行のバージョンをテストした多くのユーザーの皆様からいろいろなフィードバックをいただきました。Torsten B. Neilands は、Joseph L. Schafer の協力の元、本ユーザーガイドの例 26 から 31 までを記述しました。Eric Loken は例 32 および 33 をレビューしました。彼はまた Amos の今後の開発における重要な提案と同様に混在するモデルに対する貴重な考察を提供してくださいました。

1 つ注意点があります。Amos Development Corporation と SPSS は広範なプログラム検定を行い、Amos が正しく動作することを確認していますが、Amos を含む全ての複雑なソフトウェアには、未検出のバグが含まれる可能性があります。我々は、プログラム エラーの修正に努力しています。エラーを発見した場合は、SPSS テクニカル サポート スタッフまでお知らせください。

James L. Arbuckle

日本語訳監修：井上哲浩

(慶應義塾大学大学院経営管理研究科教授)



# チュートリアル : Amos Graphics のスタートアップガイド

## 概要

初めて統計の授業を受けたとき、苦勞して公式を覚え、紙と鉛筆で一生懸命計算して答を出しましたね。教授の指示に従ってそうするうちに、基本的な統計の概念を理解するようになったことでしょう。後に、こうした計算は全て、計算機やソフトウェアプログラムであつという間にできてしまうことを知りましたね。

このチュートリアルは、統計の入門クラスにやや似ています。Amos Graphics には、パス図を描いてラベルを付けるための効率的な方法が多数ありますが、このユーザーズガイドの例をたどっていくか、オンラインヘルプを参照するうちに、それらが見つかるでしょう。このチュートリアルの目的は、単に Amos Graphics の初歩的な使い方を示すことです。Amos の基本的な機能をカバーしてあり、初めての Amos 分析をガイドします。

チュートリアルをひと通り実行したら、より高度な機能についてはオンラインヘルプで知ることができます。あるいは、用意されている例を引き続き実行して、順序よく学ぶこともできます。

このチュートリアルで作成するパス図は、%amostutorial%\Startsps.amw ファイルにあります。このファイルは、SPSS Statistics データファイルを使用しています。同じパス図が %amostutorial%\Getstart.amw にあり、Microsoft Excel ファイルのデータを使用しています。

**ヒント** : Amos には、メニューから多くの同じタスクを実行するツールバーボタンとキーボードのショートカットがあります。このユーザーガイドでは、メニューの使用に重きが置かれています。ツールバーボタンとキーボードのショートカットの使用の詳細については、オンラインヘルプを参照してください。

## データについて

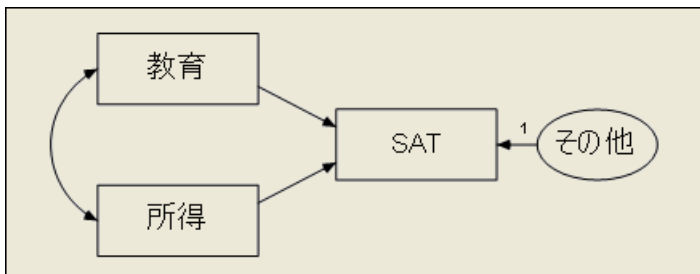
Hamilton (1990) は、21 州のそれぞれについて、いくつかの測定を行いました。このチュートリアルでは、以下の 3 つの測定を使用します。

- SAT の平均得点
- 1 人当たりの所得 (単位は \$1,000)
- 25 才以上の居住者の教育の中央値

これらのデータは、Tutorial ディレクトリの Excel 8.0 ワークブック Hamilton.xls 内の Hamilton というワークシートにあります。データは以下のとおりです。

SAT	所得	教育
899	14.345	12.7
896	16.37	12.6
897	13.537	12.5
889	12.552	12.5
823	11.441	12.2
857	12.757	12.7
860	11.799	12.4
890	10.683	12.5
889	14.112	12.5
888	14.573	12.6
925	13.144	12.6
869	15.281	12.5
896	14.121	12.5
827	10.758	12.2
908	11.583	12.7
885	12.343	12.4
887	12.729	12.3
790	10.075	12.1
868	12.636	12.4
904	10.689	12.6
888	13.065	12.4

次のパス図は、これらのデータのモデルを示しています。





これは単純な回帰モデルで、観測される 1 つの変数 SAT は、観測される他の 2 つの変数 "教育" と "所得" の線型結合と予測されます。ほぼ全ての経験データから、この予測は完全ではありません。変数 "その他" は、変数 "教育" と "所得" 以外で SAT に影響する変数を表します。

片方向の各矢印は、回帰係数を表わします。図の 1 という数字は、SAT の予測で "その他" の係数が 1 であることを指定します。モデルを識別するために、こうした制約をいくつか設ける必要があります。これは、Amos に認識させる必要のあるモデルの特徴の 1 つです。

## Amos Graphics の起動

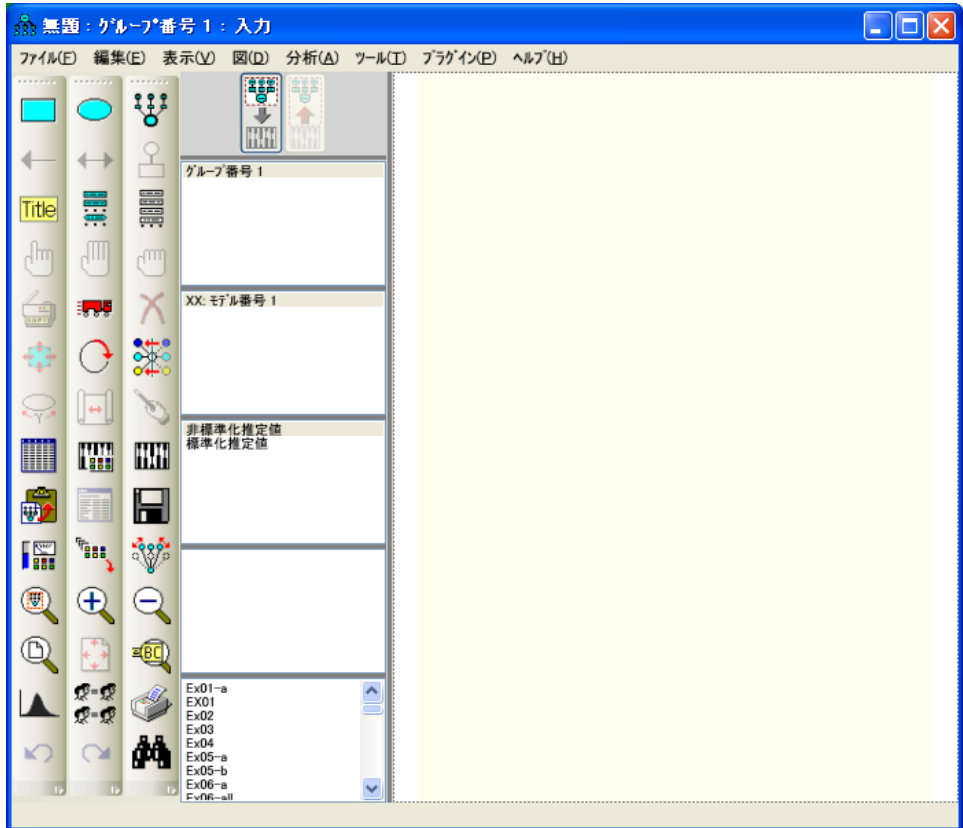
Amos Graphics は、以下のいずれの方法でも起動できます。

- Windows の [ スタート ] メニューを開いて、IBM SPSS Amos 28 Graphics を検索します。
- Windows のエクスプローラでパス図 (\*.amw) をダブルクリックします。
- Windows のエクスプローラからパス図 (\*.amw) を [Amos Graphics] ウィンドウにドラッグします。
- SPSS Statistics 内で、メニューから [Add-ons] → [Applications] → [Amos 23] の順にクリックします。

## 新しいモデルの作成

- ▶ メニューから、[ファイル]→[新規作成]の順にクリックします。

作業領域が表示されます。右側の大きな領域は、パス図を描く場所です。左側のツールバーは、よく使用されるボタンに1度のクリックでアクセスできるように用意されています。ツールバーかメニュー コマンドを使って、ほとんどの操作を行うことができます。



## データ ファイルの指定

次のステップは、Hamilton のデータが保存されているファイルを指定することです。このチュートリアルでは Microsoft Excel 8.0 (\*.xls) ファイルを使いますが、Amos では、SPSS Statistics \*.sav ファイルなどいくつかの一般的なデータベース形式をサポートしています。SPSS Statistics の [Add-ons] メニューから Amos を起動する場合、SPSS Statistics で開いているファイルが自動的に使用されます。


- ▶ メニューから、[ファイル]→[データ ファイル]の順にクリックします。
- ▶ [データ ファイル]ダイアログで、[ファイル名]をクリックします。
- ▶ [開く]ダイアログで、ファイル名「%tutorial%hamilton.xls」を入力し、[開く]ボタンをクリックします。
- ▶ [データファイル]ダイアログで、[OK]をクリックします。

## モデルの指定と変数の描画

次のステップは、モデルに変数を描くことです。観測される変数を表す 3 つの長方形をまず描き、続いて観測されない変数を表す 1 つの楕円形を描きます。

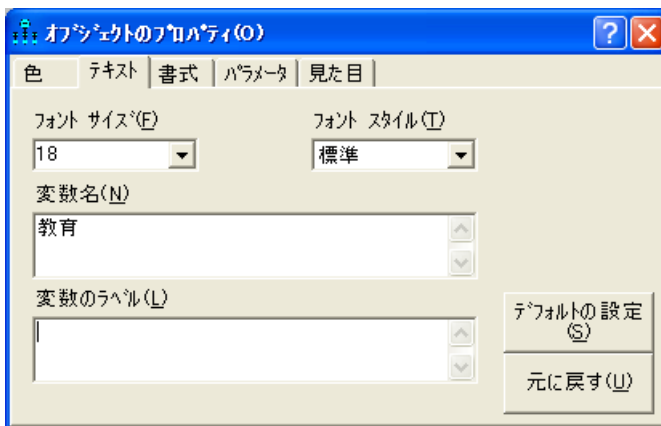
- ▶ メニューから、[図]→[観測される変数を描く]の順にクリックします。
- ▶ 描画領域で、"教育" の長方形を表示する場所にマウス ポインタを移動します。クリックアンドドラッグして長方形を描きます。長方形の位置やサイズは後で変更できるので、正確でなくてもかまいません。
- ▶ 同じ方法で、"所得" と SAT 用に 2 つの長方形を描きます。
- ▶ メニューから、[図]→[直接観測されない変数を描く]の順にクリックします。
- ▶ 描画領域で、3 つのの長方形の右にマウス ポインタを移動してクリックし、ドラッグして楕円を作成します。

描画領域内のモデルは、次のようになるはずで




## 変数の命名

- ▶ 描画領域で左上の長方形を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [テキスト] タブをクリックします。
- ▶ [変数名] テキスト ボックスに、「教育」と入力します。




- ▶ 同じ方法を使って、残りの変数に名前を付けます。[オブジェクト プロパティ] ダイアログ ボックスを閉じます。

パス図は次のように描かれているはずです。



## 矢印の描画

次の図のモデルを参考にして、パス図に矢印を加えます。

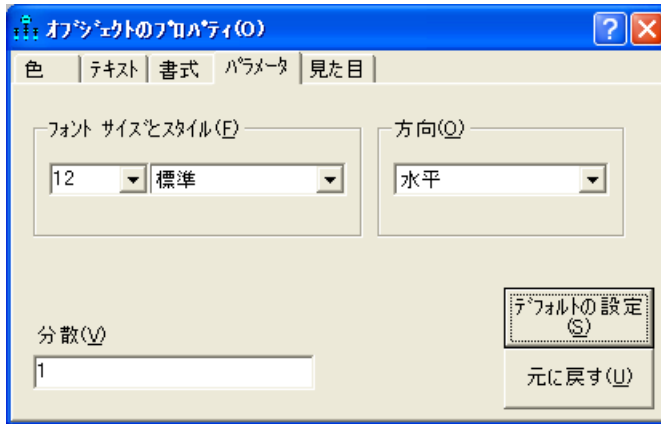


- ▶ メニューから、[図]→[パス図を描く]の順にクリックします。
- ▶ クリック アンド ドラッグして、"教育" と SAT の間に矢印を描きます。
- ▶ この方法を使って、残りの片方向矢印を描きます。
- ▶ メニューから、[図]→[共分散を描く]の順にクリックします。
- ▶ クリック アンド ドラッグして、"所得" と "教育" の間に双方向矢印を描きます。矢印のカーブは後で調整できるので、正確でなくてもかまいません。

## パラメータの制約

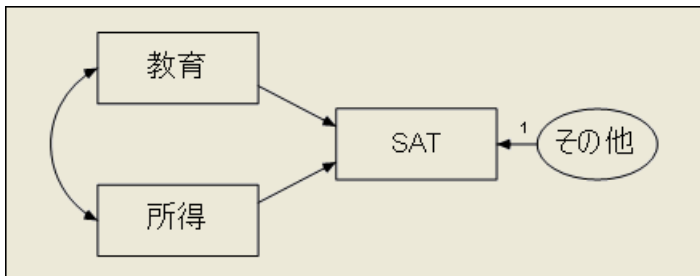
回帰モデルを識別するには、潜在変数 "その他" のスケールを定義する必要があります。そのためには、"その他" の分散または "その他" から SAT へのパス定数を正の値で固定します。パス係数を 1 で固定する方法を次に示します。

- ▶ 描画領域で "その他" と SAT の間の矢印を右クリックし、ポップアップ メニューから [オブジェクトのプロパティ] を選択します。
- ▶ [パラメータ] タブをクリックします。
- ▶ [係数] テキスト ボックスに「1」と入力します。



- ▶ [オブジェクト プロパティ] ダイアログ ボックスを閉じます。

"その他" と SAT の間の矢印の上に 1 が表示されます。パス図が完成しましたが、必要に応じて表示を変更できます。次のように描かれているはずですが。



## パス図の表示の変更

パス図の表示を変更するには、オブジェクトの移動やサイズ変更を行います。こうした変更は単に視覚上の変更で、モデルの仕様には影響しません。

### オブジェクトを移動するには

- ▶ メニューから、[編集] → [移動] の順にクリックします。
- ▶ 描画領域で、オブジェクトをクリックして新しい位置にドラッグします。

### オブジェクトや双方向矢印の形を変更するには

- ▶ メニューから、[編集] → [オブジェクトの形を変更] の順にクリックします。
- ▶ 描画領域で、オブジェクトをクリックして希望のサイズと形になるようドラッグします。

## オブジェクトを削除するには

- ▶ メニューから、[編集]→[消去]の順にクリックします。
- ▶ 描画領域で、削除するオブジェクトをクリックします。

## 動作を元に戻すには

- ▶ メニューから、[編集]→[元に戻す]の順にクリックします。

## 動作をやり直すには

- ▶ メニューから、[編集]→[やり直し]の順にクリックします。

## オプション出力の設定

Amos には、オプションの出力がいくつかあります。このステップでは、分析後にどのオプション出力部分を表示するかを選択します。

- ▶ メニューから、[表示]→[分析のプロパティ]の順にクリックします。
- ▶ [出力] タブをクリックします。
- ▶ [最小化履歴]、[標準化推定値]、および[重相関係数の平方]の各チェックボックスをオンにします。



- ▶ [分析のプロパティ] ダイアログ ボックスを閉じます。




## 分析の実行

残っている作業は、モデル適合の計算を実行することだけです。パラメータ推定値を最新に保つには、モデル、データ、または [分析のプロパティ] ダイアログ ボックスのオプションを変更するたびにこの作業を行う必要があります。

- ▶ メニューから、[分析] → [推定値を計算] の順にクリックします。
- ▶ まだファイルを保存していないので、[名前を付けて保存] ダイアログ ボックスが表示されます。ファイルの名前を入力して [保存] をクリックします。

モデル推定値が計算されます。パス図の左側にあるパネルに計算の結果が表示されます。



## 出力の表示

計算が完了したら、出力を表示するオプションとして、テキストとグラフィックスの2つがあります。

### テキスト出力を表示するには


- ▶ メニューから、[表示] → [テキスト出力の表示] の順にクリックします。

[Amos 出力] ウィンドウの左上ウィンドウ枠のツリー図で、表示するテキスト出力部分を選択します。

- ▶ パラメータ推定値を表示するには、[推定値]をクリックします。

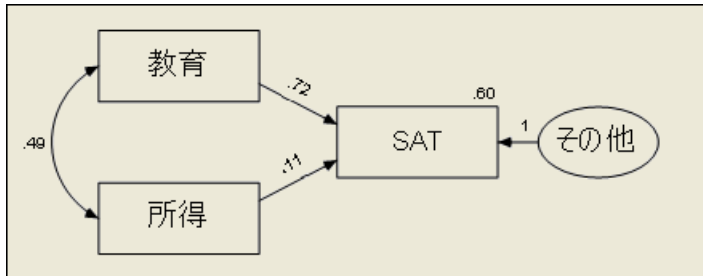
<b>係数: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
SAT <--- Income	2.156	3.125	.690	.490	
SAT <--- Educatn	136.022	30.555	4.452	***	
<b>標準化係数: (Group number 1 - Default model)</b>					
	推定値				
SAT <--- Income	.111				
SAT <--- Educatn	.717				
<b>共分散: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
Income <--> Educatn	.127	.065	1.952	.051	
<b>相関係数: (Group number 1 - Default model)</b>					
	推定値				
Income <--> Educatn	.485				
<b>分散: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
Income	2.562	.810	3.162	.002	
Educatn	.027	.008	3.162	.002	
Other	382.736	121.032	3.162	.002	
<b>重相関係数の平方: (Group number 1 - Default model)</b>					
	推定値				
SAT	.603				

## グラフィックス出力を表示するには

- ▶ [出力パス図の表示] ボタン  をクリックします。
- ▶ 描画領域の左にある [パラメータ形式] ウィンドウ枠で、[標準推定値] をクリックします。



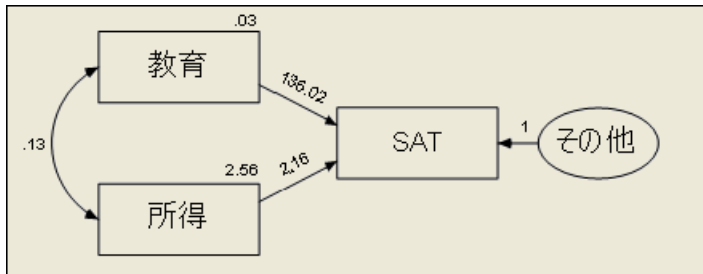
パス図は次のようになります。



0.49 という値は、「教育」と「所得」の間の相関を示します。値 0.72 と 0.11 は、標準化係数です。0.60 という値は、SAT と「教育」および「所得」の重相関係数の平方を示します。

- ▶ 描画領域の左にある [パラメータ形式] ウィンドウ枠で、[非標準化推定値] をクリックします。

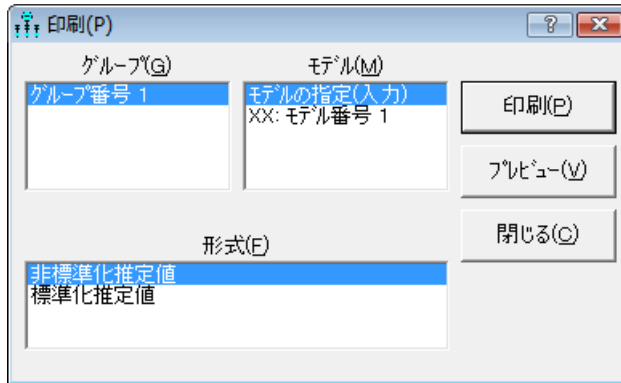
パス図は次のように描かれているはずです。



## パス図の印刷

- ▶ メニューから、[ファイル]→[印刷]の順にクリックします。

[印刷] ダイアログ ボックスが表示されます。



- ▶ [印刷] をクリックします。

## パス図のコピー

Amos Graphics では、Microsoft Word など他のアプリケーションにパス図を簡単にエクスポートすることができます。

- ▶ メニューから、[編集]→[クリップボードへコピー]の順にクリックします。
- ▶ 他のアプリケーションに切り替えて、貼り付け機能を使ってパス図を挿入します。Amos Graphics からエクスポートされるのは図のみで、背景はエクスポートされません。

## テキスト出力のコピー

- ▶ Amos Output ウィンドウで、コピーするテキストを選択します。
- ▶ 選択したテキストを右クリックし、ポップアップ メニューから[コピー]を選択します。
- ▶ 他のアプリケーションに切り替えて、貼り付け機能を使ってテキストを挿入します。

# 分散および共分散の推定

## 概要

この例では、母集団の分散と共分散を推定する方法について説明します。また、Amosの入力および出力の一般的な書式についても説明します。

## データについて

Attig (1983) は、40 人の被験者に数ページの広告を含む小冊子を示しました。次に、各被験者に対して、3 つの記憶力検定を実施しました。

変数	説明
記憶	被験者には、できるだけ多くの広告を思い出してもらいました。この変数での被験者のスコアは、正しく思い出せた広告の数としました。
ヒント	被験者にいくつかのヒントを与え、できるだけ多くの広告を思い出してもらいました。被験者のスコアは、正しく思い出せた広告の数としました。
掲載位置記憶	被験者に小冊子に掲載されていた広告のリストを与え、それぞれの広告の掲載ページを思い出してもらいました。この検定の被験者のスコアは、掲載位置を正しく思い出せた広告の数としました。


Attig は、記憶力を向上させるためのトレーニングを行った後で、再び同じ 40 名の被験者にこの検定を実施しました。したがって、トレーニングの前と後でそれぞれ 3 つの成績が測定されます。さらに、Attig は年齢、性別、教育水準に加えて、語彙試験のスコアも記録しました。Attig のデータファイルは、Amos に付属している Examples フォルダに入っています。

## データの取り込み

- ▶ メニューから、[ファイル]→[新規作成]を選択します。
- ▶ メニューから、[ファイル]→[データ ファイル]を選択します。
- ▶ [データファイル]ダイアログで、[ファイル名]をクリックします。
- ▶ [開く]ダイアログで、ファイル名「%examples%\UserGuide.xls」を入力し、[開く]ボタンをクリックします。
- ▶ [データ表を選択]ダイアログで、[Attg\_yng]を選択し、[データの表示]をクリックします。



Attg\_yng データ ファイルの Excel ワークシートが開きます。



被験者	年齢	語彙簡略	語彙得点	教育年数
1	20	13	63	14
2	34	12	64	14
3	19	10	59	13
4	25	14	79	18
5	18	4	47	12
6	18	12	66	12
7	18	5	51	12
8	18	5	57	12

ワークシートをスクロールすると、Attig の調査のすべての検定変数を参照できます。この例では、記憶 1 (事前記憶検定)、記憶 2 (事後記憶検定)、掲載位置記憶 1 (事前掲載位置記憶検定)、掲載位置記憶 2 (事後掲載位置記憶検定) の変数のみを使用しています。

- ▶ データを確認したら、データ ウィンドウを閉じます。
- ▶ [データ ファイル] ダイアログ ボックスで、[OK] をクリックします。

## データの分析


この例の分析では、トレーニング前後の記憶変数と掲載位置記憶変数の分散および共分散の推定を行います。

### モデルを指定する

- ▶ メニューから、[図] → [観測される変数を描く] を選択します。
- ▶ 描画領域で、四角形を最初に表示する場所にマウス ポインタを移動します。クリックアンドドラッグして長方形を描きます。
- ▶ メニューから、[編集] → [複製] を選択します。
- ▶ クリックし、最初の四角形から複製をドラッグします。マウス ボタンを離して、複製を配置します。

- ▶ 4つの四角形が並ぶまで、さらに2つの複製の四角形を作成します。

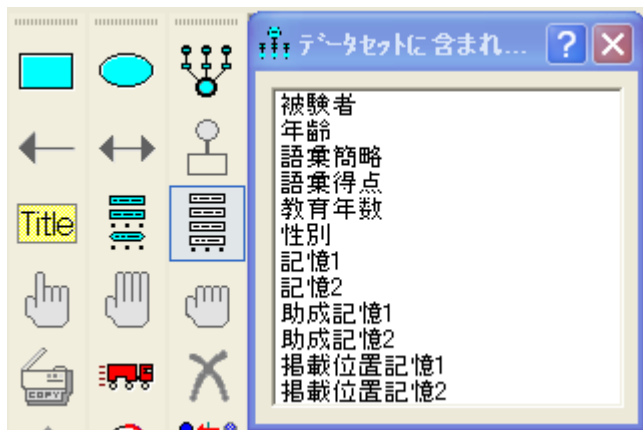
ヒント：四角形を移動する場合は、メニューから[編集]→[移動]を選択し、四角形を新しい位置にドラッグします。



## 変数に名前を付ける

- ▶ メニューから、[表示]→[データセットに含まれる変数]を選択します。

[データセットに含まれる変数]ダイアログボックスが表示されます。

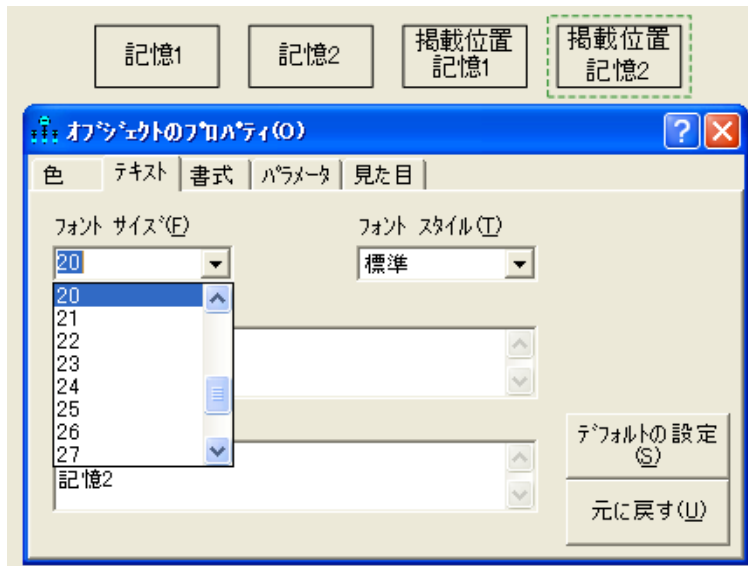


- ▶ リストから変数記憶1をクリックして、描画領域の最初の四角形にドラッグします。
- ▶ 同じ方法で、記憶2、掲載位置記憶1、掲載位置記憶2の各変数にも名前を付けます。
- ▶ [データセットに含まれる変数]ダイアログボックスを閉じます。



## フォントの変更

- ▶ 変数を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。  
[オブジェクトのプロパティ] ダイアログボックスが表示されます。
- ▶ [テキスト] タブをクリックし、希望に応じてフォント属性を調整します。

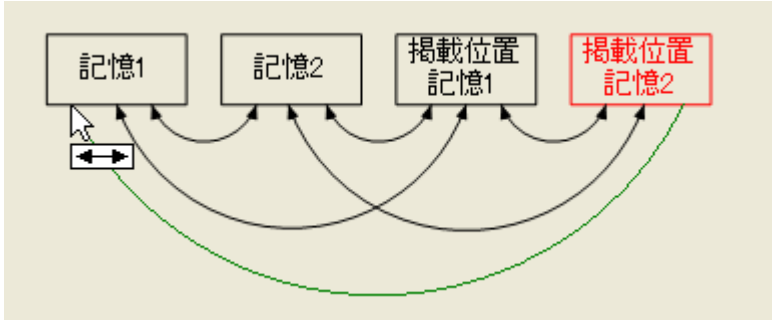


## 共分散の設定

パス図をそのままの状態にした場合、Amos Graphics は、4 つの変数の分散を推定しますが、変数間の共分散の推定は行われません。Amos Graphics では、矢印で結ばれていない 2 つの変数に対しては相関または共分散は 0 であると想定されます。観測変数間の共分散を推定するには、最初にすべてのペアを双方向の矢印で結ぶ必要があります。

- ▶ メニューから、[図] → [共分散を描く] を選択します。
- ▶ クリックし、ドラッグして、各変数と他の変数を結ぶ矢印を描画します。

パス図には 6 つの双方向矢印が描かれている必要があります。




## 分析の実行

- ▶ メニューから、[分析] → [推定値を計算] を選択します。


まだファイルを保存していないので、[名前を付けて保存] ダイアログ ボックスが表示されます。

- ▶ ファイルの名前を入力して、[保存] をクリックします。

## グラフィック出力を表示する

- ▶ [出力パス図の表示] ボタン  をクリックします。

出力パス図がパラメータ推定値と共に表示されます。



出力パス図で、ボックスの横に表示される数が分散推定値で、双方向矢印の横に表示される数が共分散推定値です。たとえば、記憶1の分散は 5.79 と推定され、掲載位置 記憶1 の分散は 33.58 と推定されます。この 2 つの変数間の共分散推定値は 4.34 です。

## テキスト出力の表示

- ▶ メニューから、[表示]→[テキスト出力の表示]の順にクリックします。
- ▶ [Amos出力]ウィンドウの左上のウィンドウ枠のツリー図で、[推定値]を選択します

Amos出力

EX01.amw

- \* 分析の要約
- \* グループについての注釈
- \* 変数の要約
- \* パラメータの要約
- \* モデルについての注釈
- \* **推定値**
- \* 最小化履歴
- \* モデル適合
- \* 実行時間

推定値 (グループ番号 1 - モデル番号 1)

スカラー推定値 (グループ番号 1 - モデル番号 1)

最尤(ML)推定値

共分散: (グループ番号 1 - モデル番号 1)

		推定値	標準誤差	検定統計量	確率	ラベル
記憶1	<--> 記憶2	2.556	1.160	2.203	.028	
記憶2	<--> 掲載位置記憶1	2.013	2.635	.764	.445	
掲載位置記憶1	<--> 掲載位置記憶2	17.904	5.225	3.427	***	
記憶2	<--> 掲載位置記憶2	.427	2.126	.201	.841	
記憶1	<--> 掲載位置記憶1	4.337	2.338	1.855	.064	
記憶1	<--> 掲載位置記憶2	3.575	1.902	1.880	.060	

分散: (グループ番号 1 - モデル番号 1)

	推定値	標準誤差	検定統計量	確率	ラベル
記憶1	5.787	1.311	4.416	***	
記憶2	7.944	1.799	4.416	***	
掲載位置記憶1	33.576	7.604	4.416	***	
掲載位置記憶2	22.159	5.018	4.416	***	

最初に表示されている推定値は、記憶1と記憶2間の共分散です。共分散は2.56と推定されています。その推定値の右横の、[標準誤差]列に、共分散の標準誤差の推定値、1.16が表示されています。推定値2.56は、母集団の共分散を中心に、約1.16の標準偏差でほぼ正規分散している乱数変数の観測値です。すなわち、セクション32ページの「Amosモデルの分布の仮定」の仮定が満たされている場合の値です。たとえば、これらの数値を使用して、 $2.56 \pm 1.96 \times 1.160 = 2.56 \pm 2.27$ を計算することによって、母集団共分散の95%の信頼区間を設定することができます。この後で、Amosを使用すると、共分散のほかにもさまざまな種類の母集団パラメータを推定できること、また、そのいずれの信頼区間でも同じ手順で設定できることを紹介します。

標準誤差の隣の [検定統計量] 列には、共分散推定値を標準誤差 ( $2.20 = 2.56 / 1.16$ ) で割って算出された検定統計量が表示されます。この検定統計量は、Attigの40名の被験者が属する母集団において記憶1と記憶2間の共分散が0であるという帰無仮説に関連しています。この仮説が真であり、依然として32ページの「Amosモデルの分布の仮定」セクションの仮定の下にある場合、検定統計量は、近似的に標準正規分布を持つ乱数変数の観測値を表します。したがって、0.05の有意確率を使用した場合、1.96より大きい検定統計量を有意であるといいます。この例では、2.20は1.96より大きいため、記憶1と記憶2の間の共分散は0.05レベルでは0と有意な差があると言えます。

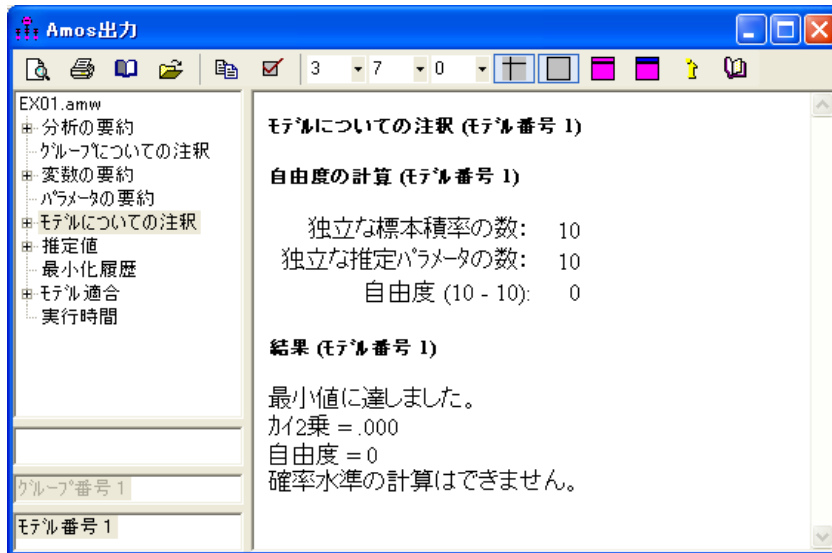
[検定統計量]の右の[P]列には、パラメータ値が母集団で0であるという帰無仮説を検定するための、両側近似p値が示されます。この表は、 $p = 0.03$ により、記憶1と記憶2間の共分散が0と有意の差があることを示しています。Pの計算では、パラメータ推定値が正規分散していると仮定していますが、これは大きな標本でのみ正しいことです。詳細については、付録Aを参照してください。

パラメータ推定値が正規分散しているという断定は、近似値に過ぎません。また、[標準誤差]列で報告されている標準誤差も近似値に過ぎず、最適でない場合があります。結果的に、今説明した信頼区間および仮説検定も近似値になります。これは、これらの結果の根拠となる理論が漸近的であるためです。漸近的とは、希望する任意の精度で適用することができるが、有意に大きな標本を使用した場合に限られることを意味します。Amosを使用して実行できるその他のさまざまな種類の分析に対して結論を一般化することはできないので、現在の標本数で近似値が満足できるものであるかどうかについては、検討しないことにします。ただし、記憶1と記憶2に相関がないという帰無仮説を再検討し、近似検定の意味するものを確認することはできます。先に、2.20は1.96よりも大きいため、共分散は0と有意の差があるという結論に達しました。2.20の標準正規分布に関連するp値は0.028(両側)であり、もちろん0.05より小さい値です。これに対して、従来のt統計量(Runyon & Haber, 1980, p. 226など)は自由度が38で2.509です( $p = 0.016$ )。この例では、どちらのp値も0.05未満であるため、どちらの検定でも0.05レベルでの帰無仮説を棄却する点では一致しています。ただし、この状況では、2つのp値は0.05の反対側にある可能性があります。この点は特に深刻にとらえる必要はありません。いずれにせよ、2つの検定では異なる結果になる可能性があるのですから。どちらの検定の方が優れているかについては疑いの余地があってはなりません。t検定は、標本数に関係なく、観測値の正規性および独立性の仮定に直接基づいています。Amosでは、検定統計量に基づく検定は同じ仮定に依存していますが、有限の標本では、検定は近似値になります。

**注:** Amosの多くのユニークな利用法では、正確確率検定、正確な標準誤差、または正確な信頼区間は使用できません。

明るい面を挙げれば、従来の推定値が存在するモデルの当てはめにおいて、最尤法のポイント推定値([推定値]列の数値など)は一般的に従来の推定値と同じです。

- ▶ ここで、[Amos出力] ウィンドウの左上のウィンドウ枠にある [モデルについての注釈] をクリックします。



次の表は、すべての Amos の分析において重要な役割を果たします。

異なる標本の積率の数	10
推定される異なるパラメータの数	10
自由度 (10 - 10)	0

[独立な標本積率の数]とは、標本の平均値、分散、および共分散です。現在の分析を含むほとんどの分析において、Amos では平均値が無視され、標本の積率は4つの変数(記憶1、記憶2、掲載位置記憶1、掲載位置記憶2)の標本分散および標本共分散となります。4つの標本分散および6つの標本共分散があるため、標本の積率の数は合計で10となります。

[独立な推定パラメータの数]は、対応する母集団の分散および共分散です。4つの母集団分散と6つの母集団共分散があるため、推定パラメータの数は10となります。

[自由度]は、標本の積率が推定パラメータの数よりも大きい数量です。この例では、標本の積率と推定パラメータ間に1対1対応があるため、自由度が0になるのは当然です。

例2で分かるように、パラメータに関する非明示的な帰無仮説では、推定する必要のあるパラメータの数が少なくなります。その結果、自由度は正の値になります。ここでは、検定する帰無仮説はありません。検定する帰無仮説がない場合、次の表はあまり意味がありません。

カイ2乗 = 0.00
自由度 = 0
確率水準の計算はできません。

この例で検定される仮説があった場合、カイ 2 乗値は、データが仮説と矛盾している度合いの測定値になっていました。カイ 2 乗値が 0 の場合、通常は、帰無仮説から逸脱していないことを示します。ただし、この例では、0 という自由度および 0 というカイ 2 乗値は、そもそも帰無仮説がなかったという事実を反映しているに過ぎません。

最小値に達しました

この行は、Amos が分散および共分散を正常に推定できたことを示しています。時には、Amos のような構造モデリング プログラムで推定値が検出されないことがあります。通常、Amos が失敗するのは、解がない、または一意の解がないという問題が生じた場合です。たとえば、線型に従属している観測変数を使用して最尤法の推定を実行しようとした場合、そのような分析は原理上実行できないため Amos は失敗します。一意の解がないという問題については、識別可能性のテーマでこのユーザーズガイドの別の場所で説明します。それほど多くはありませんが、推定の問題が難解過ぎて Amos が失敗することもあります。このような失敗の可能性は、積率構造の分析のプログラムでは一般的なことです。Amos で使用している計算方法は効率の良いものですが、Amos が実行する種類の分析をあらゆるケースで約束できるコンピュータプログラムはありません。

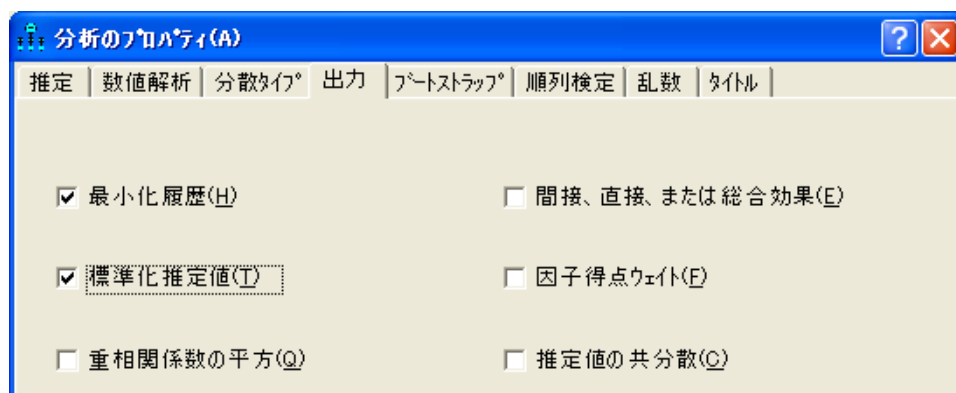
## オプション出力

これまで、Amos がデフォルトで生成する出力について説明してきました。追加の出力も要求できます。

### 標準化推定値の計算

Amos では相関ではなく共分散の推定値が表示されることを知ると、驚くかもしれません。測定尺度が任意であったり、実質的な関心がない場合、相関は共分散に比べて説明的な意味合いが強くなります。それでもなお、Amos や類似プログラムでは、共分散の推定を主張します。また、すぐに分かるように、Amos には共分散については仮説検定用の単純な方法が用意されていますが、相関についてはありません。これは主に、共分散の方がプログラムの記述が容易であるという理由によります。一方、関連する分散および共分散の推定が完了した後で、相関推定値を導き出すことは難しくありません。標準化推定値を計算するには、次の操作を行います。

- ▶ メニューから、[表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [標準化推定値] チェック ボックスをオンにします。




- ▶ [分析のプロパティ] ダイアログ ボックスを閉じます。

## 分析の再実行

[分析のプロパティ] ダイアログ ボックスでオプションを変更したため、分析を再実行する必要があります。

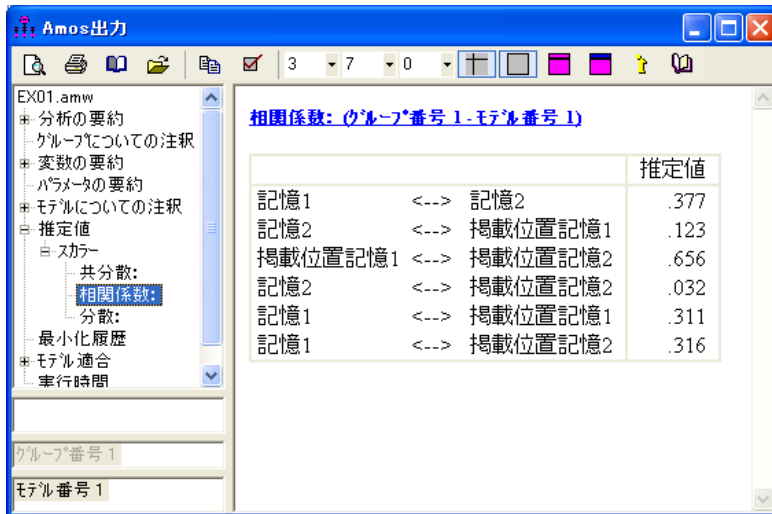
- ▶ メニューから、[モデル適合度] → [推定値を計算] を選択します。
- ▶ [出力パス図の表示] ボタンをクリックします。
- ▶ 描画領域の左の [パラメータ形式] ウィンドウ枠で、[標準化推定値] をクリックします。



## 相関推定値のテキスト出力としての表示

- ▶ メニューから、[表示] → [テキスト出力の表示] を選択します。

- ▶ [Amos出力] ウィンドウの左上のウィンドウ枠のツリー図で、[推定値]、[スカラー] を選択し、[相関係数] をクリックします



## Amos モデルの分布の仮定

仮説の検定手順、信頼区間、および最尤法推定または一般化最小 2 乗法推定における効率性の要求は、特定の仮定に依存します。第一に、観測値は独立している必要があります。たとえば、Attig の調査の 40 名の若い被験者は、若者という母集団から独立して選択する必要があります。次に、観測変数は特定の分布の要件を満たす必要があります。観測変数に多変量の正規分散がある場合は、それで十分です。すべての観測変数の多変量正規性は、多数の構造方程式モデリングおよび因子分析アプリケーションにおける標準分布の仮定です。

最尤法推定を実行できる、別のより一般的な状況があります。一部の外生変数が固定されている場合（すなわち、事前に判明しているか、誤差なしで測定されている場合）、その分布は以下の条件で、任意の形状になります。

- 固定変数の値パターンの場合、残りの (乱数) 変数は (条件付き) 正規分布となります。
- 乱数変数の (条件付き) 分散-共分散行列は、固定変数のすべてのパターンに対して同じです。
- 乱数変数の (条件付き) 期待度数は、固定変数の値に線型に依存します。

固定変数の代表的な例には、回答者をそれぞれ実験群と統制群に分類する試験的な治療があります。その他の外生変数が調査ケースと対照ケースと同様に正規分布し、条件付き分散共分散行列が同じである限り、治療は非正規分布であっても構いません。回帰分析における予測変数 (例 4 を参照) は、広く固定変数とも呼ばれます。



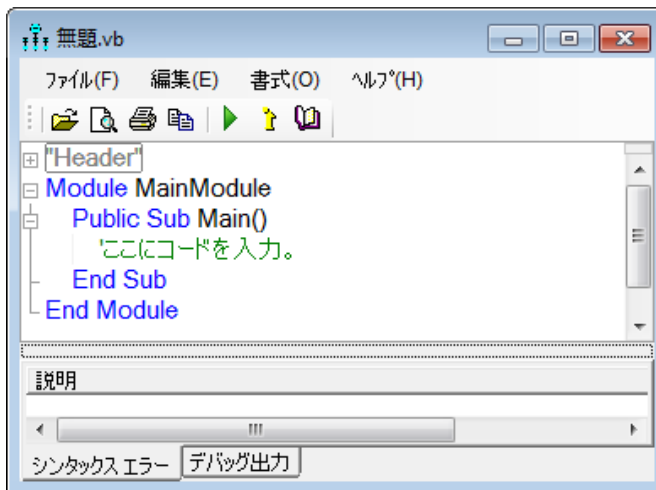
正規性と独立性の観測要件は多数の従来の手順では通例の要件であるため、多くの人がこれらの要件には慣れていません。ただし、Amosを使用する場合は、これらの要件を満たしていても、漸近結論（すなわち、大型の標本で近似的に真である結論）につながるだけであることに留意する必要があります。

## VB.NET でのモデル作成


VB.NET または C# でプログラムを記述することによってモデルを指定し、当てはめることができます。プログラムの記述は、Amos Graphics による、パス図を描画したモデルの指定に代わるものです。このセクションでは、VB.NET プログラムを記述して例1の分析を実行する方法について説明します。後のセクションでは、同じことを C# で行う方法について説明します。

Amos には、VB.NET プログラムおよび C# プログラム用の独自の組み込みエディタが付随しています。このエディタには Windows の [スタート] メニューからアクセスできます。例1で組み込みエディタを使用するには

- ▶ Windows の [スタート] メニューを開いて、IBM SPSS Amos 28 Program Editor を検索します。
- ▶ [Program Editor] ウィンドウから、[ファイル] → [新規 VB プログラム] を選択します。



- ▶ 「Your code goes here」というコメントの代わりに、モデルを指定し当てはめるための VB.NET コードを入力します。次の図は、プログラムを完全に入力した後のプログラムエディタを示しています。



```
C:\Program Files\IBM\SPSS\Amos\24\Examples\Japanese\Ex01.vb
ファイル(F)  編集(E)  書式(O)  ヘルプ(H)
[Icons]
[Header]
[Module MainModule]
  ' Example 1
  ' Estimating variances and covariances
  '
  ' Attig (1983) young subjects
  '
  Sub Main()
    Using Sem As New AmosEngine
      Sem.TextOutput()

      Sem.BeginGroup(AmosEngine.AmosDir & "Examples\Japanese\UserGuide.xls", "Attg_yng")
      Sem.AStructure("記憶1")
      Sem.AStructure("記憶2")
      Sem.AStructure("掲載位置記憶1")
      Sem.AStructure("掲載位置記憶2")
      Sem.FitModel()
    End Using
  End Sub
End Module
説明 | ライン
シNTAXエラー | デバッグ出力
```

注：%examples%ディレクトリには事前に記述済みのすべての例が格納されています。

この例の VB.NET ファイルを開くには

- ▶ [Program Editor] ウィンドウから、[ファイル]→[開く]を選択します。
- ▶ [開く]ダイアログで、ファイル名「%examples%\Ex01.vb」を入力し、[開く]ボタンをクリックします。

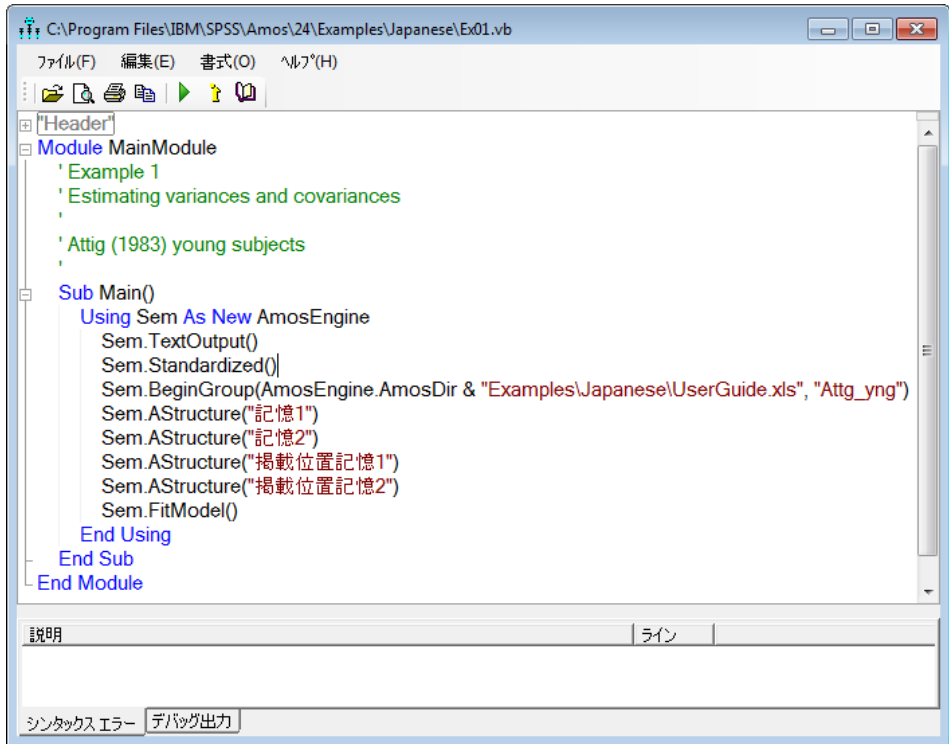
次の表には、プログラムの 1 行ごとの説明が示されています。

プログラムのステートメント	説明
Dim Sem As New AmosEngine	Sem を AmosEngine 型のオブジェクトとして宣言しています。Sem オブジェクトのメソッドとプロパティは、モデルを指定し当てはめるために使用されます。
Sem.TextOutput	分析の結果を格納する出力ファイルを作成します。分析が終わると、出力ファイルの内容が別のウィンドウに表示されます。
Sem.BeginGroup ...	単一のグループ (すなわち単一の母集団) のモデルの指定を開始します。この行は、Excel ワークブック UserGuide.xls 内の Attg_yng ワークシートに入力データが格納されていることも指定しています。Sem.AmosDir() は、Amos プログラムディレクトリの場所です。
Sem.AStructure("recall1") Sem.AStructure("recall2") Sem.AStructure("place1") Sem.AStructure("place2")	モデルを指定します。4 つの AStructure ステートメントは、記憶 1、記憶 2、掲載位置記憶 1 および掲載位置記憶 2 の分散をフリーパラメータとして宣言します。Attg_yng データファイルのその他の 8 個の変数は、この分析では除外されます。Amos プログラムでは (Amos Graphics とは異なり)、4 つの変数間で 6 つの共分散を推定できるように、観測外生変数はデフォルトで相関があるものと仮定されます。
Sem.FitModel()	モデルを当てはめます。
Sem.Dispose()	Sem オブジェクトによって使用されたりリソースを解放します。プログラムで、別の AmosEngine オブジェクトを作成する前に AmosEngine オブジェクトの Dispose メソッドを使用することは特に重要です。プロセスでは、1 度に 1 つの AmosEngine オブジェクトのインスタンスしか許可されません。
Try/Finally/End Try	Try ブロックは、プログラムの実行中にエラーが発生した場合でも、Dispose メソッドが呼び出されることを保証します。

- ▶ 分析を実行するには、メニューから [ファイル] → [実行] を選択します。

## 追加出力の生成

一部の AmosEngine メソッドでは追加出力が生成されます。たとえば、Standardized メソッドは標準化推定値を表示します。次の図は、Standardized メソッドの使用を示しています。



## C# によるモデリング

C# での Amos プログラムの記述も、VB.NET の場合と同様です。Amos の組み込みプログラム エディタで新しい C# プログラムを開始するには

- ▶ [ファイル]→[新規 C# プログラム] を選択します ([ファイル]→[新規 VB プログラム] の代わりに)。
- ▶ [ファイル]→[開く] を選択して Ex01.cs を開きます。これは、Ex01.vb の VB.NET プログラムの C# バージョンです。

## その他のプログラム開発ツール

Amos の組み込みプログラム エディタは、このユーザーズ ガイド全体で Amos プログラムの記述および実行のために使用されています。ただし、自分で選んだ開発ツールを使用することもできます。Examples フォルダには、VisualStudio サブフォルダがあり、例 1 用の Visual Studio VB.NET および C# ソリューションが収録されています。

# 仮説の検定

## 概要

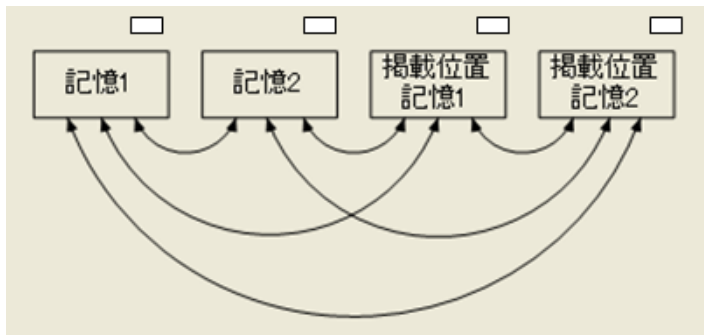
この例では、Amos を使用して、分散および共分散に関する単純な仮説を検定する方法について説明します。また、適合度のカイ 2 乗検定を紹介し、自由度の概念についても詳しく説明します。

## データについて

例 1 で説明した Attig (1983) の空間記憶データを使用します。ここでも、例 1 と同じパス図から説明を始めます。さまざまなデータフォーマットを使用できる Amos の機能を示すため、この例では、Excel ファイルの代わりに SPSS Statistics データファイルを使用します。

## パラメータ制約条件

例 1 のパス図を次に示します。変数オブジェクトは、Amos がパラメータを推定したら入力される小さな箱 (分散を表す) を周囲に持っていると考えることができます。

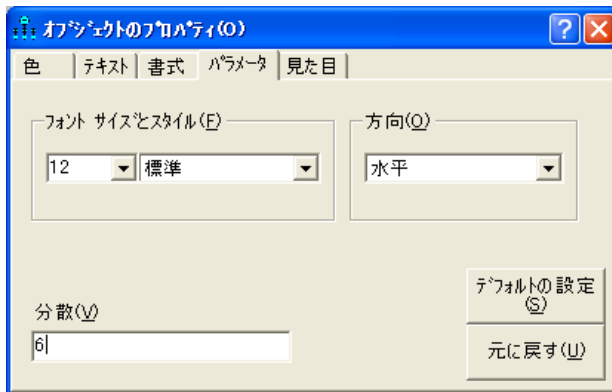


Amos に入力させるのではなく、自分でこれらの箱に入力することもできます。

## 分散の制約


記憶1の分散を6に記憶2の分散を8に設定するとします。

- ▶ 描画領域で、記憶1を右クリックし、ポップアップメニューから[オブジェクトのプロパティ]を選択します。
- ▶ [パラメータ]タブをクリックします。
- ▶ [分散]テキストボックスに「6」と入力します。



- ▶ [オブジェクトのプロパティ]を開いたままで、記憶2をクリックし、その分散を「8」に設定します。
- ▶ ダイアログボックスを閉じます。

パス図に、指定したパラメータの値が表示されます。



6と8という数字は任意に選択したに過ぎないため、これはあまり現実的ではありません。有意なパラメータ制約条件には、おそらくは理論や以前の同様のデータの分析に基づいた理論的な根拠が必要です。

## 等しいパラメータの指定

母集団において2つのパラメータが等しいかどうかの検定に関心を持つことがあります。たとえば、分散に対する特定の値を念頭に置かずに、記憶1と記憶2の分散が等しいと考えたとします。この可能性を調査するには、以下の手順を実行します。

- ▶ 描画領域で、記憶1を右クリックし、ポップアップメニューから[オブジェクトのプロパティ]を選択します。
- ▶ [パラメータ]タブをクリックします。
- ▶ [分散]テキストボックスに「v\_recall」と入力します。
- ▶ 記憶2をクリックし、その分散に「v\_recall」というラベルを付けます。
- ▶ 同じ方法で、掲載位置記憶1と掲載位置記憶2の各分散にも「v\_recall」というラベルを付けます。

どのラベルを使用するかは問題ではありません。重要なことは、強制的に等しくする各分散に対して同じラベルを入力することです。同じラベルを使用することの効果は、あらかじめ値を指定しなくても、どちらの分散にも同じ値を持たせることです。

## 等しいパラメータの指定の利点

モデルパラメータにさらに制約条件を追加する前に、記憶1と記憶2の分散、または掲載位置記憶1と掲載位置記憶2の分散など、2つのパラメータが等しくなるよう指定するのかを検討してみましょう。次の2つの利点があります。

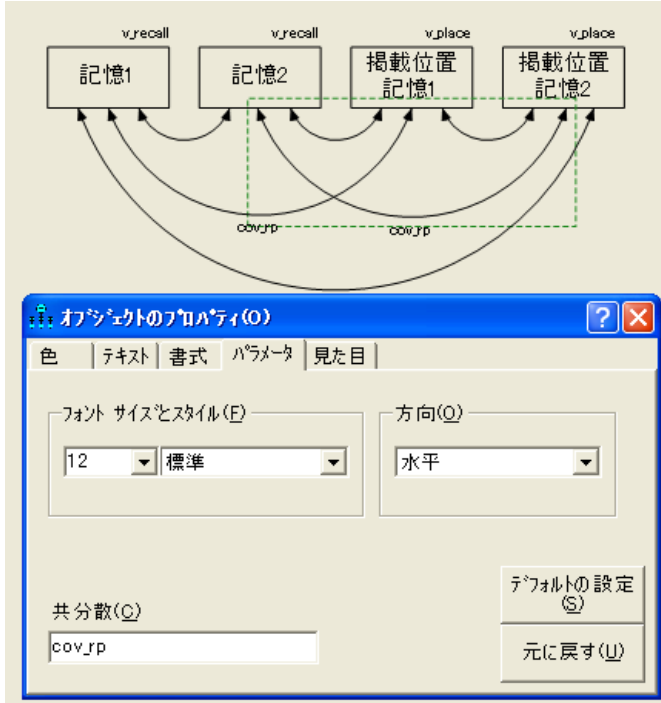
- 母集団で2つのパラメータが等しくなるように指定し、この指定を正しく行った場合、等しいパラメータだけでなく、通常は他のパラメータについても、より正確な推定値を得ることができます。パラメータが等しいことが分かっていた場合は、これが唯一の利点です。
- 2つのパラメータの等しさが単に仮説に過ぎない場合、その推定値が等しくなるように要求することにより、その仮説を検定することになります。

## 共分散の制約

モデルにはパラメータの分散以外に制限も含まれている場合があります。たとえば、記憶1と掲載位置記憶1間の共分散が記憶2と掲載位置記憶2間の共分散に等しいと仮定します。この制約を適用するには、次の手順を実行します。

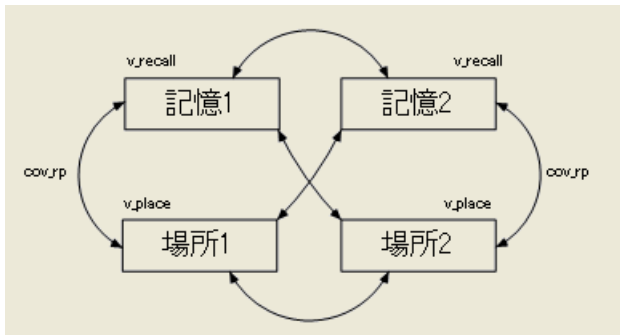
- ▶ 描画領域で、記憶1と掲載位置記憶1を結ぶ2方向の矢印を右クリックし、ポップアップメニューから[オブジェクトのプロパティ]を選択します。

- ▶ [パラメータ] タブをクリックします。
- ▶ [共分散] テキスト ボックスに、「cov\_rp」などの非数値型の文字列を入力します。
- ▶ 同じ方法で、記憶2 と掲載位置記憶2 間の共分散を cov\_rp に設定します。



## オブジェクトの移動と書式設定

小さな例では横のレイアウトで十分ですが、さらに複雑な分析の場合は実用的ではありません。次に、これまで使用してきたパス図の別のレイアウトを示します。



以下のツールを使用して、上記のような図になるまでパス図の配置を変更できます。



- オブジェクトを移動するには、メニューから [編集] → [移動] を選択し、オブジェクトを新しい場所にドラッグします。また、[オブジェクトを移動] ボタンを使用して、矢印の終点をドラッグすることもできます。
- 1つのオブジェクトから別のオブジェクトに書式をコピーするには、メニューから [編集] → [プロパティをドラッグ] を選択し、適用するプロパティを選択して、1つのオブジェクトから別のオブジェクトにドラッグします。

[プロパティをドラッグ]機能に関する詳細は、オンラインヘルプを参照してください。

## データの入力

- ▶ メニューから、[ファイル] → [データ ファイル] の順にクリックします。
- ▶ [データ ファイル] ダイアログ ボックスで、[ファイル名] をクリックします。
- ▶ %examples% フォルダを参照します。
- ▶ [ファイルの種類] リストで、[IBM SPSS Statistics (\*.sav)] を選択し、[Attg\_yng] をクリックして、[開く] をクリックします。
- ▶ SPSS Statistics がインストールされている場合、[データ ファイル] ダイアログ ボックスで [データの表示] ボタンをクリックします。SPSS Statistics ウィンドウが開き、データが表示されます。

	項目	年齢	v_short	ホキマラ	教育年数	性別	記憶1	記憶2	ヒント1	ヒント2
1	1	20	13	63	14	1	14	9	14	11
2	2	34	12	64	14	0	12	9	14	13
3	3	19	10	59	13	1	12	12	15	14
4	4	25	14	79	18	0	8	11	11	11
5	5	18	4	47	12	0	6	8	9	11
6	6	18	12	66	12	0	11	15	11	15
7	7	18	5	51	12	0	9	12	10	15
8	8	.	5	57	12	0	9	10	9	10
9	9	19	8	61	13	0	11	15	11	15

- ▶ データを確認し、データ ビューを閉じます。
- ▶ [データ ファイル] ダイアログ ボックスで、[OK] をクリックします。

## 分析の実行

- ▶ メニューから、[分析]→[推定値を計算]を選択します。
- ▶ [名前を付けて保存]ダイアログボックスでファイルの名前を入力し、[保存]をクリックします。  
モデル推定値が計算されます。

## テキスト出力の表示

- ▶ メニューから、[表示]→[テキスト出力の表示]の順にクリックします。
- ▶ パラメータ推定値を表示するには、[Amos出力]ウィンドウの左上のウィンドウ枠のツリー図で、[推定値]をクリックします

スカラー推定値 (グループ番号 1 - モデル番号 1)						
最尤(ML)推定値						
共分散: (グループ番号 1 - モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
記憶2 <-->	記憶1	2.872	1.208	2.377	.017	
記憶2 <-->	場所2	2.712	1.821	1.489	.136	cov_rp
場所2 <-->	場所1	17.149	5.155	3.327	***	
記憶1 <-->	場所1	2.712	1.821	1.489	.136	cov_rp
記憶1 <-->	場所2	4.608	2.166	2.127	.033	
記憶2 <-->	場所1	2.220	2.216	1.002	.316	
分散: (グループ番号 1 - モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
記憶1		7.055	1.217	5.798	***	v_recall
記憶2		7.055	1.217	5.798	***	v_recall
場所2		27.525	5.177	5.317	***	v_place
場所1		27.525	5.177	5.317	***	v_place

等しくなるように指定されたパラメータの推定値が実際に等しいことが分かります。この場合の標準誤差は、例1で得た標準誤差よりも一般的に小さくなります。また、パラメータに制約条件が設定されているため、自由度は正の値になっています。

- ▶ [Amos出力] ウィンドウの左上のウィンドウ枠で、[モデルについての注釈] をクリックします

自由度の計算 (モデル番号 1)	
独立な標本積率の数:	10
独立な推定パラメータの数:	7
自由度 (10 - 7):	3

標本の分散および共分散は 10 個ありますが、推定パラメータの数は 7 個だけです。7 という数は次のようにして得られました。記憶 1 と記憶 2 の分散には `v_recall` というラベルが付けられ、等しくなるように制約されているため、1 つのパラメータとしてカウントされています。掲載位置記憶 1 と掲載位置記憶 2 の分散 (`v_place` というラベルが付けられている) も、もう 1 つの単一パラメータとしてカウントされています。3 つ目のパラメータは等共分散記憶 1 <> 掲載位置記憶 1 および記憶 2 <> 掲載位置記憶 2 (`cov_rp` というラベル) に相当します。これら 3 つのパラメータに 4 つのラベルがなく制限されていない共分散を加えて、推定パラメータは全部で 7 つになります。

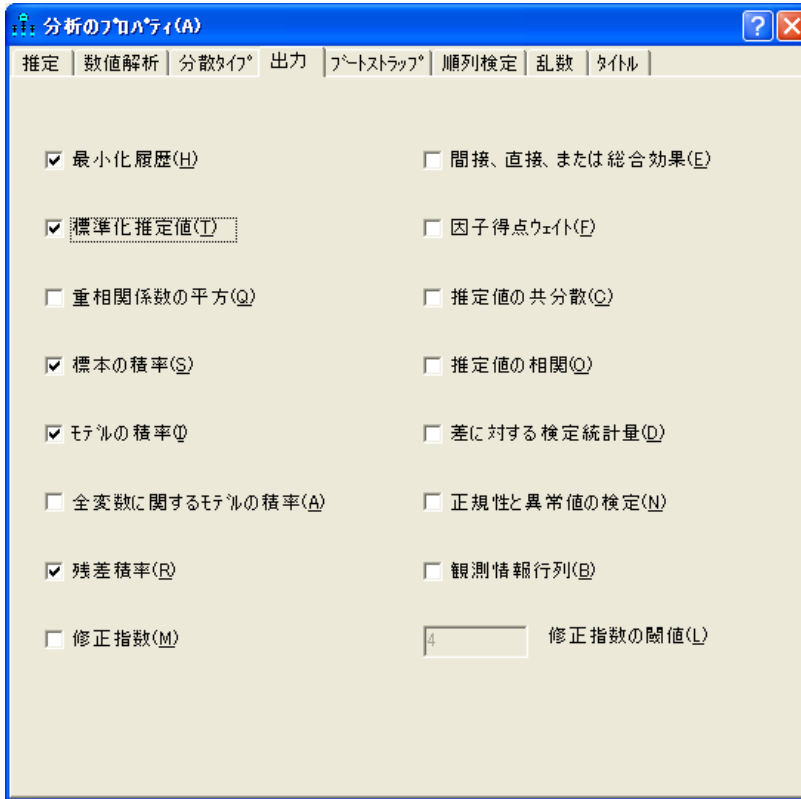
自由度 ( $10 - 7 = 3$ ) も、元の 10 個の分散および共分散に設定された制約の数と考えることができます。

## オプション出力

これまで説明した出力は、すべてデフォルトで生成されます。追加の出力も要求できます。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [出力] タブをクリックします。

- ▶ [最小化履歴]、[標準化推定値]、[標本の積率]、[モデルの積率]、および[残差積率]のチェックボックスがオンになっていることを確認してください。



- ▶ メニューから、[分析]→[推定値を計算]を選択します。  
モデルの推定値が再計算されます。

## 分散共分散行列推定値

- ▶ 行列に収集された標本の分散および共分散を参照するには、メニューから [表示]→[テキスト出力の表示]を選択します。
- ▶ [Amos出力] ウィンドウの左上隅のツリー図で、[標本の積率] をクリックします

標本の共分散行列を次に示します。

	場所1	場所2	記憶1	記憶2
場所1	33.578			
場所2	17.905	22.160		
記憶1	4.338	3.575	5.788	
記憶2	2.014	.427	2.556	7.944

- ▶ ツリー図で、[推定値]を展開し、[行列]をクリックします。

モデルの共分散の行列を次に示します。

	場所1	場所2	記憶1	記憶2
場所1	27.525			
場所2	17.149	27.525		
記憶1	2.712	4.608	7.055	
記憶2	2.220	2.712	2.872	7.055

標本の共分散行列とモデルの共分散行列の違いに注意してください。モデルでは共分散構造に3つの制約条件が設定されるため、モデルの分散および共分散は標本の値とは異なります。たとえば、掲載位置記憶1の標本の分散は33.58ですが、モデルの分散は27.53です。残差共分散(標本の共分散からモデルの共分散を引いたもの)の行列を得るには、[出力]タブで[残差積率]の横にチェックマークを入れ、分析を再実行します。

残差共分散の行列を次に示します。

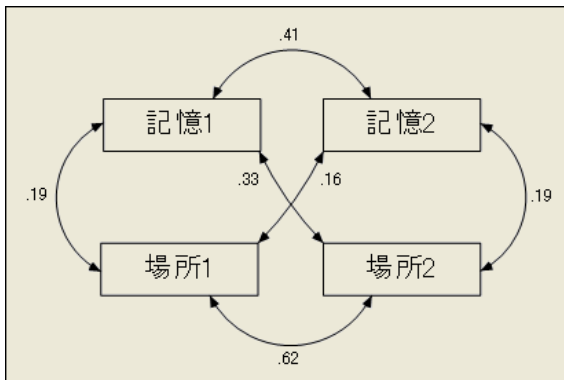
	場所1	場所2	記憶1	記憶2
場所1	6.052			
場所2	.756	-5.365		
記憶1	1.625	-1.033	-1.267	
記憶2	-.207	-2.285	-.316	.890

## 共分散および分散推定値のパス図への表示

例1のように、パス図に共分散および分散推定値を表示することができます。

- ▶ [出力パス図の表示] ボタンをクリックします。
- ▶ 描画領域の左にある [パラメータ形式] ウィンドウ枠で、[非標準化推定値] をクリックします。または、[標準化推定値] をクリックして、パス図で相関推定値を要求することもできます。

相関が表示されたパス図を次に示します。

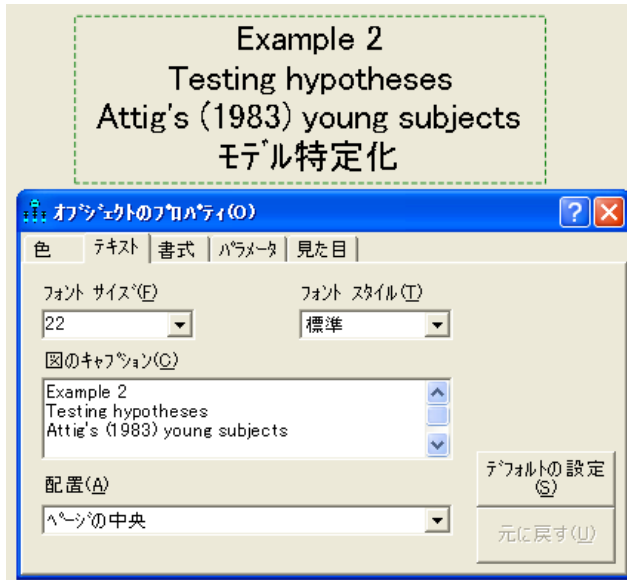


## 出力のラベル付け

表示された値が共分散または相関のどちらであるかを覚えておくのが、困難な場合もあります。この問題を避けるため、Amos を使用して出力にラベルを付けることができます。

- ▶ ファイル Ex02.amw を開きます。
- ▶ パス図でキャプションを右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。

- ▶ [テキスト] タブをクリックします。



図のキャプションの一番下の行に「¥format」という語が表示されています。¥format のように¥記号で始まる語を、テキスト マクロといいます。Amos では、テキスト マクロは現在表示されているモデルに関する情報で置き換えられます。テキスト マクロ ¥format は、表示されるパス図のバージョンによって、「モデル特定化」、「非標準化推定値」、および「標準化推定値」のいずれかの見出しで置き換えられます。

## 仮説の検定

モデルの共分散は、帰無仮説の下での母集団の分散および共分散の最適な推定値です。(帰無仮説とは、等しい推定値になるよう要求されたパラメータが母集団において真に等しい場合です。)例1から分かるように、標本の共分散は、母集団の値に関する仮定を行わずに得られる最適な推定値です。これらの2つの行列の比較は、帰無仮説が正しいかどうかという問題に関連しています。帰無仮説が正しい場合、モデルの共分散と標本の共分散は両方とも、対応する母集団の値の最尤推定値となります(モデルの共分散の方が良い推定値ではありません)。したがって、2つの行列は互いに似ていると予想されます。これに反して、帰無仮説が誤っている場合、標本の共分散のみが最尤推定値となり、モデルの共分散と似ていることを期待する根拠はありません。

カイ2乗統計量は、モデルの共分散が標本の共分散とどの程度異なっているかの全体的な測定値となります。

カイ2乗 = 6.276
自由度 = 3
確率水準 = 0.099

一般的に、モデルの共分散が標本の共分散から異なっていればいるほど、カイ2乗統計量も大きくなります。例1のように、モデルの共分散が標本の共分散と同じである場合は、カイ2乗統計量は0になったはずですが、カイ2乗統計量を使用して、等しい推定値を持つよう要求されているパラメータが、実際に母集団で等しいという帰無仮説を検定することができます。ただし、単にカイ2乗統計量が0かどうかを確認するだけの問題ではありません。モデルの共分散および標本の共分散は単なる推定値に過ぎないため、同一であると予想することができるのです(両方とも同じ母集団の共分散の推定値であったとしても)。実際には、帰無仮説が真であった場合でも、自由度の近辺でカイ2乗を生成する程度には異なると予想できます。言い換えると、帰無仮説が真の場合でも、3というカイ2乗値は異常ではありません。それどころか、帰無仮説が真の場合、カイ2乗値(6.276)は、自由度が3の近似カイ2乗分布を持つ乱数変数の単一の観測値です。確率は約0.099で、そのような観測値は6.276となります。したがって、帰無仮説が真であるかどうかは、0.05レベルでは有意ではありません。

## パス図へのカイ2乗統計量の表示

パス図の図のキャプションに表示されるカイ2乗統計量とその自由度を得るには、テキストマクロ「%cmin」および「%df」を使用します。このテキストマクロは、カイ2乗統計量とその自由度の数値で置き換えられます。テキストマクロ「%p」を使用すると、カイ2乗分布下の対応する右側の確率を表示することができます。

- ▶ メニューから、[図]→[図のキャプション]を選択します。
- ▶ パス図上で、図のキャプションを表示する場所をクリックします。  
[図のキャプション]ダイアログボックスが表示されます。
- ▶ [図のキャプション]ダイアログボックスで、次のように、「%cmin」、「%df」、「%p」の各テキストマクロを含むキャプションを入力します。

図のキャプション(F)

中央揃え(C)  
 左揃え(L)  
 右揃え(R)  
 ページの中央に置く(P)

フォント サイズ(F)  
 20

太字(B)  
 斜体(I)

終了後CtrlキーとEnterキーを押す


OK  
キャンセル

キャプション(A)

Chi-square = %cmin (%df df)  
p=%p




このキャプションを含むパス図が、次のように表示されます。



## VB.NET でモデルを作成する

次のプログラムは、例 2 の制約されたモデルを当てはめます。



```

C:\Program Files\IBM\SPSS\Amos\24\Examples\Japanese\Ex02.vb
ファイル(F)  編集(E)  書式(O)  ヘルプ(H)
[Icons]
[Header]
[Module MainModule]
' Example 2:
' Testing hypotheses
'
' Estimating variance and
' covariance parameters from
' the Attig (1983) study,
' young respondents only.
'
Sub Main()
    Using Sem As New AmosEngine
        Sem.TextOutput()

        Sem.Standardized()
        Sem.ImpliedMoments()
        Sem.SampleMoments()
        Sem.ResidualMoments()

        Sem.BeginGroup(AmosEngine.AmosDir & "Examples\Japanese\Attg_yng.sav")
        Sem.AStructure("記憶1 (v_recall)")
        Sem.AStructure("記憶2 (v_recall)")
        Sem.AStructure("場所1 (v_place)")
        Sem.AStructure("場所2 (v_place)")
        Sem.AStructure("記憶1 <> 場所1 (cov_rp)")
        Sem.AStructure("記憶2 <> 場所2 (cov_rp)")

        Sem.FitModel()
    End Using
End Sub
End Module
説明 | ライン
シNTAX エラー | デバッグ出力

```

次の表には、プログラムの 1 行ごとの説明が示されています。

プログラムのステートメント	説明
Dim Sem As New AmosEngine	Sem を AmosEngine 型のオブジェクトとして宣言しています。Sem オブジェクトのメソッドとプロパティは、モデルを指定し当てはめるために使用されます。
Sem.TextOutput	分析の結果を格納する出力ファイルを作成します。分析が終わると、出力ファイルの内容が別のウィンドウに表示されます。
Sem.Standardized() Sem.ImpliedMoments() Sem.SampleMoments() Sem.ResidualMoments()	標準化推定値、モデルの共分散、標本の共分散、および残差共分散を表示します。
Sem.BeginGroup ...	単一のグループ (すなわち単一の母集団) のモデルの特定を開始します。この行は、SPSS Statistics ファイル Attg_yng.sav に入力データが格納されていることも指定しています。Sem.AmosDir() は、Amos プログラム ディレクトリの場所です。
Sem.AStructure("recall1 (v_recall)") Sem.AStructure("recall2 (v_recall)") Sem.AStructure("place1 (v_place)") Sem.AStructure("place2 (v_place)") Sem.AStructure("recall1 <>place1 (cov_rp)") Sem.AStructure("recall2 <>place2 (cov_rp)")	モデルを指定します。最初の 4 つの AStructure ステートメントは、パラメータ名をかつこで囲んで使用することにより、観測変数の分散を制約します。記憶 1 と記憶 2 の分散には両方とも v_recall というラベルが付いているため、これらは同じ分散になる必要があります。掲載位置記憶 1 と掲載位置記憶 2 の分散も、同様に等しくなるように制約されています。最後の 2 つの AStructure 行は、それぞれ共分散を表しています。2 つの共分散はどちらも cov_rp という名前です。したがって、これらの共分散は等しくなるよう制約されています。
Sem.FitModel()	モデルを当てはめます。
Sem.Dispose()	Sem オブジェクトによって使用されたリソースを解放します。プログラムで、別の AmosEngine オブジェクトを作成する前に AmosEngine オブジェクトの Dispose メソッドを使用することは特に重要です。プロセスでは、1 度に 1 つの AmosEngine オブジェクトのインスタンスしか許可されません。
Try/Finally/End Try	Try ブロックは、プログラムの実行中にエラーが発生した場合でも、Dispose メソッドが呼び出されることを保証します。

- ▶ 分析を実行するには、メニューから [ファイル] → [実行] を選択します。

## タイミングがすべて

AStructure 行は BeginGroup の後に来る必要があります。そうでないと、AStructure 行で指定されている変数が attg\_yng.sav データセットの観測変数であると認識されません。

一般的に、Amos のプログラムでは、ステートメントの順序が重要です。Amos プログラムの編成では、メソッドは 3 つの一般的なグループに分かれます。<sup>1</sup>

### グループ 1 - 宣言用のメソッド

Amos に計算および表示する結果を教えるメソッドのグループです。TextOutput、Standardized、ImpliedMoments、SampleMoments、および ResidualMoments はグループ 1 のメソッドです。この例で使用されていない、他のグループ 1 のメソッドについては、『Amos 28 Programming Reference Guide』に記載されています。

### グループ 2 - データおよびモデル指定用のメソッド

データ記述コマンドおよびモデル特定コマンドのグループです。BeginGroup および AStructure はグループ 2 のメソッドです。その他のメソッドについては、『Amos 28 Programming Reference Guide』に記載されています。

### グループ 3 - 結果取得用のメソッド

結果を取得するためのコマンドです。これまで、グループ 3 のメソッドはまだ使用していません。グループ 3 のメソッド使用例については、『Amos 28 Programming Reference Guide』に記載されています。

**ヒント:** Amos プログラムを記述する場合、Amos エンジンのメソッドを呼び出す順序に細心の注意を払うことが重要です。グループ 1、グループ 2、そして最後にグループ 3 の順序で記述する必要があります。

ルールのタイミングの詳細とメソッドおよびそのメソッドがどのグループに所属するかについての完全なリストは、『Amos 28 Programming Reference Guide』を参照してください。

<sup>1</sup> Initialize メソッドのみで構成される、4 番目の特殊なグループもあります。オプションの Initialize メソッドを使用する場合、グループ 1 のメソッドより前に指定する必要があります。

# その他の仮説の検定

## 概要

この例では、2つの変数に相関がないという帰無仮説の検定方法を説明し、自由度の概念について詳しく解説し、漸近的に正確な検定の意味するものを具体的に示します。

## データについて

この例では、Attig (1983) の空間記憶調査の被験者グループと、年齢およびボキャブラリの2つの変数を使用します。タブ区切りテキストファイルとして書式設定されたデータを使用します。

## データの取り込み


- ▶ メニューから、[ファイル]→[新規作成]を選択します。
- ▶ メニューから、[ファイル]→[データファイル]の順にクリックします。
- ▶ [データファイル]ダイアログボックスで、[ファイル名]を選択します。
- ▶ %examples% フォルダを参照します。
- ▶ [ファイルの種類]リストで、[テキスト (\*.txt)]を選択し、[Attg\_old.txt]をクリックして、[開く]をクリックします。
- ▶ [データファイル]ダイアログボックスで、[OK]をクリックします。

## 2つの変数に相関がないという仮説の検定

Attig の 40 名の年長の被験者では、年齢とボキャブラリ間の標本の相関は、0.09 です (0 からそれほど乖離していません)。とは言え、この相関は著しく有意であると言えるでしょうか。それを調べるために、この 40 人の被験者の属する母集団において、年齢とボキャブラリ間の相関が 0 であるという帰無仮説を検定することにします。年齢とボキャブラリに相関がないという制約の下で、分散共分散行列を推定します。

### モデルを指定する

例1 で学習した方法を使用して、パス図で 2 つの観測変数年齢とボキャブラリを描画し、名前を付けることから始めます。



Amos では、年齢とボキャブラリ間の共分散が 0 であることを指定するための 2 つの方法があります。最も明白な方法は、単に 2 つの変数を結ぶ双方向の矢印を描画しないことです。2 つの外生変数を結ぶ双方向の矢印がないということは、相関がないことを意味しています。したがって、何も描かなければ、上記の単純なパス図で指定されたモデルは年齢とボキャブラリ間の共分散 (ひいては相関) が 0 であることを指定します。

共分散パラメータを制約する 2 つ目の方法は、例 1 と例 2 で紹介された、より一般的な手順です。

- ▶ メニューから、[図] → [共分散を描く] の順にクリックします。
- ▶ クリックし、ドラッグして、ボキャブラリと年齢を結ぶ矢印を描きます。
- ▶ 矢印を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [パラメータ] タブをクリックします。
- ▶ [共分散] テキストボックスに「0」と入力します。
- ▶ [オブジェクトプロパティ] ダイアログボックスを閉じます。

パス図は次のようになります。



- ▶ メニューから、[分析]→[推定値を計算]を選択します。  
[名前を付けて保存]ダイアログボックスが表示されます。
- ▶ ファイルの名前を入力して、[保存]をクリックします。  
モデル推定値が計算されます。

## テキスト出力の表示

- ▶ メニューから、[表示]→[テキスト出力の表示]の順にクリックします。
- ▶ [Amos出力]ウィンドウの左上のウィンドウ枠のツリー図で、[推定値]を選択します  
パラメータ推定値はこの分析の主要な目的ではありませんが、以下のようになります。

共分散: (グループ番号 1 - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
年齢 <--> ポキャブラリ	.000				

相関係数: (グループ番号 1 - モデル番号 1)	
	推定値
年齢 <--> ポキャブラリ	.000

分散: (グループ番号 1 - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
年齢	21.574	4.886	4.416	***	
ポキャブラリ	131.294	29.732	4.416	***	

この分析では、年齢とポキャブラリに相関がないという1つの制約条件に対応する1つの自由度があります。自由度は、次のテキストで表示されている計算によっても得られます。この計算を表示するには、次の手順を実行します。

- ▶ [Amos出力]ウィンドウの左上のウィンドウ枠で、[モデルについての注釈]をクリックします

自由度の計算 (モデル番号 1)	
独立な標本積率の数:	3
独立な推定パラメータの数:	2
自由度 (3 - 2):	1

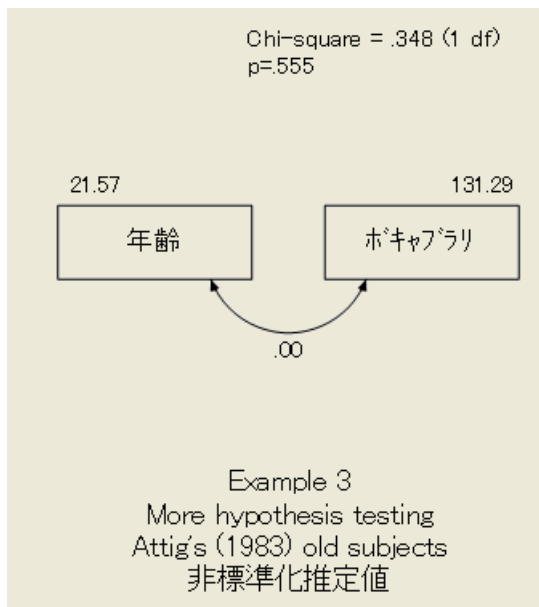
3つの標本の積率は、年齢の分散、ポキャブラリの分散、およびこれらの共分散です。2つの独立な推定パラメータは、2つの母集団の分散です。共分散はこのモデルでは0に固定されており、標本の情報からは推定されません。



## グラフィック出力の表示

- ▶ [出力パス図の表示] ボタンをクリックします。
- ▶ 描画領域の左にある [パラメータ形式] ウィンドウ枠で、[非標準化推定値] をクリックします。

非標準化推定値のパス図の出力、および年齢とボキャブラリに相関がないという帰無仮説の検定を次に示します。



この大きさの逸脱が偶発的に帰無仮説から得られる確率は 0.555 です。従来の有意水準では、帰無仮説は棄却されません。

この帰無仮説検定用の通常の  $t$  統計量は 0.59 ( $df = 38$ ,  $p = 0.56$  両側) です。 $t$  統計量に関連する確率水準は正確です。有限標本では正確なカイ 2 乗分布がないため、カイ 2 乗統計量の確率水準 0.555 は外れています。この場合でも、0.555 という確率水準は悪くはありません。

ここで興味深い問題が生じます。Amos によって表示された確率水準を使用して 0.05 レベルまたは 0.01 レベルで帰無仮説を検定した場合、真の帰無仮説を棄却する実際の確率はどうなるのでしょうか。この帰無仮説の場合、標本数によって異なりますが、回答があります。次の表の第 2 列は、複数の標本数について、Amos を使用して 0.05 レベルでゼロの相関の帰無仮説を検定した場合の、実際のタイプ I の誤りの確率を示しています。3 番目の列は、0.01 の有意水準を使用した場合の実際のタイプ I の誤りの確率を示しています。この表は、標本数が多くなればなるほど、真の有意水準が予想値に近づくことを示しています。非常に残念ながら、Amos を使用して検定できる

すべての仮説について、このような表を作成することはできません。しかし、次のことはこうした表のどれについてもあてはまります。上から下に向かって、**0.05** 列の数値は **0.05** に近づき、**0.01** 列の数値は **0.01** に近くなっていきます。最尤法理論に基づく仮説検定が漸近的に正しいというのは、このことを意味しています。

次の表は、Amos を使用して 2 つの変数間に相関がないという仮説を検定した場合の、タイプ I の誤りの実際の確率を示しています。

標本数	名義有意水準	
	<b>0.05</b>	<b>0.01</b>
<b>3</b>	0.250	0.122
<b>4</b>	0.150	0.056
<b>5</b>	0.115	0.038
<b>10</b>	0.073	0.018
<b>20</b>	0.060	0.013
<b>30</b>	0.056	0.012
<b>40</b>	0.055	0.012
<b>50</b>	0.054	0.011
<b>100</b>	0.052	0.011
<b>150</b>	0.051	0.010
<b>200</b>	0.051	0.010
<b>&gt;500</b>	0.050	0.010

## VB.NET でのモデル作成

以下は、この例の分析を実行するためのプログラムです。

The screenshot shows a Visual Basic .NET program window titled "C:\Program Files\IBM\SPSS\Amos\24\Examples\Japanese\Ex03.vb". The code is as follows:

```

Module MainModule
    ' Example 3:
    ' More hypothesis testing.
    '
    ' Testing for a zero correlation between
    ' age and vocabulary knowledge.
    ' Attig's (1983) sample of young subjects
    ' subjects is used.
    '
    Sub Main()
        Using Sem As New AmosEngine
            Sem.TextOutput()
            Sem.Standardized()
            Sem.ImpliedMoments()
            Sem.SampleMoments()

            Sem.BeginGroup(AmosEngine.AmosDir & "Examples\Japanese\Attg_old.txt")
            Sem.AStructure("年齢 <-> ホキャブラリ (0)")

            Sem.FitModel()
        End Using
    End Sub
End Module

```

At the bottom of the window, there are buttons for "シNTAXエラー" (Syntax Error) and "デバッグ出力" (Debug Output).

Structure メソッドは、共分散を定数 0 で固定して制約します。このプログラムでは、年齢とボキャブラリの分散を明示的には参照していません。Amos のデフォルトの動作は、それらの制約条件なしで分散を推定することです。プログラムで明示的に制約されている分散を除き、すべての外生変数の分散はフリーパラメータとして扱われます。



# 来の線型回帰

## 概要

この例では、3 個の観測変数の線型結合として単一の観測変数を予測する、従来の線型回帰分析について説明します。特定可能性の概念についても説明します。

## データについて

Warren、White、および Fuller は、98 名の農場共同組合長を対象に調査を行いました (1974)。ここでは次の 4 つの測定値を使用します。

変数	説明
成果	「計画、組織、制御、調整、および指導」に関する実績の 24 項目の変数
知識	「収益を目標とした管理の経済局面および製品知識」に関する知識の 26 項目の検定
価値	「経済的目標を達成するための手段を合理的に評価する傾向」の 30 項目の検定
満足度	「管理的役割を果たすことによる満足度」の 11 項目の検定

5 つ目の測定値である `past_training` も報告されていますが、ここでは使用しません。

この例では、`%examples%` フォルダにある `UserGuide.xls` ファイルの Excel ワークシート `Warren5v` を使用します

標本分散と標本共分散を次に示します。

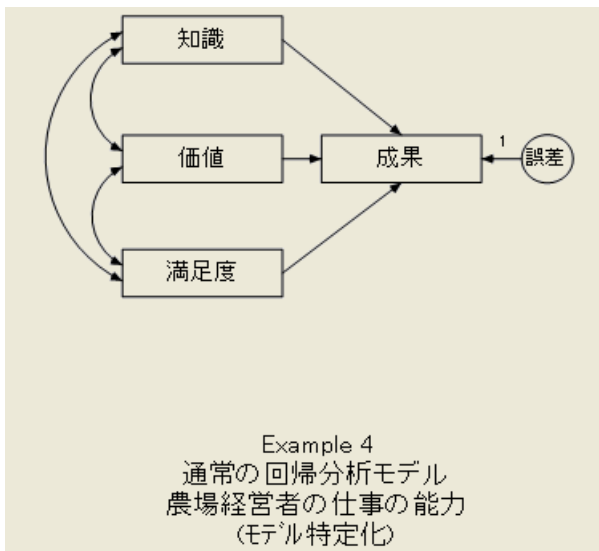
rowtype	varname	成果	知識	価値	満足度	教育
n		98	98	98	98	98
cov	成果	0	.	.	.	.
cov	知識	0	0	.	.	.
cov	価値	0	0	0	.	.
cov	満足度	0	0	0	0	.
cov	教育	0	0	0	0	0
mean		0	1	3	2	2

Warren5v には標本の平均値も含まれます。生データは使用できませんが、標本の積率(平均、分散、および共分散)が提供される限り、Amos による大部分の分析では必要ありません。実際に、この例では標本分散と標本共分散のみ必要です。差し当たって Warren5v では標本の平均値は必要ないので、Amos はそれらの値を無視します。

## データの分析

知識、価値、および満足度の得点を使用して成果を予測する場合を考えてみましょう。具体的には、知識、価値、および満足度の線型結合によって成果の得点の近似値を求めることができると考えます。ただし、この予測は完全ではないので、モデルに誤差変数を含める必要があります。

この関係の初期パス図を次に示します。



一方向の矢印は線型従属を表します。たとえば、知識から成果を指す矢印は、成果の得点が一部知識に依存することを示します。変数誤差は直接観測されないため、円で囲まれています。誤差が表すのは、測定エラーによる成果の得点のランダムな変動だけではありません。誤差は、年齢構成、社会経済状況、言語能力、その他成果が依存

する要素でこの調査では測定されなかった要素も表します。パス図には、成果の得点に影響するすべての変数が示されると考えられるので、この変数は不可欠です。この円がない場合、このパス図は成果が知識、価値、および満足度と厳密な線型結合であるというありえない関係を示すこととなります。

パス図の双方向の矢印は、相関する可能性がある変数を結びます。誤差とその他の変数を結ぶ双方向矢印が存在しないのは、誤差は他のすべての予測変数と無相関であると仮定されることを示します（線型回帰における基本的仮定）。成果もその他の変数と双方向矢印で結ばれていませんが、この理由は異なります。成果はその他の変数に依存するため、必然的にそれらの変数と相関する可能性があります。

## モデルを指定する

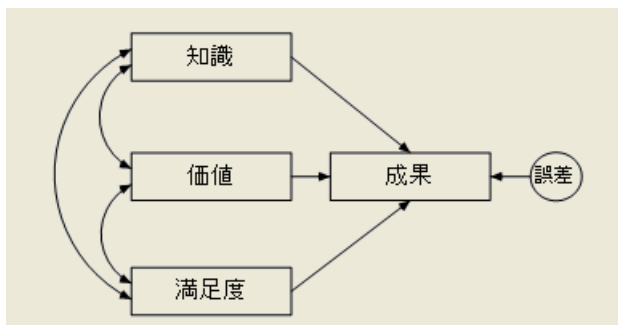
これまでの3つの例で学習したことを使用して、次の操作を行います。

- ▶ 新しいパス図を開始します。
- ▶ 分析されるデータセットが UserGuide.xls ファイルの Excel ワークシート Warren5v にあることを指定します。
- ▶ 4つの四角形を作成し、**知識**、**価値**、**満足度**、および**成果**のラベルを付けます。
- ▶ 誤差変数用の楕円を作成します。
- ▶ 外生または予測変数（知識、価値、満足度、および誤差）から内生または応答変数（成果）を指す一方向矢印を作成します。

**注：**少なくとも1つの一方向矢印が内生変数を指している必要があります。これに対し外生変数は一方向矢印の起点となるだけで、指されることはありません。

- ▶ 観測外生変数（知識、満足度、および価値）を結ぶ3つの双方向矢印を作成します。

作成されたパス図は次のようになります。



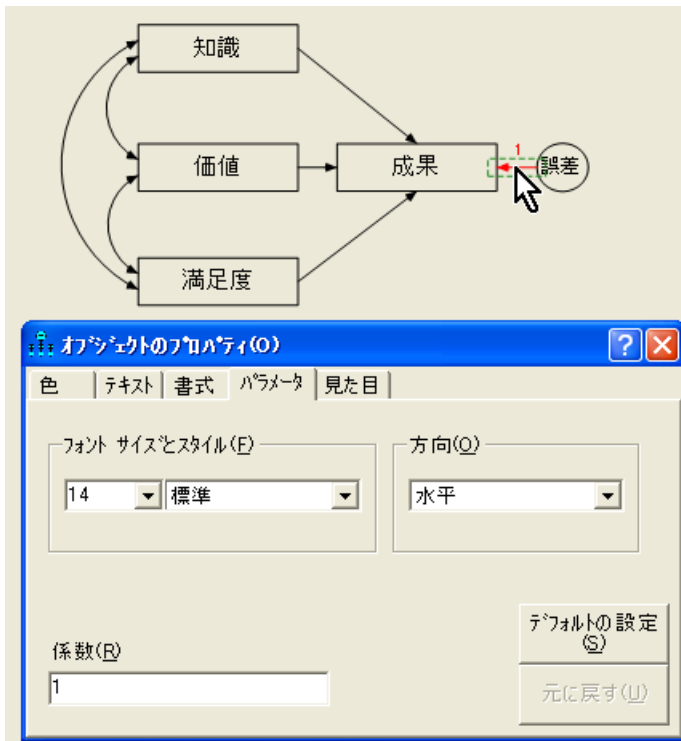
## 特定

この例では、誤差に対する成果の回帰の係数が推定できず、誤差の分散も推定できません。これは、「全部で5ドルの道具を買った」と聞いただけで、購入した道具それぞれの価格と購入した道具の数とを推定しようとするようなものです。価格と数を推定するには情報が不十分です。

成果を予測する際に誤差に適用される係数、または誤差変数自体の分散をゼロ以外の任意の値に固定することにより、この特定問題を解決できます。係数を1に固定してみましょう。これにより、従来の線型回帰と同じ推定値が得られます。

## 係数を固定する

- ▶ 誤差から成果を指す矢印を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [パラメータ] タブをクリックします。
- ▶ [係数] ボックスに「1」と入力します。



すべての誤差変数の係数を1に設定するのは面倒です。幸いにして、Amos Graphicsには大部分の場合に適用できる方法があらかじめ用意されています。



- ▶ [既存の変数に固有の変数を追加] ボタンをクリックします。
- ▶ 内生変数をクリックします。

誤差変数が自動的に追加され、係数が 1 に固定されます。内生変数を繰り返しクリックすると、誤差変数の位置が変わります。

## テキスト出力を表示する

最尤法の推定値を次に示します。

係数: (ウルーフ番号 1-モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
成果 <--- 知識	.258	.054	4.822	***	
成果 <--- 価値	.145	.035	4.136	***	
成果 <--- 満足度	.049	.038	1.274	.203	
共分散: (ウルーフ番号 1-モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
知識 <--> 満足度	.004	.007	.632	.528	
価値 <--> 満足度	-.006	.011	-.593	.553	
知識 <--> 価値	.028	.008	3.276	.001	
分散: (ウルーフ番号 1-モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
知識	.051	.007	6.964	***	
価値	.120	.017	6.964	***	
満足度	.089	.013	6.964	***	
誤差	.012	.002	6.964	***	

パス成果<— 誤差の値はデフォルト値 1 に固定されているので表示されません。異なる定数を選択すると他の推定値がどのような影響を受けるかを確認してください。このような変更の影響を受けるのは誤差の分散の推定値だけであることがわかります。

次の表に、成果<— 誤差係数にさまざまな値を選択した場合の分散の推定値を示します。

固定係数	推定される誤差の分散
0.5	0.050
0.707	0.025
1.0	0.0125
1.414	0.00625
2.0	0.00313

このパスの係数を 1 ではなく 2 に固定した場合を考えてみましょう。この場合、分散の推定値は係数 4 で割られます。パス係数に固定係数を掛けるとともに、誤差分散を同じ係数の平方根で割るという規則を当てはめることができます。これを拡張すると、係数の 2 乗の積と誤差分散が常に一定になります。これが、係数 (と誤差分散) が特定不能であるということです。これらのいずれかに値を割り当てるともう一方を推定できますが、同時に両方を推定することはできません。

これまで説明した特定可能性の問題は、変数の分散と、それに関連付けられた係数が、変数の測定単位に応じて異なるという事実によって発生します。誤差は非観測変数なので、自然な方法で測定単位を指定することはできません。誤差の測定単位を間接的に選択する方法として、誤差に関連付けられた係数に任意の値を割り当てる方法が考えられます。すべての非観測変数にはこの特定不能性の問題があり、測定単位を決定する何らかの制約を設けることによって問題を解決する必要があります。

非観測変数誤差の単位を変更しても、全体的なモデルの適合度は変わりません。すべての分析で、次の出力が得られます。

カイ 2 乗 = 0.00  
 自由度 = 0  
 確率水準の計算はできません。

4 個の標本分散と 6 個の標本共分散で、合計 10 個の標本の積率があります。3 個の回帰パス、4 個のモデル分散、3 個のモデル共分散で、合計 10 個のパラメータを推定する必要があります。このため、モデルの自由度はゼロになります。このようなモデルはしばしば飽和モデルまたは識別可能モデルと呼ばれます。

標準化された係数の推定値には、次のものがあります。

**標準化係数: (グループ番号 1 - モデル番号 1)**

	推定値
成果 <--- 知識	.407
成果 <--- 価値	.349
成果 <--- 満足度	.101

**相関係数: (グループ番号 1 - モデル番号 1)**

	推定値
知識 <--> 満足度	.064
価値 <--> 満足度	-.060
知識 <--> 価値	.333

標準化された係数と相関は、すべての変数を測定する単位から独立しているので、識別制約の選択による影響を受けません。

重相関の2乗も測定単位から独立しています。Amosでは、内生変数ごとに重相関係数の平方が表示されます。

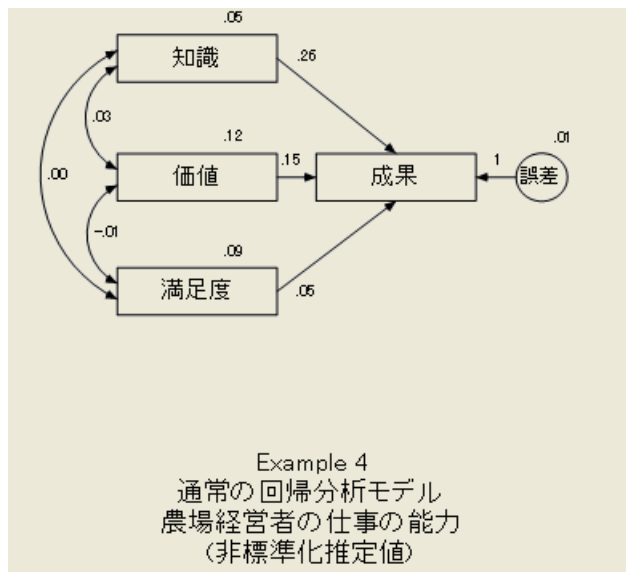
**重相関係数の平方: (グループ番号 1 - モデル番号 1)**

	推定値
成果	.399

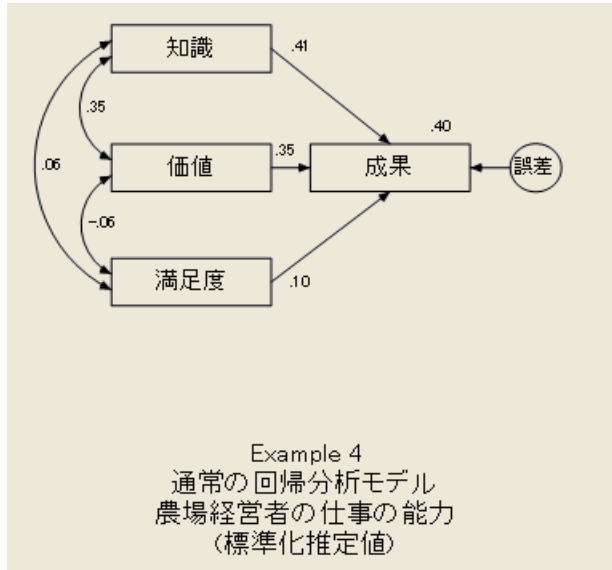
注: 変数の重相関係数の平方は、予測変数が分散に占める割合になります。上の例では、知識、価値、および満足度が成果の分散の40%を占めています。

## グラフィック出力を表示する

次のパス図の出力には、標準化されていない値が示されています。



標準化された解は次のとおりです。



## その他のテキスト出力を表示する

- ▶ [Amos 出力] ウィンドウの左上のウィンドウ枠にあるツリー図で、[変数の要約] をクリックします。

<b>現行モデルには次の変数があります。(グループ番号 1)</b>	
観測される内生変数	
成果	
観測される外生変数	
知識	
価値	
満足度	
観測されない外生変数	
誤差	
<b>変数カウント (グループ番号 1)</b>	
モデルに含まれる変数の数:	5
観測される変数の数:	4
観測されない変数の数:	1
外生変数の数:	4
内生変数の数:	1

内生変数は一方向矢印によって指される変数であり、他の変数に依存します。外生変数は一方向矢印によって指されない変数であり、他の変数に依存しません。

上のリストの確認は、入力ファイルで最もよく見られる(不注意による)エラーである、入力エラーの検出に役立ちます。「成果」と2回入力しようとして、その内1回は誤って「製菓」と入力してしまった場合、両方の語がリストに表示されます。

- ▶ ここで、[Amos出力] ウィンドウの左上のウィンドウ枠にある [モデルについての注釈] をクリックします。

次の出力は、パス図にフィードバック ループがないことを示しています。

**グループについての注釈 (グループ番号 1)**


モデルが逐次的です。  
標本数 = 98

後ほど、変数を選択し、一方向の矢印に沿ってトレースすることにより、同じ変数に戻るパスを含むパス図を示します。

**注:** フィードバック ループのあるパス図は非再帰と呼ばれます。フィードバック ループのないパス図は再帰と呼ばれます。

## VB.NET でモデルを作成する

この例のモデルは、単一の回帰式で構成されています。パス図の一方向矢印は、それぞれ係数を表します。これらの係数を推定するためのプログラムを次に示します。



```

C:\Program Files\IBM\SPSS\Amos\24\Examples\Japanese\Ex04.vb
ファイル(F) 編集(E) 書式(O) ヘルプ(H)
[Icons]
[Header]
Module MainModule
    ' Example 4:
    ' Conventional linear regression
    '
    ' Using data from the Warren, White and
    ' Fuller (1974) study of job performance
    ' of farm managers.
    '
Sub Main()
    Using Sem As New AmosEngine
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()
        Sem.ImpliedMoments()
        Sem.SampleMoments()

        Sem.BeginGroup(AmosEngine.AmosDir & "Examples\Japanese\UserGuide.xls", "Warren5v")
        Sem.AStructure("成果 <--- 知識")
        Sem.AStructure("成果 <--- 価値")
        Sem.AStructure("成果 <--- 満足度")
        Sem.AStructure("成果 <--- 誤差 (1)")

        Sem.FitModel()
    End Using
End Sub
End Module
説明 | ライン
シNTAX エラー | デバッグ出力

```

Sem.BeginGroup の後の 4 行は、Amos Graphics のパス図の一方向矢印に対応します。最後の AStructure 行の (1) により、誤差係数を定数 1 に固定します。

## 外生変数間の相関に関する仮定

プログラムの実行時に、Amos が外生変数間の相関を仮定します。これらの相関は Amos Graphics では仮定されません。これらの仮定は、多くのモデル、特にパラメータがあるモデルの指定を単純化します。Amos Graphics でのモデルの指定とプログラムによるモデルの指定の相違は次のとおりです。

- Amos Graphics は完全に WYSIWYG (What You See Is What You Get) です。2 個の外生変数の間に双方向矢印を作成する場合 (制約なし)、Amos Graphics はそれらの共分散を推定します。2 個の外生変数が双方向矢印で接続されていない場合、Amos Graphics はそれらの変数は無相関であると仮定します。

Amos プログラムのデフォルトの仮定は次のとおりです。

- 固有の変数 (他の 1 個の変数にのみ影響する非観測外生変数) は相互に無相関であり、他のすべての外生変数とも無相関であると仮定されます。
- 固有の変数以外の外生変数は、それらの変数間で相関があると仮定されます。

Amos プログラムでは、これらのデフォルトの仮定が、従来の線型回帰分析の標準の仮定に反映されます。このため、この例では、予測変数知識、価値、および満足度は相関があり、誤差はこれらの予測変数と無相関であると仮定されます。

## AStructure メソッドの式形式

AStructure メソッドでは、式形式でモデルを指定できます。たとえば、次のプログラムに含まれる 1 つの Sem.AStructure ステートメントにより、70 ページのプログラムと同じモデルを 1 行で指定できます。このプログラムは、Examples ディレクトリに Ex04-eq.vb という名前で保存されています。

```

Module MainModule
    ' Example 4-EQ:
    ' Conventional linear regression
    '
    ' Using data from the Warren, White and
    ' Fuller (1974) study of job performance
    ' of farm managers.
    Sub Main()
        Using Sem As New AmosEngine
            Sem.TextOutput()
            Sem.Standardized()
            Sem.Smc()
            Sem.ImpliedMoments()
            Sem.SampleMoments()

            Sem.BeginGroup(AmosEngine.AmosDir & "Examples\Japanese\UserGuide.xls", "Warren5v")
            Sem.AStructure("成果 = 知識 + 価値 + 満足度 + 誤差(1)")

            Sem.FitModel()
        End Using
    End Sub
End Module

```

上の AStructure 行では、各予測変数（式の右側）が推定される係数と関連付けられていることに注意してください。次のように空の括弧を使用することにより、これらの係数を明示できます。

```
Sem.AStructure("成果 = () 知識 + () 価値 + () 満足度 + 誤差(1)")
```

空の括弧はオプションです。デフォルトでは、各予測変数の係数が自動的に推定されます。



# 非観測変数

## 概要

この例では、非観測変数を使用した回帰分析について説明します。

## データについて

前の例の変数は、信頼性にある程度の問題があることは否定できません。成果の信頼性が不明であるため、予測変数が成果の分散に占める割合が 39.9% に過ぎないという事実の解釈において若干の問題が発生します。検定の信頼性が非常に低い場合、その事実自体が成果の得点を正確に予測できない原因になります。一方で、予測変数の信頼性の低さにより、係数の推定値が偏る可能性があるため、より深刻な問題が発生します。

Rock 等の調査 (1977) に基づくこの例では、前の分析に含まれる 4 つの検定の信頼性を評価します。完全に信頼できる、仮定の 4 つの検定用に係数の推定値も取得します。Rock 等は、前の例で説明した Warren、White、および Fuller のデータ (1974) を再調査しました。ここでは各検定をランダムに 2 分割し、それぞれの得点を個別に記録しています。

入力変数の一覧を次に示します。

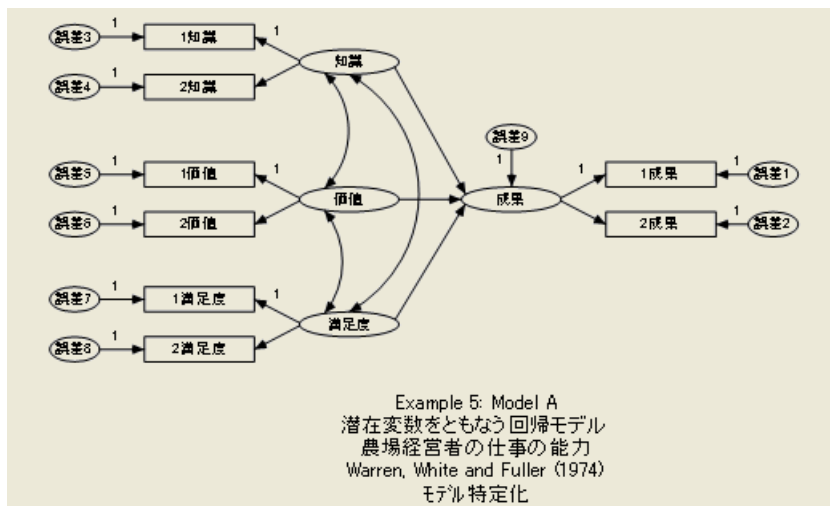
変数名	説明
1 成果	成果役割の 12 項目のサブセット
2 成果	成果役割の 12 項目のサブセット
1 知識	13-知識の 13 項目のサブセット
2 知識	13-知識の 13 項目のサブセット
1 価値	15-価値方向の 15 項目のサブセット
2 価値	15-価値方向の 15 項目のサブセット
1 満足度	5-満足度役割の 5 項目のサブセット
2 満足度	6-満足度役割の 5 項目のサブセット
past_training	学校教育のレベル

この例では、Lotus データ ファイルの Warren9v.wk1 を使用して、これらのサブセットの標本分散と標本散を取得します。ファイルに表示される標本の平均値は、この例では使用しません。このファイルには学校教育 (past\_training) に関する統計も存在しますが、この分析には使用されません。データ セットの一部を次に示します。

UserGuide.xls				
ファイル(F) 書式(O) ヘルプ(H)				
Grant	rowtype_	varname_	1 成果	2 成果
Grant_x	n		98	98
Grnt_fem	cov	1 成果	0.0271	
Grnt_mal	cov	2 成果	0.0172	0.0222
Hamilton	cov	1 知識	0.0219	0.0193
Olss_all	cov	2 知識	0.0164	0.013
Olss_cnt	cov	1 価値	0.0284	0.0294
Olss_exp	cov	2 価値	0.0217	0.0185
Warren5v				
Warren9v				

## モデル A

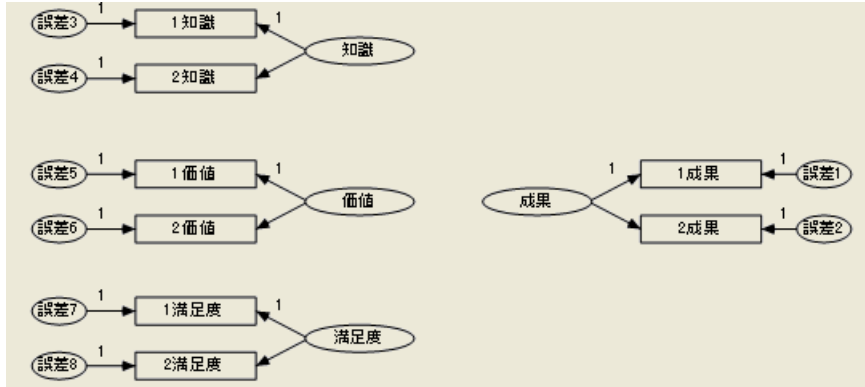
次のパス図は、8つのサブセット用のモデルを表します。



図の4つの楕円には、知識、価値、満足度、および成果のラベルが付けられています。これらは、2分割された8つの検定によって間接的に測定される非観測変数を表します。

## 測定モデル

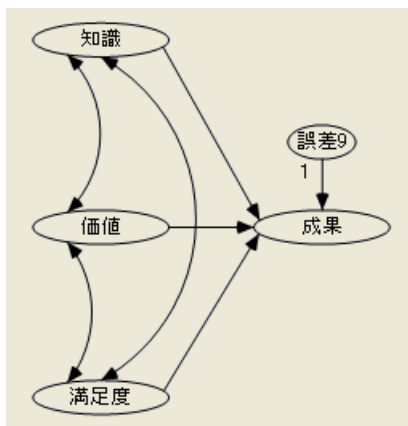
モデルの中で、観測変数が非観測（または潜在的）変数にどのように依存するかを指定する部分を測定モデルと呼ぶ場合があります。このモデルには、4つの異なる測定サブモデルがあります。



たとえば、知識サブモデルの例を考えてみましょう。2分割されたサブセット、1知識と2知識の得点は、元になる単一の変数で、直接観測されない知識によって決まると仮定されます。このモデルによると、2つのサブセットの測定エラーを表す誤差3と誤差4の影響により、2つのサブセットの得点は一致しない可能性があります。1知識と2知識は、潜在変数知識の指標と呼ばれます。知識の測定モデルが示すパターンは、上のパス図で後3回繰り返されます。

## 構造モデル

モデルの中で、潜在変数がどのように相互に関連するかを指定する部分を構造モデルと呼ぶ場合があります。



このモデルの構造部分は、例4の構造部分と同じです。この例が例4と異なるのは測定モデルだけです。

## 特定

このモデルの13の非観測変数では確実な特定はできません。パラメータに対する適切な制約によって各非観測変数の測定単位を固定する必要があります。この処理は、例4で非観測変数に使用した方法を13回繰り返すことによって行われます。この方法では、パス図で各非観測変数を起点とする一方向の矢印を探し、対応する係数を1などの任意の値に固定します。非観測変数を起点とする一方向矢印が複数ある場合、そのいずれかでこの処理を実行します。74ページの「モデルA」のパス図は、特定可能性制約の適切な選択肢の1つを示しています。

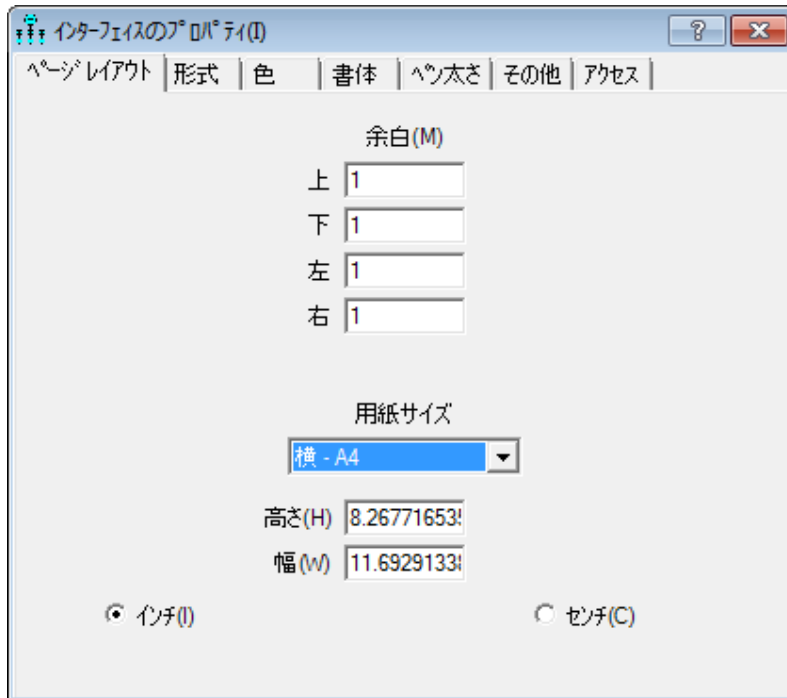
## モデルを指定する

パス図は縦長ではなく横長になるので、パス図に合うように描画領域の形を変更することができます。デフォルトでは、Amosの描画領域は印刷方向が縦の場合に合わせて幅より高さが大きくなっています。

### 描画領域の方向を変更する

- ▶ メニューから、[表示]→[インターフェイスのプロパティ]を選択します。
- ▶ [インターフェイスのプロパティ]ダイアログボックスで、[ページレイアウト]タブをクリックします。

- ▶ [用紙サイズ] を [A4 横] などの「横方向」用紙サイズに設定します。




- ▶ [適用] をクリックします。

## パス図を作成する

これで、ページ 74 のパス図に示すモデルを作成する準備ができました。モデルを作成するにはいくつかの方法があります。1つの方法は、最初に測定モデルを作成する方法です。ここでは、潜在変数の1つである知識の測定モデルを作成し、他の3つの原型として使用します。


- ▶ 非観測変数知識用の楕円を作成します。



- ▶ メニューから、[図] → [指標変数を描く] を選択します。

- ▶ 楕円の中を 2 回クリックします。

クリックするごとに、知識の指標変数が 1 つ作成されます。



画面からわかるように、[指標変数を描く]ボタンが有効になっている場合、非観測変数を複数回クリックして複数の指標を作成し、固有の変数またはエラー変数を完成できます。Amos Graphics は指標間の適切な間隔を保持し、識別制約を自動的に挿入します。


## 指標を回転する

デフォルトでは指標は知識の楕円の上に表示されますが、位置を変更することができます。

- ▶ メニューから、[編集] → [回転] を選択します。

- ▶ 知識の楕円をクリックします。

知識の楕円をクリックするごとに、指標が時計方向に 90° 回転します。楕円を 3 回クリックすると、指標は下の図のようになります。



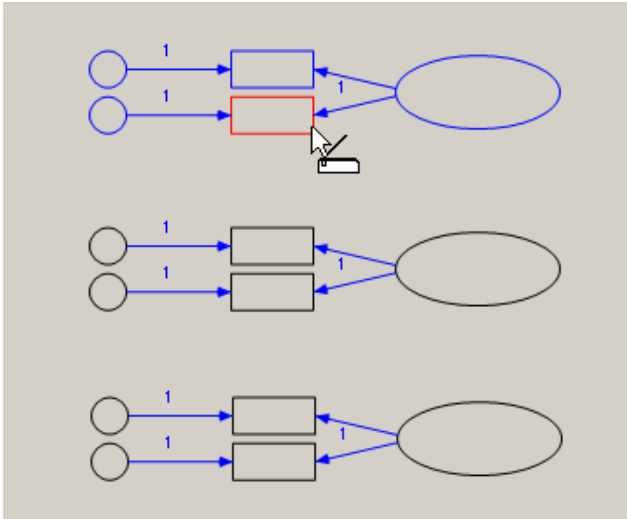
## 測定モデルを複製する

次の手順は、価値 と満足度の測定モデルの作成手順です。

- ▶ メニューから、[編集] → [すべて選択] を選択します。


測定モデルが青になります。

- ▶ メニューから、[編集]→[複写]を選択します。
- ▶ 測定モデルの任意の部分をクリックし、コピーを元の測定モデルの下にドラッグします。
- ▶ この手順を繰り返し、元の測定モデルの上に3つ目の測定モデルを作成します。  
パス図は次のように描かれているはずです。



- ▶ 成果用に4つ目のコピーを作成し、元の測定モデルの右に配置します。
- ▶ メニューから、[編集]→[反転]を選択します。

これにより、成果の2つの指標の配置が次のように変更されます。



## 変数名を入力する

- ▶ 各オブジェクトを右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログボックスで、[テキスト] タブをクリックし、[変数名] テキストボックスに名前を入力します。  
または、メニューから [表示] → [データセットに含まれる変数] を選択し、変数名をパス図内のオブジェクトにドラッグすることもできます。

## 構造モデルを完成する

構造モデルの完成に必要な手順は残りわずかです。

- ▶ 知識、価値、および満足度を結ぶ3つの共分散パスを作成します。
- ▶ 潜在的予測変数である知識、価値、および満足度のそれぞれから、潜在的従属変数である成果へ向かって一方向矢印を作成します。
- ▶ 非観測変数である誤差9を成果の予測変数として追加します(メニューから [図] → [固有の変数を描く] を選択します)。

74 ページに示すようなパス図が作成されます。このパス図を含む Amos Graphics の入力ファイルは Ex05-a.amw になります。

## モデル A の結果

練習として、次の自由度の計算を確認してください。

### 自由度の計算 (Default model)

独立な標本積率の数: 36  
 独立な推定パラメータの数: 22  
 自由度 (36 - 22): 14

モデル A が正しいという仮説が承認されます。

カイ2乗 = 10.335  
 自由度 = 14  
 確率水準 = .737



パラメータの推定値は、識別制約の影響を受けます。

係数: (グループ番号 1-モデル番号 1)						
			推定値	標準誤差	検定統計量	確率 ラベル
成果	<--	知識	.337	.125	2.697	.007
成果	<--	満足度	.061	.054	1.127	.260
成果	<--	価値	.176	.079	2.225	.026
2満足度	<--	満足度	.792	.438	1.806	.071
1満足度	<--	満足度	1.000			
2価値	<--	価値	.763	.185	4.128	***
1価値	<--	価値	1.000			
2知識	<--	知識	.683	.161	4.252	***
1知識	<--	知識	1.000			
1成果	<--	成果	1.000			
2成果	<--	成果	.867	.116	7.450	***
共分散: (グループ番号 1-モデル番号 1)						
			推定値	標準誤差	検定統計量	確率 ラベル
価値	<-->	知識	.037	.012	3.036	.002
満足度	<-->	価値	-.008	.013	-.610	.542
満足度	<-->	知識	.004	.009	.462	.644
分散: (グループ番号 1-モデル番号 1)						
			推定値	標準誤差	検定統計量	確率 ラベル
満足度			.090	.052	1.745	.081
価値			.100	.032	3.147	.002
知識			.046	.015	3.138	.002
誤差9			.007	.003	2.577	.010
誤差3			.041	.011	3.611	***
誤差4			.035	.007	5.167	***
誤差5			.080	.025	3.249	.001
誤差6			.087	.018	4.891	***
誤差7			.022	.049	.451	.652
誤差8			.045	.032	1.420	.156
誤差1			.007	.002	3.110	.002
誤差2			.007	.002	3.871	***

これに対し標準化推定値は、識別制約の影響を受けません。標準化推定値を計算するには、次の操作を行います。

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [標準化推定値] チェック ボックスをオンにします。

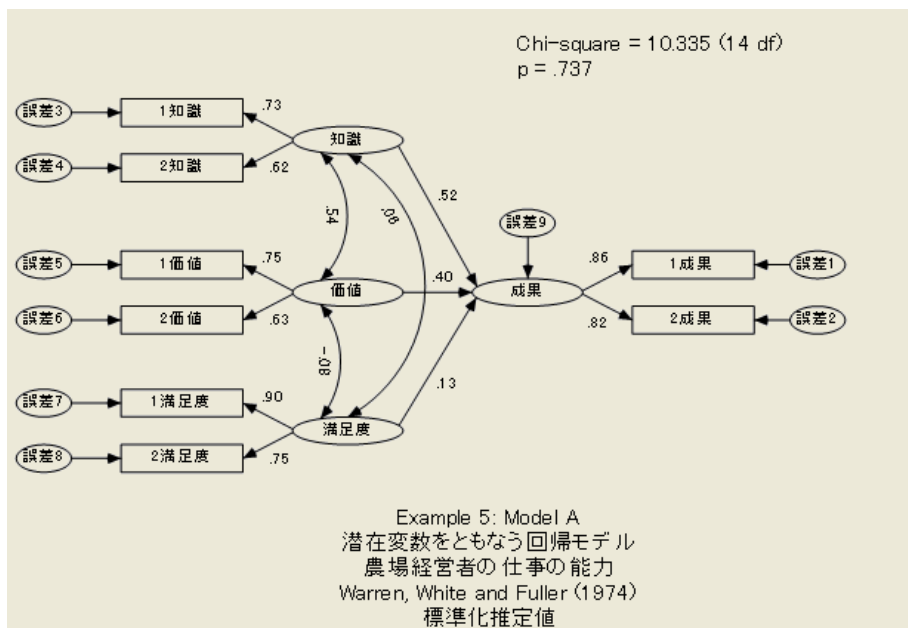
標準化係数: (ラベル*番号 1-モデル番号 1)		
		推定値
成果	<--- 知識	.516
成果	<--- 満足度	.130
成果	<--- 価値	.398
2満足度	<--- 満足度	.747
1満足度	<--- 満足度	.896
2価値	<--- 価値	.633
1価値	<--- 価値	.745
2知識	<--- 知識	.618
1知識	<--- 知識	.728
1成果	<--- 成果	.856
2成果	<--- 成果	.819

相関係数: (ラベル*番号 1-モデル番号 1)		
		推定値
価値	<--> 知識	.542
満足度	<--> 価値	-.084
満足度	<--> 知識	.064

## グラフィック出力を表示する

標準化推定値が表示されたパス図は次のようになります。



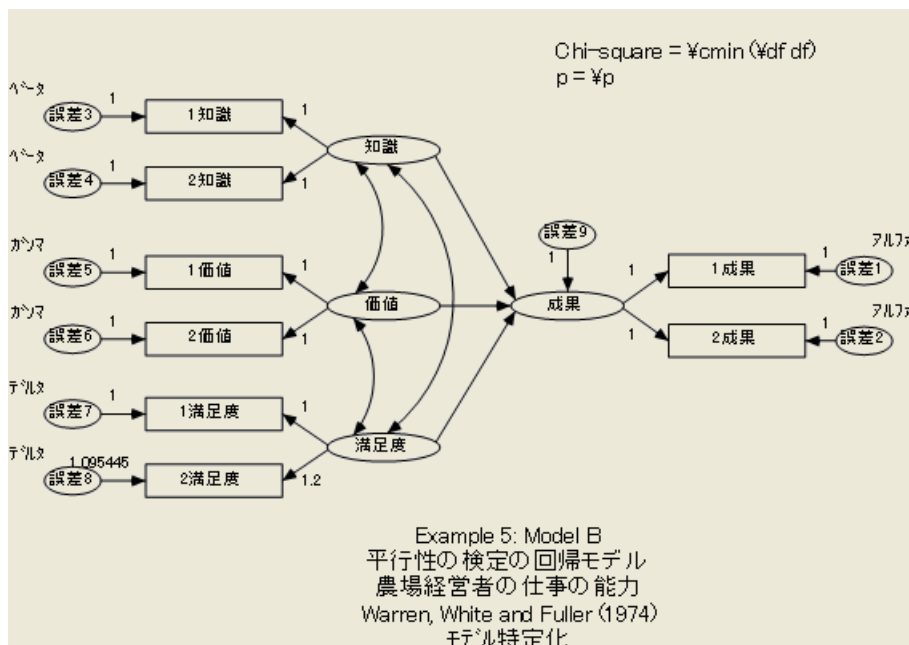
成果の上の値は、純粋な知識、価値、および満足度が、成果の分散の 66% を占めることを示します。観測変数の上に表示される値は、8 つの独立したサブセットの信頼性の推定値です。元の検定 (2 分割する前) で信頼性を求める式は、Rock 等の調査 (1977) または心理検定の理論に関する書籍に記載されています。

## モデル B

モデル A が正しい (反証がない) という仮定の上で、1 知識と 2 知識が並行検定であるという追加の仮定を検討します。並行検定の仮定では、知識に対する 1 知識の回帰が、知識に対する 2 知識の回帰と同じになる必要があります。さらに、1 知識と 2 知識に関連付けられた誤差変数の分散が等しくなる必要があります。1 成果と 2 成果だけでなく、1 価値と 2 価値も並列検定であるという仮定からも同様の結論が導かれます。ただし、1 満足度と 2 満足度が並行であるという仮定は完全に正しいとは言えません。元の検定の項目数が奇数であり、正確に 2 分割できないため、サブセットの一方がもう一方よりやや長くなります。つまり、2 満足度が 1 満足度より 20% 長くなります。これらの検定は長さのみ異なるという仮定から、次の結論が導かれます。

- 満足度に対する 2 満足度の回帰の係数は、満足度に対する 1 満足度の回帰の係数の 1.2 倍になる必要があります。
- 誤差 7 と誤差 8 の分散が等しいとすると、誤差 8 の係数は、誤差 7 の係数の  $\sqrt{1.2} = 1.095445$  倍の大きさになる必要があります。

これらのパラメータ制約を適用するため、パス図を最初から作成し直す必要はありません。モデル A 用に作成したパス図を土台として使用し、2 つの係数の値を変更します。変更後のパス図は次のようになります。



## モデル B の結果

モデル B ではパラメータ制約の追加により、次のように自由度が増加します。

### 自由度の計算 (モデル番号 1)

独立な標本積率の数: 36  
独立な推定パラメータの数: 14  
自由度 (36 - 14): 22

カイ 2 乗統計量も増加しますが、大幅な増加ではありません。これは、モデル B のデータからの逸脱が大きくないことを示します。

カイ 2 乗 = 26.967  
自由度 = 22  
確率水準 = .212

実際にモデル B が正しい場合、関連付けられたパラメータ推定値は、モデル A から取得される値より優先されます。ここでは、識別制約の選択による影響が大き過ぎるので、生のパラメータ推定値は提示されません。ただし、標準化推定値と重相関係数の平方は次のようになります。

**標準化係数: (グループ番号 1 - モデル番号 1)**

		推定値
成果	<--- 知識	.529
成果	<--- 満足度	.114
成果	<--- 価値	.382
2満足度	<--- 誤差8	.578
2満足度	<--- 満足度	.816
1満足度	<--- 満足度	.790
2価値	<--- 価値	.685
1価値	<--- 価値	.685
2知識	<--- 知識	.663
1知識	<--- 知識	.663
1成果	<--- 成果	.835
2成果	<--- 成果	.835

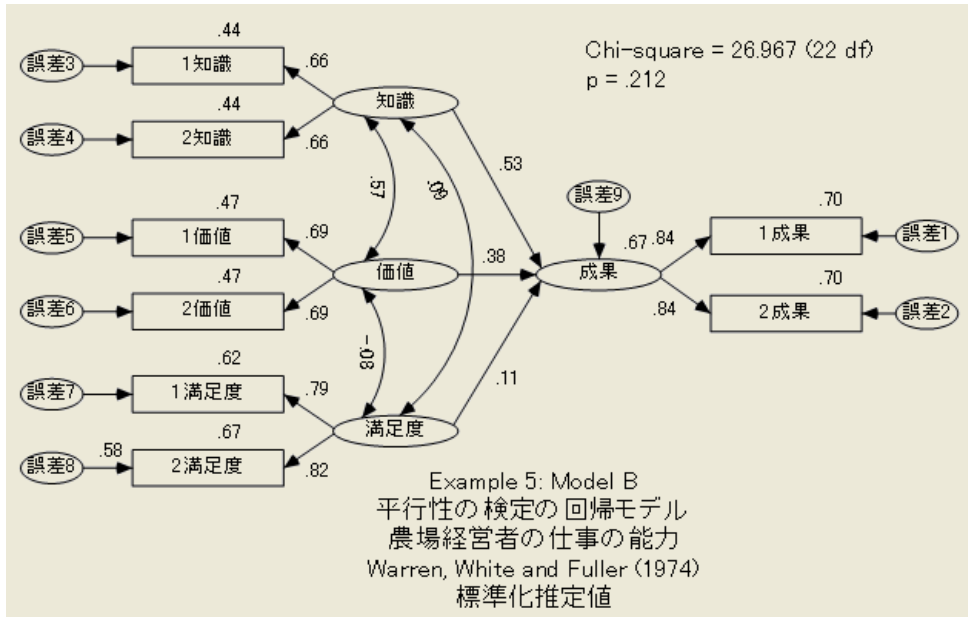
**相関係数: (グループ番号 1 - モデル番号 1)**

		推定値
満足度	<--> 価値	-.085
価値	<--> 知識	.565
満足度	<--> 知識	.094

**重相関係数の平方: (グループ番号 1 - モデル番号 1)**

	推定値
成果	.671
2成果	.698
1成果	.698
2満足度	.666
1満足度	.625
2価値	.469
1価値	.469
2知識	.439
1知識	.439

パス図に表示される標準化推定値と重相関係数の平方は次のようになります。



## モデル A に対するモデル B の検定

場合によっては、同じデータセット用のモデルとして 2 つの選択肢があり、どちらのモデルがデータにより適合するかを判断する必要があります。一方のパラメータに追加の制約を適用することによってもう一方のモデルを取得できる場合は常に、直接比較を実行できます。この例はそのようなケースです。ここでは、モデル A のパラメータに 8 つの追加制約を適用することによってモデル B を取得しました。たとえば、母集団パラメータに関する強い仮説を表すという意味において、2 つのモデルではモデル B が強いモデルです (モデル A が弱いモデルです)。強いモデルほど自由度が大きくなります。強いモデルのカイ 2 乗統計量は、少なくとも弱いモデルのカイ 2 乗統計量と同じ大きさになります。

弱いモデル (モデル A) に対する強いモデル (モデル B) の検定は、大きいカイ 2 乗統計量から小さいカイ 2 乗統計量を引くことによって得られます。この例では、新しい統計量は  $16.632 (= 26.967 - 10.335)$  になります。強いモデル (モデル B) が正しく指定されている場合、この統計量はカイ 2 乗と近似の分布を示し、自由度はもう一方のモデルの自由度との差に等しくなります。この例では、自由度の差は  $8 (= 22 - 14)$  になります。モデル B では、モデル A のすべてのパラメータ制約に加えて、8 つの制約を適用します。

要するに、モデル B が正しい場合、自由度 8 のカイ 2 乗分布から、16.632 という値が得られます。弱いモデル (モデル A) だけが正しく、強いモデル (モデル B) は正しくない場合、新しい統計量が大きくなる傾向があります。このため、新しいカイ 2 乗統計量が極端に大きくなる場合は、強いモデル (モデル B) を棄却して弱いモデル (モデル A) を選ぶ必要があります。自由度が 8 の場合、15.507 以上のカイ 2 乗値は 0.05 レベルで有意となります。この検定に基づいて、ここではモデル B を棄却します。

カイ 2 乗値 26.967、自由度 22 に基づく、モデル B が正しいという前の結論はどうなったのでしょうか。2 つの結論の不一致は、2 つの検定は仮定が異なるという理由によって説明できます。自由度 8 に基づく検定では、モデル B の検定時にモデル A が正しいと仮定します。自由度 22 に基づく検定では、モデル A に関するそのような仮定は行いません。モデル A が正しいと確信している場合は、モデル A に対してモデル B を比較する検定 (自由度 8 に基づく検定) を使用する必要があります。そうでない場合は、自由度 22 に基づく検定を使用する必要があります。

## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。

```

Sub Main()
    Dim Sem As New AmosEngine

    Try
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()

        Sem.BeginGroup(AmosEngine.AmosDir & "Examples#Warren9v.wk1")
        Sem.AStructure("1成果 <--- 成果 (1)")
        Sem.AStructure("2成果 <--- 成果")
        Sem.AStructure("1知識 <--- 知識 (1)")
        Sem.AStructure("2知識 <--- 知識")
        Sem.AStructure("1価値 <--- 価値 (1)")
        Sem.AStructure("2価値 <--- 価値")
        Sem.AStructure("1満足度 <--- 満足度 (1)")
        Sem.AStructure("2満足度 <--- 満足度")

        Sem.AStructure("1成果 <--- 誤差1 (1)")
        Sem.AStructure("2成果 <--- 誤差2 (1)")
        Sem.AStructure("1知識 <--- 誤差3 (1)")
        Sem.AStructure("2知識 <--- 誤差4 (1)")
        Sem.AStructure("1価値 <--- 誤差5 (1)")
        Sem.AStructure("2価値 <--- 誤差6 (1)")
        Sem.AStructure("1満足度 <--- 誤差7 (1)")
        Sem.AStructure("2満足度 <--- 誤差8 (1)")

        Sem.AStructure("成果 <--- 知識")
        Sem.AStructure("成果 <--- 満足度")
        Sem.AStructure("成果 <--- 価値")
        Sem.AStructure("成果 <--- 誤差9 (1)")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub

```

外生変数間の相関に関する Amos の仮定により (例4 参照)、知識、価値、および満足度の相関が可能であることをプログラムで示す必要はありません。また、誤差1、誤差2...、誤差9は相互に無相関であり、他のすべての外生変数とも無相関であることを示す必要もありません。



## モデル B

モデル B に適合するプログラムを次に示します。

```

Sub Main()
  Dim Sem As New AmosEngine

  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(AmosEngine.AmosDir & "Examples#Warren9v.wk1")
    Sem.AStructure("1成果 <--- 成果 (1)")
    Sem.AStructure("2成果 <--- 成果 (1)")
    Sem.AStructure("1知識 <--- 知識 (1)")
    Sem.AStructure("2知識 <--- 知識 (1)")
    Sem.AStructure("1価値 <--- 価値 (1)")
    Sem.AStructure("2価値 <--- 価値 (1)")
    Sem.AStructure("1満足度 <--- 満足度 (1)")
    Sem.AStructure("2満足度 <--- 満足度 (1.2)")

    Sem.AStructure("成果 <--- 知識")
    Sem.AStructure("成果 <--- 価値")
    Sem.AStructure("成果 <--- 満足度")
    Sem.AStructure("成果 <--- 誤差 (1)")

    Sem.AStructure("1成果 <--- 誤差1 (1)")
    Sem.AStructure("2成果 <--- 誤差2 (1)")
    Sem.AStructure("1知識 <--- 誤差3 (1)")
    Sem.AStructure("2知識 <--- 誤差4 (1)")
    Sem.AStructure("1価値 <--- 誤差5 (1)")
    Sem.AStructure("2価値 <--- 誤差6 (1)")
    Sem.AStructure("1満足度 <--- 誤差7 (1)")
    Sem.AStructure("2満足度 <--- 誤差8 (1.095445)")

    Sem.AStructure("誤差1 (アルファ)")
    Sem.AStructure("誤差2 (アルファ)")
    Sem.AStructure("誤差8 (デルタ)")
    Sem.AStructure("誤差7 (デルタ)")
    Sem.AStructure("誤差6 (ガンマ)")
    Sem.AStructure("誤差5 (ガンマ)")
    Sem.AStructure("誤差4 (ハータ)")
    Sem.AStructure("誤差3 (ハータ)")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub

```



# 探索分析

## 概要

この例では、時間に関する潜在変数を使用した構造モデルの作成、探索分析での修正指数と検定統計量の使用、単一分析での複数モデルの比較方法、およびモデルの積率、因子得点係数、総合効果、間接効果の計算方法について説明します。

## データについて

Wheaton 等は、1966 年から 1971 年にわたって 932 人のデータを長期的に追跡した調査結果を報告しました (1977)。Jöreskog および Sörbom 等は以後 Wheaton のデータを使用して、積率構造の分析を行っています (1984)。この例では、次に示す Wheaton の 6 つの測定値を使用します。

変数名	説明
anomia67 (失語傾向 (67 年))	anomia (失語傾向) 尺度の 1967 年の得点
anomia71 (失語傾向 (71 年))	1971 年の anomia (失語傾向) の得点
powles67 (無気力感 (67 年))	powles (無気力感) 尺度の 1967 年の得点
powles71 (無気力感 (71 年))	1971 年の powles (無気力感) の得点
education (教育年数)	1966 年に記録された就学年数
SEI (社会経済指標)	1966 年に使用された Duncan の社会経済指標

これら 6 つの測定値の標本の平均値、標準偏差、および相関を見てみましょう。SPSS Statistics ファイル *Wheaton.sav* に次の表があります。データの読み込み後、分析の必要に応じて Amos が標準偏差と相関を分散と共分散に変換します。この分析では標本の平均値は使用しません。

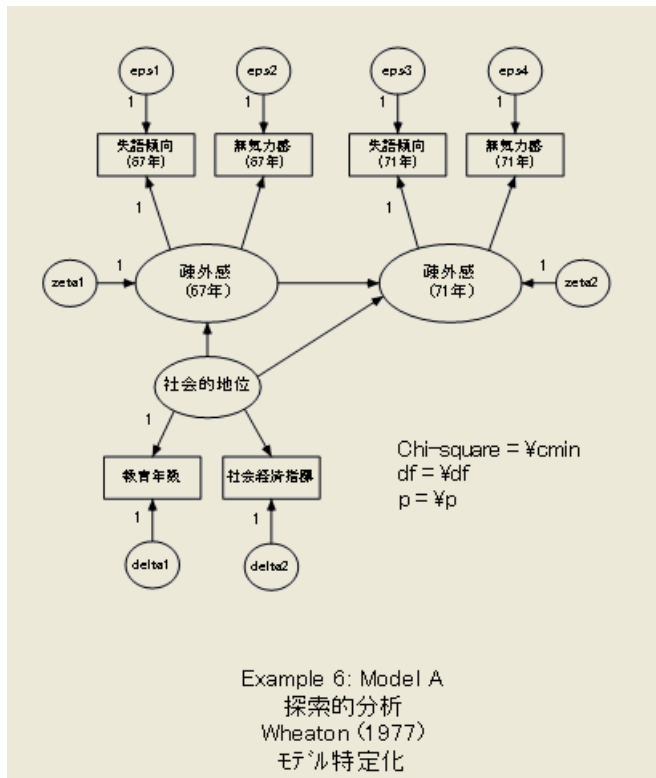
rowtype_	varname_	anomia67	powles67	anomia71	powles71	education	sei
n		932	932	932	932	932	932
corr	anomia67	1					
corr	powles67	0.66	1				
corr	anomia71	0.56	0.47	1			
corr	powles71	0.44	0.52	0.67	1		
corr	education	-0.36	-0.41	-0.35	-0.37	1	
corr	sei	-0.3	-0.29	-0.29	-0.28	0.54	1
stddev		3.44	3.06	3.54	3.16	3.1	21.22
mean		13.61	14.76	14.13	14.9	10.9	37.49

## Wheaton データ用のモデル A

Jöreskog と Sörbom は、93 ページ に示す Wheaton データ用のモデルを提示し (1984)、モデル A と呼んでいます。このモデルでは、すべての観測変数が、元になる非観測変数に依存すると断定します。たとえば、*anomia67* (失語傾向 (67 年)) と *powles67* (無気力感 (67 年)) の両方が非観測変数 *67\_alienation* (疎外感 (67 年)) に依存します。この変数は、Jöreskog と Sörbom が疎外感と呼ぶ仮想変数です。非観測変数 *eps1* と *eps2* は、例 5 における変数誤差 1 と誤差 2 と同じ役割を果たすように見えます。ただし、ここでは解釈が異なります。例 5 では、誤差 1 と誤差 2 は測定誤差として自然に解釈されません。この例では、*anomia* (失語傾向) 尺度と *powles* (無気力感) 尺度が同じ対象を測定するように設計されていないため、それらの相違は測定誤差によるものだけではないと判断する方が妥当と思われる。このため、この場合の *eps1* と *eps2* は、*anomia67* (失語傾向 (67 年)) と *powles67* (無気力感 (67 年)) の測定誤差を表すだけでなく、*67\_alienation* (疎外感 (67 年)) (両方に影響する変数の 1 つ) の他に 2 つの検定の得点に影響する可能性があるすべての変数を表すと考える必要があります。

## モデルの特定化

Amos Graphics でモデル A を指定するには、次に示すパス図を作成するか、標本ファイル Ex06-a.amw を開きます。8 つの固有の変数 (delta1、delta2、zeta1、zeta2、および eps1 ~ eps4) は相互に無相関であり、3 つの潜在的変数 ses、67\_alienation (疎外感 (67年))、および 71\_alienation (疎外感 (71年)) とともに無相関であることに注意してください。



## 特定

モデル A は、各非観測変数の測定尺度が不定であるという一般的な問題を除いて特定されます。各非観測変数の測定尺度は、その変数を基点とするパスのいずれかで係数を単一の値 (1) に設定することによって自由に固定できます。パス図には、単一の値 (1) に固定された 11 の係数、つまり、非観測変数ごとに 1 つの制約が示されています。これらの制約によって十分にモデルを特定できます。

## 分析の結果

このモデルには、推定される 15 個のパラメータ (6 個の係数と 9 個の分散) があります。また、21 個の標本の積率 (6 個の標本分散と 15 個の標本共分散) があります。これにより自由度が 6 のままになります。

### 自由度の計算 (モデル番号 1)

独立な標本積率の数: 21  
 独立な推定パラメータの数: 15  
 自由度 (21 - 15): 6

Wheaton のデータはモデル A のデータから大きく離れています。

カイ2乗 = 71.544  
 自由度 = 6  
 確率水準 = .000

## 棄却の処理

提示されたモデルを統計的な見地から棄却する必要がある場合、いくつかの方法があります。

- 統計仮説の検定は、モデルの選択には不適切であると言えます。Jöreskog は、因子分析においてこの問題を取り上げました (1967)。モデルは、よくても近似に過ぎず、幸いにして正確に一致しなくても有効であるという考え方が広く受け入れられています。この考え方によると、非常に多くの標本を使用して検定を行った場合、統計的な見地からモデルの棄却が発生することは避けられません。この点から考えると、純粋に統計的な見地によるモデルの棄却は (特に標本が大きい場合) 必ずしも問題ではありません。
- 棄却されたモデルに代わる別のモデルを最初から考案することができます。
- 棄却されたモデルがデータにより適合するように小規模な修正を加えることができます。

この例では最後の方法について説明します。データに適合するようにモデルを修正する最も自然な方法は、いくつかの仮定を緩める方法です。たとえば、モデル A では `eps1` と `eps3` が無相関であると仮定しています。`eps1` と `eps3` を双方向矢印で結ぶことにより、この制限を緩めることができます。このモデルでは、`anomia67` (失語傾向 (67年)) は `ses` に直接依存しないことも指定されています。`ses` から `anomia67` (失語傾向 (67年)) に一方向矢印を描くことにより、この仮定を削除できます。モデル A では、制約によってパラメータを他のパラメータと等しくすることはありませんが、そのような制約が存在する場合、適合度を高めるためこのような制約の削除を検討する場合があります。当然のことながら、モデルの仮定を緩める際には、特定されるモデルが特定されないモデルにならないように注意する必要があります。

## 修正指数

修正の可能性ごとに個別の分析を実行することにより、モデルに対するさまざまな修正を検定できますが、この方法は時間がかかります。修正指数を使用すると、多くの修正の可能性を単一の分析で評価できます。これにより、小さいカイ 2 乗値で効果が上がるようなモデル修正案が提示されます。

### 修正指数を使用する

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [修正指数] チェック ボックスをオンにします。この例では、[修正指数の閾値] が [4] に設定されたままにします。

モデル A の修正指数を次に示します。

修正指数 (Group number 1 - Default model)		
<b>共分散: (Group number 1 - Default model)</b>		
	修正指数	改善度
eps2 <--> delta1	5.905	-.424
eps2 <--> eps4	26.545	.825
eps2 <--> eps3	32.071	-.988
eps1 <--> delta1	4.609	.421
eps1 <--> eps4	35.367	-1.069
eps1 <--> eps3	40.911	1.253
<b>分散: (Group number 1 - Default model)</b>		
	修正指数	改善度
<b>係数: (Group number 1 - Default model)</b>		
	修正指数	改善度
powles71 <--- powles67	5.457	.057
powles71 <--- anomia67	9.006	-.065
anomia71 <--- powles67	6.775	-.069
anomia71 <--- anomia67	10.352	.076
powles67 <--- powles71	5.612	.054
powles67 <--- anomia71	7.278	-.054
anomia67 <--- powles71	7.706	-.070
anomia67 <--- anomia71	9.065	.068

表の列見出しの M.I. は、修正指数 (Modification Index) の略です。この修正指数は、Jöreskog および Sörbom によって示された指数です (1984)。最初に示されている修正指数 (5.905) は、eps2 と delta1 の相関が可能な場合に発生するカイ 2 乗の減少を控えめに推定した値です。新しいカイ 2 乗統計量は自由度が 5 ( $= 6 - 1$ ) になり、65.639 ( $71.544 - 5.905$ ) より大きくなることはありません。実際にはカイ 2 乗統計量の減少が 5.905 より大きくなる可能性があります。Par Change の列は、各パラメータが 0 に固定されずに推定された場合の変化の概算値を示します。Amos は、eps2 と delta1 の間の共分散を  $-0.424$  と推定します。小さい修正指数に基づき、eps2 と delta1 の相関を可能にすることによって得られるものは多くないと考えられます。また、許容可能な適合度が得られたとしても、理論的に見てこの修正が正しいとは言えません。

### 修正指数の閾値を変更する

デフォルトでは 4 以上の修正指数のみ表示されますが、この閾値は変更できます。

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [修正指数の閾値] テキスト ボックスに値を入力します。非常に低い閾値を設定すると、小さ過ぎて意味のない修正指数が多数表示されます。

モデル A の最大修正指数は 40.911 です。これは、eps1 と eps3 の相関を可能にすると、カイ 2 乗統計量が少なくとも 40.911 減少することを示します。これら 2 つの変数が相関する必要があることは妥当と思われるので、この修正は考慮に値します。Eps1 は、67\_alienation (疎外感(67年)) の変化に起因しない anomia67 (失語傾向(67年)) の変動を表します。同様に eps3 は、71\_alienation (疎外感(71年)) の変化に起因しない anomia71 (失語傾向(71年)) の変動を表します。nomia67 (失語傾向(67年)) と anomia71 (失語傾向(71年)) は、同じ計測による (異なる時間の) 尺度の得点です。nomia (失語傾向) 尺度によって alienation 以外の測定を行う場合、eps1 と eps3 の間にゼロ以外の相関が期待されます。実際には正の相関が期待されますが、これは Par Change 列の数値が正であるという事実と合致します。


eps1 と eps3 が相関すると予測する理論的な根拠は、eps2 と eps4 にも適用されます。修正指数は、eps2 と eps4 の相関の可能性も提示します。ただし、ここではこの修正の可能性を無視し、eps1 と eps3 の相関を可能にすることによってモデル A の結果の確認に進みます。新しいモデルは Jöreskog と Sörbom のモデル B になります。



## Wheaton データ用のモデル B

モデル A のパス図を基に、eps1 と eps3 の間に双方向矢印を描くことにより、モデル B を取得できます。新しい双方向矢印が印刷領域を超えて伸びる場合、[形] ボタンを使用して双方向矢印のカーブを調整できます。[移動] ボタンを使用して双方向矢印の終点の位置を変更することもできます。

モデル B のパス図は Ex06-b.amw ファイルにあります。



## テキスト出力

eps1 と eps3 の間に追加された共分散により、自由度が 1 減少します。

独立な標本積率の数: 21
独立な推定パラメータの数: 15
自由度 (21 - 15): 6

カイ2乗統計量は、既定の 40.911 より大幅に低下します。

カイ2乗 = 6.383  
 自由度 = 5  
 確率水準 = .271

モデル B は棄却できません。モデル B の適合度に問題がないので、eps2 と eps4 の相関を可能にするという、上で説明した可能性は追求しません (モデル B に欠けている対称性を実現するため、eps2 と eps4 の間のゼロ以外の相関を可能にする引数を作成できます)。

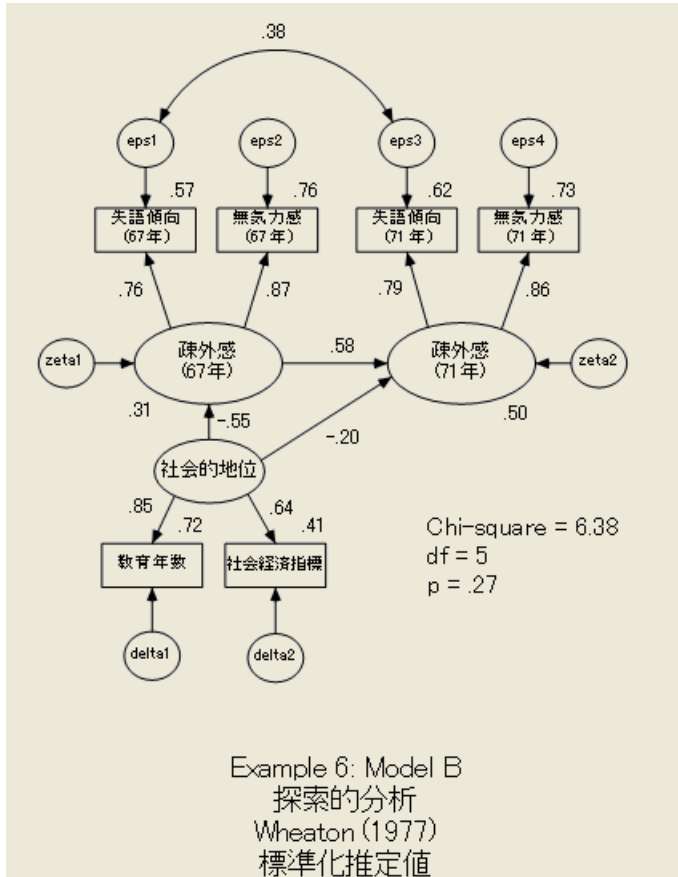
異なる識別制約が適用されている場合、生のパラメータ推定値が異なるので、これらの推定値の解釈には注意が必要です。

係数: (Group number 1 - Default model)				
	推定値	標準誤差	検定統計量	確率ラベル
67_alienation <--- ses	-.550	.053	-10.294	***
71_alienation <--- 67_alienation	.617	.050	12.421	***
71_alienation <--- ses	-.212	.049	-4.294	***
powles71 <--- 71_alienation	.971	.049	19.650	***
anomia71 <--- 71_alienation	1.000			
powles67 <--- 67_alienation	1.027	.053	19.322	***
anomia67 <--- 67_alienation	1.000			
educatio <--- ses	1.000			
SEI <--- ses	5.164	.421	12.255	***
共分散: (Group number 1 - Default model)				
	推定値	標準誤差	検定統計量	確率ラベル
eps1 <--> eps3	1.886	.240	7.866	***
分散: (Group number 1 - Default model)				
	推定値	標準誤差	検定統計量	確率ラベル
ses	6.872	.657	10.458	***
zeta1	4.700	.433	10.864	***
zeta2	3.862	.343	11.257	***
eps1	5.059	.371	13.650	***
eps2	2.211	.317	6.968	***
eps3	4.806	.395	12.173	***
eps4	2.681	.329	8.137	***
delta1	2.728	.516	5.292	***
delta2	266.567	18.173	14.668	***

新しい共分散パスに関連付けられた検定統計量が大きいことに注意してください。eps1 と eps3 の間の共分散は明らかにゼロではありません。このことは、共分散が 0 に固定されたモデル A の適合度が不十分であることを示します。

## モデル B のグラフィック出力

次のパス図に、標準化推定値と重相関係数の平方を示します。



モデル内の誤差変数が表すのは測定誤差だけではないため、重相関係数の平方を信頼性の推定値として解釈することはできません。むしろ、各重相関係数の平方は、対応する信頼性の下限の推定値になります。たとえば、**education** (教育年数) の例を考えてみましょう。ses が分散の 72% を占めています。これにより、信頼性が少なくとも 0.72 であると推定されます。教育年数が就学年数で測定されることを考えると、その信頼性ははるかに大きいと思われます。

## 修正指数の誤用

モデルを改良する際に、修正指数に全面的に従う必要はありません。理論的または常識的に意味がある場合のみ修正を考える必要があります。

そのような制限なしで修正指数を盲信すると、適合度の大幅な向上を求めて非常に多くの修正の可能性を調べることとなります。このような方法は、偶然の利用により、許容可能なカイ 2 乗値を含む不適切な (不合理な) モデルを生成する傾向があります。この問題は、MacCallum (1986) と、MacCallum、Rozenowski、および Necowitz (1992) によって取り上げられています。

## 新しい制約の追加によってモデルを改良する

修正指数は、カイ 2 乗統計量が自由度より速く減少するように、パラメータ数を増加することによってモデルを改良する方法を提示します。この技法は誤用の可能性もありますが、多くの調査で適切な役割を果たしています。その他の技法を使用して、許容可能なカイ 2 乗値をより多く含むモデルを生成することもできます。この技法では、カイ 2 乗統計量の増加が比較的少なくなると共に、自由度の増加が比較的大きくなるように追加の制約を導入します。このような修正の多くは、C.R. 列の検定統計量を確認することによって大まかに評価できます。単一の検定統計量を使用して、単一の母集団パラメータが 0 に等しくなるという仮説の検定を行う方法については既に説明しました (例 1 参照)。ただし、検定統計量には別の解釈もあります。パラメータの検定統計量の 2 乗は、そのパラメータを 0 に固定して分析を繰り返す場合にカイ 2 乗統計量が増加する量とほぼ等しくなります。

### 検定統計量を計算する

2 つのパラメータ推定値がほぼ等しいことが判明した場合、それら 2 つのパラメータが正確に等しくなるように指定された新しいモデルを仮定することにより、適合度のカイ 2 乗検定を改良できます。大きな差がないパラメータのペアの配置を支援するため、Amos ではパラメータのペアごとに検定統計量を提供します。

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [差に対する検定統計量] チェック ボックスをクリックします。

Amos ではパラメータの差に対する検定統計量を計算する際に、モデルの指定時に名前を付けなかったパラメータ用に名前を生成します。名前はテキスト出力のパラメータ推定値の横に表示されます。

モデル B のパラメータ推定値を次に示します。Amos によって生成されたパラメータ名は Label 列に示されます。

<b>係数: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
67_alienation <--- ses	-.550	.053	-10.294	***	par_6
71_alienation <--- 67_alienation	.617	.050	12.421	***	par_4
71_alienation <--- ses	-.212	.049	-4.294	***	par_5
powles71 <--- 71_alienation	.971	.049	19.650	***	par_1
anomia71 <--- 71_alienation	1.000				
powles67 <--- 67_alienation	1.027	.053	19.322	***	par_2
anomia67 <--- 67_alienation	1.000				
educatio <--- ses	1.000				
SEI <--- ses	5.164	.421	12.255	***	par_3
<b>共分散: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
eps1 <--> eps3	1.886	.240	7.866	***	par_7
<b>分散: (Group number 1 - Default model)</b>					
	推定値	標準誤差	検定統計量	確率	ラベル
ses	6.872	.657	10.458	***	par_8
zeta1	4.700	.433	10.864	***	par_9
zeta2	3.862	.343	11.257	***	par_10
eps1	5.059	.371	13.650	***	par_11
eps2	2.211	.317	6.968	***	par_12
eps3	4.806	.395	12.173	***	par_13
eps4	2.681	.329	8.137	***	par_14
delta1	2.728	.516	5.292	***	par_15
delta2	266.567	18.173	14.668	***	par_16

パラメータ名は、次の表で検定統計量を解釈するために必要です。

Critical Ratios for Differences between Parameters (Default model)

	par_1	par_2	par_3	par_4	par_5	par_6
par_1	.000					
par_2	.877	.000				
par_3	9.883	9.741	.000			
par_4	-4.429	-5.931	-10.579	.000		
par_5	-17.943	-16.634	-12.284	-18.098	.000	
par_6	-22.343	-26.471	-12.661	-17.300	-5.115	.000
par_7	3.903	3.689	-6.762	5.056	8.490	10.124
par_8	8.955	8.866	1.707	9.576	10.995	11.797
par_9	8.364	7.872	-.714	9.256	11.311	12.047
par_10	7.781	8.040	-2.362	9.470	11.683	12.629
par_11	11.106	11.705	-.186	11.969	14.039	15.431
par_12	3.826	3.336	-5.599	4.998	7.698	8.253
par_13	10.425	9.659	-.621	10.306	12.713	13.575
par_14	4.697	4.906	-4.642	6.353	8.554	9.602
par_15	3.393	3.283	-7.280	4.019	5.508	5.975
par_16	14.615	14.612	14.192	14.637	14.687	14.712

Critical Ratios for Differences between Parameters (Default model)

	par_7	par_8	par_9	par_10	par_11	par_12
par_7	.000					
par_8	7.128	.000				
par_9	5.388	-2.996	.000			
par_10	4.668	-4.112	-1.624	.000		
par_11	9.773	-2.402	.548	2.308	.000	
par_12	.740	-6.387	-5.254	-3.507	-4.728	.000
par_13	8.318	-2.695	1.69	1.554	-.507	5.042
par_14	1.798	-5.701	-3.909	-2.790	-4.735	.999
par_15	1.482	-3.787	-2.667	-1.799	-3.672	.855
par_16	14.563	14.506	14.439	14.458	14.387	14.544

Critical Ratios for Differences between Parameters (Default model)

	par_13	par_14	par_15	par_16
par_13	.000			
par_14	-3.322	.000		
par_15	-3.199	.077	.000	
par_16	14.400	14.518	14.293	.000

主対角線の下にある 0 を無視すると、検定統計量の表にはパラメータのペアごとに 1 つずつ、合計 120 のエントリがあります。表の左上付近にある 0.877 という数値に着目してください。この検定統計量は、par\_1 と par\_2 という名前のパラメータの差を、この差の推定標準誤差で割った値です。これら 2 つのパラメータは、powles71 (無気力感(71年)) ← 71\_alienation (疎外感(71年)) および powles67 (無気力感(67年)) ← 67\_alienation (疎外感(67年)) の係数です。

32 ページに示す分布の仮定に基づき、標準正規分布の表を使用して検定統計量を評価し、2 つのパラメータが母集団において等しいかどうかを検定できます。0.877 は 1.96 より小さいので、2 つの係数が母集団において等しいという仮説を 0.05 レベルでは否定しません。

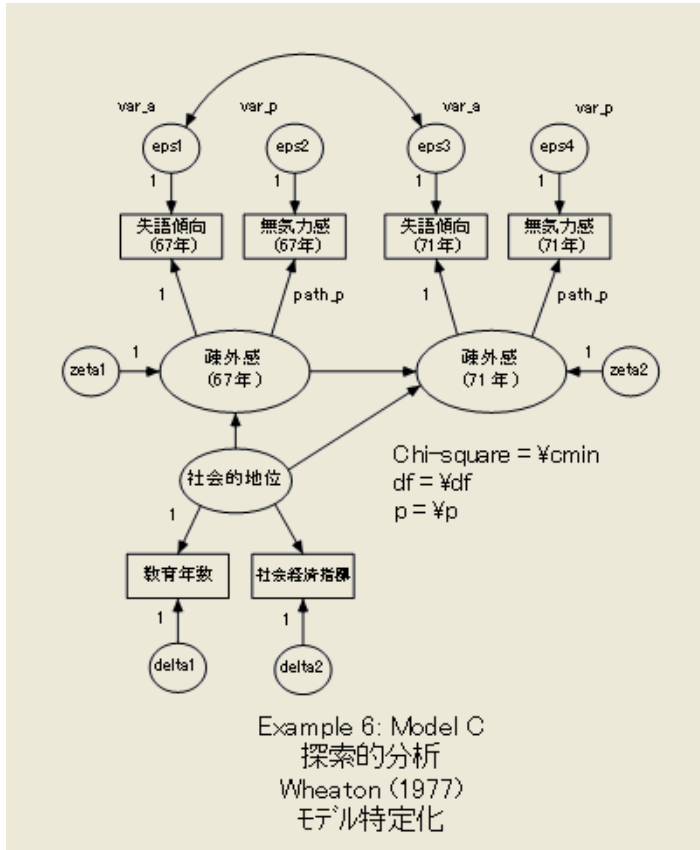
パラメータ間の差に対する検定統計量の 2 乗は、2 つのパラメータが等しくなるように設定された場合にカイ 2 乗統計量が増加する量とほぼ同じです。0.877 の 2 乗は 0.769 なので、2 つの係数の推定値が等しくなるようにモデル B を修正すると、カイ 2 乗値はおよそ  $6.383 + 0.769 = 7.172$  になります。新しいモデルの自由度は 5 ではなく 6 になります。適合度は向上しますが (モデル B の  $p = 0.307$  に対し  $p = 0.275$ )、それ以上のことはできません。

最小検定統計量を見てみましょう。表の最小検定統計量は、par\_14 と par\_15 という名前のパラメータの 0.077 です。これらの 2 つのパラメータは、eps4 と delta1 の分散です。0.077 の 2 乗は約 0.006 です。eps4 と delta1 の分散が等しくなると仮定するモデル B の修正により、カイ 2 乗値が 6.383 を約 0.006 超えますが、自由度は 5 ではなく 6 です。関連する確率レベルは約 0.381 になります。この修正の唯一の問題は、修正に正当な理由がないと思われることです。つまり、eps4 と delta1 の分散が等しくなると予測する先験見的な理由がないと思われます。

差に対する検定統計量の表の誤用については先程説明しました。ただし、この表は少数の仮定の迅速な調査には有効です。この表の適切な使用例として、anomia67 (失語傾向(67年)) と anomia71 (失語傾向(71年)) の観測値が、2 つの状況で同じ計測方法を使用して取得されたという事実を考えてみてください。同じことは powles67 (無気力感(67年)) と powles71 (無気力感(71年)) にも当てはまります。2 つの状況で検定が同様の役割を果たすことは妥当であると思われます。差に対する検定統計量は、この仮定と一致します。eps1 と eps3 (par\_11 と par\_13) の分散は、検定統計量 -0.51 と異なります。eps2 と eps4 (par\_12 と par\_14) の分散は、検定統計量 1.00 と異なります。alienation での powles (無気力感) の係数 (par\_1 and par\_2) は、検定統計量 0.88 と異なります。個々に見た場合、これらの差のいずれも従来の有意確率で有意ではありません。これは、3 つの差がすべて 0 になるように制約されるモデルをより注意して調査する価値があることを示します。この新しいモデルをモデル C と呼びます。

## Wheaton データ用のモデル C

Ex06-c.amw ファイルにあるモデル C のパス図を次に示します。



path\_p では、alienation (疎外感) から powles (無気力感) を予測するための係数が、1967年と1971年で同じになる必要があります。var\_a を使用して、eps1 と eps3 の分散が等しくなるように指定します。var\_p を使用して、eps2 と eps4 の分散が等しくなるように指定します。

## モデル C の結果

モデル C はモデル B より自由度が3 上がります。

### 自由度の計算 (Default model)

独立な標本積率の数: 21  
独立な推定パラメータの数: 13  
自由度 (21 - 13): 8



## Model C の検定

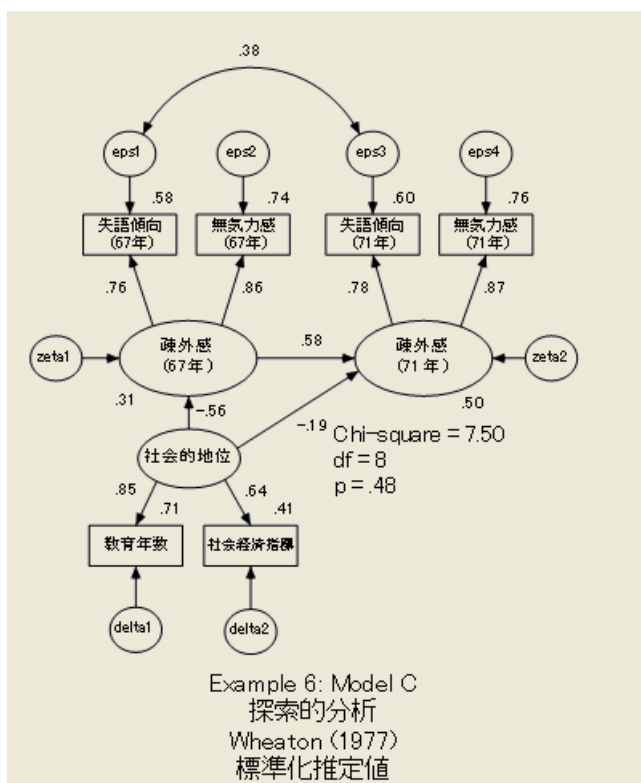
予想どおりモデル C は許容可能な適合度を示し、確率レベルがモデル B より高くなります。

カイ2乗 = 7.501 自由度 = 8 確率水準 = .484
--

モデル B に対するモデル C の検定は、カイ 2 乗値の差 ( $7.501 - 6.383 = 1.118$ ) と自由度の差 ( $8 - 5 = 3$ ) を調べることによって実行できます。カイ 2 乗値 1.118、自由度 3 は有意ではありません。

## モデル C のパラメータ推定値

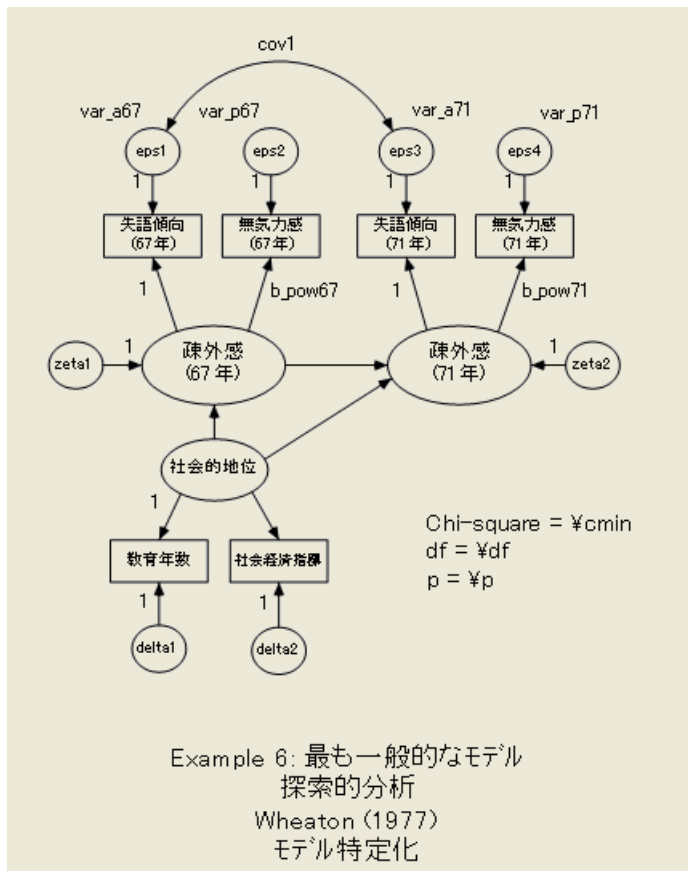
モデル C の標準化推定値を次に示します。



## 単一分析での複数モデルの使用

Amos では単一の分析に複数のモデルを適合できます。これにより、すべてのモデルの結果を 1 つの表にまとめることができます。Amos では入れ子にしたモデルの比較でカイ 2 乗検定を実行することも可能です。この例では、モデル B のパラメータ制約によってモデル A と C をそれぞれ取得できるように指定することにより、モデル A、B、および C を単一の分析に適合できます。


Ex06-all.amw ファイルに含まれる次のパス図では、モデル A またはモデル C を生成するために制約する必要があるモデル B のパラメータに次の名前が割り当てられています。



このパス図の 7 つのパラメータには、var\_a67、var\_p67、var\_a71、var\_p71、b\_pow67、b\_pow71、および cov1 という名前が付けられています。2 つのパラメータに同じ名前が付けられることはないため、パラメータに名前を付けることによってパラメータが等しくなるように制約されることはありません。ただし、これから説明するように、変数に名前を付けることによってさまざまな方法でパラメータを制約できます。

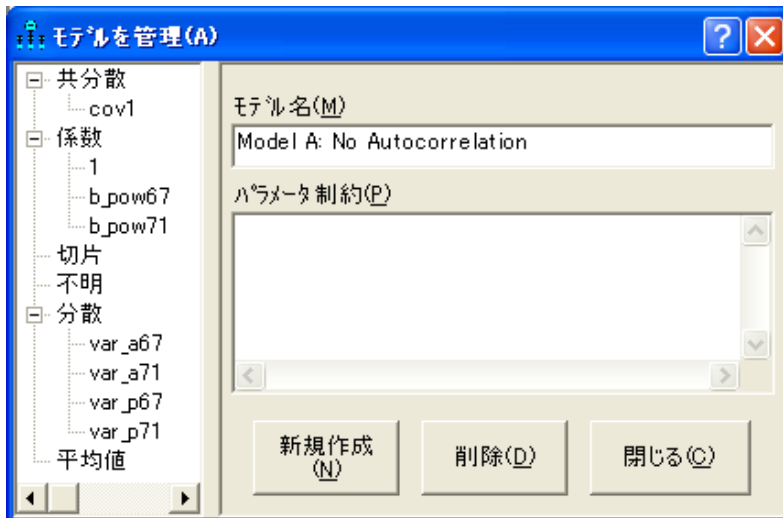
上に示すパラメータ名を使用して、cov1 = 0 を要求することにより、最も一般的なモデル (モデル B) からモデル A を取得できます。

- ▶ パス図の左側にある [モデル] パネルで、[デフォルト モデル] をダブルクリックします。

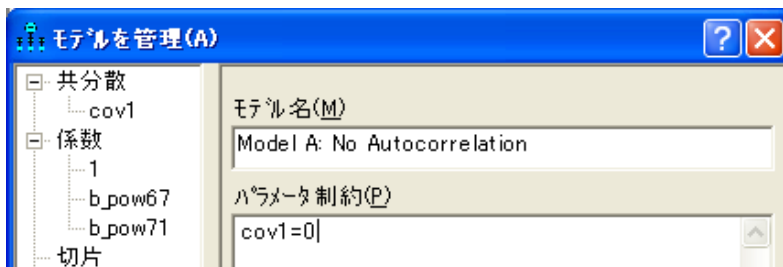


[モデル管理] ダイアログ ボックスが表示されます。

- ▶ [モデル名] テキスト ボックスに、「Model A: No Autocorrelation」と入力します。



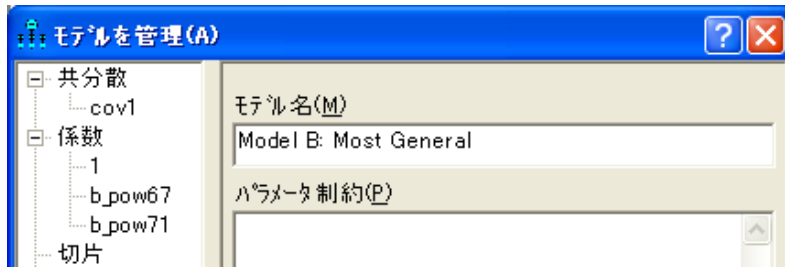
- ▶ 左側のパネルで cov1 をダブルクリックします。  
[パラメータ制約] ボックスに cov1 が表示されることを確認します。
- ▶ [パラメータ制約] ボックスに「cov1=0」と入力します。



これでモデル A の指定が完了しました。

- ▶ [モデル管理] ダイアログ ボックスで、[新規作成] をクリックします。

- ▶ [モデル名] テキスト ボックスに、「Model B: Most General」と入力します。



モデル B にはパス図に示す以外の制約がないので、直ちにモデル C に進むことができます。

- ▶ [新規作成] をクリックします。
- ▶ [モデル名] テキスト ボックスに、「Model C: Time-Invariance」と入力します。
- ▶ [パラメータ制約] ボックスに、次のように入力します。

```
b_pow67 = b_pow71
var_a67 = var_a71
var_p67 = var_p71
```

完成度を高めるため、4 つ目のモデル (モデル D) を導入し、モデル A の 1 つの制約とモデル C の 3 3 つの制約を結合します。モデル D は制約を入力し直さなくても指定できます。

- ▶ [新規作成] をクリックします。
- ▶ [モデル名] テキスト ボックスに、「Model D: A and C Combined」と入力します。
- ▶ [パラメータ制約] ボックスに、次のように入力します。

```
Model A: No Autocorrelation
Model C: Time-Invariance
```


これらの行により、Model A と Model C の両方の制約をモデル D に組み込むことを指定します。

これで 4 つのモデルすべてのパラメータ制約が設定されました。最後の手順は、分析の実行と出力の表示です。

## 複数モデルによる出力

### 個々のモデルのグラフィック出力を表示する

複数のモデルを適合している場合、[モデル] パネルを使用して個々のモデルの図を表示します。[モデル] パネルはパス図の左隣にあります。モデルを表示するには、モデルの名前をクリックします。



### 4つのモデルすべての適合度の統計を表示する

- ▶ メニューから、[表示] → [テキスト出力の表示] の順にクリックします。
- ▶ [Amos出力] ウィンドウの左上のウィンドウ枠にあるツリー図で、[モデルの適合度] をクリックします。

カイ2乗統計量を表示する出力の一部を次に示します。

CMIN					
モデル	NPAR	CMIN	自由度	確率	CMIN/DF
Model A: No Autocorrelation	15	71.544	6	.000	11.924
Model B: Most General	16	6.383	5	.271	1.277
Model C: Time-Invariance	13	7.501	8	.484	.938
Model D: A and C Combined	12	73.077	9	.000	8.120
飽和モデル	21	.000	0		
独立モデル	6	2131.790	15	.000	142.119

CMIN 列には、各モデルの最小乖離度が示されます。最尤法の推定値の場合(デフォルト)、CMIN 列はカイ2乗統計量になります。p 列には、各モデルの検定用の対応する上側確率が示されます。

モデルのペアが入れ子になっている場合、カイ2乗比較検定と関連付けられた p 値を含む、モデル比較表が提供されます。

- ▶ [Amos 出力] ウィンドウの左上のウィンドウ枠にあるツリー図で、[モデル比較] をクリックします。

ネストしたモデルの比較							
<b>モデル Model A: No Autocorrelation は正しいという仮定の下で:</b>							
モデル	自由度	CMIN	確率	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
Model D: A and C Combined	3	1.533	.675	.001	.001	-.027	-.027
<b>モデル Model B: Most General は正しいという仮定の下で:</b>							
モデル	自由度	CMIN	確率	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
Model A: No Autocorrelation	1	65.160	.000	.031	.031	.075	.075
Model C: Time-Invariance	3	1.117	.773	.001	.001	-.002	-.002
Model D: A and C Combined	4	66.693	.000	.031	.031	.048	.048
<b>モデル Model C: Time-Invariance は正しいという仮定の下で:</b>							
モデル	自由度	CMIN	確率	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
Model D: A and C Combined	1	65.576	.000	.031	.031	.051	.051

たとえば、この表からモデル C の適合度はモデル B より大きく低下しないことがわかります ( $p = 0.773$ )。つまり、モデル B が正しいと仮定すると、時間不変性の仮説を受け入れることとなります。

一方で、モデル A の適合度はモデル B より大きく低下することがわかります ( $p = 0.000$ )。つまり、Model B が正しいと仮定すると、 $\text{eps1}$  と  $\text{eps3}$  が無相関であるという仮説を否定することとなります。

## オプション出力を取得する

観測変数間の分散と共分散は、モデル C が正しいという仮説の下で推定できます。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [モデルの積率] を選択します (チェック マークが表示されます)。
- ▶ モデル内の誤差変数を除くすべての変数に対するモデルの分散と共分散を取得するには、[全変数に対するモデルの積率] を選択します。

モデル C で [全変数に対するモデルの積率] を選択すると、次の出力が得られます。

モデルの(全変数に関する)共分散 (Group number 1 - Model C: Time-Invariance)						
	ses	67_alienation	71_alienation	SEI	educatio	
ses	6.858					
67_alienation	-3.838	6.914				
71_alienation	-3.720	4.977	7.565			
SEI	35.484	-19.858	-19.246	449.805		
educatio	6.858	-3.838	-3.720	35.484	9.600	
powles71	-3.717	4.973	7.559	-19.231	-3.717	
anomia71	-3.720	4.977	7.565	-19.246	-3.720	
powles67	-3.835	6.909	4.973	-19.842	-3.835	
anomia67	-3.838	6.914	4.977	-19.858	-3.838	

モデルの(全変数に関する)共分散 (Group number 1 - Model C: Time-Invariance)				
	powles71	anomia71	powles67	anomia67
powles71	9.989			
anomia71	7.559	12.515		
powles67	4.969	4.973	9.339	
anomia67	4.973	6.865	6.909	11.864

観測変数に対するモデルの分散と共分散は、標本分散と標本共分散と同じではありません。対応する母集団の推定値として、モデルの分散と共分散は標本分散と標本共分散より優れています (Model C が正しいと仮定した場合)。

[分析のプロパティ] ダイアログ ボックスで [標準化推定値] と [全変数に関するモデルの積率] チェック ボックスの両方をオンにしている場合、モデルの共分散行列だけでなく、すべての変数のモデルの相関行列も提供されます。

モデル内のすべての変数に対するモデルの共分散行列を使用して、観測変数に対する非観測変数の回帰を実行できます。結果の係数推定値は、[因子得点ウェイト] チェック ボックスをオンにすることによって取得できます。モデル C の推定因子得点ウェイトを次に示します。

因子得点ウェイト (Group number 1 - Model C: Time-Invariance)						
	SEI	educatio	powles71	anomia71	powles67	anomia67
ses	.029	.542	-.055	-.016	-.069	-.028
67_alienation	-.003	-.061	.134	-.027	.471	.242
71_alienation	-.003	-.049	.491	.253	.134	-.031

因子得点ウェイトの表では、非観測変数ごとに個別の行と、観測変数ごとに個別の列があります。個々の ses 得点を推定する場合を考えてみましょう。表の ses 行にある 6 つのウェイトを使用して、6 つの個々の観測得点の重み付き合計を計算します。

## 間接効果、直接効果、総合効果を取得する

パス図の一方方向矢印に関連付けられた係数を直接効果と呼ぶ場合があります。たとえばモデル C では、ses は 71\_alienation (疎外感(71年)) に対して直接効果があります。同様に、71\_alienation (疎外感(71年)) は powles71 (無気力感(71年)) に対して直接効果があります。この場合、ses は (疎外感(71年) を介して) powles71 (無気力感(71年)) に対して間接効果があると言います。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [間接、直接または総合効果] チェック ボックスをオンにします。

モデル C では、出力に次の総合効果の表が含まれます。

総合効果 (Group number 1 - Model C: Time-Invariance)			
	ses	67_alienation	71_alienation
67_alienation	-.560	.000	.000
71_alienation	-.542	.607	.000
SEI	5.174	.000	.000
educatio	1.000	.000	.000
powles71	-.542	.607	.999
anomia71	-.542	.607	1.000
powles67	-.559	.999	.000
anomia67	-.560	1.000	.000

表の最初の行は、67\_alienation (疎外感(67年)) が直接的または間接的に ses のみに依存することを示します。67\_alienation (疎外感(67年)) に対する ses の総合効果は  $-0.56$  です。効果が負の値の場合、その他の要素がすべて等しく、比較的高い ses の得点が比較的低い 67\_alienation (疎外感(67年)) の得点と関連することを示します。表の 5 行目を見ると、powles71 (無気力感(71年)) が直接的または間接的に ses、67\_alienation (疎外感(67年))、および 71\_alienation (疎外感(71年)) に依存しています。ses の低得点、67\_alienation (疎外感(67年)) の高得点、および 71\_alienation (疎外感(71年)) の高得点は、powles71 (無気力感(71年)) の高得点と関連します。直接、間接、および総合効果の解釈の詳細については、Fox の調査 (1980) を参照してください。



## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。このプログラムは Ex06-a.vb として保存されています。

```
Sub Main()  
    Dim Sem As New AmosEngine  
    Try  
        Sem.TextOutput()  
        Sem.Mods(4)  
        Sem.BeginGroup(Sem.AmosDir & "Examples\Wheaton.sav")  
        Sem.AStructure("anomia67 <--- 67_alienation (1)")  
        Sem.AStructure("anomia67 <--- eps1 (1)")  
        Sem.AStructure("powles67 <--- 67_alienation")  
        Sem.AStructure("powles67 <--- eps2 (1)")  
        Sem.AStructure("anomia71 <--- 71_alienation (1)")  
        Sem.AStructure("anomia71 <--- eps3 (1)")  
        Sem.AStructure("powles71 <--- 71_alienation")  
        Sem.AStructure("powles71 <--- eps4 (1)")  
  
        Sem.AStructure("67_alienation <--- ses")  
        Sem.AStructure("67_alienation <--- zeta1 (1)")  
  
        Sem.AStructure("71_alienation <--- 67_alienation")  
        Sem.AStructure("71_alienation <--- ses")  
        Sem.AStructure("71_alienation <--- zeta2 (1)")  
  
        Sem.AStructure("education <--- ses (1)")  
        Sem.AStructure("education <--- delta1 (1)")  
        Sem.AStructure("SEI <--- ses")  
        Sem.AStructure("SEI <--- delta2 (1)")  
        Sem.FitModel()  
    Finally  
        Sem.Dispose()  
    End Try  
End Sub
```

## モデル B

モデル B に適合するプログラムを次に示します。このプログラムは Ex06-b.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.Crdiff()
    Sem.BeginGroup(Sem.AmosDir & "Examples\Wheaton.sav")
    Sem.AStructure("anomia67 <--- 67_alienation (1)")
    Sem.AStructure("anomia67 <--- eps1 (1)")
    Sem.AStructure("powles67 <--- 67_alienation")
    Sem.AStructure("powles67 <--- eps2 (1)")
    Sem.AStructure("anomia71 <--- 71_alienation (1)")
    Sem.AStructure("anomia71 <--- eps3 (1)")
    Sem.AStructure("powles71 <--- 71_alienation")
    Sem.AStructure("powles71 <--- eps4 (1)")
    Sem.AStructure("67_alienation <--- ses")
    Sem.AStructure("67_alienation <--- zeta1 (1)")
    Sem.AStructure("71_alienation <--- 67_alienation")
    Sem.AStructure("71_alienation <--- ses")
    Sem.AStructure("71_alienation <--- zeta2 (1)")
    Sem.AStructure("education <--- ses (1)")
    Sem.AStructure("education <--- delta1 (1)")
    Sem.AStructure("SEI <--- ses")
    Sem.AStructure("SEI <--- delta2 (1)")
    Sem.AStructure("eps1 <--> eps3") ' Autocorrelated residual
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## モデル C

モデル C に適合するプログラムを次に示します。このプログラムは Ex06-c.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.AllImpliedMoments()
    Sem.FactorScoreWeights()
    Sem.TotalEffects()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Wheaton.sav")
    Sem.AStructure("anomia67 <--- 67_alienation (1)")
    Sem.AStructure("anomia67 <--- eps1 (1)")
    Sem.AStructure("powles67 <--- 67_alienation (path_p)")
    Sem.AStructure("powles67 <--- eps2 (1)")
    Sem.AStructure("anomia71 <--- 71_alienation (1)")
    Sem.AStructure("anomia71 <--- eps3 (1)")
    Sem.AStructure("powles71 <--- 71_alienation (path_p)")
    Sem.AStructure("powles71 <--- eps4 (1)")
    Sem.AStructure("67_alienation <--- ses")
    Sem.AStructure("67_alienation <--- zeta1 (1)")
    Sem.AStructure("71_alienation <--- 67_alienation")
    Sem.AStructure("71_alienation <--- ses")
    Sem.AStructure("71_alienation <--- zeta2 (1)")
    Sem.AStructure("education <--- ses (1)")
    Sem.AStructure("education <--- delta1 (1)")
    Sem.AStructure("SEI <--- ses")
    Sem.AStructure("SEI <--- delta2 (1)")
    Sem.AStructure("eps3 <--> eps1")
    Sem.AStructure("eps1 (var_a)")
    Sem.AStructure("eps2 (var_p)")
    Sem.AStructure("eps3 (var_a)")
    Sem.AStructure("eps4 (var_p)")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## 複数のモデルを適合する

3つのモデル A、B、および C をすべてを単一の分析に適合させるには、最初に次のプログラムを実行します。このプログラムは、一部のパラメータに固有の名前を割り当てます。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.AllImpliedMoments()
    Sem.TotalEffects()
    Sem.FactorScoreWeights()
    Sem.Mods(4)
    Sem.Crdiff()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Wheaton.sav")
    Sem.AStructure("anomia67 <--- 67_alienation (1)")
    Sem.AStructure("anomia67 <--- eps1 (1)")
    Sem.AStructure("powles67 <--- 67_alienation (b_pow67)")
    Sem.AStructure("powles67 <--- eps2 (1)")

    Sem.AStructure("anomia71 <--- 71_alienation (1)")
    Sem.AStructure("anomia71 <--- eps3 (1)")
    Sem.AStructure("powles71 <--- 71_alienation (b_pow71)")
    Sem.AStructure("powles71 <--- eps4 (1)")

    Sem.AStructure("67_alienation <--- ses")
    Sem.AStructure("67_alienation <--- zeta1 (1)")
    Sem.AStructure("71_alienation <--- 67_alienation")
    Sem.AStructure("71_alienation <--- ses")
    Sem.AStructure("71_alienation <--- zeta2 (1)")

    Sem.AStructure("education <--- ses (1)")
    Sem.AStructure("education <--- delta1 (1)")
    Sem.AStructure("SEI <--- ses")
    Sem.AStructure("SEI <--- delta2 (1)")

    Sem.AStructure("eps3 <--> eps1 (cov1)")

    Sem.AStructure("eps1 (var_a67)")
    Sem.AStructure("eps2 (var_p67)")
    Sem.AStructure("eps3 (var_a71)")
    Sem.AStructure("eps4 (var_p71)")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

パラメータ名は固有なので、パラメータに名前を付けることによってパラメータが制約されることはありません。ただし、パラメータに名前を付けることにより、Model メソッドを使用して制約を適用することができます。プログラムの Sem.FitModel 行の代わりに次の行を追加すると、毎回異なるパラメータ制約を適用してモデルを 4 回適合します。

```
Sem.Model("Model A: No Autocorrelation", "cov1 = 0")
Sem.Model("Model B: Most General", "")
Sem.Model("Model C: Time-Invariance", _
    "b_pow67 = b_pow71; var_a67 = var_a71; var_p67 = var_p71")
Sem.Model("Model D: A and C Combined", _
    "Model A: No Autocorrelation; Model C: Time-Invariance")
Sem.FitAllModels()
```

最初の行は、Model A: No Autocorrelation という名前のモデルを定義します。このモデルでは、cov1 という名前のパラメータが 0 に固定されています。

2 行目は、Model B: Most General という名前のモデルを定義します。このモデルでは、モデルパラメータに適用される追加の制約はありません。

3 回目の Model メソッドでは、Model C: Time-Invariance という名前のモデルを定義します。このモデルでは、次の同等性の制約を適用します。

```
b_pow67 = b_pow71
var_a67 = var_a71
var_p67 = var_p71
```

4 回目の Model メソッドでは、Model D: A and C Combined という名前のモデルを定義します。このモデルでは、モデル A の 1 つの制約とモデル C の 3 つの制約を結合します。

最後のモデル指定 (モデル D) は、それまでのモデル指定を使用して、より制約の多い新しいモデルを定義する方法を示します。

すべてのモデルを一度に適合するには、FitModel メソッドの代わりに FitAllModels メソッドを使用する必要があります。FitModel メソッドは 1 つのモデルしか適合しません。デフォルトでは、このメソッドは最初のモデル (この例ではモデル A) を適合します。最初のモデルを適合するには FitModel(1)、2 番目のモデルを適合するには FitModel(2) を使用します。FitModel(「Model C: Time-Invariance」) と指定してモデル C を適合することもできます。

Ex06-all.vb には、4 つのモデルすべてを適合するプログラムが含まれます。



# 非再帰 モデル

## 概要

この例では、非再帰モデルを使用した構造方程式モデルの作成について説明します。

## データについて

Felson と Bohrnstedt は、小学校 6 年生から中学 2 年生の女子生徒 209 人を対象とした調査を実施しました (1979)。この調査では次の変数に関する測定値を取得しました。

変数	説明
academic	認められる学力。最も学力が優れていると思う級友 3 人の名前という項目に基づく計量社会学的測定値。
athletic	認められる運動能力。最も運動能力が優れていると思う級友 3 人の名前という項目に基づく計量社会学的測定値。
attract	認められる魅力。最も外見が優れていると思う級友 3 人の名前 (自分は除く) という項目に基づく計量社会学的測定値。
GPA	成績平均点。
height	被験者の学年と性別の平均の高さからの偏差。
weight	高さで調整されたウェイト。
rating	別の市の子供たちに被験者の写真を見せることによって得られた肉体的魅力の評価。

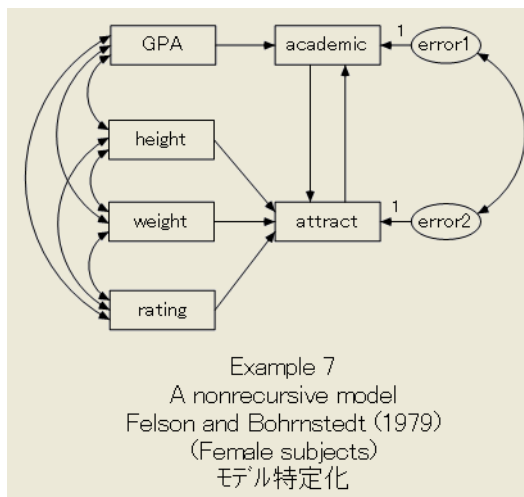
これら 6 つの変数の標本の相関、平均、および標準偏差は、SPSS Statistics ファイル Fels\_fem.sav に保存されています。SPSS Statistics データ エディタに表示されるデータ ファイルを次に示します。

	rowtype_	varname_	academic	athletic	attract	gpa	height	weight	rating
1	n		209.00	209.00	209.0	209.0	209.0	209.0	209.0
2	corr	academic	1.00	.	.	.	.	.	.
3	corr	athletic	.43	1.00	.	.	.	.	.
4	corr	attract	.50	.48	1.00	.	.	.	.
5	corr	GPA	.49	.22	.32	1.00	.	.	.
6	corr	height	.10	-.04	-.03	.18	1.00	.	.
7	corr	weight	.04	.02	-.16	-.10	.34	1.00	.
8	corr	rating	.09	.14	.43	.15	-.16	-.27	1.00
9	stddev		.16	.07	.49	3.49	2.91	19.32	1.01
10	mean		.12	.05	.42	10.34	.00	94.13	2.65

この例では標本の平均値は使用しません。

## Felson と Bohrnstedt のモデル

Felson と Bohrnstedt は、7つの測定変数の内6つを使用する次のモデルを提示しました。



認められる **academic** の結果は、GPA と認められる魅力 (**attract**) の関数としてモデル化されます。同様に、認められる **academic** の結果は、**height**、**weight**、および別の市の子供たちから得られた魅力の **rating** の関数としてモデル化されます。このモデルで特に注目すべき点は、認められる学力は認められる魅力に依存し、逆もまた同様であるということです。このようなフィードバックループを含むモデルを非再帰（再帰と非再帰の定義については例4を参照）と呼びます。現在のモデルは、**attract** から **academic** へのパスおよびその逆のパスをトレースできるので非再帰です。このパス図は Ex07.amw ファイルに保存されています。



## モデルの特定

特定のため、2つの非観測変数誤差1と誤差2の測定単位を確定する必要があります。上のパス図には、1に固定された2つの係数が示されています。モデルを特定するにはこれら2つの制約で十分です。

## 分析の結果

### テキスト出力

モデルの自由度は2で、モデルが不適切であるという十分な根拠はありません。

```
カイ2乗 = 2.761
自由度 = 2
確率水準 = .251
```

ただし、テキスト出力にあるいくつかの極端に小さい検定統計量によって示されるように、このモデルが不必要に複雑であることを示すいくつかの根拠があります。

係数: (Group number 1 - Default model)						
			推定値	標準誤差	検定統計量	確率 ラベル
academic	<--	GPA	.023	.004	6.241	***
attract	<--	height	.000	.010	.050	.960
attract	<--	weight	-.002	.001	-1.321	.186
attract	<--	rating	.176	.027	6.444	***
academic	<--	academic	1.607	.349	4.599	***
academic	<--	attract	-.002	.051	-.039	.969

共分散: (Group number 1 - Default model)						
			推定値	標準誤差	検定統計量	確率 ラベル
GPA	<-->	rating	.526	.246	2.139	.032
height	<-->	rating	-.468	.205	-2.279	.023
GPA	<-->	weight	-6.710	4.676	-1.435	.151
GPA	<-->	height	1.819	.712	2.555	.011
height	<-->	weight	19.024	4.098	4.643	***
weight	<-->	rating	-5.243	1.395	-3.759	***
error1	<-->	error2	-.004	.010	-.382	.702

分散: (Group number 1 - Default model)						
			推定値	標準誤差	検定統計量	確率 ラベル
GPA			12.122	1.189	10.198	***
height			8.428	.826	10.198	***
weight			371.476	36.426	10.198	***
rating			1.015	.100	10.198	***
error1			.019	.003	5.747	***
error2			.143	.014	9.974	***

検定統計量から判断すると、次に示す3つの帰無仮説は、それぞれ従来の有意確率レベルで許容されることがわかります。

- 認められる魅力は高さに依存しない (検定統計量 = 0.050)。
- 認められる学力は認められる魅力に依存しない (検定統計量 = -0.039)。
- 残差変数誤差1と誤差2は無相関である (検定統計量 = -0.382)。

厳密に言うと、検定統計量を使用して3つの仮説すべてを一度に検定することはできません。代わりに、3つの制約すべてを同時に組み込んだモデルを作成する必要があります。この方法についてはここでは取り上げません。

上に示された生のパラメータ推定値は(誤差1と誤差2の変数を除いて)識別制約の影響を受けません。当然のことですが、これらの推定値は観測変数の測定単位の影響を受けます。反対に、標準化推定値はすべての測定単位から独立しています。

## 標準化推定値を取得する

分析を実行する前に、次の操作を行います。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [標準化推定値] を選択します (チェック マークが表示されます)。
- ▶ ダイアログ ボックスを閉じます。

標準化係数: (Group number 1 - Default model)			
			推定値
academic	<--	GPA	.492
attract	<--	height	.003
attract	<--	weight	-.078
attract	<--	rating	.363
attract	<--	academic	.525
academic	<--	attract	-.006
相関係数: (Group number 1 - Default model)			
			推定値
GPA	<-->	rating	.150
height	<-->	rating	-.160
GPA	<-->	weight	-.100
GPA	<-->	height	.180
height	<-->	weight	.340
weight	<-->	rating	-.270
error1	<-->	error2	-.076

ここで、これまでに統計的に有意でないことが判明している係数と相関が、記述的にも小さいことがわかります。

## 重相関係数の平方を取得する

重相関係数の平方は、標準化推定値と同様に測定単位から独立しています。重相関の2乗を取得するには、分析を実行する前に次の操作を行います。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [重相関係数の平方] を選択します (チェック マークが表示されます)。
- ▶ ダイアログ ボックスを閉じます。

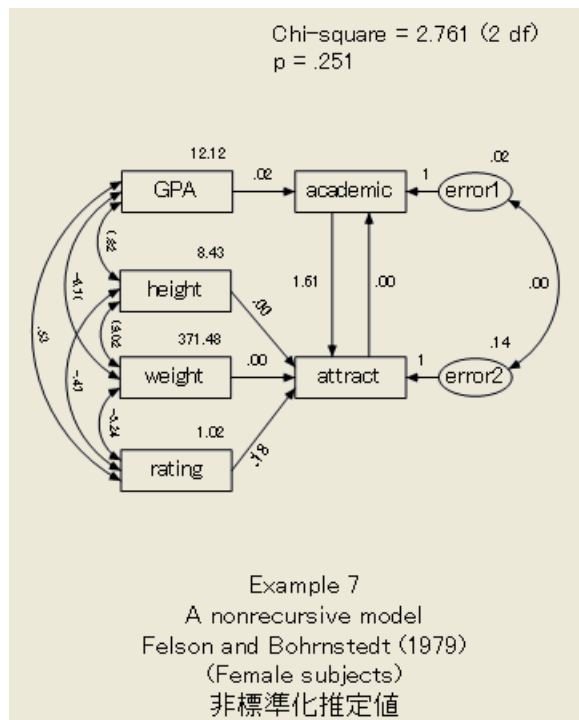
### 重相関係数の平方: (Group number 1 - Default model)

	推定値
attract	.402
academic	.236

重相関係数の平方により、このモデルの2つの内生変数はモデル内のその他の変数によってあまり正確に予測されないことがわかります。このことは、適合度のカイ2乗検定は予測精度の測定にはならないことを示します。

## グラフィック出力

標準化推定値と重相関係数の平方を表示するパス図の出力を次に示します。



## 安定指数

非再帰モデルにはフィードバックループがあるため、再帰モデルでは発生しない特定の問題が発生する可能性があります。現在のモデルでは、魅力が認められる学力に依存し、認められる学力が魅力に依存し、さらに魅力が認められる学力に依存するというように繰り返されます。これは無限回帰のように見えるだけでなく、実際に無限回帰になります。線型従属のこの無限シーケンスにより、魅力、学力、およびモデルのその他の変数間に明確な関係が定義されるかどうか疑問に思われる方もあるでしょう。その答えは、明確な関係が定義される可能性もあり、されない可能性もあります。すべては係数に依存します。一部の係数の値では、線型従属の無限シーケンスが一連の明確に定義された関係に収束します。このような場合、線型従属のシステムが安定していると言い、そうでない場合は不安定であると言います。

注: パス図を見て線型システムが安定しているかどうかを判断することはできません。係数を確認する必要があります。

Amos では母集団にどのような係数があるかを確認できませんが、そのような係数を推定し、その推定値から安定指数 (Fox (1980)、Bentler および Freeman (1983) による) を計算します。

安定指数が  $-1$  から  $+1$  までの間の場合、そのシステムは安定しており、そうでない場合は不安定です。この例のシステムは安定しています。

次の変数の安定指数は 0.003 です。

魅力  
学力

非再帰モデルの安定指数を表示するには、次の操作を行います。

- ▶ [Amos出力] ウィンドウの左上のウィンドウ枠にあるツリー図で、[グループ/モデルについての注釈] をクリックします。

不安定なシステム (安定指数が 1 以上) は不可能であり、同じ意味で負の分散も不可能です。安定指数 1 (または 1 以上) が得られた場合、モデルが不適切であるか、標本サイズが小さすぎて係数の正確な推定値を提示できないことを意味します。パス図にいくつかのループがある場合、Amos ではループごとに安定指数を計算します。安定指数のいずれかが 1 以上の場合、その線型システムは不安定です。

## VB.NET でのモデル作成

この例のモデルに適合するプログラムを次に示します。このプログラムは Ex07.vb ファイルに保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_fem.sav")
    Sem.AStructure("academic <--- GPA")
    Sem.AStructure("academic <--- attract")
    Sem.AStructure("academic <--- error1 (1)")

    Sem.AStructure("attract <--- height")
    Sem.AStructure("attract <--- weight")
    Sem.AStructure("attract <--- rating")
    Sem.AStructure("attract <--- academic")
    Sem.AStructure("attract <--- error (1)")

    Sem.AStructure("error2 <--> error1")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

Felson と Bohrnstedt のモデルには最後の AStructure 行が不可欠です。この行がないと、Amos は誤差 1 と誤差 2 が無相関であると仮定します。

同じモデルを次のような方程式形式で指定できます。

```
Sub Main()
  Dim Sem As New AmosEngine

  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_fem.sav")
    Sem.AStructure("academic = GPA + attract + error1 (1)")
    Sem.AStructure("attract = height + weight + rating + "_
      & "academic + error2 (1)")
    Sem.AStructure("error2 <--> error1")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```



# 因子分析

## 概要

この例では、確認的因子分析について説明します。

## データについて

Holzinger と Swineford は、シカゴの 2 つの学校に在籍する中学 1 年生と中学 2 年生 301 人を対象とした心理学検定を実施しました (1939)。この例では、1 つの学校 (Grant-White 校) の 73 人の女子生徒から取得された得点を使用します。この例で使用する 6 つの検定を次の表に示します。

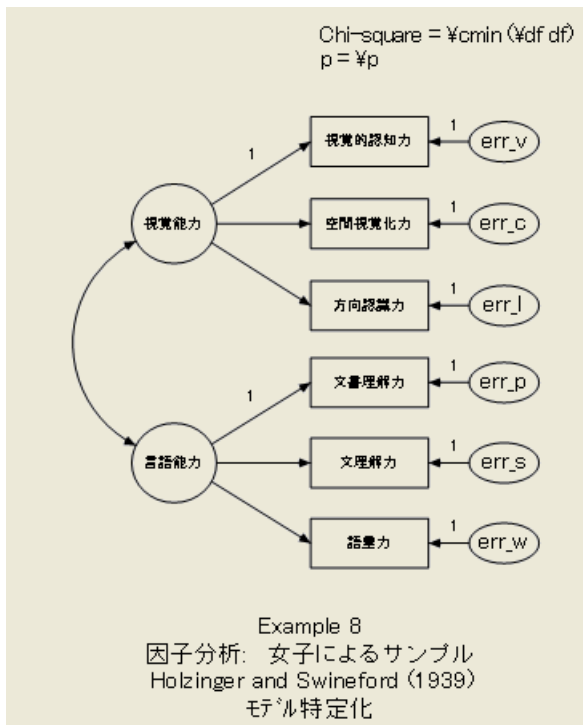
変数	説明
visperc	視覚認知力の得点
cubes	空間視覚化力の検定
lozenges	空間(方向)の認知力の検定
paragraph	文書理解力の得点
sentence	文理解力の得点
wordmean	語彙力に関する検定の得点

Grnt\_fem.sav ファイルには次の検定の得点が保存されています。

visperc	cubes	lozenges	paragraph	sentence	wordmean
33	22	17	8	17	10
30	25	20	10	23	18
36	33	36	17	25	41
28	25	9	10	18	11
30	25	11	11	21	8
20	25	6	9	21	16
17	21	6	5	10	10
33	31	30	11	23	18

## 共通因子モデル

6つの検定を使用する次のモデルを検討してみましょう。



このモデルでは、最初の3つの検定は *spatial* (視覚能力) という名前の非観測変数に依存すると断言しています。*spatial* (視覚能力) は直接観測されない基礎能力 (空間能力) として解釈できます。このモデルによると、最初の3つの検定の結果はこの能力に依存します。さらに、これらの各検定の結果は、空間能力以外の要素にも依存する可能性があります。たとえば、*visperc* (視覚認知力) の場合、固有の変数 *err\_v* も関連します。*err\_v* は、パス図には特に示されない、*visperc* (視覚認知力) に対するあらゆる影響を表します。*err\_v* は *visperc* (視覚認知力) の測定誤差を表しますが、*visperc* (視覚認知力) の得点に影響を与える可能性があり、モデルには特に示されない社会経済状況、年齢、体力、語彙力、およびその他の特性や能力も表します。



ここに示すモデルは共通因子分析モデルです。共通因子分析の用語では、非観測変数 **spatial** (視覚能力) を共通因子と呼び、3つの非観測変数 **err\_v**、**err\_c**、および **err\_l** を独自因子と呼びます。パス図にはその他の共通因子 **verbal** (言語能力) が表示されています。最後の3つの検定はこの共通因子に依存します。パス図には、上記以外の3つの独自因子、**err\_p**、**err\_s**、および **err\_w** も表示されています。2つの共通因子、**spatial** (視覚能力) と **verbal** (言語能力) は相関が可能です。一方で、独自因子は相互に無相関であり、共通因子とも無相関であると仮定されます。共通因子から観測変数へのパス係数は、因子負荷と呼ばれる場合があります。

## 特定

このモデルは、通常どおり、各非観測変数の測定尺度が不定であるという点を除いて特定されます。各非観測変数の測定尺度は、一部の回帰式で係数を1などの定数に設定することによって自由に設定できます。上のパス図にこの方法を示します。このパス図では、8つの係数が1に固定され、非観測変数ごとに1つの係数が固定されています。これらの制約によって十分にモデルを特定できます。

提示されたモデルは、各非観測変数が1つの共通因子にのみ依存する、特に単純な共通因子分析モデルです。共通因子分析の他の適用例では、観測変数が任意の数の共通因子に同時に依存できます。一般的なケースでは、共通因子モデルが特定されるかどうかを判断するのは非常に困難です (Davis (1993)、Jöreskog (1969, 1979) による)。この例および前の例における特定可能性の説明は、非観測変数の自然な測定単位の不足が特定不能の唯一の原因であるような印象を与え、問題を実際以上に単純化しているように見えます。非観測変数の測定単位の不足が常に特定不能の原因になることは事実です。幸いにして、これまで何度も取り上げているように、この原因は対応が容易です。

ただし、簡単な対応策がない、特定可能性に関する別の種類の問題が発生する可能性もあります。特定可能性の条件は各モデルで個別に設定する必要があります。Jöreskog と Sörbom は、パラメータに同等性の制約条件を適用することにより、多数のモデルの特定を実現する方法を示しました (1984)。因子分析モデル (およびその他の多くのモデル) の場合、モデルを特定可能にするために何が必要かを解明するには、モデルに対する深い理解が必要です。モデルが特定可能かどうかわからない場合は、Amos によって特定不能と報告されるかどうかを確認するため、モデルを適合してみることができます。実際に、この実証的アプローチは高い効果を上げています。原則的な反論 (McDonald および Krane (1979) による) もありますが、モデルの特定状態を事前に判断する代替方法はありませぬ。Bollen は、その優れた著書の中で、さまざまな種類の特定不能性の原因と対応について論じています (1989)。

## モデルを指定する

Amos は、128 ページ に示すパス図から直接モデルを分析します。理論的にはモデルを **spatial**(視覚能力) と **verbal** (言語能力) の枝に分離できることに注意してください。2つの枝の構造上の類似を使用して、モデルを迅速に作成できます。

## モデルを作成する

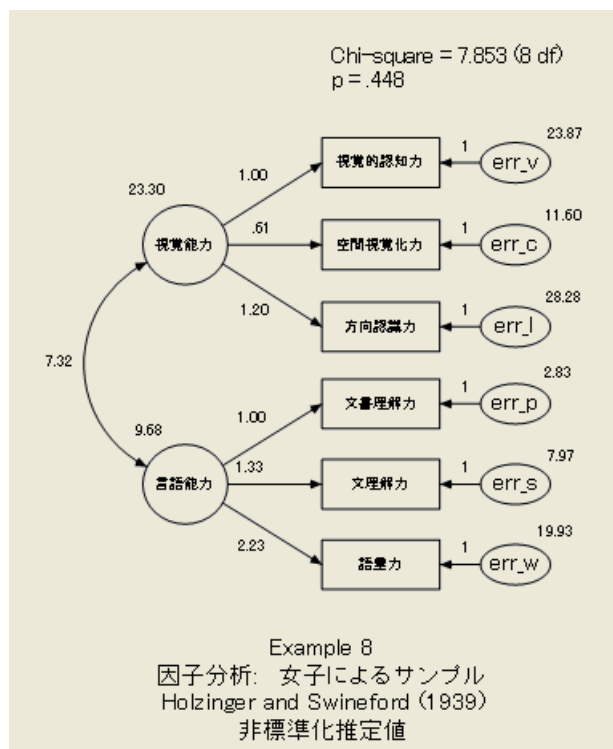
最初の枝を作成した後で、次の操作を行います。

- ▶ メニューから、[編集]→[すべて選択] を選択します。
- ▶ 枝全体のコピーを作成するには、メニューから、[編集]→[複写] を選択し、枝に含まれるオブジェクトのいずれかをパス図の別の場所にドラッグします。

**spatial**(視覚能力) と **verbal** (言語能力) を結ぶ双方向矢印を必ず作成してください。この双方向矢印がないと、Amos は 2つの共通因子が無相関であると仮定します。この例の入力ファイルは **Ex08.amw** です。

## 分析の結果

分析の標準化されていない結果を次に示します。図の右上に示すように、このモデルはデータに非常によく適合しています。



練習として、自由度の計算を確認してみましょう。

自由度の計算 (デフォルト モデル)	
異なる標本の積率の数	21
推定される異なるパラメータの数	13
自由度 (21 - 13)	8

パラメータの推定値（標準化された値と標準化されていない値の両方）を次に示します。予想どおり、空間能力と語彙力の間の相関により、係数は正になります。

<b>係数: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
visperc	<---	spatial	1.000			
cubes	<---	spatial	.610	.143	4.250	***
lozenges	<---	spatial	1.198	.272	4.405	***
paragrap	<---	verbal	1.000			
sentence	<---	verbal	1.334	.160	8.322	***
wordmean	<---	verbal	2.234	.263	8.482	***
<b>標準化係数: (Group number 1 - Default model)</b>						
			推定値			
visperc	<---	spatial	.703			
cubes	<---	spatial	.654			
lozenges	<---	spatial	.736			
paragrap	<---	verbal	.880			
sentence	<---	verbal	.827			
wordmean	<---	verbal	.841			
<b>共分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial	<-->	verbal	7.315	2.571	2.846	.004
<b>相関係数: (Group number 1 - Default model)</b>						
			推定値			
spatial	<-->	verbal	.487			
<b>分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial			23.302	8.123	2.868	.004
verbal			9.682	2.159	4.485	***
err_v			23.873	5.986	3.988	***
err_c			11.602	2.584	4.490	***
err_l			28.275	7.892	3.583	***
err_p			2.834	.868	3.263	.001
err_s			7.967	1.869	4.263	***
err_w			19.925	4.951	4.024	***

## 標準化推定値を取得する

上に示す標準化推定値を取得するには、分析を実行する前に次の操作を行います。

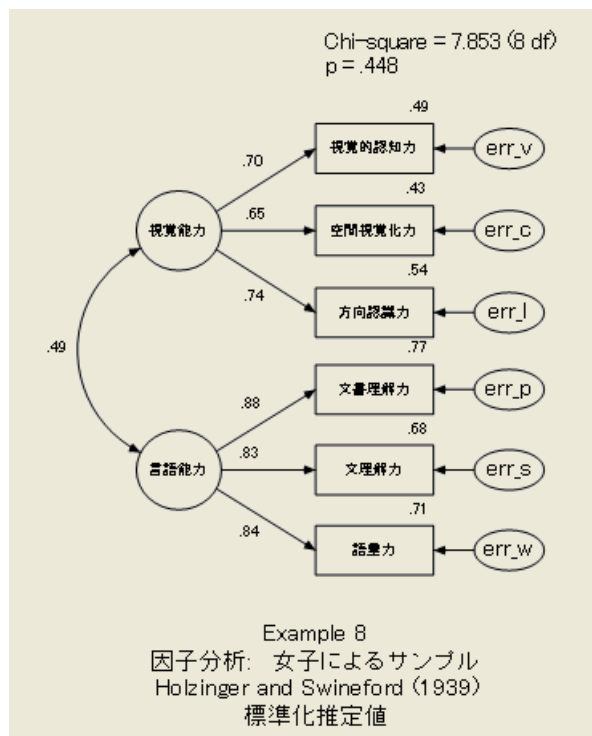
- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。

- ▶ [標準化推定値] を選択します (チェック マークが表示されます)。
- ▶ 次の図に示すように、内生変数ごとに重相関係数の平方が必要な場合は、[重相関係数の平方] も選択します。
- ▶ ダイアログ ボックスを閉じます。

重相関係数の平方: (Group number 1 - Default model)	
	推定値
wordmean	.708
sentence	.684
paragrap	.774
lozenges	.542
cubes	.428
visperc	.494

## 標準化推定値を表示する

- ▶ [Amos出力] ウィンドウで、[出力パス図の表示] ボタンをクリックします。
- ▶ パス図の左側にある [パラメータ形式] パネルで、[標準化推定値] を選択します。  
標準化推定値が表示されたパス図を次に示します。



重相関係数の平方は次のように解釈できます。wordmean (語彙力)の例を見ると、その変数の 71% を語彙力が占めています。この変数の残り 29% を占めるのは固有の因子 err\_w です。err\_w が測定誤差のみを表す場合、wordmean (語彙力)の信頼性の推定値は 0.71 であると言えます。実際は、0.71 は wordmean (語彙力)の信頼性の下限の推定値です。

Holzinger と Swineford のデータは、新しい因子分析技法に関する専門書や実証で繰り返し分析されてきました。この例で使用する 6 つの検定は、Jöreskog と Sörbom による同様の例 (1984) で使用された 9 つの検定のより大きなサブセットから取得されたものです。ここで使用する因子分析モデルも両者のモデルを基にしています。因子分析の文献に見られる、Holzinger と Swineford のデータの探求に関する長い歴史を考えると、現在のモデルが非常によく適合することは偶然ではありません。通常の場合以上に、ここに示された結果を新たなデータセットで確認する必要があります。

## VB.NET でのモデル作成

次のプログラムは、Holzinger と Swineford のデータ用の因子モデルを指定します。このプログラムは Ex08.vb ファイルに保存されています。

```
Sub Main()
    Dim Sem As New AmosEngine
    Try
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()

        Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")
        Sem.AStructure("visperc = (1) spatial + (1) err_v")
        Sem.AStructure("cubes = spatial + (1) err_c")
        Sem.AStructure("lozenges = spatial + (1) err_l")

        Sem.AStructure("paragrap = (1)spatial + (1) err_p")
        Sem.AStructure("sentence = spatial + (1) err_s")
        Sem.AStructure("wordmean= spatial + (1) err_w")
        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub
```

因子 (spatial(視覚能力)と verbal(言語能力))の相関を明示的に可能にする必要はありません。固有の因子は相互に無相関であり、これら 2 つの因子とも無相関であることを指定する必要もありません。これらは Amos プログラムのデフォルトの仮定です (Amos Graphics ではデフォルトではありません)。

# 共分散分析の代替分析

## 概要

この例では、完全に信頼できる共変量を必要としない、共分散分析の単純な代替分析について説明します。より有効な、ただしより複雑な代替分析については例 16 で説明します。

## 共分散分析とその代替分析

共分散分析は、実験研究や準実験研究で、実験群間の既存の相違による影響を低減するためにしばしば使用される技法です。実験群への無作為な割り当てにより、グループ間で系統的な前処置が異なる可能性が除去されるとしても、共分散分析によって処置効果の評価の精度を向上できるという利点があります。

各共変量が誤差なしで測定されると仮定すると、共分散分析の有用性は低下します。この方法では他の仮定も行いますが、共変量が完全に信頼できるという仮定は特に注目されています (Cook および Cambell (1979) など)。これは、1 つにはこの仮定を破棄すると非常に悪い結果になる可能性があるからです。信頼できない共変量を使用すると、処置の効果がない場合があると判断したり、効果がある場合がないと判断するなどの誤った結論に到達する可能性があります。信頼できない共変量によって、実際には有効な処置が有害であるかのように見える場合さえあります。と同時に、残念ながら、共変量が完全に信頼できるという仮説を満たすことは通常は不可能です。

この例では、変数を誤差なしで測定する必要がない共分散分析の代替分析について説明します。ここに示す方法は、Bentler と Woodward 等によって使用された方法です (1979)。Sörbom による別の方法 (1978) については、例 16 で説明します。Sörbom の方法がより一般的です。この方法では、共分散分析の他の仮定を検定し、いくつかの仮定を緩和することもできます。Sörbom の方法は、その一般性により比較的複雑になります。反対に、この例で示す方法は、共変量が誤差なしで測定されるという仮定を除いて、共分散分析の通常の仮定を使用します。この方法の利点は、比較的単純であることです。

この例では、2つの実験群と1つの共変量を使用します。この例を任意の数の実験群と共変量に一般化することができます。Sörbom は、この例と例16で使用しているデータを使用しています(1978)。分析はSörbomの例に厳密に従っています。

## データについて

Olsson は、11歳の生徒213人を対象に、2つの状況で一連の8つの検定を実施しました(1973)。この例では、8つの検定の内、同意語と反意語の2つを使用します。一連の検定を2回実施する間に、108人の生徒(実験群)は検定の結果を向上させるためのトレーニングを受けました。それ以外の105人の生徒(統制群)は特別なトレーニングを受けていません。2つの状況で2回検定を実施した結果、213人の生徒に対してそれぞれ4つの得点が得られました。実験群と統制群のメンバを識別するため、5番目の2分変数も作成されています。全体として、この例では次の変数を使用します。

変数	説明
pre_syn (同意語(事前))	同意語検定の事前検定の得点。
反意語(事前)	反意語検定の事前検定の得点。
同意語(事後)	同意語検定の事後検定の得点。
post_opp (反意語(事後))	反意語検定の事後検定の得点。
treatment (訓練)	特別なトレーニング(訓練)を受けた生徒は1、受けなかった生徒は0の値になる2分変数。この変数は、この例の分析用に特に作成されたものです。

5つの測定値の相関と標準偏差は、Microsoft Excel ワークブック UserGuide.xls のワークシート Olss\_all にあります。データセットは次のとおりです。

rowtype_	varname_	pre_syn	pre_opp	post_syn	post_opp	treatment
n		213	213	213	213	213
corr	pre_syn	1				
corr	pre_opp	0.78255618	1			
corr	post_syn	0.78207295	0.69286541	1		
corr	post_opp	0.70438031	0.77390019	0.77567354	1	
corr	treatment	0.16261758	0.07784579	0.37887943	0.32533034	1
stddev		6.68680566	6.49938562	6.95007062	6.95685347	0.4999504

treatment (訓練) と各事後検定の間には正の相関があります。これは、トレーニングを受けた生徒の方がトレーニングを受けなかった生徒より事後検定の結果が良かったことを示します。treatment (訓練) と各事前検定の間にも正の相関がありますが、比較的小さい相関です。これは、統制群と実験群が、事前検定では同等であったことを示します。生徒は統制群と実験群に無作為に割り当てられているので、これは予測どおりです。

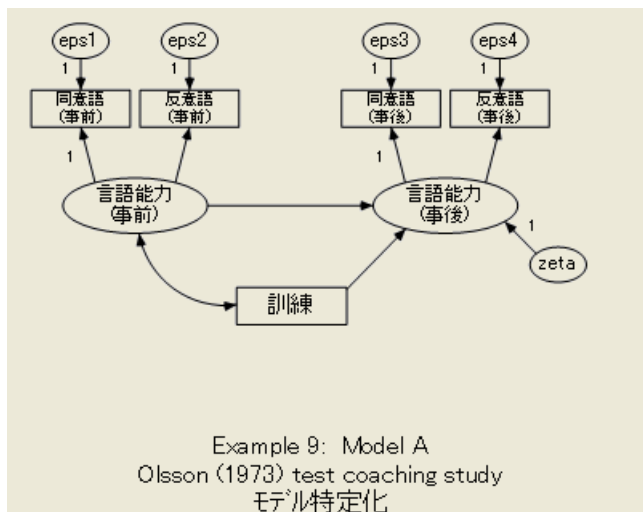


## 共分散分析

検定の結果に対するトレーニングの効果を評価するため、事後検定のいずれかを基準変数として、2つの事前検定を共変量として使用する共分散分析の実行を検討できます。この分析が適切に機能するには、同意語の事前検定と反意語の事前検定の両方が完全に信頼できる必要があります。

### Olsson データ用のモデル A

次のパス図に示す Olsson データ用のモデルについて検討してみましょう。このモデルでは、pre\_syn (同意語 (事前)) と pre\_opp (反意語 (事前)) の両方が、pre\_verbal (言語能力 (事前)) という名前の非観測能力の不完全な測定値であると断言します。この非観測能力は事前検定の時点での語彙力と考えられます。固有の変数 eps1 と eps2 は、pre\_syn (同意語 (事前)) と pre\_opp (反意語 (事前)) の測定誤差だけでなく、このパス図には示されない、2つの検定に対するその他の影響も表します。



同様に、このモデルでは、post\_syn (同意語 (事後)) と post\_opp (反意語 (事後)) が、post\_verbal (言語能力 (事後)) という名前の非観測能力の不完全な測定値であると断言します。この非観測能力は事後検定の時点での語彙力と考えられます。Eps3 と eps4 は、測定誤差と、このパス図には示されないその他の変動の原因を表します。

モデルには、事後検定の時点での語彙力の測定に役立つ2つの変数が示されています。そのような予測変数の1つが、事前検定の時点での語彙力です。事後検定の時点での語彙力が、事前検定の時点での語彙力に依存することは予想どおりです。過去の結果はしばしば将来の結果の優れた予測変数になるので、このモデルでは潜在変数 pre\_verbal (言語能力 (事前)) を共変量として使用します。ただし、最も注目するのは2つ目の予測変数である treatment (訓練) です。ここでは、treatment (訓練) から post\_verbal (言語能力 (事後)) を指す矢印に関連付けられた係数と、それが0と大きく異なるかど

うかに主に注目します。言い換えれば、特定の係数が 0 であるという追加の仮説の下で、上に示すモデルが正しいと認められるかどうかを確認することが最終的な目的です。そのためにまず、モデル A が現状のまま受け入れられるかどうかを検討する必要があります。

## 特定

7つの非観測変数の測定単位は不定です。この問題は、上の図の各非観測変数を基点とする一方向矢印を1つ探し、対応する係数を単一の値(1)に固定することによって解決できます。上のパス図に示された7つの1は、識別制約を満たすために十分であることがわかります。

## モデル A を指定する

モデル A を指定するには、137 ページに示すようなパス図を作成します。このパス図は、Ex09-a.amw ファイルとして保存されています。

## モデル A の結果

モデル A には考慮すべき経験的証拠があります。

カイ2乗 = 33.215 自由度 = 3 確率水準 = .000
---

これは良くないデータです。モデル A を受け入れることができた場合、post\_verbal (言語能力(事後))を treatment(訓練)で回帰させる係数を 0 に固定して分析を繰り返す次の手順を実行できます。ただし、今それを実行しても意味がありません。処置の効果がない強いモデルを検定する土台として使用するため、正しいと確信されるモデルから開始する必要があります。

## より適切なモデルを探す

モデル A がよりデータに適合するように、何らかの修正方法があると考えられます。修正指数から、適切な修正を行うためのいくつかの示唆が得られます。

### 修正指数を要求する

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[出力] タブをクリックします。
- ▶ [修正指数] を選択し、右にあるフィールドに適切な閾値を入力します。この例では、閾値はデフォルト値の 4 のままにします。



閾値 4 で修正指標を要求すると、次の追加出力が得られます。

修正指数 (Group number 1 - Default model)			
共分散: (Group number 1 - Default model)			
		修正指数	改善度
eps2 <-->	eps4	13.161	3.249
eps2 <-->	eps3	10.813	-2.822
eps1 <-->	eps4	11.968	-3.228
eps1 <-->	eps3	9.788	2.798

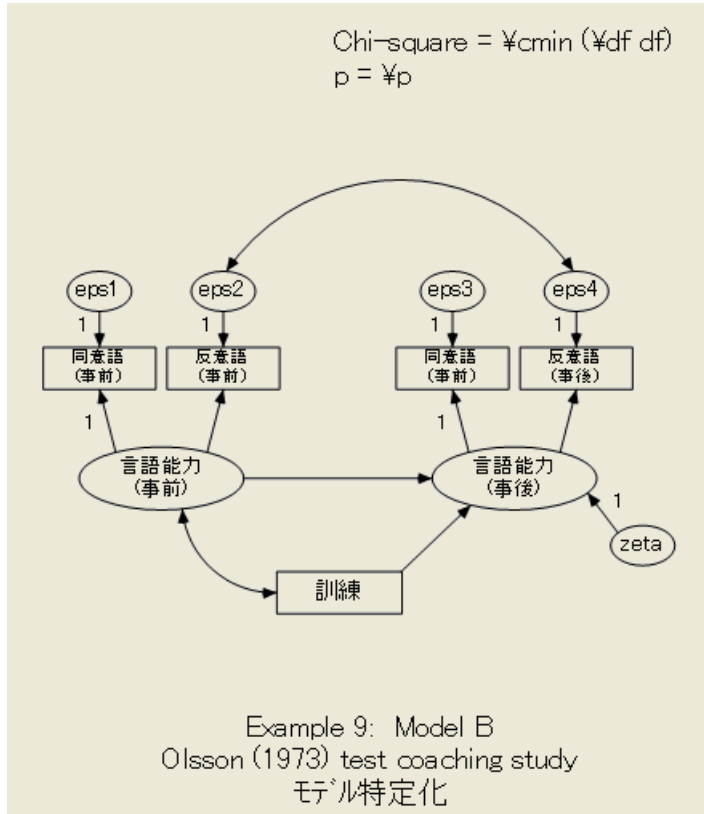
M.I. 列の最初の修正指数によると、固有の変数 **eps2** と **eps4** の相関が可能な場合、カイ 2 乗統計量が少なくとも 13.161 減少します (実際の減少はより大きくなる可能性があります)。同時に、当然のことですが、追加のパラメータを推定する必要があるため、自由度が 1 下がります。13.161 が最大修正指数であるため、この値を最初に検討し、**eps2** と **eps4** の相関を可能にすることが妥当かどうかを確認する必要があります。

**eps2** は、事前検定の語彙力以外のすべての **pre\_opp** (反意語 (事前)) 測定値を表します。同様に、**eps4** は事後検定の語彙力以外のすべての **post\_opp** (反意語 (事後)) 測定値を表します。両方の反意語検定の実施により、語彙力以外に何らかの安定した特性または能力が測定されると考えられます。この場合、**eps2** と **eps4** の間に正の相関が予測されます。実際に、**eps2** と **eps4** の共分散に関連付けられた、予測されるパラメータの変化 (Par Change 列の数値) は正であり、共分散が 0 に固定されていない場合は共分散が正の推定値になると考えられることを示します。

加えて、**eps2** と **eps4** の相関を可能にすることを推奨する理由は、**eps1** と **eps3** にもほぼ同様に適用されます。これらの共分散にも非常に大きな修正指数があります。ただし、現時点では、モデル A に 1 つのパラメータ (**eps2** と **eps4** の共分散) のみ追加します。この新しいモデルを **Model B** と呼びます。

## Olsson データ用のモデル B

モデル B のパス図を下に示します。モデル B は、モデル A のパス図を基に、eps2 と eps4 を結ぶ双方向矢印を追加することによって取得できます。このパス図は Ex09-b.amw ファイルに保存されています。



パス図を表示するとわかるように、パス図の一番上に誤差変数が配置されており、双方向矢印を描くスペースがありません。この問題を解決するには、次の操作を行います。

- ▶ メニューから、[編集]→[ページサイズに調整]を選択します。  
または、次の方法も可能です。
- ▶ 双方向矢印を描き、ページ境界を越える場合は、[画面に当てはまるようにパス図を拡大/縮小] ボタン (ページに矢印が付いたボタン) ボタンをクリックします。ページ境界内に収まるようにパス図が縮小されます。

## モデル B の結果

eps2 と eps4 の相関を可能にすると、カイ 2 乗統計量が大幅に減少します。

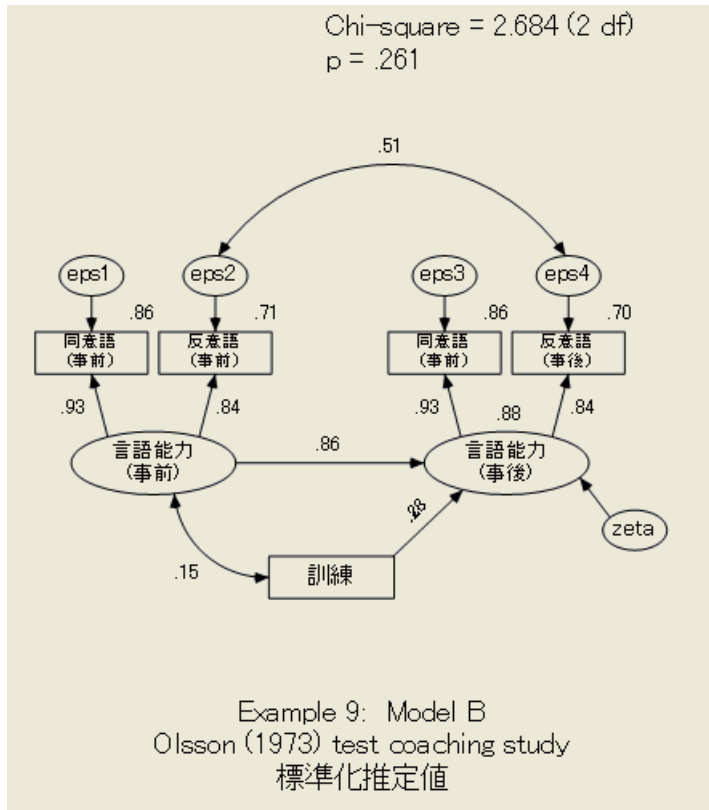
カイ乗 = 2.684  
 自由度 = 2  
 確率水準 = .261

eps1 と eps3 の共分散の修正指数が 9.788 であったモデル A の結果を思い出してください。明らかに、eps2 と eps4 の共分散に加えてこの共分散を除去しても、このような減少が発生するとカイ 2 乗統計量が負の値になるため、カイ 2 乗統計量がさらに 9.788 減少することはありません。このため修正指数は、対応する制約 — およびその制約のみ — を除去した場合に発生するカイ 2 乗統計量の減少の最小値を表します。

次に示す生のパラメータ推定値は、識別制約が異なるとパラメータ推定値も異なるので、解釈が困難です。

係数: (Group number 1 - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
post_verbal	<--- pre_verbal	.889	.053	16.900	***	
post_verbal	<--- treatment	3.640	.477	7.625	***	
pre_syn	<--- pre_verbal	1.000				
pre_opp	<--- pre_verbal	.881	.053	16.606	***	
post_syn	<--- post_verbal	1.000				
post_opp	<--- post_verbal	.906	.053	16.948	***	
共分散: (Group number 1 - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
pre_verbal	<--> treatment	.467	.226	2.066	.039	
eps2	<--> eps4	6.797	1.344	5.059	***	
分散: (Group number 1 - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
pre_verbal		38.491	4.501	8.552	***	
treatment		.249	.024	10.296	***	
zeta		4.824	1.331	3.625	***	
eps1		6.013	1.502	4.004	***	
eps2		12.255	1.603	7.646	***	
eps3		6.546	1.501	4.360	***	
eps4		14.685	1.812	8.102	***	

予想どおり、eps2 と eps4 の共分散は正になります。パラメータ推定値と共に表示される最も興味深い結果は、post\_verbal (言語能力(事後))に対する treatment (訓練)の効果の検定統計量です。この検定統計量は、treatment (訓練)が post\_verbal (言語能力(事後))に対して大きな効果があることを示します。この係数が 0 に固定されるようにモデル B を修正することにより、この効果の大きさに関するより適切な検定を容易に取得できます。一方で、Amos Graphics によって次のような標準化推定値と重相関係数の 2 乗が表示されます。



この例では、主に特定の仮説の検定に注目しており、パラメータ推定値には特に注意する必要はありません。ただし、パラメータ推定値自体が特に注目されない場合でも、とにかく値を確認してそれらの値が妥当かどうかを判断することは良い考えです。たとえば、ここでは **eps2** と **eps4** の間の相関の正確な状態には注意しませんが、正であると予測されます。同様に、このモデルの係数に負の推定値があることは予想外です。どのようなモデルでも、変数の分散が負にならないことがわかっているので、負の分散推定値は常に不適切な推定値になります。標本がかなり大きい場合など、推定値全体の正常度チェックを実行できない場合は、それらの値が取得されたモデルがデータに適合している場合でも、モデルの正しさを疑う必要があります。

## Olsson データ用のモデル C

これで、合理的に正しいと確信できるモデル (モデル B) が作成されたので、**post\_verbal** (言語能力 (事後)) が **treatment** (訓練) に依存しないという制約を追加した場合にうまくいくかどうかを確認します。つまり、ここでは新しいモデル (モデル C と呼びます) の検定を行います。モデル C の大部分はモデル B と同じですが、**post\_verbal** (言語能力 (事後)) で **treatment** (訓練) の係数が 0 になるように指定されている点のみ異なります。

## モデル C のパス図を作成する

モデル C のパス図を作成するには、次の操作を行います。

- ▶ モデル B のパス図を基に作成します。
- ▶ `treatment` (訓練) から `post_verbal` (言語能力(事後)) を指す矢印を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログボックスで、[パラメータ] タブをクリックし、[係数] テキストボックスに「0」と入力します。

モデル C のパス図は、Ex09-c.amw ファイルに保存されています。

## モデル C の結果

モデル C は、従来のすべての有意水準で棄却する必要があります。

カイ2乗 = 55.396 自由度 = 3 確率水準 = .000
---

モデル B が正しく、モデル C の正しさのみ疑わしいと仮定する場合、次のようにしてモデル C のより適切な検定を取得できます。モデル B からモデル C を作成する際に、カイ 2 乗統計量が 52.712 (= 55.396 - 2.684) 増加する一方で、自由度が 1 (= 3-2) 増加しています。モデル C が正しい場合、自由度 1 で近似のカイ 2 乗分布を持つ乱数変数の観測値が 52.712 になります。このような乱数変数が 52.712 を超える確率はごくわずかです。`treatment` (訓練) は `post_verbal` (言語能力(事後)) に対して大きな効果があります。

## すべてのモデルを一度に適合する

標本ファイル Ex09-all.amw では、3 つのモデル (A から C) すべてを単一の分析に適合します。単一の分析に複数のモデルを適合する手順については、例 16 で説明しています。

## VB.NET でのモデル作成

### モデル A

次のプログラムはモデル A を適合します。このプログラムは Ex09-a.vb ファイルに保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Ols_all")
    Sem.AStructure("pre_syn = (1) pre_verbal + (1) eps1")
    Sem.AStructure("pre_opp = pre_verbal + (1) eps2")

    Sem.AStructure("post_syn = (1) pre_verbal + (1) eps3")
    Sem.AStructure("post_opp = pre_verbal + (1) eps4")

    Sem.AStructure("pre_verbal = pre_verbal + treatment + (1) zeta")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

### モデル B

次のプログラムはモデル B を適合します。このプログラムは Ex09-b.vb ファイルに保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Ols_all")
    Sem.AStructure("pre_syn = (1) pre_verbal + (1) eps1")
    Sem.AStructure("pre_opp = pre_verbal + (1) eps2")
    Sem.AStructure("post_syn = (1) pre_verbal + (1) eps3")
    Sem.AStructure("post_opp = pre_verbal + (1) eps4")

    Sem.AStructure("pre_verbal = pre_verbal + treatment + (1) zeta")

    Sem.AStructure("eps2 <---> eps4")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```



## モデル C

次のプログラムはモデル C を適合します。このプログラムは Ex09-c.vb ファイルに保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Olss_all")
    Sem.AStructure("pre_syn = (1) pre_verbal + (1) eps1")
    Sem.AStructure("pre_opp = pre_verbal + (1) eps2")
    Sem.AStructure("post_syn = (1) pre_verbal + (1) eps3")
    Sem.AStructure("post_opp = pre_verbal + (1) eps4")

    Sem.AStructure("pre_verbal = pre_verbal + (0) treatment + (1) zeta")

    Sem.AStructure("eps2 <--> eps4")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## 複数のモデルを適合する

次のプログラム (Ex09-all.vb) は、3 つのモデル (A から C) をすべて適合します。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Olss_all")
    Sem.AStructure("pre_syn = (1) pre_verbal + (1) eps1")
    Sem.AStructure("pre_opp = pre_verbal + (1) eps2")
    Sem.AStructure("post_syn = (1) pre_verbal + (1) eps3")
    Sem.AStructure("post_opp = pre_verbal + (1) eps4")

    Sem.AStructure("pre_verbal = pre_verbal + (effect) treatment + (1) zeta")

    Sem.AStructure("eps2 <--> eps4 (cov2_4)")

    Sem.Model("Model_A", "cov2_4 = 0")
    Sem.Model("Model_B")
    Sem.Model("Model_C", "effect = 0")
    Sem.FitAllModels()
  Finally
    Sem.Dispose()
  End Try
End Sub
```



# 複数グループの同時分析

## 概要

この例では、2つのデータセットに同時にモデルを適合する方法について説明します。Amosでは、複数のグループ(または標本)から取得されたデータのモデルを同時に作成できます。この複数グループ機能により、次のいくつかの例に示すように、さらに多くの種類の分析を実行できます。

## 複数グループの分析

ここで、例1から例3で使用されている、若年被験者と高齢被験者から取得された Attig (1983) の記憶力データをもう一度振り返ってみましょう。この例では、2つのグループの結果を比較し、類似性を確認します。ただし、高齢者と若年者を個別に分析することによってこれらのグループを比較することはありません。代わりに、パラメータを推定し、両方のグループに関する仮説を同時に検定する単一の分析を実行します。この方法には、若年者と高齢者のグループを個別に分析する場合と比較して2つの利点があります。まず、若年者と高齢者の間に相違が検出された場合、その大きさを検定できます。次に、若年者と高齢者の間に相違がない場合、またはグループ間の相違がいくつかのモデルパラメータのみに関するものである場合、両方のグループを同時分析すると、単一グループ分析を個別に2回実施した場合に取得される推定値より、正確なパラメータ推定値が提供されます。

## データについて

ここでは、若年被験者と高齢被験者の両方から取得された Attig の記憶力データを使用します。高齢被験者のデータの一部を次に示します。このデータは、Microsoft Excel ブック UserGuide.xls のワークシート Attg\_old にあります。

項目	年齢	教育年数	性別	記憶1	記憶2
1	65	16	1	5	11
2	68	18	0	12	16
3	64	17	1	11	11
4	77	16	0	3	3
5	72	12	0	8	9
6	75	12	1	10	9
7	69	12	0	8	7
8	74	12	0	7	6
9	66	12	0	8	12
10	77	12	0	8	11

若年被験者のデータはワークシート `Attg_yng` にあります。この例では、測定値記憶 1 と助成記憶 1 のみ使用します。

複数グループ分析のデータはさまざまな方法で分類できます。1つの方法は、グループごとに1つのファイルを使用してデータを異なるファイルに保存する方法です(この例ではこの方法を使用します)。2つ目の方法として、すべてのデータを1つの大きいファイルに保存し、グループの所属変数を含める方法が考えられます。

## モデル A

ここでは、2つの変数記憶 1 と助成記憶 1 用に非常に小さいモデル (モデル A) を作成することから開始します。このモデルでは単に、高齢被験者と同様若年被験者も、記憶 1 と助成記憶 1 がいくつかの指定されない分散と共分散を持つ 2 つの変数であることを示します。若年者と高齢者で分散と共分散が異なってもかまいません。

## グループの相違を指定するための規則

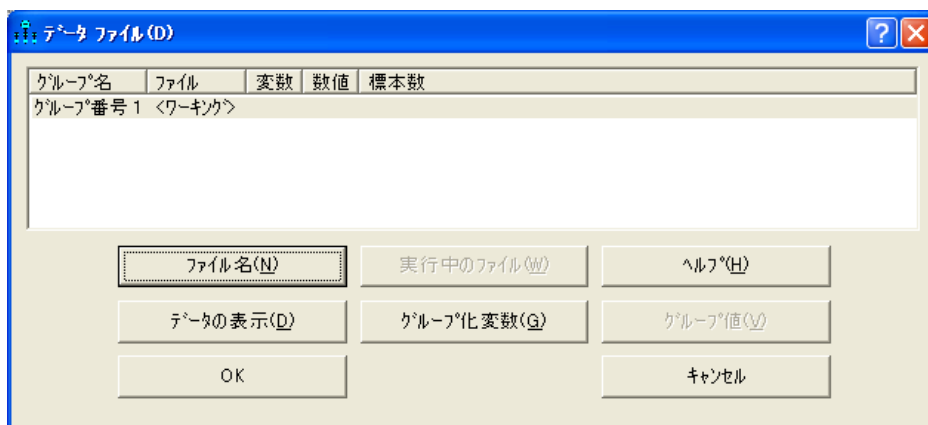
複数グループ分析の主な目的は、グループがどの程度異なるかを解明することです。すべてのグループで、同じパラメータ値を含む同じパス図を使用しますか。または、同じパラメータ図でグループごとに異なるパラメータ値を使用しますか。あるいは、グループごとに異なるパス図が必要ですか。Amos Graphics では、複数グループ分析におけるグループの相違を指定するため次の規則が用意されています。

- 明示的に宣言されていない限り、すべてのグループで同じパス図を使用します。
- 名前のないパラメータには異なるグループの異なる値を使用できます。これにより、Amos Graphics のデフォルトの複数グループモデルでは、すべてのグループで同じパス図を使用しますが、グループごとに異なるパラメータ値を使用できます。
- 異なるグループのパラメータに同じラベルを指定することにより、これらのパラメータが同じ値になるように制約できます (この方法については 158 ページのモデル B で説明します)。

## モデル A を指定する

- ▶ メニューから、[ファイル]→[新規作成]を選択して新しいパス図の作成を開始します。
- ▶ メニューから、[ファイル]→[データ ファイル]を選択します。

[データ ファイル]ダイアログ ボックスでは、[グループ番号 1]という名前の 1 つのグループにのみデータ ファイルを指定できることに注意してください。ここではまだ複数グループ分析であることを指定していません。

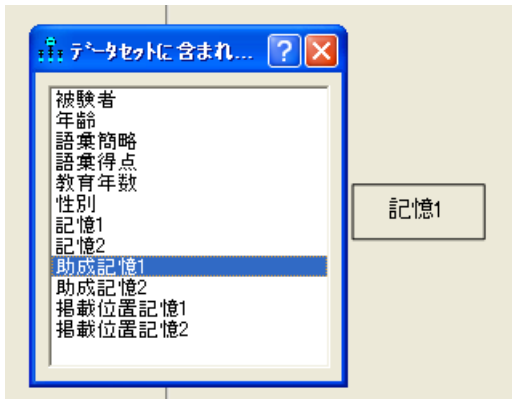


- ▶ [ファイル名]をクリックし、Amos の Examples ディレクトリにある Excel ブックの UserGuide.xls を選択して、[開く]をクリックします。
- ▶ [データ表を選択]ダイアログ ボックスで、ワークシート Attg\_yng を選択します。




- ▶ [OK] をクリックして [データ表の選択] ダイアログ ボックスを閉じます。
- ▶ [OK] をクリックして、[データ ファイル] ダイアログ ボックスを閉じます。


- ▶ メニューから、[表示]→[データセットに含まれる変数]を選択します。
- ▶ 観測変数記憶1と助成記憶1を図にドラッグします。



- ▶ 記憶1と助成記憶1を双方向矢印で結びます。




- ▶ パス図にキャプションを追加するには、メニューから、[図]→[図のキャプション]を選択し、パス図にキャプションを表示する位置をクリックします。
- ▶ [図のキャプション]ダイアログボックスで、テキストマクロ %group と %format を含むタイトルを入力します。




- ▶ [OK] をクリックして若年者グループのモデル指定を完了します。
- ▶ 2つ目のグループを追加するには、メニューから、[分析]→[グループ管理]を選択します。

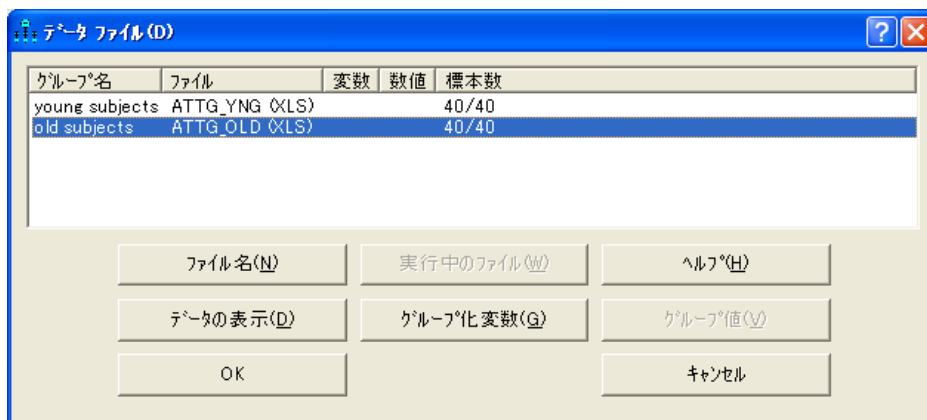
- ▶ [グループ管理] ダイアログ ボックスで、[グループ名] テキスト ボックスの名前を「グループ番号 1」から「young subjects」に変更します。



- ▶ [新規作成] をクリックして 2 つ目のグループを作成します。
- ▶ [グループ名] テキスト ボックスの名前を「グループ番号 2」から「old subjects」に変更します。



- ▶ [閉じる] をクリックします。
  - ▶ メニューから、[ファイル] → [データ ファイル] を選択します。
- [データ ファイル] ダイアログ ボックスに、young subjects と old subjects という名前の 2 つのグループが表示されます。
- ▶ 高齢被験者のデータ セットを指定するには、[データ ファイル] ダイアログ ボックスで [old subjects] を選択します。



- ▶ [ファイル名] をクリックし、Amos の Examples ディレクトリにある Excel ブックの UserGuide.xls を選択して、[開く] をクリックします。
- ▶ [データ表を選択] ダイアログ ボックスで、ワークシート Attg\_old を選択します。



- ▶ [OK] をクリックします。

## テキスト出力

モデル A は自由度が 0 になります。

自由度の計算 (Default model)	
独立な標本積率の数:	6
独立な推定パラメータの数:	6
自由度 (6 - 6):	0

Amos では次のようにして異なる標本の積率を計算します。若年被験者には 2 つの標本分散と 1 つの標本共分散があり、3 つの標本の積率が生成されます。高齢被験者にも 3 つの標本の積率があり、合計 6 つの標本の積率が生成されます。推定されるパラメータは母集団の積率であり、この積率も 6 つあります。自由度が 0 なので、このモデルは検定できません。

カイ2乗 = .000
自由度 = 0
確率水準の計算はできません。

[Amos 出力] ウィンドウに若年者のパラメータ推定値を表示するには、次の操作を行います。

- ▶ 左上のウィンドウ枠にあるツリー図で、[推定値] をクリックします。



- ▶ ウィンドウの左側にある [グループ] パネルで、[young subjects] をクリックします。

共分散: (young subjects - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
recall1 <->	cued1	3.225	.944	3.416	***	
分散: (young subjects - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
recall1		5.787	1.311	4.416	***	
cued1		4.210	.953	4.416	***	

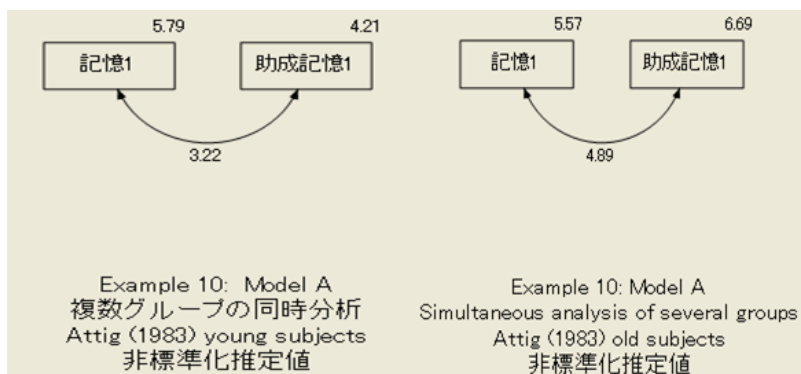
高齢被験者のパラメータ推定値を表示するには、次の操作を行います。

- ▶ [グループ] パネルで、[old subjects] をクリックします。

共分散: (old subjects - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
recall1 <->	cued1	4.887	1.252	3.902	***	
分散: (old subjects - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
recall1		5.569	1.261	4.416	***	
cued1		6.694	1.516	4.416	***	

## グラフィック出力

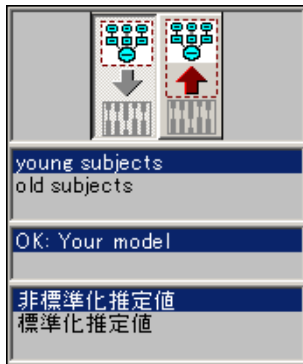
次の図は、2つのグループの非標準化推定値を示す出力パス図です。



[Amos Graphics] ウィンドウの左側にあるパネルで、さまざまな表示オプションを選択できます。

- 入力パス図または出力パス図を表示するには、[入力パス図の表示] または [出力パス図の表示] ボタンをクリックします。
- [グループ] パネルで [young subjects] または [old subjects] のいずれかを選択します。

- [パラメータ形式] パネルで、[非標準化推定値] または [標準化推定値] のいずれかを選択します。



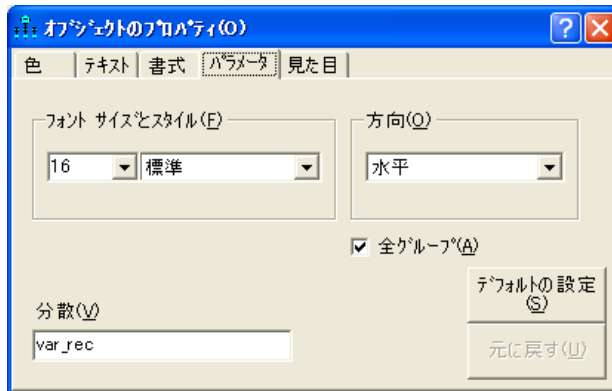
## モデル B

2つのグループのパラメータ推定値が異なることを確認するのは容易です。では、どの程度異なるのでしょうか。差の大きさを確認する1つの方法として、分析を繰り返す方法がありますが、ここでは若年者の各パラメータを高齢者の対応するパラメータと等しくする必要があります。この結果作成されたモデルをモデル B と呼びます。

モデル B では、各パラメータに名前を付け、高齢者グループと若年者グループで同じパラメータ名を使用する必要があります。

- ▶ まず、パス図の左側にある [グループ] パネルで [young subjects] をクリックします。
- ▶ パス図で記憶 1 の四角を右クリックします。
- ▶ ポップアップ メニューから、[オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[パラメータ] タブをクリックします。

- ▶ [分散] テキスト ボックスに、記憶1の分散の名前を入力します。たとえば、「var\_rec」と入力します。

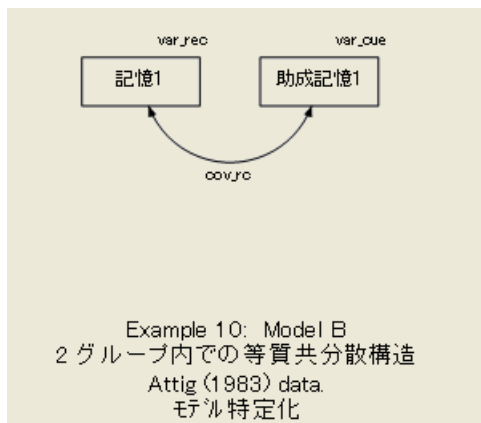


- ▶ [全グループ] を選択します (チェック マークが表示されます)。

ここにチェック マークが付いている場合、すべてのグループの記憶1の分散に var\_rec という名前が割り当てられます。ここにチェック マークが付いていない場合、var\_rec は若年者グループのみの記憶1の分散の名前になります。

- ▶ [オブジェクトのプロパティ] ダイアログ ボックスが開いた状態で、[助成記憶1] をクリックし、分散の名前として「var\_cue」と入力します。
- ▶ 双方向矢印をクリックし、共分散の名前として「cov\_rc」と入力します。常に [全グループ] が選択されていることを確認してください。

各グループのパス図は次のようになります。



## テキスト出力

モデル B には制約が適用されるため、6 つではなく 3 つの異なるパラメータのみ推定されます。これにより、自由度が 0 から 3 に増加します。

### 自由度の計算 (Default model)

```

独立な標本積率の数: 6
独立な推定パラメータの数: 3
自由度 (6 - 3): 3

```

モデル B は、従来のすべての有意水準で受け入れることができます。

```

カイ2乗 = 4.588
自由度 = 3
確率水準 = .205

```

若年被験者用のモデル B に基づいて取得されたパラメータ推定値を次に示します(高齢被験者のパラメータ推定値も同じです)。

### 共分散: (young subjects - Default model)

	推定値	標準誤差	検定統計量	確率	ラベル
recall <-> cued1	4.056	.780	5.202	***	cov_rec


### 分散: (young subjects - Default model)

	推定値	標準誤差	検定統計量	確率	ラベル
recall1	5.678	.909	6.245	***	var_rec
cued1	5.452	.873	6.245	***	var_cue

モデル B に基づいて取得された標準誤差推定値 (若年被験者で 0.780、0.909、および 0.873) は、モデル A に基づいて取得された対応する推定値 (0.944、1.311、および 0.953) より小さいことがわかります。モデル B が正しいと考える限り、モデル A の推定値よりモデル B の推定値の方が適していると言えます。

## グラフィック出力

モデル B では、両方のグループの出力パス図が同じになります。



## VB.NET でのモデル作成

### モデル A

モデル A を適合するプログラム (Ex10-a.vb) を次に示します。

```
Sub Main()  
    Dim Sem As New AmosEngine  
    Try  
        Sem.TextOutput()  
  
        Sem.BeginGroup(Sem.AmosDir & "Examples\UserGuide.xls", "Attg_yng")  
        Sem.GroupName("young subjects")  
        Sem.AStructure("recall1")  
        Sem.AStructure("cued1")  
  
        Sem.BeginGroup(Sem.AmosDir & "Examples\UserGuide.xls", "Attg_old")  
        Sem.GroupName("old subjects")  
        Sem.AStructure("recall1")  
        Sem.AStructure("cued1")  
        Sem.FitModel()  
    Finally  
        Sem.Dispose()  
    End Try  
End Sub
```

この2つのグループ分析では BeginGroup メソッドを2回使用します。最初の BeginGroup 行は、Attg\_yng データセットを指定します。その後の3行によってそのグループの名前とモデルを示します。2番目の BeginGroup 行は Attg\_old データセットを指定し、その後の3行によってそのグループの名前とモデルを示します。各グループのモデルは単に、記憶1と助成記憶1が、制約されない分散と指定されない共分散を持つ2つの変数であることを示します。GroupName メソッドはオプションですが、Amos による出力へのラベル付けに役立つので、複数グループ分析では有効です。

## モデル B

次に示すモデル B のためのプログラムは、Ex10-b.vb に保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"

    Sem.Standardized()
    Sem.TextOutput()

    Sem.BeginGroup(dataFile, "Attg_yng")
    Sem.GroupName("young subjects")
    Sem.AStructure("recall1 (var_rec)")
    Sem.AStructure("cued1 (var_cue)")
    Sem.AStructure("recall1 <>cued1 (cov_rc)")
    Sem.BeginGroup(dataFile, "Attg_old")
    Sem.GroupName("old subjects")
    Sem.AStructure("recall1 (var_rec)")
    Sem.AStructure("cued1 (var_cue)")
    Sem.AStructure("recall1 <>cued1 (cov_rc)")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

パラメータ名の `var_rec`、`var_cue`、および `cov_rc` (かっこ内) を使用して、一部のパラメータが若年者と高齢者で同じ値になるように指定します。`var_rec` という名前を 2 回使用するには、記憶 1 が両方のグループで同じ分散を持つ必要があります。同様に、`var_cue` という名前を 2 回使用するには、助成記憶 1 が両方のグループで同じ分散を持つ必要があります。`cov_rc` という名前を 2 回使用するには、記憶 1 と助成記憶 1 が両方のグループで同じ共分散を持つ必要があります。

## 複数モデルの入力

モデル A と B の両方を適合するプログラム (Ex10-all.vb) を次に示します。<sup>1</sup>

```
Sub Main()  
  Dim Sem As New AmosEngine  
  Try  
    Sem.Standardized()  
    Sem.TextOutput()  
  
    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Attg_yng")  
    Sem.GroupName("young subjects")  
    Sem.AStructure("recall1      (yng_rec)")  
    Sem.AStructure("cued1       (yng_cue)")  
    Sem.AStructure("recall1 <->cued1 (yng_rc)")  
  
    Sem.BeginGroup(Sem.AmosDir & "Examples¥UserGuide.xls", "Attg_old")  
    Sem.GroupName("old subjects")  
    Sem.AStructure("recall1      (old_rec)")  
    Sem.AStructure("cued1       (old_cue)")  
    Sem.AStructure("recall1 <->cued1 (old_rc)")  
  
    Sem.Model("Model A")  
    Sem.Model("Model B", "yng_rec=old_rec", "yng_cue=old_cue", _  
              "yng_rc=old_rc")  
    Sem.FitAllModels()  
  Finally  
    Sem.Dispose()  
  End Try  
End Sub
```

Sem.Model ステートメントは、最後のグループの AStructure 指定の直後にくる必要があります。どの Model ステートメントが最初にきても問題はありません。

<sup>1</sup> 例 6 (Ex06-all.vb) では、複数のモデル制約が単一の文字列で指定され、個々の制約はセミコロンで区切られています。この例では、各制約が独自の文字列で指定され、個々の文字列はカンマで区切られています。どちらの唆文も使用できます。





# Felson と Bohrnstedt の女子生徒と男子生徒のデータ

## 概要

この例では、同時方程式モデルを2つのデータセットに一度に適合する方法について説明します。

## Felson と Bohrnstedt のモデル

例7では、209人の女子生徒の標本を使用して、認められる魅力と認められる学力に関する Felson と Bohrnstedt のモデル (1979) を検証しました。ここでは、同じモデルを使用して、例7のデータと207人の男子生徒の別の標本から取得されたデータに同時に適用します。測定された変数の相互の関連が、男子生徒と女子生徒で同様かどうかという問題を検証します。

## データについて

Felson と Bohrnstedt による女子生徒のデータ (1979) については例7で説明しました。SPSS Statistics ファイル Fels\_mal.sav から取得された男子生徒のデータを次の表に示します。

rowtype_	varname_	academic	athletic	attract	GPA	skills	height	weight	rating
n		207	207	207	207	207	207	207	207
corr	academic	1							
corr	athletic	0.47	1						
corr	attract	0.49	0.72	1					
corr	GPA	0.58	0.27	0.3	1				
corr	skills	0.35	0.65	0.44	0.35	1			
corr	height	-0.02	0.15	0.04	-0.11	0.12	1		
corr	weight	-0.11	-0.01	-0.19	-0.16	-0.05	0.51	1	
corr	rating	0.11	0.24	0.28	0.13	0.38	0.06	-0.18	1
stddev		0.16	0.21	0.49	4.04	0.74	3.41	24.32	0.97
mean		0.1	0.17	0.44	8.63	2.93	0	101.91	2.59

男子生徒のデータ ファイルには 8 つの変数があるのに、女子生徒のデータ ファイルには 7 つの変数しかないことに注意してください。追加の変数 `skills` はこの例のどのモデルでも使用しないので、データ ファイルに存在しても無視されます。

## 女子生徒と男子生徒用のモデル A を指定する

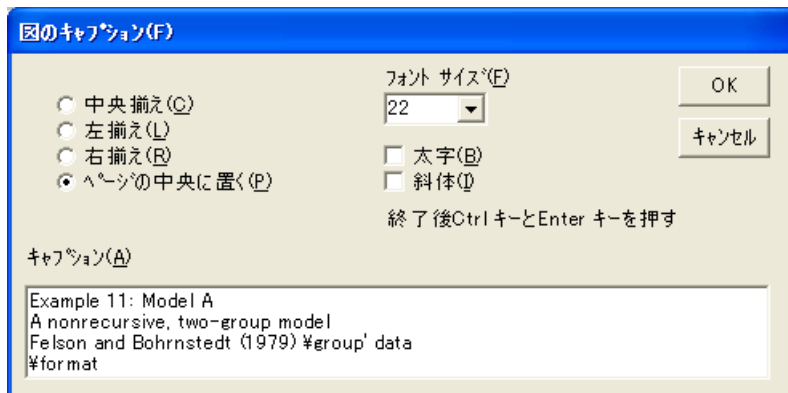
認められる魅力と学力に関する Felson と Bohrnstedt のモデルを、女子生徒だけでなく男子生徒にも拡張することを検討してみましょう。これを行うには、例 7 に示す女子生徒のみのモデル指定を基にして、2 つのグループに適合するように修正します。例 7 のパス図を既に作成している場合は、この例の出発点としてそのパス図を使用できます。追加のパス図を作成する必要はありません。

複数グループ分析では、パス図にパラメータ推定値を表示できるのは一度に 1 グループだけです。どのグループのパラメータ推定値が表示されているかを確認するため、図のキャプションを表示すると便利です。

### 図のキャプションを指定する

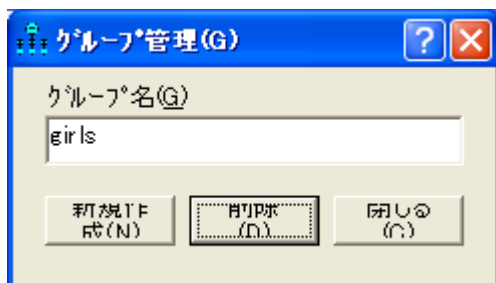
グループ名を表示する図のキャプションを作成するには、キャプションに `¥group` テキスト マクロを配置します。

- ▶ メニューから、[図] → [図のキャプション] を選択します。
- ▶ パス図にキャプションを表示する位置をクリックします。
- ▶ [図のキャプション] ダイアログ ボックスで、テキスト マクロ `¥group` を含むタイトルを入力します。次に例を示します。

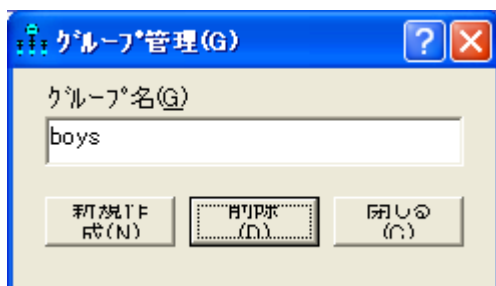


例 7 では 1 つのグループしかないなので、グループの名前に注意する必要はありませんでした。デフォルトのグループ番号 1 という名前をそのまま使用できました。今回は 2 つのグループを管理するので、グループにわかりやすい名前を付ける必要があります。

- ▶ メニューから [分析] → [グループ管理] を選択します。
- ▶ [グループ管理] ダイアログ ボックスで、[グループ名] に「girls」と入力します。

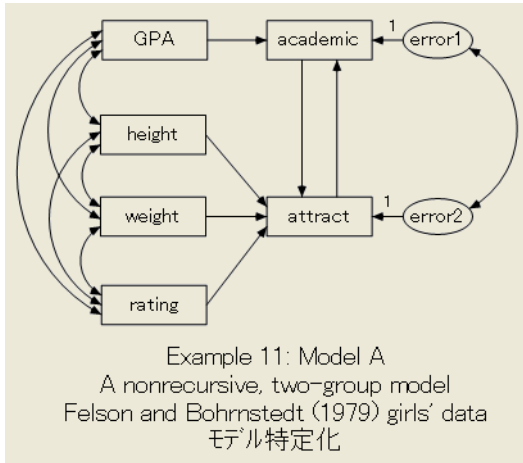


- ▶ [グループ管理] ダイアログ ボックスが開いたままの状態、[新規作成] をクリックして2つ目のグループを作成します。
- ▶ [グループ名] テキスト ボックスに「boys」と入力します。



- ▶ [閉じる] をクリックして [グループ管理] ダイアログ ボックスを閉じます。
- ▶ メニューから、[ファイル] → [データ ファイル] を選択します。
- ▶ [データ ファイル] ダイアログ ボックスで、[girls] をダブルクリックし、データ ファイル Fels\_fem.sav を選択します。
- ▶ 次に、[boys] をダブルクリックし、データ ファイル Fels\_mal.sav を選択します。
- ▶ [OK] をクリックして、[データ ファイル] ダイアログ ボックスを閉じます。

男子生徒の標本用のパス図は次のようになります。



女子生徒と男子生徒のパス図は同じになりますが、2つのグループでパラメータの値が等しくなる必要はないことに注意してください。このことは、係数、共分散、および分散の推定値が男子生徒と女子生徒では異なる可能性があることを意味します。

## モデル A のテキスト出力

例7の1つのグループの代わりにここでは2つのグループを使用するので、推定する標本の積率とパラメータの数が2倍になります。このため、自由度も例7の2倍になります。

自由度の計算 (Default model)	
独立な標本積率の数:	42
独立な推定パラメータの数:	38
自由度 (42 - 38):	4

このモデルは、両方のグループのデータに非常によく適合しています。

カイ2乗 = 3.183
自由度 = 4
確率水準 = 0.528

これにより、Felson と Bohrnstedt のモデルが男子生徒と女子生徒の両方で正しいという仮説を受け入れます。次に注意するのはパラメータ推定値です。ここでは、女子生徒の推定値を男子生徒の推定値とどのように比較するか注目します。女子生徒のパラメータ推定値は次のとおりです。

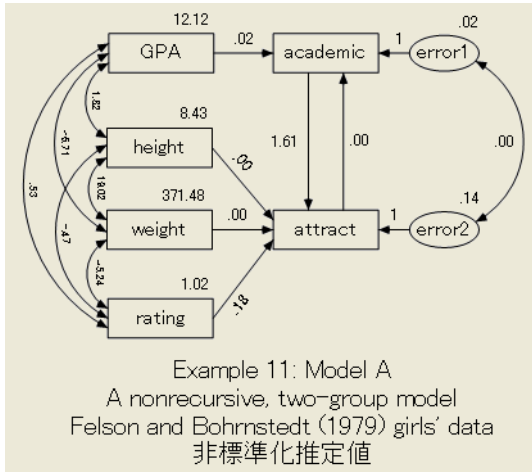
係数: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
academic <--	GPA	.023	.004	6.241	***	par_1
attract <--	height	.000	.010	.050	.960	par_2
attract <--	weight	-.002	.001	-1.321	.186	par_3
attract <--	rating	.176	.027	6.444	***	par_4
attract <--	academic	1.607	.350	4.599	***	par_11
academic <--	attract	-.002	.051	-.039	.969	par_12
共分散: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA <-->	rating	.526	.246	2.139	.032	par_5
height <-->	rating	-.468	.205	-2.279	.023	par_6
GPA <-->	weight	-6.710	4.676	-1.435	.151	par_7
GPA <-->	height	1.819	.712	2.555	.011	par_8
height <-->	weight	19.024	4.098	4.642	***	par_9
weight <-->	rating	-5.243	1.395	-3.759	***	par_10
error1 <-->	error2	-.004	.010	-.382	.702	par_13
分散: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA		12.122	1.189	10.198	***	par_27
height		8.428	.826	10.198	***	par_28
weight		371.476	36.427	10.198	***	par_29
rating		1.015	.100	10.198	***	par_30
error1		.019	.003	5.747	***	par_31
error2		.143	.014	9.974	***	par_32

これらのパラメータ推定値は例7と同じものです。標準誤差、検定統計量、および p 値も同じです。男子生徒の非標準化推定値は次のとおりです。

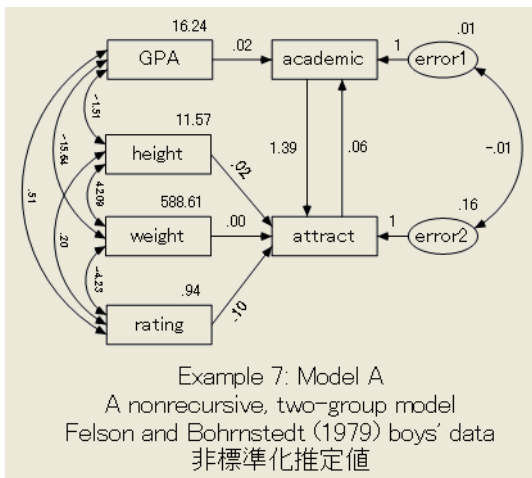
係数: (boys - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
academic <--	GPA	.021	.003	6.927	***	par_14
attract <--	height	.019	.010	1.967	.049	par_15
attract <--	weight	-.003	.001	-2.484	.013	par_16
attract <--	rating	.095	.030	3.150	.002	par_17
attract <--	academic	1.386	.315	4.398	***	par_24
academic <--	attract	.063	.059	1.071	.284	par_25
共分散: (boys - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA <-->	rating	.507	.274	1.850	.064	par_18
height <-->	rating	.198	.230	.860	.390	par_19
GPA <-->	weight	-15.645	6.899	-2.268	.023	par_20
GPA <-->	height	-1.508	.961	-1.569	.117	par_21
height <-->	weight	42.091	6.455	6.521	***	par_22
weight <-->	rating	-4.226	1.662	-2.543	.011	par_23
error1 <-->	error2	-.010	.011	-.898	.369	par_26
分散: (boys - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA		16.243	1.600	10.149	***	par_33
height		11.572	1.140	10.149	***	par_34
weight		588.605	57.996	10.149	***	par_35
rating		.936	.092	10.149	***	par_36
error1		.015	.002	7.571	***	par_37
error2		.164	.016	10.149	***	par_38

## モデル A のグラフィック出力

非標準化推定値が表示された女子生徒のパス図を次に示します。



男子生徒の推定値が表示されたパス図を次に示します。

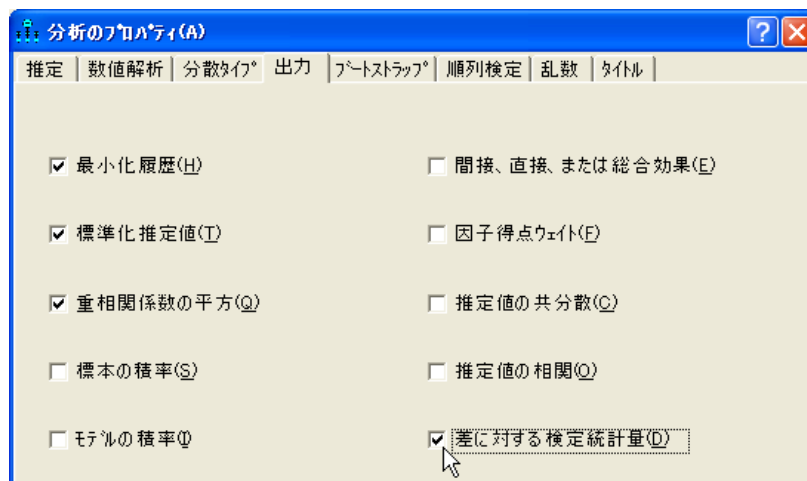


モデル A の女子生徒と男子生徒の推定値を視覚的に検査し、性差を確認できます。1 つのパラメータの値が女子生徒と男子生徒で大幅に異なるかどうかを確認するには、自由なパラメータのすべてのペア間の差に対する検定統計量の表を調べます。

### パラメータの差に対する検定統計量を取得する

- ▶ メニューから、[表示]→[分析のプロパティ]を選択します。
- ▶ [分析のプロパティ]ダイアログボックスで、[出力]タブをクリックします。

- ▶ [パラメータの差に対する検定統計量] を選択します。



ただし、この例では差に対する検定統計量は使用せず、グループの差を確認する代替方法を使用します。

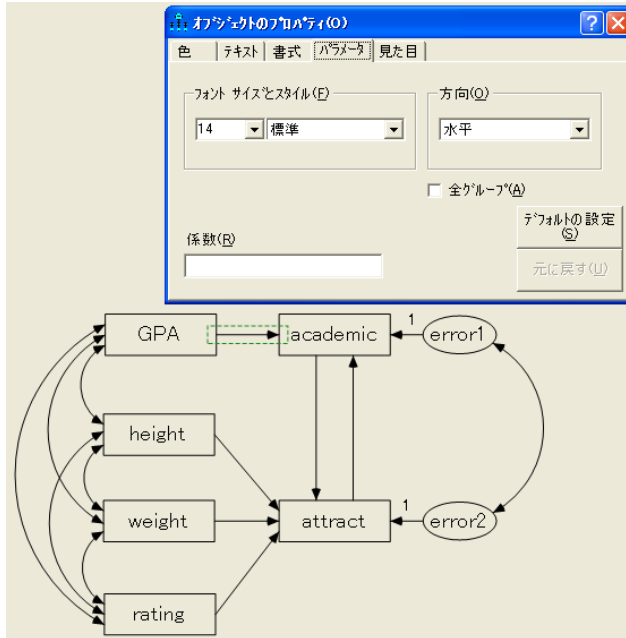
## 女子生徒と男子生徒のモデル B

ここでは主に係数に注目し、(モデル B では) 女子生徒と男子生徒が同じ係数になると仮定します。このモデルでは、外生変数の分散と共分散がグループによって異なる可能性があります。

このモデルでは、変数間の線型従属がすべてのグループで不変である必要がある一方で、height や weight などの変数の分布が男子生徒と女子生徒で異なる可能性があります。モデル B では、各グループで 6 つの係数を制約する必要があります。

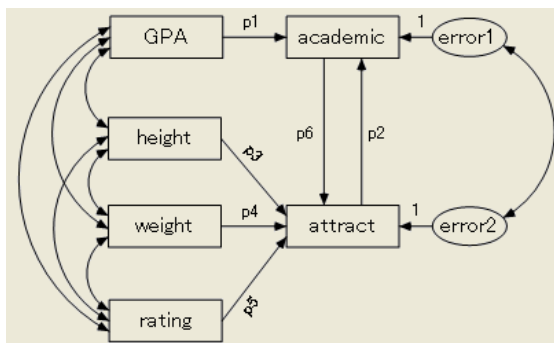
- ▶ 最初に、パス図の左側にある [グループ] パネルで [girls] をクリックし、女子生徒のパス図を表示します。
- ▶ 一方向矢印のいずれかを右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログボックスの [パラメータ] タブをクリックします。
- ▶ [係数] テキストボックスに名前を入力します。

- ▶ [全グループ] を選択します。[全グループ] の横にチェック マークが表示されます。チェック マークが付いている場合、すべてのグループでこの係数に同じ名前が割り当てられます。



- ▶ [オブジェクトのプロパティ] ダイアログ ボックスが開いた状態で、別の一方向矢印をクリックし、[係数] テキスト ボックスに別の名前を入力します。
- ▶ すべての係数に名前を付けるまでこの操作を繰り返します。常に [全グループ] を選択 (チェック マークを付ける) してください。

すべての係数に名前を付けたら、各標本のパス図は次のようになります。





## モデル B の結果

### テキスト出力

モデル B はデータに非常によく適合しています。

カイ2乗 = 9.493
自由度 = 10
確率水準 = 0.486

モデル A とモデル B を比較すると、有意でないカイ2乗 ( $9.493 - 3.183 = 6.310$ ) と自由度 ( $10 - 4 = 6$ ) が得られます。モデル B が正しいと仮定すると、モデル B の推定値がモデル A の推定値より適していると考えられます。

女子生徒の標本の非標準化パラメータ推定値は次のとおりです。

係数: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
academic	<-- GPA	.021	.002	9.326	***	p1
attract	<-- height	.000	.010	.042	.967	p3
attract	<-- weight	-.002	.001	-1.275	.202	p4
attract	<-- rating	.176	.027	6.429	***	p5
attract	<-- academic	1.618	.360	4.489	***	p6
academic	<-- attract	.008	.044	.181	.856	p2
共分散: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA	<--> rating	.526	.246	2.139	.032	par_7
height	<--> rating	-.468	.205	-2.279	.023	par_8
GPA	<--> weight	-6.710	4.676	-1.435	.151	par_9
GPA	<--> height	1.819	.712	2.555	.011	par_10
height	<--> weight	19.024	4.098	4.642	***	par_11
weight	<--> rating	-5.243	1.395	-3.759	***	par_12
error1	<--> error2	-.006	.010	-.572	.567	par_13
分散: (girls - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA		12.122	1.189	10.198	***	par_26
height		8.428	.826	10.198	***	par_27
weight		371.476	36.427	10.198	***	par_28
rating		1.015	.100	10.198	***	par_29
error1		.019	.003	6.511	***	par_30
error2		.143	.014	9.936	***	par_31

男子生徒の非標準化パラメータ推定値は次のとおりです。

係数: (boys - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
academic <--	GPA	.021	.002	9.326	***	p1
attract <--	height	.019	.010	1.946	.052	par_14
attract <--	weight	-.003	.001	-2.488	.013	par_15
attract <--	rating	.096	.030	3.184	.001	par_16
attract <--	academic	1.375	.308	4.463	***	par_23
academic <--	attract	.052	.053	.980	.327	par_24

共分散: (boys - Default model)						
		推定値	標準誤差	検定統計量	確率	ラベル
GPA <-->	rating	.507	.274	1.850	.064	par_17
height <-->	rating	.198	.230	.860	.390	par_18
GPA <-->	weight	-15.645	6.899	-2.268	.023	par_19
GPA <-->	height	-1.508	.961	-1.569	.117	par_20
height <-->	weight	42.091	6.455	6.521	***	par_21
weight <-->	rating	-4.226	1.662	-2.543	.011	par_22
error1 <-->	error2	-.008	.010	-.792	.428	par_25

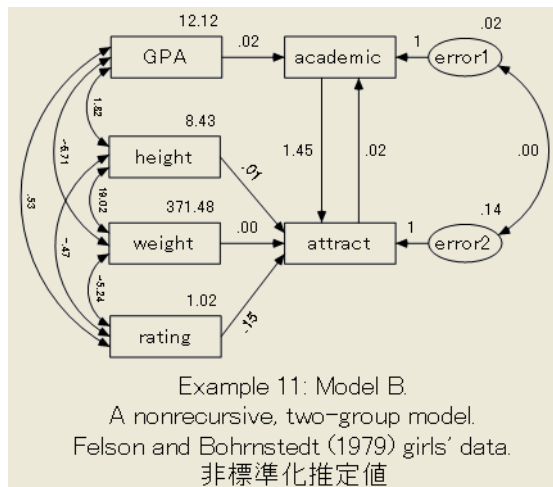
  

分散: (boys - Default model)					
	推定値	標準誤差	検定統計量	確率	ラベル
GPA	16.243	1.600	10.149	***	par_32
height	11.572	1.140	10.149	***	par_33
weight	588.605	57.996	10.149	***	par_34
rating	.936	.092	10.149	***	par_35
error1	.015	.002	7.376	***	par_36
error2	.164	.016	10.149	***	par_37

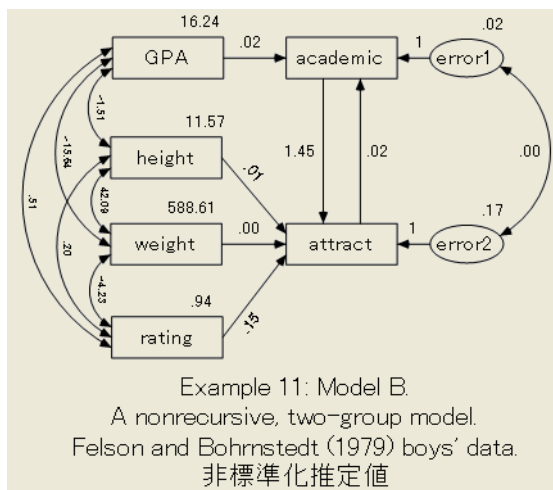
モデル B の指定により、男子生徒の推定係数は女子生徒の推定係数と同じになります。

## グラフィックス出力

女子生徒の出力パス図は次のとおりです。



男子生徒の出力は次のとおりです。



## モデル A と B を単一の分析に適合する

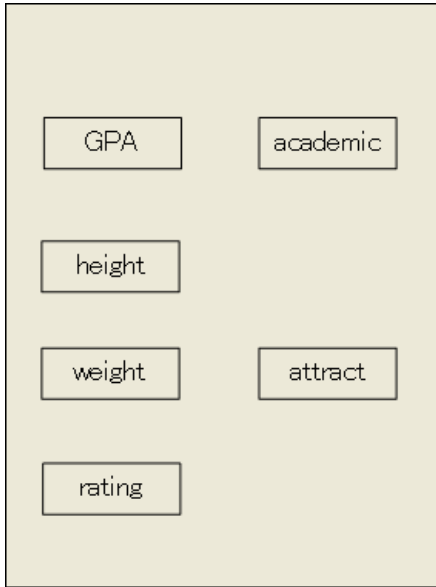
モデル A とモデル B を同一の分析に適合することができます。Amos の Examples ディレクトリにある Ex11-ab.amw ファイルに、この方法が示されています。

## 女子生徒と男子生徒のモデル C

すべてのパラメータを男子生徒と女子生徒で同じ値にするなど、モデル B に制約を追加することも検討できます。つまり、Felson と Bohrnstedt のモデルが両方のグループで正しくなる必要があると同時に、観測変数の分散/共分散行列全体が男子生徒と女子生徒で同じになると仮定します。このコースを進める代わりに、ここで Felson と Bohrnstedt のモデルから離れて、観測変数が女子生徒と男子生徒で同じ分散/共分散行列になるという仮定に注目してみましょう。この仮定を具象化するモデル (モデル C) を作成します。

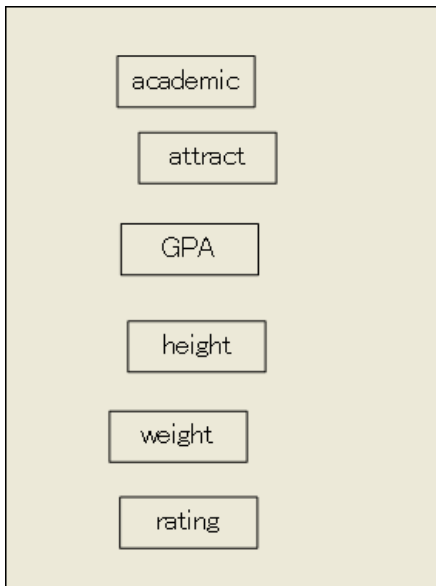
## 例 11

- ▶ モデル A またはモデル B のパス図を基にして、6 つの観測変数を除くすべてのオブジェクトをパス図から削除します ([編集]→[消去]を選択します)。パス図は次のようになります。



四角形の各ペアを双方向矢印で結ぶ必要があります。合計 15 の双方向矢印が必要です。

- ▶ 出力結果の外観を改善するには、メニューから [編集]→[移動] を選択し、マウスを使用して 6 つの四角形を次のように一列に並べます。




[プロパティをドラッグ] オプションを使用すると、四角形を一直線上に整列できます。

- ▶ メニューから、[編集]→[プロパティをドラッグ]を選択します。
- ▶ [プロパティをドラッグ]ダイアログボックスで、[高さ]、[幅]、および[X座標]を選択します。各項目の横にチェックマークが表示されます。
- ▶ マウスを使用して、これらのプロパティを **academic** から **attract** にドラッグします。  
これにより、**attract** の x 座標が **academic** と同じになります。つまり、一直線上に整列します。**attract** と **academic** のサイズが異なる場合は、サイズも同じになります。
- ▶ 次に、**attract** から **GPA** へ、**GPA** から **height** へ、以下同様にプロパティをドラッグします。6 つの変数がすべて一直線上に整列するまでこの操作を続けます。



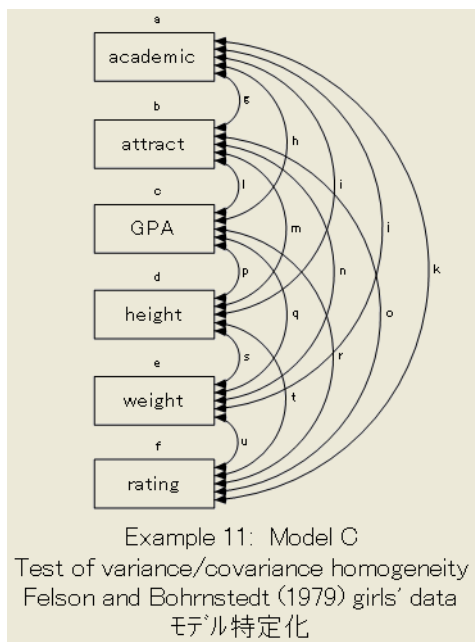
- ▶ 四角形の間隔を均等にするには、メニューから、[編集]→[すべて選択]を選択します。
- ▶ 次に、[編集]→[垂直に配置]を選択します。  
多数の双方向矢印を一度に作成するための特殊なボタンがあります。前の手順で 6 つの変数がすべて選択された状態で、次の操作を行います。

- ▶ メニューから、[プラグイン]→[共分散を描く (Draw Covariances)] を選択します。  
選択した変数間で使用可能なすべての共分散パスが作成されます。



- ▶ すべての分散と共分散に適切な名前のラベルを付けます。たとえば、a から u のラベルを付けます。[オブジェクトのプロパティ]ダイアログボックスで、パラメータに名前を付ける際には常に[全グループ]にチェックマークが付いていることを確認してください。
- ▶ メニューから、[分析]→[モデル管理] を選択し、男子生徒用の2つ目のグループを作成します。
- ▶ [ファイル]→[データ ファイル] を選択し、このグループに男子生徒のデータ セット (Fels\_ma1.sav) を指定します。

Ex11-c.amw ファイルには、モデル C のモデル指定が含まれます。入力パス図は次のとおりです。このパス図は両方のグループで同じになります。



## モデル C の結果

モデル C は、従来のすべての有意水準で棄却する必要があります。

カイ2乗 = 48.977
自由度 = 21
確率水準 = 0.001

この結果は、男子生徒と女子生徒の相違がまったくないモデルの提示によって時間を浪費してはいけないことを示しています。

## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。このプログラムは Ex11-a.vb として保存されています。

```
Sub Main()  
    Dim Sem As New AmosEngine  
    Try  
        Sem.TextOutput()  
  
        Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_fem.sav")  
        Sem.GroupName("girls")  
        Sem.AStructure("academic = GPA + attract + error1 (1)")  
        Sem.AStructure _  
            ("attract = height + weight + rating + academic + error2 (1)")  
        Sem.AStructure("error2 <--> error1")  
  
        Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_ma1.sav")  
        Sem.GroupName("boys")  
        Sem.AStructure("academic = GPA + attract + error1 (1)")  
        Sem.AStructure _  
            ("attract = height + weight + rating + academic + error2 (1)")  
        Sem.AStructure("error2 <--> error1")  
  
        Sem.FitModel()  
    Finally  
        Sem.Dispose()  
    End Try  
End Sub
```



## モデル B

次のプログラムはモデル B を適合します。このプログラムでは、パラメータ ラベル p1 から p6 を使用してグループ全体に同等性の制約条件を適用します。このプログラムは Ex11-b.vb に保存されています。

```
Sub Main()
    Dim Sem As New AmosEngine
    Try
        Sem.TextOutput()

        Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_fem.sav")
        Sem.GroupName("girls")
        Sem.AStructure("academic = (p1) GPA + (p2) attract + (1) error1")
        Sem.AStructure("attract = "& _
            "(p3) height + (p4) weight + (p5) rating + (p6) academic + (1) error2")
        Sem.AStructure("error2 <--> error1")

        Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_mal.sav")
        Sem.GroupName("boys")
        Sem.AStructure("academic = (p1) GPA + (p2) attract + (1) error1")
        Sem.AStructure("attract = "& _
            "(p3) height + (p4) weight + (p5) rating + (p6) academic + (1) error2")
        Sem.AStructure("error2 <--> error1")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub
```

## モデル C

モデル C 用の VB.NET プログラムはここには示しません。このプログラムは Ex11-c.vb ファイルに保存されています。

## 複数のモデルを適合する

次のプログラムはモデル A と B の両方を適合します。このプログラムは Ex11-ab.vb ファイルに保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_fem.sav")
    Sem.GroupName("girls")
    Sem.AStructure("academic = (g1) GPA + (g2) attract + (1) error1")
    Sem.AStructure("attract = "& _
      "(g3) height + (g4) weight + (g5) rating + (g6) academic + (1) error2")
    Sem.AStructure("error2 <--> error1")

    Sem.BeginGroup(Sem.AmosDir & "Examples\Fels_ma1.sav")
    Sem.GroupName("boys")
    Sem.AStructure("academic = (b1) GPA + (b2) attract + (1) error1")
    Sem.AStructure("attract = "& _
      "(b3) height + (b4) weight + (b5) rating + (b6) academic + (1) error2")
    Sem.AStructure("error2 <--> error1")

    Sem.Model("Model_A")
    Sem.Model("Model_B", _
      "g1=b1", "g2=b2", "g3=b3", "g4=b4", "g5=b5", "g6=b6")

    Sem.FitAllModels()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

# 複数のグループの同時因子分析

## 概要

この例は、複数の母集団のそれぞれに対して、同じ因子分析モデルが適用されるかどうかを検定する方法を示します。異なる母集団に対しては、パラメータも異なる可能性があります (Jöreskog, 1971 年)。

## データについて

ここでは、例 8 で説明した Holzinger と Swineford (1939 年) のデータを使用します。ただし、今回は Grant-White の標本から、例 8 で調べた 73 人の少女のデータだけでなく、72 人の少年のデータも分析します。Grnt\_fem.sav ファイルに保存されている少女のデータについては、例 8 で説明しました。以下に、Grnt\_ma1.sav ファイルに保存されている少年の標本 データを示します。

visperc	cubes	lozenges	paragraph	sentence	wordmean
23	19	4	10	17	10
34	24	22	11	19	19
29	23	9	9	19	11
16	25	10	8	25	24
27	26	6	10	16	13
32	21	8	1	7	11
38	31	12	10	11	14

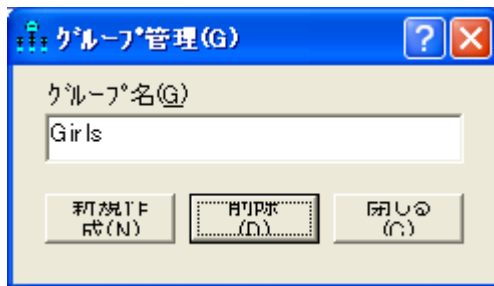
## Holzinger と Swineford の少年少女のモデル A

例 8 の共通因子分析モデルは、少女の場合と同じく、少年の場合にも適用されるという仮説を考えます。例 8 のパス図は、この 2 グループのモデルの出発点として使用できます。Amos Graphics では、デフォルトで両方のグループが同じパス図を持っていると仮定されます。そのため、2 つのグループに対してパス図を 2 回描く必要はありません。

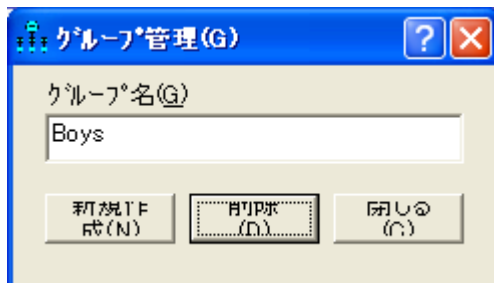
例 8 では、グループは 1 つしかないため、グループの名前は重要ではありませんでした。デフォルトのグループ番号 1 という名前をそのまま使用できました。今回は 2 つのグループを管理するので、グループにわかりやすい名前を付ける必要があります。

### グループに名前を付ける

- ▶ メニューから [分析] → [グループ管理] を選択します。
- ▶ [グループ管理] ダイアログ ボックスで、[グループ名] に「Girls」と入力します。



- ▶ [グループ管理] ダイアログ ボックスを開いたまま、[新規作成] をクリックして別のグループを作成します。
- ▶ [グループ名] テキスト ボックスに「Boys」と入力します。

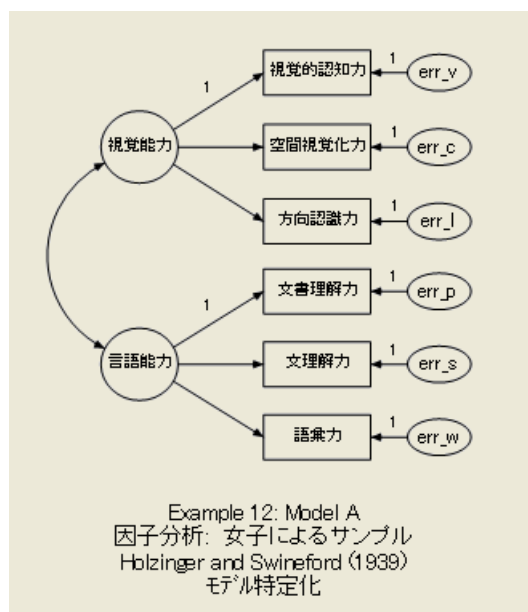


- ▶ [閉じる] をクリックして [グループ管理] ダイアログ ボックスを閉じます。

## データの指定

- ▶ メニューから、[ファイル]→[データ ファイル] を選択します。
- ▶ [データ ファイル]ダイアログ ボックスで、Girls をダブルクリックして、データ ファイルに grnt\_fem.sav を指定します。
- ▶ 次に Boys をダブルクリックして、データ ファイルに grnt\_mal.sav を指定します。
- ▶ [OK] をクリックして、[データ ファイル]ダイアログ ボックスを閉じます。

少女の標本のパス図は次のようになります。



少年のパス図も同じです。ただし、パラメータ推定値は2つのグループで異なる場合もあることに注意してください。

## モデル A の結果

### テキスト出力

このモデルの自由度の計算では、例 8 のすべての数値がちょうど 2 倍になります。

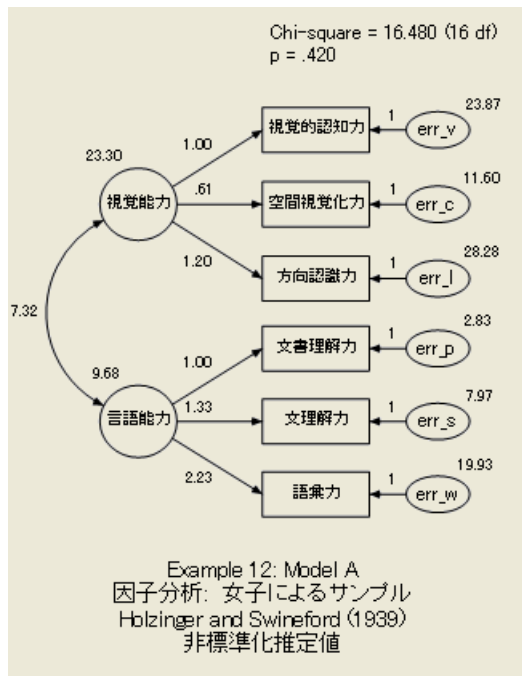
自由度の計算 (デフォルト モデル)	
異なる標本の積率の数	42
推定される異なるパラメータの数	26
自由度 (42 - 26)	16

通常の有意水準では、モデル A は適合します。モデル A が棄却される場合は、2 つのグループのうち少なくとも 1 つのパス図を変更する必要があります。

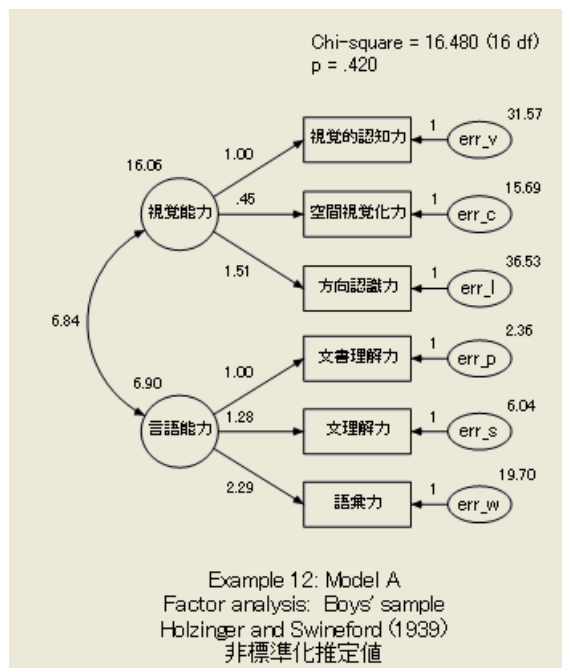
カイ 2 乗 = 16.480
自由度 = 16
確率水準 = 0.420

### グラフィック出力

ここに示すのは、73 人の少女の (標準化されていない) パラメータ推定値です。これは、少女だけを調べた例 8 で得られたものと同じ推定値です。



72 人の少年の出力パス図は、次のようになります。



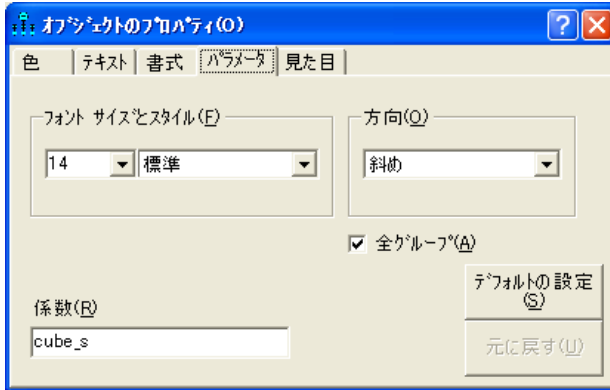
推定された係数は、グループ間でほとんど変わっていないことに注意してください。2つの母集団は同じ係数を持っているように思われます。モデル B では、この仮説を検定します。

## Holzinger と Swineford の少年少女のモデル B

ここでは、少年と少女のパス図は同じであるという仮説を使用します。次に、少年と少女が同じパラメータ値を持つかどうかを調べます。次のモデル (モデル B) では、少年の母集団のすべてのパラメータが、少女の対応するパラメータと等しくなることまでは要求しません。要求するのは、因子パターン (つまり、係数) が、両方のグループで等しくなることです。モデル B では、少年と少女は異なる固有の分散を持つことができます。共通因子の分散および共分散も、グループ間で異なる場合があります。

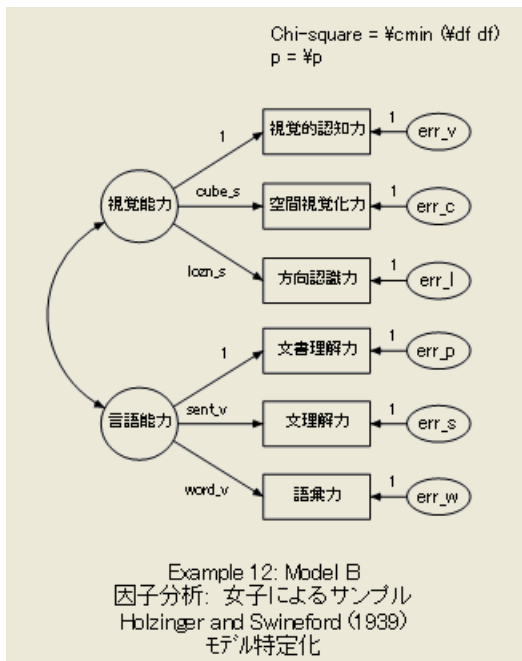
- ▶ モデル A をモデル B の出発点として使用します。
- ▶ まず、パス図の左にある [グループ] パネルで **Girls** をクリックして、少女のパス図を表示します。
- ▶ **spatial** (視覚能力) から **cubes** (空間視覚化力) へ伸びる矢印を右クリックして、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログボックスの [パラメータ] タブをクリックします。

- ▶ [係数] テキスト ボックスに「cube\_s」と入力します。
- ▶ [全グループ] を選択します。[全グループ] の横にチェック マークが表示されます。チェック マークを付けることにより、両方のグループでこの係数に同じ名前が割り当てられます。



- ▶ [オブジェクトのプロパティ] ダイアログ ボックスを開いたまま、残りの片矢印を順にクリックし、それぞれ [係数] テキスト ボックスに名前を入力します。この操作を繰り返して、すべての係数に名前を付けます。常に [全グループ] を選択 (チェック マークを付ける) してください。(既に 1 に固定されている係数は、そのままにしてください。)

2 つの標本のパス図は、いずれも次のようになります。





## モデル B の結果

### テキスト出力

モデル B で追加された制約条件のため、データから推定されるパラメータの数は 4 つ少なくなり、自由度の数は 4 だけ増えます。

自由度の計算 (デフォルト モデル)	
異なる標本の積率の数	42
推定される異なるパラメータの数	22
自由度 (42 - 20)	20

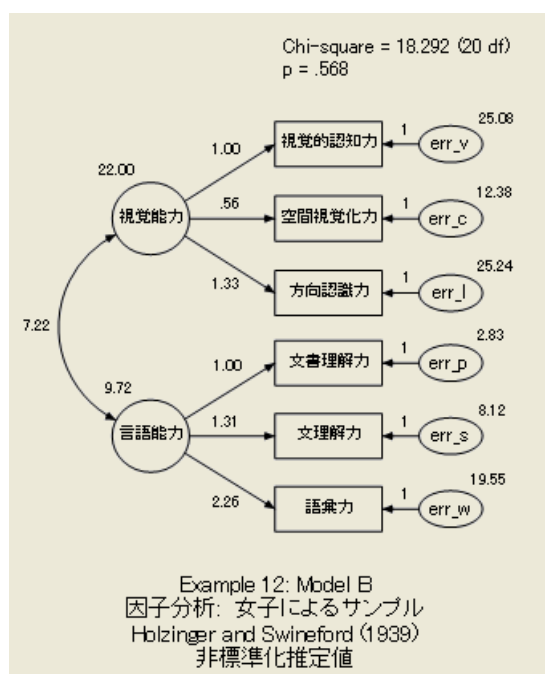
カイ 2 乗適合度統計量は許容可能です。

カイ 2 乗 = 18.292
自由度 = 20
確率水準 = 0.568

モデル A とモデル B のカイ 2 乗の差  $18.292 - 16.480 = 1.812$  も、通常の有意水準では大きな差ではありません。したがって、グループによらない因子パターンを指定したモデル B は、Holzinger と Swineford のデータに適合します。

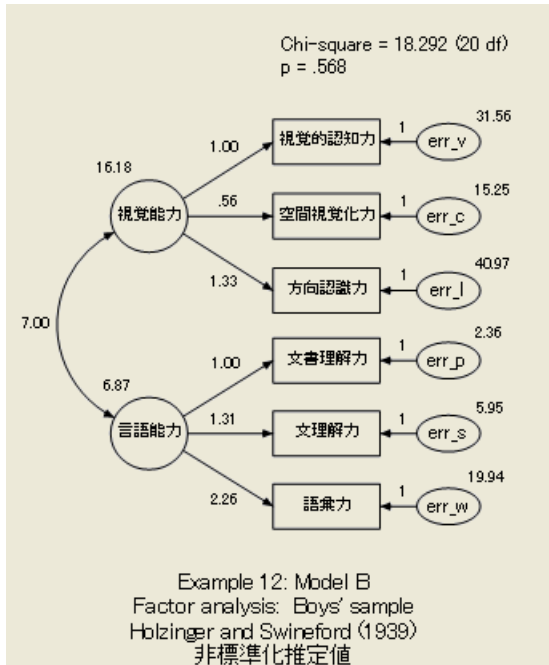
### グラフィック出力

ここに示すのは、73 人の少女のパラメータ推定値です。



例 12

ここに示すのは、72 人の少年のパラメータ推定値です。



予想されるとおり、モデル B のパラメータ推定値は、モデル A の推定値とは異なっています。次の表に、2 つのモデルの推定値と標準誤差を並べて示しています。

[パラメータ]	モデル A		モデル B	
少女の標本	推定値	標準誤差	推定値	標準誤差
g: cubes (空間視覚化力) <--- spatial (視覚能力)	0.610	0.143	0.557	0.114
g: lozenges (方向認識力) <--- spatial (視覚能力)	1.198	0.272	1.327	0.248
g: sentence (文理解力) <--- verbal (言語能力)	1.334	0.160	1.305	0.117
g: wordmean (語彙力) <--- verbal (言語能力)	2.234	0.263	2.260	0.200
g: spatial (視覚能力) <---> verbal (言語能力)	7.315	2.571	7.225	2.458
g: var(spatial)	23.302	8.124	22.001	7.078
g: var(verbal)	9.682	2.159	9.723	2.025
g: var(err_v)	23.873	5.986	25.082	5.832
g: var(err_c)	11.602	2.584	12.382	2.481
g: var(err_l)	28.275	7.892	25.244	8.040
g: var(err_p)	2.834	0.869	2.835	0.834
g: var(err_s)	7.967	1.869	8.115	1.816
g: var(err_w)	19.925	4.951	19.550	4.837
少年の標本	推定値	標準誤差	推定値	標準誤差
b: cubes (空間視覚化力) <--- spatial (視覚能力)	0.450	0.176	0.557	0.114
b: lozenges (方向認識力) <--- spatial (視覚能力)	1.510	0.461	1.327	0.248
b: sentence (文理解力) <--- verbal (言語能力)	1.275	0.171	1.305	0.117
b: wordmean (語彙力) <--- verbal (言語能力)	2.294	0.308	2.260	0.200
b: spatial (視覚能力) <---> verbal (言語能力)	6.840	2.370	6.992	2.090
b: var(spatial)	16.058	7.516	16.183	5.886
b: var(verbal)	6.904	1.622	6.869	1.465
b: var(err_v)	31.571	6.982	31.563	6.681
b: var(err_c)	15.693	2.904	15.245	2.934
b: var(err_l)	36.526	11.532	40.974	9.689
b: var(err_p)	2.364	0.726	2.363	0.681
b: var(err_s)	6.035	1.433	5.954	1.398
b: var(err_w)	19.697	4.658	19.937	4.470

2つを除いて、すべての標準誤差の推定値がモデルBの方が小さくなっています。これには、制約条件のないパラメータも含まれます。これが、モデルBが正しいということ仮定して、モデルAではなくモデルBのパラメータ推定値を使用する理由です。

## VB.NET でのモデル作成

### モデル A

次のプログラム (Ex12-a.vb) は、モデル A の少年少女を表しています。

```
Sub Main()
    Dim Sem As New AmosEngine
    Try
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()

        Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")
        Sem.GroupName("Girls")
        Sem.AStructure("visperc = (1) spatial + (1) err_v")
        Sem.AStructure("cubes = spatial + (1) err_c")
        Sem.AStructure("lozenges = spatial + (1) err_l")

        Sem.AStructure("paragrap = (1)spatial + (1) err_p")
        Sem.AStructure("sentence = spatial + (1) err_s")
        Sem.AStructure("wordmean= spatial + (1) err_w")

        Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_mal.sav")
        Sem.GroupName("Boys")
        Sem.AStructure("visperc = (1) spatial + (1) err_v")
        Sem.AStructure("cubes = spatial + (1) err_c")
        Sem.AStructure("lozenges = spatial + (1) err_l")

        Sem.AStructure("paragrap = (1)spatial + (1) err_p")
        Sem.AStructure("sentence = spatial + (1) err_s")
        Sem.AStructure("wordmean= spatial + (1) err_w")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub
```

少年についても、少女と同じモデルを指定します。ただし、少年のパラメータ値は対応する少女のパラメータ値とは異なる場合があります。

## モデル B

ここでは、モデル B に適合するプログラムを示します。モデル B では、いくつかのパラメータに同じ名前を付け、等しくなるように制約条件を設定しています。このプログラムは、Ex12-b.vb という名前で保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")
    Sem.GroupName("Girls")
    Sem.AStructure("visperc = (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (lozn_s) spatial + (1) err_l")

    Sem.AStructure("paragrap = (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (word_v)spatial + (1) err_w")

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_ma.sav")
    Sem.GroupName("Boys")
    Sem.AStructure("visperc = (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (lozn_s) spatial + (1) err_l")

    Sem.AStructure("paragrap = (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (word_v)spatial + (1) err_w")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```



# 平均値に関する仮説の推定および検定

## 概要

この例は、平均値の推定方法および平均値に関する仮説の検定方法を示します。大規模な標本では、ここで示す方法は多変量分散分析と同等です。

## 平均値と切片のモデル作成

Amos や同様のプログラムを使用する場合、通常は分散、共分散、係数を推定し、これらのパラメータに関する仮説を検定します。平均値と切片は通常は推定せず、平均値と切片に関する仮説は通常は検定しません。平均値と切片は、これらのパラメータを含むモデルの指定は比較的難しいため、構造モデルの方程式から外される場合も少なくありません。

しかし、Amos は平均値と切片のモデル作成が容易になるように設計されています。ここで示す例は、平均値と切片を推定し、仮説を検定する方法を示す最初の例です。この例では、モデルのパラメータは分散、共分散、平均値のみから構成されます。後の例では、回帰式に係数と切片を導入します。

## データについて


この例では、例 1 で説明した Attig (1983 年) のメモリ データを使用します。ここでは、若者および老人両方の被験者のデータを使用します。2 つのグループの生データは、UserGuide.xls という Microsoft Excel ワークブックの Attg\_yng および Attg\_old ワークシートに含まれています。この例で使用する測定値は、記憶 1 および助成記憶 1 だけです。

## 若者および老人の被験者のモデル A

例 10 のモデル B の分析では、記憶 1 および助成記憶 1 は、若者と老人の両方のグループについて、分散および共分散が同じであるという結論になりました。少なくとも、見つかった仮説の反証は有意なものではありませんでした。この例でのモデル A は、例 10 のモデル B の分析に手を加えたものです。今回は、2 つの変数 (記憶 1 および助成記憶 1) の平均値も推定します。

## Amos Graphics の平均構造モデル

Amos Graphics では、平均値に関する仮説の推定と検定は、分散および共分散構造の分析とそれほど違いありません。例 10 のモデル B を出発点にします。若者と老人の被験者は、次のような同じパス図を持っています。



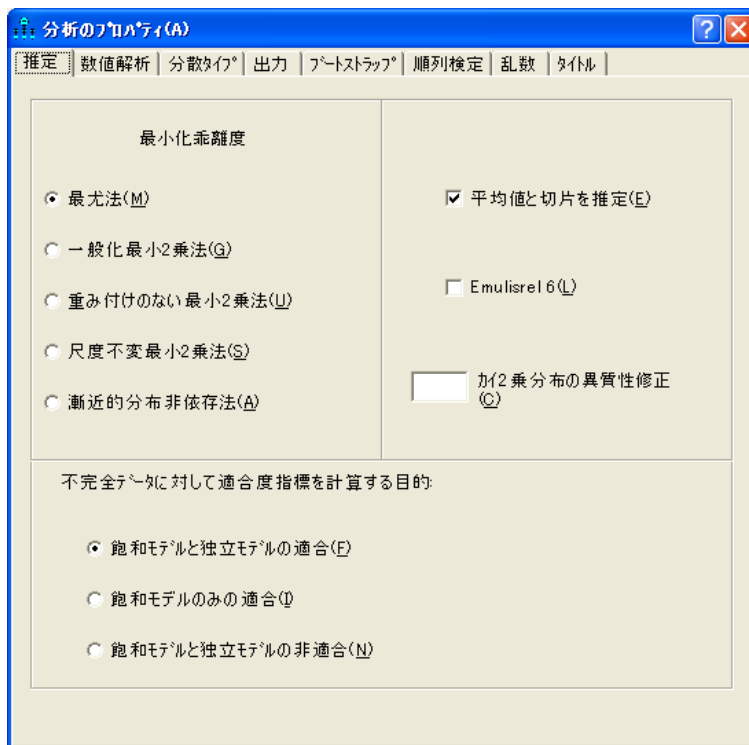
両方のグループで、同じパラメータ名を使用します。これにより、必要なパラメータ推定値が両グループで同じになります。

例 10 には、平均値と切片はありません。このモデルに平均値と切片を導入するには、次の操作を実行します。


- ▶ メニューから、[表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[推定] タブをクリックします。



- ▶ [平均値と切片を推定] を選択します。



パス図は次のようになります(どちらのグループも同じパス図です)。



パス図には、各外生変数について、パラメータの平均値、分散の組が表示されています。このモデルには内生変数がないため、切片はありません。パス図の各変数について、カンマの後に分散の名前が続きます。モデルの平均値はまだ名前を付けていないため、カンマの前は空白になっています。

[分析]メニューから[推定値を計算]を選択すると、Amosは2つの平均値、2つの分散、および各グループの共分散を推定します。分散と共分散はグループ間で等しくなるという制約条件がありますが、平均値には制約条件はありません。

[平均値と切片を推定]を選択(チェックマークを付ける)すると、Amos Graphicsの動作は次のように変わります。

- 平均値と切片のフィールドが[オブジェクトのプロパティ]ダイアログボックスの[パラメータ]タブに表示されます。
- 係数、分散、共分散だけでなく、平均値と切片にも制約条件を適用することができます。
- メニューから[分析]→[推定値を計算]を選択すると、平均値と切片—が推定されます。制約条件がある場合は適用されません。
- 標本の共分散を入力として与える場合、標本の平均値を与える必要があります。

[平均値と切片を推定]にチェックマークを「付けない」場合は次のようになります。

- 分散、共分散、および係数のフィールドだけが[オブジェクトのプロパティ]ダイアログボックスの[パラメータ]タブに表示されます。制約条件はこれらのパラメータにのみ指定できます。
- [推定値を計算]を選択する場合、Amosは分散、共分散、係数は推定しますが、平均値と切片は推定「しません」。
- 標本の平均値を与えずに、標本の共分散を入力として与えることができます。標本の平均値を与えても無視されます。
- 平均モデルを当てはめた後に[平均値と切片を推定]のチェックマークを外した場合、出力パス図には平均値と切片が残ります。平均値と切片のない正しい出力パス図を表示するには、[平均値と切片を推定]のチェックマークを外してからモデルの推定値を「再計算」します。

以上の規則に従って[平均値と切片を推定]チェックボックスを使用して、従来のパスモデルと同様に、簡単に平均モデルの推定および検定ができます。

## モデル A の結果

### テキスト出力

このモデルの自由度の数は、例 10 のモデル B と同じです。ここでは、異なる方法で自由度を求めます。今回は、独立な標本積率の数には標本の平均値だけでなく、標本の分散および共分散も含まれます。若者の標本には、2つの分散、1つの共分散、2つの平均値があり、合計 5 つの標本積率があります。同様に、老人の標本にも 5 つの標本積率があります。したがって、両方の標本を合わせると 10 個の標本積率があります。推定パラメータは 7 つあります。それぞれ、var\_rec (記憶 1 の分散)、var\_cue (助成記憶 1 の分散)、cov\_rc (記憶 1 と助成記憶 1 の共分散)、若者と老人の中での記憶 1 の平均値 (2 つ)、若者と老人の中での助成記憶 1 の平均値 (2 つ) です。

したがって、自由度の数は次のように計算されます。

**自由度の計算 (Default model)**

独立な標本積率の数: 10  
 独立な推定パラメータの数: 7  
 自由度 (10 - 7): 3

ここでのカイ2乗統計量も、例10のモデルBと同じです。通常の有意水準では、若者と老人が同じ分散と共分散を持つという仮説は適用できます。

カイ2乗 = 4.588  
 自由度 = 3  
 確率水準 = 0.205

ここに示すのは、40人の若者の被験者のパラメータ推定値です。

平均値 : (young subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1	10.250	.382	26.862	***	
助成記憶1	11.700	.374	31.292	***	
共分散: (young subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1 <-> 助成記憶1	4.056	.780	5.202	***	cov_rc
分散: (young subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1	5.678	.909	6.245	***	var_rec
助成記憶1	5.452	.873	6.245	***	var_cue

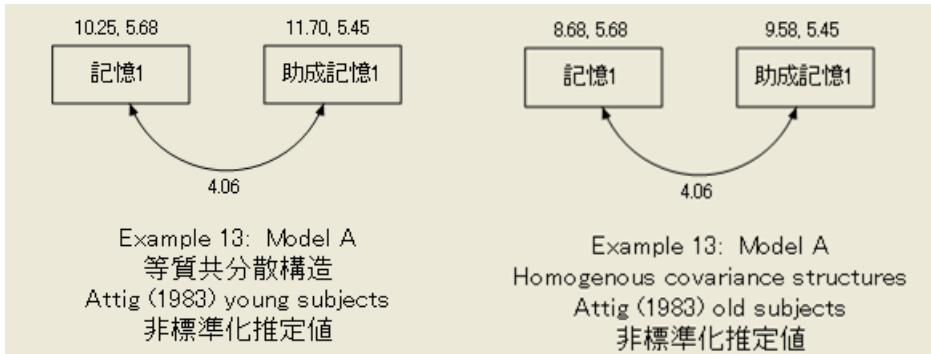
ここに示すのは、40人の老人の被験者の推定値です。

平均値 : (old subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1	8.675	.382	22.735	***	
助成記憶1	9.575	.374	25.609	***	
共分散: (old subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1 <-> 助成記憶1	4.056	.780	5.202	***	cov_rc
分散: (old subjects - モデル番号 1)					
	推定値	標準誤差	検定統計量	確率	ラベル
記憶1	5.678	.909	6.245	***	var_rec
助成記憶1	5.452	.873	6.245	***	var_cue

平均値を除いて、これらの推定値は例10のモデルBで得られた推定値と同じです。標準誤差および検定統計量の推定値も同じです。このことは、平均値に制約条件を指定せずに平均値を推定しても、残りのパラメータや標準誤差の推定値には影響しないことを示しています。

## グラフィック出力

2つのグループのパス図の出力を次に示します。各変数の隣に、平均値と分散の組が表示されています。たとえば、若者の被験者の場合、変数記憶1の平均の推定値は10.25、分散の推定値は5.68です。

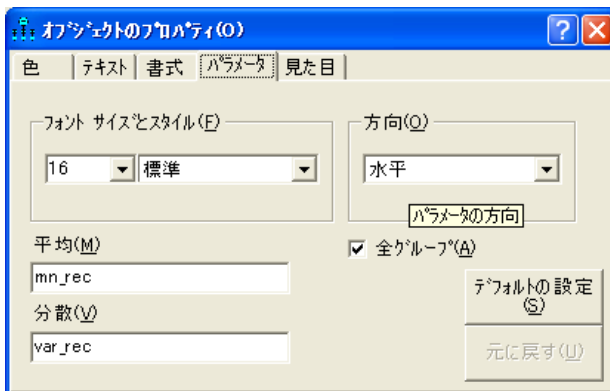


## 若者および老人の被験者のモデル B

ここからは、モデル A が正しいと仮定して、両方のグループの記憶1 および助成記憶1の平均値が同じであるという、より限定的な仮説を考えます。

記憶1 および助成記憶1の平均値に制約条件を指定するには、次の操作を実行します。

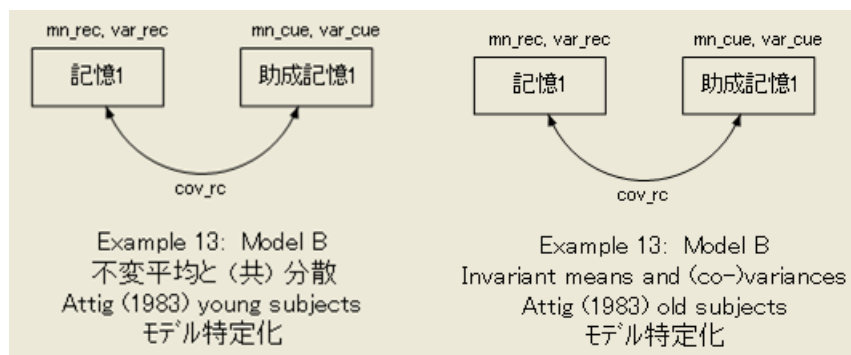
- ▶ 記憶1を右クリックして、ポップアップメニューから[オブジェクトのプロパティ]を選択します。
- ▶ [オブジェクトのプロパティ]ダイアログボックスの[パラメータ]タブをクリックします。



[平均値] テキストボックスには、数値か名前のいずれかを入力できます。ここでは、「mn\_rec」という名前を入力します。

- ▶ [全グループ] を選択します。([全グループ] の隣にチェック マークが表示されます。チェック マークを付けると、すべてのグループの記憶 1 の平均値に `mn_rec` という名前を割り当て、すべてのグループで記憶 1 の平均値が同じであることが要求されます。)
- ▶ 記憶 1 の平均値に `mn_rec` という名前を付けた後、同じ手順で助成記憶 1 の平均値に `mn_cue` という名前を付けます。

2 つのグループのパス図は、次のようになります。



このパス図は、Ex13-b.amw ファイルに保存されています。

## モデル B の結果

平均値に新しい制約条件を指定すると、モデル B の自由度は 5 になります。

自由度の計算 (Default model)	
独立な標本積率の数:	10
独立な推定パラメータの数:	5
自由度 (10 - 5):	5

通常の有意水準では、モデル B は棄却されます。

カイ 2 乗 = 19.267
自由度 = 5
確率水準 = 0.002

## モデル B とモデル A との比較

モデル A が正しく、モデル B が誤りである場合 (これは、モデル A は適用でき、モデル B は棄却されたことから理に適っています)、平均値が等しいという仮定が誤っていることとなります。分散と共分散が等しいという仮定の下で平均値が等しいという仮説をさらに検定するには、次の方法があります。モデル B をモデル A と比較すると、カイ 2 乗統計量の差は 14.679、自由度の差は 2 です。モデル B は、モデル A に制約条件を追加して得られたため、モデル B が正しい場合、差の 14.679 は、自由度の差 2 によるカイ 2 乗変数についての観測値です。この大きさのカイ 2 乗値を得られる確率は 0.001 です。したがって、モデル A を受け入れてモデル B は棄却し、2 つのグループの平均値は異なると結論することができます。

モデル B をモデル A と比較することは、Amos の通常の多変量分散分析に非常に近い方法です。実際、Amos のカイ 2 乗検定は漸近的にのみ正しいという点を除いて、Amos の検定は通常の MANOVA と同等です。対照的に、この例の場合、MANOVA では正確な検定を行うことができます。

## 複数のモデル入力

単一の分析でモデル A およびモデル B を両方当てはめることができます。Ex13-all.amw ファイルでこの方法を示します。単一の分析で両方のモデルを当てはめる利点のひとつは、2 つのモデルが入れ子になっていることを Amos が認識し、カイ 2 乗値の差だけでなく、モデル B をモデル A に対して検定する場合の p 値を自動的に計算することです。

## VB.NET での平均構造モデル作成

### モデル A

ここで示すプログラム (Ex13-a.vb) は、モデル A に適合します。このプログラムでは、例 10 のモデル B で使用した分散と共分散の制限を保持し、さらに平均値についても制約条件を指定します。

```

Sub Main()
    Dim Sem As New AmosEngine
    Try
        Dim dataFile As String = AmosEngine.AmosDir & "Examples\UserGuide.xls"

        Sem.TextOutput()
        Sem.ModelMeansAndIntercepts()

        Sem.BeginGroup(dataFile, "Atte_yng")
        Sem.GroupName("young_subjects")
        Sem.AStructure("記憶1 (var_rec)")
        Sem.AStructure("助成記憶1 (var_cue)")
        Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
        Sem.Mean("記憶1")
        Sem.Mean("助成記憶1")

        Sem.BeginGroup(dataFile, "Atte_old")
        Sem.GroupName("old_subjects")
        Sem.AStructure("記憶1 (var_rec)")
        Sem.AStructure("助成記憶1 (var_cue)")
        Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
        Sem.Mean("記憶1")
        Sem.Mean("助成記憶1")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub

```

ModelMeansAndIntercepts メソッドを使用して、(外生変数の) 平均値および(内生変数の予測における) 切片が明示的なモデルパラメータとして推定されるように指定します。

Mean メソッドは、記憶 1 および助成記憶 1 の平均値を推定するために各グループで 2 回使用します。このプログラムで Mean メソッドを使用しない場合、記憶 1 および助成記憶 1 の平均値は 0 で固定されます。Amos プログラムで ModelMeansAndIntercepts メソッドを使用する場合、別の平均値を指定しないと、Amos では各外生変数の平均値が 0 と仮定されます。平均値を推定する外生変数につき 1 回 Model メソッドを使用する必要があります。ModelMeansAndIntercepts メソッドを使用する場合は、Amos プログラムがこのように動作することを考慮する必要はありません。

注: Amos プログラムで Sem.ModelMeansAndIntercepts メソッドを使用する場合、平均値を推定する外生変数ごとに 1 回、Mean メソッドを呼び出す必要があります。Mean メソッドを使用して明示的に推定しない外生変数は、平均値が 0 と仮定されます。

この点が Amos Graphics と違います。Amos Graphics では、[ 平均値と切片を推定 ] にチェック マークを付けると、平均値に明示的な制約条件が指定されていない限り、すべての外生変数の平均値が制約条件のないパラメータとして扱われます。

## モデル B

次のプログラム (Ex13-b.vb) は、モデル B に適合します。グループによらない分散と共分散が要求されることに加え、このプログラムではグループ間で等しい平均値を持つことも要求されます。

```
Sub Main0
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = AmosEngine.AmosDir & "Examples\UserGuide.xls"

    Sem.TextOutput()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "Attg_young")
    Sem.GroupName("young_subjects")
    Sem.AStructure("記憶1 (var_rec)")
    Sem.AStructure("助成記憶1 (var_cue)")
    Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
    Sem.Mean("記憶1", "mn_rec")
    Sem.Mean("助成記憶1", "mn_cue")

    Sem.BeginGroup(dataFile, "Attg_old")
    Sem.GroupName("old_subjects")
    Sem.AStructure("記憶1 (var_rec)")
    Sem.AStructure("助成記憶1 (var_cue)")
    Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
    Sem.Mean("記憶1", "mn_rec")
    Sem.Mean("助成記憶1", "mn_cue")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```



## 複数のモデルを適合する

次のプログラムは、モデル A およびモデル B の両方に適合します。このプログラムは、Ex13-all.vb という名前で保存されています。

```
Sub Main0
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = AmosEngine.AmosDir & "Examples\UserGuide.xls"

    Sem.TextOutput 0
    Sem.ModelMeansAndIntercepts 0

    Sem.BeginGroup(dataFile, "Attg_young")
    Sem.GroupName("young_subjects")
    Sem.AStructure("記憶1 (var_rec)")
    Sem.AStructure("助成記憶1 (var_cue)")
    Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
    Sem.Mean("記憶1", "mn_rec")
    Sem.Mean("助成記憶1", "mn_cue")

    Sem.BeginGroup(dataFile, "Attg_old")
    Sem.GroupName("old_subjects")
    Sem.AStructure("記憶1 (var_rec)")
    Sem.AStructure("助成記憶1 (var_cue)")
    Sem.AStructure("記憶1 <> 助成記憶1 (cov_rc)")
    Sem.Mean("記憶1", "mn_rec")
    Sem.Mean("助成記憶1", "mn_cue")

    Sem.FitModel 0
  Finally
    Sem.Dispose 0
  End Try
End Sub
```



# 明示的な切片を持つ回帰

## 概要

この例は、通常回帰分析で切片を推定する方法を示します。

## Amos が行う仮定

通常、ある変数が他の変数に線形従属すると指定する場合、Amos では付加定数、つまり切片を含む従属を表す線形方程式を仮定しますが、切片の推定は行いません。たとえば例 4 では、変数成果を他の 3 つの変数 (知識、価値、満足度) に線形従属するように指定しました。Amos では、次の形式の回帰方程式を仮定します。

$$\text{成果} = a + b_1 \times \text{知識} + b_2 \times \text{価値} + b_3 \times \text{満足度} + \text{error}$$

ここで、 $b_1$ 、 $b_2$ 、 $b_3$  は係数、 $a$  は切片です。例 4 では、係数  $b_1$  から  $b_3$  を推定しました。Amos では、例 4 の  $a$  は推定せず、パス図にも現れません。それでも、回帰方程式に  $a$  が存在すると仮定して  $b_1$ 、 $b_2$ 、 $b_3$  を推定しました。同様に、知識、価値、満足度が平均値を持つと仮定しましたが、平均値は推定せず、パス図にも現れません。通常は回帰方程式の平均値と切片をこの方法で扱えば十分です。しかし、場合によっては切片を推定したり、切片に関する仮説を検定したりする必要があることもあります。その場合、この例で示す手順に従う必要があります。

## データについて

ここでは、例 4 で最初に使用した Warren, White, Fuller (1974 年) のデータをもう一度使用します。ここでは、Examples ディレクトリにある UserGuide.xls の Warren5v という Excel ワークシートを使用します。以下に、標本の積率 (平均値、分散、共分散) を示します。

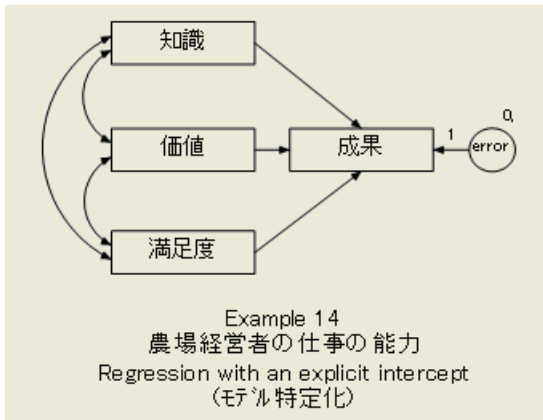
rowtype_	varname_	成果	知識	価値	満足度	教育
n		98	98	98	98	98
cov	成果	0.0209				
cov	知識	0.0177	0.052			
cov	価値	0.0245	0.028	0.1212		
cov	満足度	0.0046	0.0044	-0.0063	0.0901	
cov	教育	0.0187	0.0192	0.0353	-0.0066	0.0946
mean		0.0589	1.3796	2.8773	2.4613	2.1174

## モデルを指定する

例4で指定したものと同一回帰モデルを指定できます。例4の操作を行っている場合、そのパス図をこの例の出発点として使用できます。Amosで平均値と切片を推定するには、1つだけ変更する必要があります。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスの [推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します。

パス図は次のようになります。



変数誤差の上に、0, という文字列が表示されていることに注意してください。カンマの左の0は、変数誤差の平均値が0で固定されていることを示します。これは、線形回帰モデルでは通常の仮定です。0, のカンマの右に何も無いのは、誤差の分散が定数ではなく、名前を付けられていないことを表します。

[平均値と切片を推定] にチェック マークを付けると、Amosでは各予測変数について平均値を推定し、成果を予測する回帰方程式の切片を推定します。

## 分析の結果

### テキスト出力

現在の分析では例 4 と同じ結果になりますが、3 つの平均値と 1 つの切片が明示的に推定されます。自由度の数はここでも 0 ですが、自由度の計算は少し異なります。標本の平均値がこの分析に必要です。したがって、独立な標本積率の数には標本の分散と共分散だけでなく平均値も含まれます。標本には 4 つの平均値、4 つの分散、6 つの共分散があり、合計で 14 個の標本の積率があります。パラメータ推定値については、3 つの係数と 1 つの切片があります。また、3 つの予測変数には 3 つの平均値、3 つの分散、3 つの共分散があります。最後に、1 つの誤差分散があります。合計で 14 個のパラメータ推定値があります。

#### 自由度の計算 (Default model)

独立な標本積率の数:	14
独立な推定パラメータの数:	14
自由度 (14 - 14):	0

自由度が 0 であるため、検定する仮説はありません。

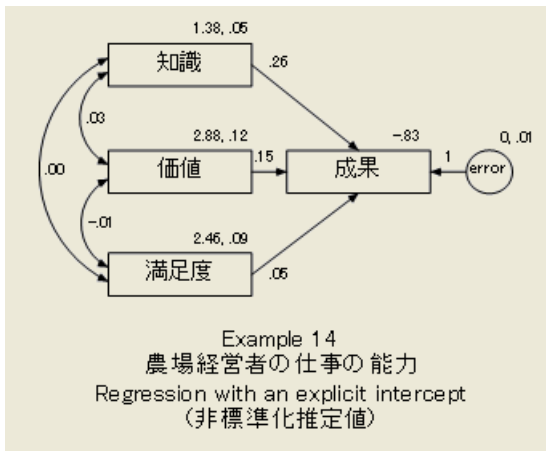
カイ 2 乗 = 0.000
自由度 = 0
確率水準の計算はできません。

係数、分散、共分散の推定は例 4 と同じです。また、関係する標準誤差、検定統計量、p 値も同じです。

係数: (グループ番号 1-モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
成果 <--	知識	.258	.054	4.822	***	
成果 <--	価値	.145	.035	4.136	***	
成果 <--	満足度	.049	.038	1.274	.203	
平均値: (グループ番号 1-モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
	価値	2.877	.035	81.818	***	
	知識	1.380	.023	59.891	***	
	満足度	2.461	.030	81.174	***	
共分散: (グループ番号 1-モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
知識 <-->	満足度	.004	.007	.632	.528	
価値 <-->	満足度	-.006	.011	-.593	.553	
知識 <-->	価値	.028	.008	3.276	.001	
分散: (グループ番号 1-モデル番号 1)						
		推定値	標準誤差	検定統計量	確率	ラベル
	知識	.051	.007	6.964	***	
	価値	.120	.017	6.964	***	
	満足度	.089	.013	6.964	***	
	error	.012	.002	6.964	***	

### グラフィック出力

この例の標準化されていない推定値を示すパス図を、以下に示します。内生変数成果の真上に切片  $-0.83$  が表示されています。



## VB.NET でのモデル作成

参照用に、例4の Amos プログラム (方程式版) をここに示します。

```
Sub Main0
  Dim Sem As New AmosEngine

  Try
    Sem.TextOutput0
    Sem.Standardized0
    Sem.Smc0
    Sem.ImpliedMoments0
    Sem.SampleMoments0

    Sem.BeginGroup(AmosEngine.AmosDir & "Examples#UserGuide.xls", "Warren5v")
    Sem.AStructure("成果 = 知識 + 価値 + 満足度 + error (1)")
    Sem.FitModel0
  Finally
    Sem.Dispose0
  End Try
End Sub
```

次の例14のモデルのプログラムは、同じ結果に加えて、平均値と切片の推定値を与えます。このプログラムは、Ex14.vb という名前で保存されています。

```
Sub Main0
  Dim Sem As New AmosEngine

  Try
    Sem.TextOutput0
    Sem.Standardized0
    Sem.Smc0
    Sem.ImpliedMoments0
    Sem.SampleMoments0
    Sem.ModelMeansAndIntercepts0

    Sem.BeginGroup(AmosEngine.AmosDir & "Examples#UserGuide.xls", "Warren5v")
    Sem.AStructure("成果 = 0 + 知識 + 価値 + 満足度 + error (1)")

    Sem.Mean("知識")
    Sem.Mean("価値")
    Sem.Mean("満足度")

    Sem.FitModel0
  Finally
    Sem.Dispose0
  End Try
End Sub
```

Sem.ModelMeansAndIntercepts ステートメントにより Amos が平均値と切片を明示的なモデルパラメータとして扱うことに注意してください。もう1つの例4との違いは、AStructure の行に、1組の空のかっことプラス記号を追加していることです。追加した空のかっこは、回帰方程式の切片を表します。

Sem.Mean ステートメントにより、知識、価値、満足度 の平均の推定値を求めます。Mean メソッドの呼び出しでは、0 以外の平均値を持つ外生変数をそれぞれ引数として指定する必要があります。このプログラムで Mean メソッドを使用しない場合、Amos では外生変数の平均値は 0 で固定されます。

切片パラメータは、(この例で示したように) Sem.AStructure コマンドで 1 組のかっこを追加することで指定できますが、Intercept メソッドを使用して指定することもできます。次のプログラムでは、Intercept メソッドを使用して、成果を予測する回帰方程式に切片が存在することを指定します。

```
Sub Main()
    Dim Sem As New AmosEngine

    Try
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()
        Sem.ImpliedMoments()
        Sem.SampleMoments()
        Sem.ModelMeansAndIntercepts()

        Sem.BeginGroup(AmosEngine.AmosDir & "Examples\UserGuide.xls", "Warren5v")
        Sem.AStructure("成果 <--- 知識")
        Sem.AStructure("成果 <--- 価値")
        Sem.AStructure("成果 <--- 満足度")
        Sem.AStructure("成果 <--- Error (1)")

        Sem.Mean("知識")
        Sem.Mean("価値")
        Sem.Mean("満足度")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub
```



# 構造平均による因子分析

## 概要

この例は、複数の母集団のデータの共通因子分析で因子平均を推定する方法を示します。

## 因子平均

伝統的に、共通因子分析モデルでは、変数の平均値に関する仮定は行いません。特に、モデルでは共通因子の平均に関する仮定は行いません。実際、因子平均を推定したり、従来の単一標本の因子分析で仮説を検定したりすることは不可能です。

しかし、Sörbom (1974 年) は、複数の母集団のデータを分析する限り、適切な仮定の下で因子平均について推論することが可憫であることを示しました。Sörbom の手法を使用すると、すべての母集団のすべての因子の平均を推定することはできませんが、母集団間の因子平均の差を推定することはできます。たとえば、共通因子分析モデルを少女の標本と少年の標本に同時に当てはめた例 12 を考えます。各グループに 2 つの共通因子があり、言語能力 (verbal) および空間能力 (spatial) と解釈されました。例 12 で使用した方法では、言語能力の平均や空間能力の平均を調査できません。Sörbom の方法ではこれが可能です。Sörbom の方法では、少女または少年のどちらについても平均値を推定することはできませんが、各因子について、少女と少年の平均値の差を推定することはできます。この方法では、因子平均の差についての有意確率の検定もできます。

因子分析モデルの状態の特定は、因子平均を推定する場合の難しい問題です。実際、Sörbom の業績は、パラメータに制約条件を課して、因子分析モデルを特定して因子平均の差を推定する方法を示したことです。ここでは、Sörbom のガイドラインに従って、この例のモデルを特定します。

## データについて

ここでは、例 12 の Holzinger と Swineford (1939 年) のデータを使用します。少女のデータセットは Grnt\_fem.sav にあります。少年のデータセットは Grnt\_mal.sav にあります。

## 少年と少女のモデル A

### モデルを指定する

この例では、少年と少女の空間能力の平均は同じであり、言語能力の平均も同じであるという帰無仮説を検定するためのモデルを構成する必要があります。ここで、空間能力および言語能力は共通因子です。この仮説に意味を持たせるには、視覚能力 (spatial) および言語能力 (verbal) を、少年に対しても少女に対しても同様に観測変数に関連付ける必要があります。これは、少女の係数と切片を、少年の係数と切片に等しくする必要がありますということです。

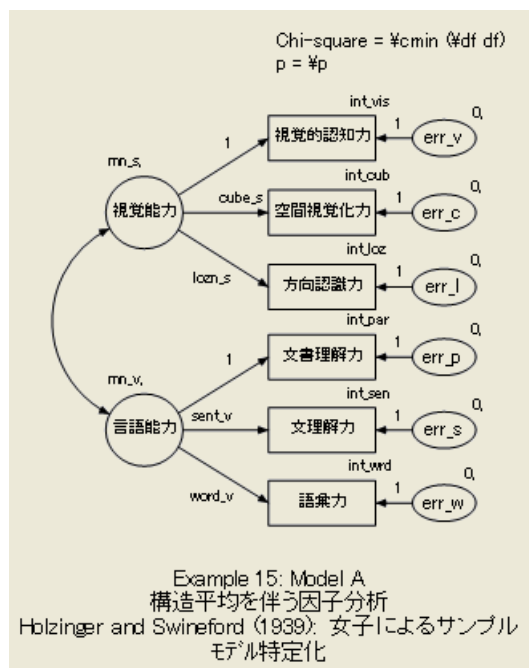
例 12 のモデル B は、この例のモデル A を指定するための出発点として使用できます。例 12 のモデル B を出発点として、以下の操作を実行します。

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。係数は既にグループ間で等しいという制約条件を指定されています。切片がグループ間で等しいという制約条件を設定するには、次の操作を実行します。
- ▶ visperc (視覚認知力) などの観測変数の 1 つを右クリックします。
- ▶ ポップアップ メニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[パラメータ] タブをクリックします。
- ▶ [切片] テキスト ボックスに、「int\_vis」などのパラメータ名を入力します。
- ▶ [全グループ] を選択し、両方のグループで切片の名前を「int\_vis」にします。
- ▶ 同じ操作を繰り返して、残りの 5 つの切片にも名前を付けます。

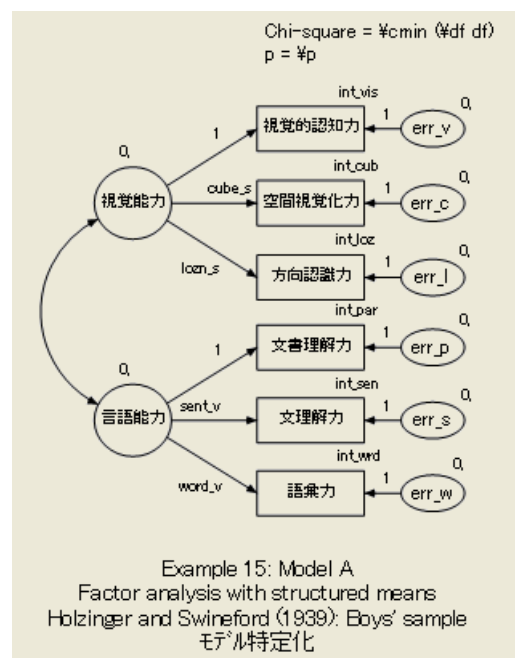
Sörbom が示したように、1 つのグループの因子平均を定数に固定する必要があります。ここでは、少年の視覚能力 (spatial) および言語能力 (verbal) を 0 に固定します。例 13 では、変数の平均値を定数値に固定する方法を示しています。

注: [オブジェクトのプロパティ] ダイアログ ボックスを使用して少年の因子平均を 0 に固定する場合、[全グループ] のチェック マークを付けないように注意してください。

少年の因子平均を 0 に固定してから、同じ手順に従って、少女の因子平均にも名前を割り当てます。この時点で、少女のパス図は次のようになります。



少年のパス図は次のようになります。



## グループ間の制約条件について

切片および係数に関するグループ間の制約条件は、母集団によって満たされる場合と満たされない場合があります。モデルを当てはめた結果の 1 つが、これらの制約条件が少女と少年の母集団で保持されるかどうかの検定になります。これらの制約条件から始めた理由は、(Sörbom が指摘しているように) 因子平均を推定する場合、モデルを特定するためには切片および係数に関する制約条件のいくつかを課す必要があるためです。これらの制約条件だけがモデルを特定するための制約条件ではありませんが、妥当と思われるものです。

少年と少女のパス図の唯一の違いは、2 つの因子平均の制約条件にあります。少年の場合、平均は 0 で固定されています。少女の場合、両方の因子平均が推定されます。少女の因子平均には `mn_s` および `mn_v` という名前が付けられています。それぞれの因子平均に固有の名前が付けられているため、因子平均には制約条件はありません。

少年の因子平均は、モデルを特定するために 0 に固定されています。Sörbom は、ここでまったく違う制約条件を課したとしても、少年と少女の因子平均を同時に推定することは不可能であることを示しました。例として、言語能力を考えます。少年の言語能力の平均をある定数 (0 など) に固定する場合、少女の言語能力の平均を推定することができます。別の方法として、少女の言語能力の平均をある定数に固定して、少年の言語能力の平均を推定することもできます。残念ながら、両方の平均を同時に推定することはできません。その代わりに、どちらの平均を固定した場合も、その平均をどんな値に固定した場合も、少年の平均と少女の平均の差は同じになります。

## モデル A の結果

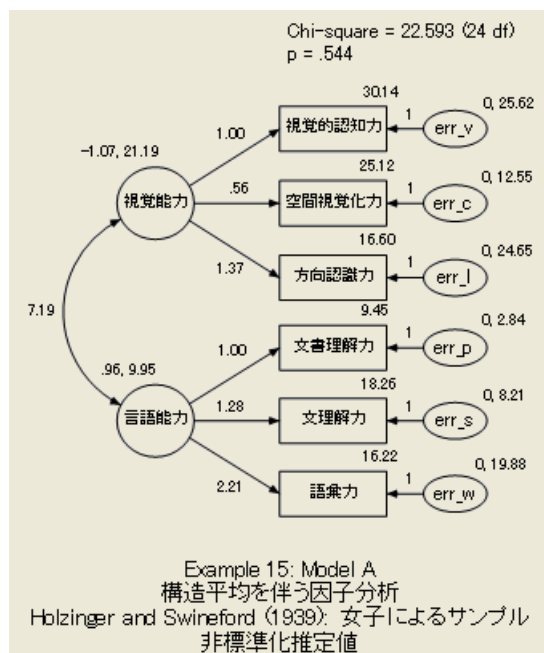
### テキスト出力

通常の有意水準では、モデル A を棄却する理由はありません。

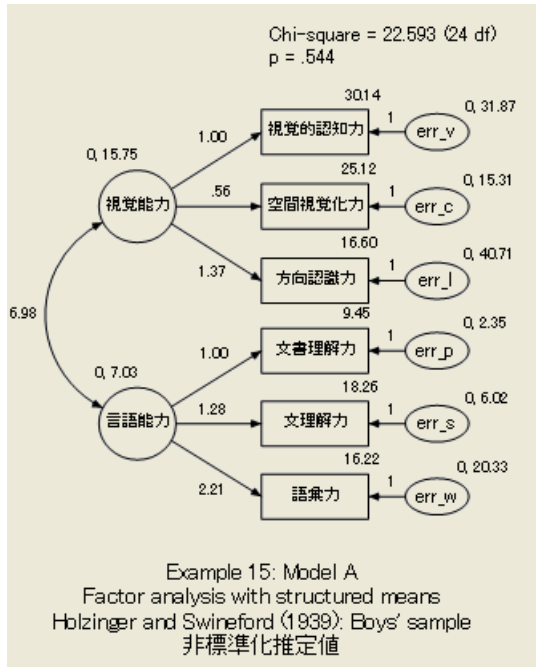
カイ 2 乗 = 22.593
自由度 = 24
確率水準 = 0.544

## グラフィック出力

ここで関心があるのは、主に言語能力の平均と空間能力の平均の推定値です。他のパラメータの推定値にはあまり関心はありません。しかし、通常どおり、すべての推定値が妥当であるか確かめる必要があります。ここに示すのは、73人の少女の標準化されていないパラメータ推定値です。



ここに示すのは、少年の推定値です。



少女の空間能力の平均の推定値は  $-1.07$  です。少年の空間能力の平均は  $0$  で固定しています。したがって、少女の空間能力の平均は、少年の空間能力の平均よりも  $1.07$  単位だけ低いと推定されています。この差は、最初に少年の平均を  $0$  に固定したことには影響されません。少年の平均を  $10.000$  に固定していた場合、少女の平均は  $8.934$  と推定されていました。少女の平均を  $0$  に固定していた場合、少年の平均は  $1.07$  と推定されていました。

空間能力はどのような単位で表されているのでしょうか。空間能力の  $1.07$  単位の差は、単位の大きさに応じて大きな差にも小さい差にもなります。空間能力の `visperc` (視覚認知力) を回帰する係数は  $1$  に等しいので、空間能力は `visperc` (視覚認知力) の検定の得点と同じ単位で表されているということが出来ます。もちろん、これはユーザーが `visperc` (視覚認知力) の検定に詳しくないと有用な情報にはなりません。`visperc` (視覚認知力) に関係なく  $1.07$  という平均の差を評価する別の方法もあります。ここには載せていませんが、テキスト出力の一部に、少年の `spatial` (視覚能力) の分散の推定値は  $15.752$  であり、標準偏差は約  $4.0$  であることが示されています。少女の場合、`spatial` (視覚能力) の分散の推定値は  $21.188$ 、標準偏差は約  $4.6$  です。この大きさの標準偏差では、通常は  $1.07$  という差はあまり大きいとは考えられません。

少女と少年の間の、 $1.07$  単位の差の統計上の有意性は容易に評価できます。少年の平均は  $0$  に固定されているため、必要なのは少女の平均が  $0$  から大きく離れているかどうかを調べるだけです。

ここに、テキスト出力の少女の因子平均の推定値を示します。

平均値 : (Girls - Default model)					
	推定値	標準誤差	検定統計量	確率	ラベル
spatial	-1.066	.381	-1.209	.226	mn_s
verbal	.956	.521	1.836	.066	mn_v

少女の空間能力の平均の検定統計量は $-1.209$ で、 $0$ から大きく離れてはいません ( $p = 0.226$ )。言い換えると、少年の平均から大きく離れてはいません。

言語能力に注目すると、少女の平均は、少年の平均より  $0.96$  単位高いと推定されます。言語能力の標準偏差は、少年では約  $2.7$ 、少女では約  $3.15$  です。したがって、言語能力の  $0.96$  単位は、一方のグループの標準偏差の約  $1/3$  です。少年と少女の間の差は、 $0.05$  レベルで有意となります ( $p = 0.066$ )。

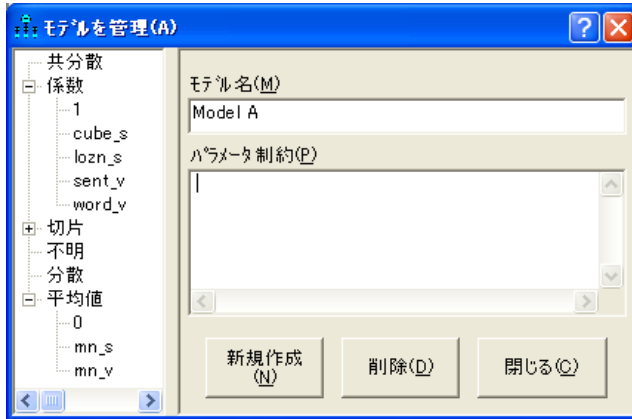
## 少年と少女のモデル B

モデル A の議論では、検定統計量を使用して 2 回の有意差検定を行いました。空間能力における性別の違いについての検定と、言語能力における性別の違いについての検定です。ここでは、空間能力または言語能力のいずれにおいても性別による違いはないという帰無仮説の検定を行います。このため、少年と少女が空間能力でも言語能力でも同じ平均値を持つという制約条件を追加して分析を繰り返します。少年の平均値は既に  $0$  に固定されているため、少女の平均値を少年の平均値と同じにするということは、少女の平均値も  $0$  にするということです。

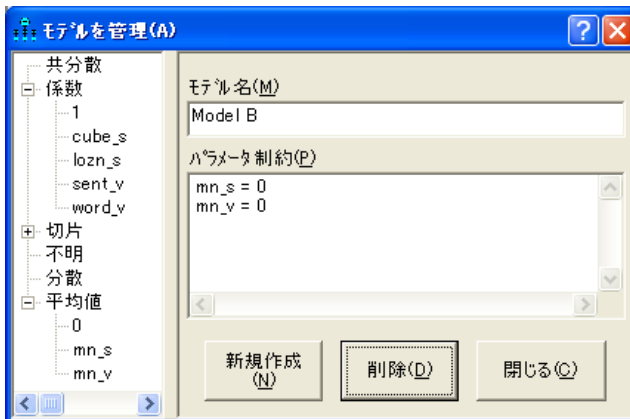
少女の因子平均には、mn\_s および mn\_v という名前が付けられています。平均値を  $0$  に固定するには、次の操作を実行します。

- ▶ メニューから [分析] → [モデルを管理] の順に選択します。
- ▶ [モデル管理] ダイアログ ボックスの [モデル名] テキスト ボックスに「Model A」と入力します。

- ▶ [パラメータ制約] ボックスは空白のまま残しておきます。



- ▶ [新規作成] をクリックします。
- ▶ [モデル名] テキスト ボックスに「Model B」と入力します。
- ▶ [パラメータ制約] テキスト ボックスに「mn\_s = 0」および「mn\_v = 0」という制約条件を入力します。



- ▶ [閉じる] をクリックします。

ここで [分析] → [推定値を計算] を選択すると、Amos はモデル A およびモデル B の両方を当てはめます。Ex15-all.amw ファイルには、この 2 つのモデルの設定があります。



## モデル B の結果

モデル A を比較の基準として使用しない場合、通常の有意水準を使用すると、モデル B は適用可能です。

カイ 2 乗 = 30.624
自由度 = 26
確率水準 = 0.243

## モデル A およびモデル B の比較

モデル B の検定の別の方法として、モデル A が正しいと仮定して、モデル B がモデル A よりも大きく劣った適合をしないかどうかを検定することもできます。この比較についてのカイ 2 乗検定はテキスト出力で与えられます。

- ▶ [Amos出力] ウィンドウで、左上のペインのツリー図にある [モデル比較] をクリックします。

**モデル Model A は正しいという仮定の下で:**

モデル	自由度	CMIN	確率	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
Model B	2	8.030	.018	.024	.026	.021	.023

この表は、モデル B にはモデル A よりも 2 多い自由度があり、カイ 2 乗統計量は 8.030 だけ大きいことを示しています。モデル B が正しい場合、カイ 2 乗の値がこのような大きい差になる確率は 0.018 であり、モデル B に対する反証となります。

## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。このプログラムは Ex15-a.vb として保存されています。

```
Sub Main()
    Dim Sem As New AmosEngine
    Try
        Sem.TextOutput()
        Sem.Standardized()
        Sem.Smc()
        Sem.ModelMeansAndIntercepts()

        Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")
        Sem.GroupName("Girls")
        Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
        Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
        Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
        Sem.AStructure("paragrap = (int_par) + (1)spatial + (1) err_p")
        Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
        Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
        Sem.Mean("spatial", "mn_s")
        Sem.Mean("verbal", "mn_v")

        Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_mal.sav")
        Sem.GroupName("Boys")
        Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
        Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
        Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
        Sem.AStructure("paragrap = (int_par) + (1)spatial + (1) err_p")
        Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
        Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
        Sem.Mean("spatial", "0")
        Sem.Mean("verbal", "0")
    Finally
        Sem.Dispose()
    End Try
End Sub
```

AStructure メソッドは、各内生変数につき 1 回呼び出されます。少女のグループで Mean メソッドを使用して、言語能力および空間能力の因子が制約なく推定されるように指定します。プログラムでは、Mean メソッドを使用して、少年のグループにおける言語能力および空間能力の平均が 0 になるという指定も行っています。実際には、Amos ではデフォルトで平均を 0 と仮定します。したがって、少年に対する Mean メソッドは必要ありません。

## モデル B

モデル B に適合するプログラムを次に示します。このモデルでは、少年と少女の両方の因子平均が 0 に固定されています。このプログラムは、Ex15-b.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\userguide.xls"
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "grnt_fem")
    Sem.GroupName("Girls")
    Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
    Sem.AStructure("paragraph = (int_par) + (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
    Sem.Mean("spatial ", "0")
    Sem.Mean("verbal", "0")
    Sem.BeginGroup(dataFile, "grnt_mal")
    Sem.GroupName("Boys")
    Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
    Sem.AStructure("paragraph = (int_par) + (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
    Sem.Mean("spatial ", "0")
    Sem.Mean("verbal", "0")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## 複数のモデルの当てはめ

次のプログラム (Ex15-all.vb) は、モデル A とモデル B の両方に適合します。

```

Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")
    Sem.GroupName("Girls")
    Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
    Sem.AStructure("paragrap = (int_par) + (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
    Sem.Mean("spatial", "mn_s")
    Sem.Mean("verbal", "mn_v")

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_mal.sav")
    Sem.GroupName("Boys")
    Sem.AStructure("visperc = (int_vis) + (1) spatial + (1) err_v")
    Sem.AStructure("cubes = (int_cub) + (cube_s) spatial + (1) err_c")
    Sem.AStructure("lozenges = (int_loz) + (lozn_s) spatial + (1) err_l")
    Sem.AStructure("paragrap = (int_par) + (1)spatial + (1) err_p")
    Sem.AStructure("sentence = (int_sen) + (sent_v)spatial + (1) err_s")
    Sem.AStructure("wordmean= (int_wrd) + (word_v)spatial + (1) err_w")
    Sem.Mean("spatial", "0")
    Sem.Mean("verbal", "0")

    Sem.Model("Model A") ' 因子平均の性別による差
    Sem.Model("Model B", "mn_s=0", "mn_v=0") ' 因子平均を等しくする
    Sem.FitAllModels()
  Finally
    Sem.Dispose()
  End Try
End Sub

```

# 共分散分析に対する Sörbom の代替案

## 概要

この例は、2 つ以上のグループでの長期的な観測による潜在的な構造方程式モデルの作成、潜在変数と自己相関残差を取り入れて従来の共分散分析技術を一般化するモデル (1978 年の Sörbom と比較します)、および従来の共分散分析で行われた仮定の検定方法を示します。

## 前提条件

例 9 では、従来の共分散分析に対して、信頼できない共変量がある場合でも使用できる代替案を示しました。残念ながら、共分散分析は完全に信頼できる共変量を仮定する以外にも前提条件が必要で、例 9 の方法は他の前提条件にも依存しています。Sörbom (1978 年) は、これらの前提条件の多くを検定し、前提条件の一部を緩和することができます、より一般的な方法を開発しました。

この例では、Sörbom が自分の方法を紹介するために使用したのと同じデータを使用します。説明も Sörbom の解説に厳密に従います。

## データについて

ここでは、例9で紹介した Olsson (1973 年) のデータをもう一度使用します。108 人の実験被験者から得た標本の平均値、分散、共分散は、UserGuide.xls という Microsoft Excel ワークブックの Olss\_exp ワークシートに格納されています。

rowtype_	varname_	pre_syn	pre_opp	post_syn	post_opp
n		108	108	108	108
cov	pre_syn	50.084			
cov	pre_opp	42.373	49.872		
cov	post_syn	40.76	36.094	51.237	
cov	post_opp	37.343	40.396	39.89	53.641
mean		20.556	21.241	25.667	25.87

105 人の統制群の被験者から得た標本の平均値、分散、共分散は、Olss\_cnt ワークシートに格納されています。

rowtype_	varname_	pre_syn	pre_opp	post_syn	post_opp
n		105	105	105	105
cov	pre_syn	37.626			
cov	pre_opp	24.933	34.68		
cov	post_syn	26.639	24.236	32.013	
cov	post_opp	23.649	27.76	23.565	33.443
mean		18.381	20.229	20.4	21.343

両方のデータセットに、分散と共分散の通例の不偏推定値が含まれています。つまり、共分散行列の要素は  $(N-1)$  で割ることで得られます。これは、Amos が共分散行列を読み込むために使用するデフォルトの設定でもあります。ただし、モデルの当てはめの場合は、デフォルトの動作は  $(N)$  で割って得られる) 母集団共分散行列の最尤法の推定を標本の共分散行列として使用します。Amos では、不偏推定値から最尤法の推定値に自動的に移行します。

## デフォルトの動作の変更

- ▶ メニューから、[表示]→[分析のプロパティ]を選択します。
- ▶ [分析のプロパティ]ダイアログボックスの[分散タイプ]タブをクリックします。

入力として指定された共分散

最尤推定値共分散(M)

不偏推定値共分散(U)

分析対象の共分散

最尤推定値共分散(A)

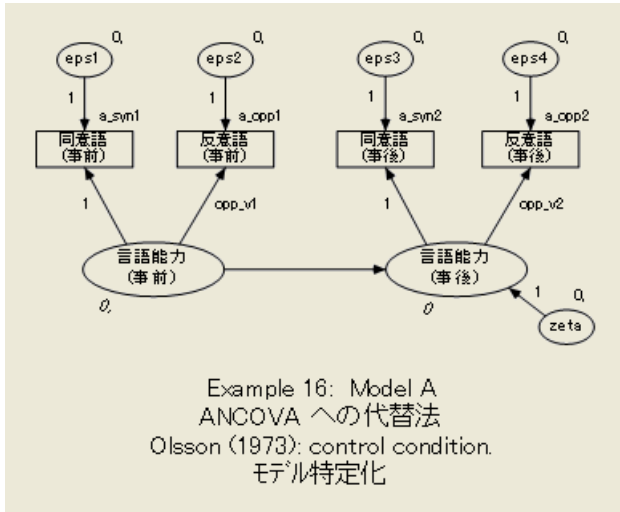
不偏推定値共分散(N)

Amos で使用されるデフォルトの設定では、データモデルの欠損値に一致する結果を得られます(例17および例18で解説します)。LISREL (Jöreskog と Sörbom、1989年) や EQS (Bentler、1985年) などの他の SEM プログラムでは、代わりに不偏積率を分析し、標本のサイズが小さい場合はわずかに異なる結果になります。[分散タイプ] タブの [不偏推定値共分散] オプションを両方選択すると、Amos では LISREL や EQS と同じ推定値を生成します。付録 B では、共分散行列の最尤法の推定値と不偏推定値のどちらを選択して当てはめを行うかに関するトレードオフについて、詳しく解説します。

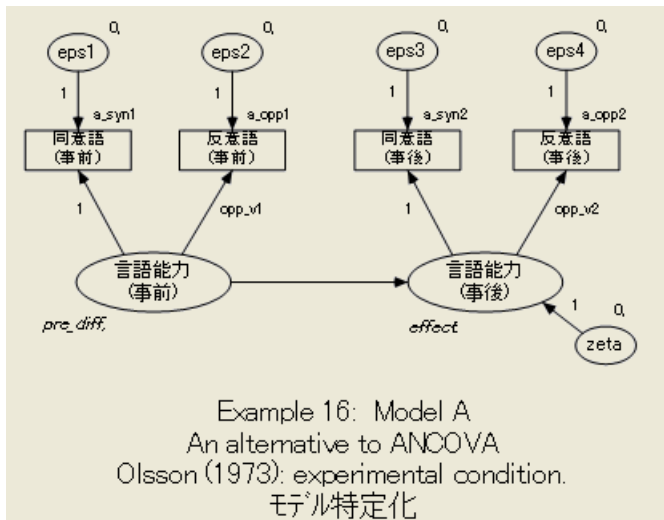
## モデル A

### モデルを指定する

Olsson のデータに対して、Sörbom の最初のモデル (モデル A) を考えます。統制群のパス図は次のようになります。



次のパス図は、実験群のモデル A です。



このモデルでは平均値と切片が重要であるため、次の操作をしっかりと実行してください。

- ▶ メニューから、[表示]→[分析のプロパティ]を選択します。



- ▶ [推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。

モデル A の各グループで、pre\_syn (同意語 (事前)) と pre\_opp (反意語 (事前)) が pre\_verbal (言語能力 (事前)) という単一の潜在変数の指標であり、post\_syn (同意語 (事後)) と post\_opp (反意語 (事後)) が post\_verbal (言語能力 (事後)) という別の潜在変数の指標であることが指定されます。潜在変数 pre\_verbal (言語能力 (事前)) は学習開始時の言語能力、post\_verbal (言語能力 (事後)) は学習終了時の言語能力と解釈されます。これが Sörbom の測定モデルです。構造モデルでは、post\_verbal (言語能力 (事後)) は pre\_verbal (言語能力 (事前)) に線形従属すると指定されます。

opp\_v1 と opp\_v2 のラベルにより、測定モデルの係数が両方のグループで同じであることが要求されます。同様に、a\_syn1、a\_opp1、a\_syn2、a\_opp2 ラベルにより、測定モデルの切片が両方のグループで同じであることが要求されます。この等質性の制約条件は、誤った仮定である可能性もあります。実際、これから行う分析の結果の 1 つは、これらの仮定の検定になります。Sörbom が指摘しているように、構造モデルのパラメータに関する仮説を推定および検定できるようにするためには、測定モデルのパラメータに関するいくつかの仮定を行う必要があります。

統制群の被験者については、pre\_verbal (言語能力 (事前)) の平均値および post\_verbal (言語能力 (事後)) の切片が 0 に固定されています。これにより、グループの比較を行う場合は統制群が参照する群になります。潜在変数の平均値と切片を特定するには、このような統制群を選ぶ必要があります。

実験被験者の場合、潜在因子のパラメータの平均値と切片は、0 以外の値をとることが可能です。pre\_diff ラベルの付いた潜在変数の平均値は試験前の言語能力の差を表し、effect ラベルの付いた切片は統制群と比較した実験群の向上度を表します。この例のパス図は、Ex16-a.amw ファイルに保存されています。

Sörbom のモデルでは、6 つの観測されない外生変数の分散にグループ間の制約条件を課していないことに注意してください。つまり、4 つの観測変数は統制状態と実験状態で異なる固有の分散を持ち、pre\_verbal (言語能力 (事前)) および zeta の分散も 2 つのグループで異なる場合があります。モデル X、モデル Y、およびモデル Z を作成するときに、これらの仮定をより厳密に調査します。

## モデル A の結果

### テキスト出力

[Amos 出力] ウィンドウで、左上のペインのツリー図にある [モデルについての注釈] をクリックすると、モデル A は通常の有意水準では適用できないことが示されます。

カイ 2 乗 = 34.775
自由度 = 6
確率水準 = 0.000

モデル A が誤りであることを示す次のメッセージも出力されます。

**次の分散は負です。(control - Default model)**

zeta  
-2.868

実験群と統制群を意味のある比較ができるようにしたまま、データに適合するようにモデル A を修正することは可能でしょうか。ここでは、分析を繰り返して修正指数を要求することが有効です。修正指数を得るには、次の操作を実行します。

- ▶ メニューから [表示] → [分析のプロパティ]
- ▶ [分析のプロパティ] ダイアログ ボックスの [出力] タブをクリックします。
- ▶ [修正指数] を選択し、[修正指数] の右にあるテキスト ボックスに適切なしきい値を入力します。この例では、しきい値はデフォルト値の 4 のままにします。



ここに示すのは、実験群から出力された修正指数です。

**修正指数 (experimental - Default model)**

**共分散: (experimental - Default model)**

		修正指数	改善度
eps2 <-->	eps4	10.508	4.700
eps2 <-->	eps3	8.980	-4.021
eps1 <-->	eps4	8.339	-3.908
eps1 <-->	eps3	7.058	3.310

**分散: (experimental - Default model)**

		修正指数	改善度
		修正指数	改善度

**係数: (experimental - Default model)**

		修正指数	改善度
		修正指数	改善度

**平均値: (experimental - Default model)**

		修正指数	改善度
		修正指数	改善度

**切片: (experimental - Default model)**

		修正指数	改善度
		修正指数	改善度

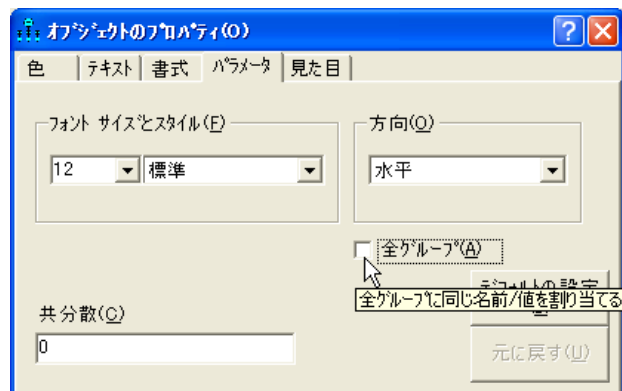
統制群では、しきい値の 4 より大きい修正指数を持つパラメータはありません。

## モデル B

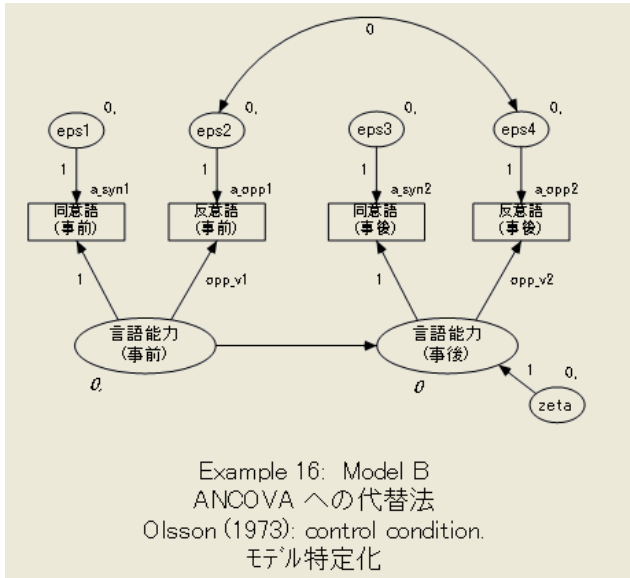
モデル A で得られた修正指数の最大値から、実験群の  $\text{eps2}$  と  $\text{eps4}$  の間の共分散を追加することが示唆されます。修正指数が示すのは、 $\text{eps2}$  と  $\text{eps4}$  が 0 でない共分散を持つことができる場合、カイ 2 乗統計量は少なくとも 10.508 下がるということです。変更パラメータの統計量 4.700 は、共分散の推定値が任意の値をとることができる場合、共分散の推定値が正の値になることを示しています。提示された修正値は妥当な値です。 $\text{eps2}$  は  $\text{pre\_opp}$  (反意語(事前)) の固有の分散を表し、 $\text{eps4}$  は  $\text{post\_opp}$  (反意語(事後)) の固有の分散を表します。 $\text{pre\_opp}$  (反意語(事前)) と  $\text{post\_opp}$  (反意語(事後)) の測定値は、2 つの異なる状況で同じ検定(反意語)を実施して得られます。したがって、 $\text{eps2}$  および  $\text{eps4}$  が正の相関関係を持つと考えるのは妥当です。

次に、変更されたモデルを考えます。このモデル B では、 $\text{eps2}$  および  $\text{eps4}$  は、実験群内で相関関係を持つことができます。モデル A からモデル B を得るには、次の操作を実行します。

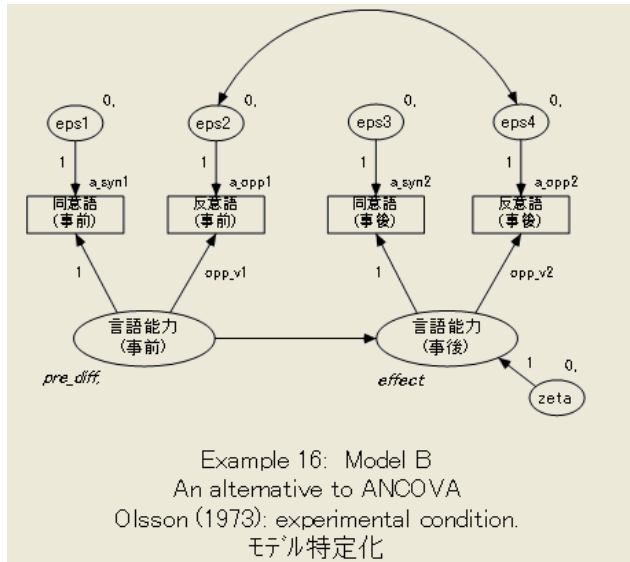
- ▶  $\text{eps2}$  と  $\text{eps4}$  を結ぶ両矢印を引きます。  
矢印を引くことで、 $\text{eps2}$  と  $\text{eps4}$  は両グループで相関関係を持つことができます。統制群では相関させたくないの、統制群では共分散を 0 に固定する必要があります。手順は次のとおりです。
- ▶ (パス図の左にある)[グループ]パネルで control をクリックして、統制群のパス図を表示します。
- ▶ 両矢印を右クリックして、ポップアップメニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ]ダイアログボックスの [パラメータ] タブをクリックします。
- ▶ [共分散] テキストボックスに「0」と入力します。
- ▶ [全グループ] のチェックボックスが空であることを確認します。チェックボックスが空の場合、共分散の制約条件は統制群にのみ適用されます。



モデル B の統制群のパス図をここに示します。



実験群のパス図は次のようになります。



## モデル B の結果

モデル A からモデル B に移行すると、カイ 2 乗統計量は (見込みの 10.508 より大きく) 17.712 下がり、自由度の数は 1 だけ下がります。

カイ 2 乗 = 17.063
自由度 = 5
確率水準 = 0.004

モデル B はモデル A よりは改善されていますが、十分な改善ではありません。モデル B は、まだデータにうまく適合しません。さらに、統制群の zeta の分散は、モデル A の場合と同じく負の推定値を持ちます (ここでは示しません)。これらの 2 つの事実は、モデル B に対する強力な反証になります。しかし、修正指数はモデル B をさらに修正できることを示しているため、まだ望みはあります。統制群の修正指数は次のようになります。

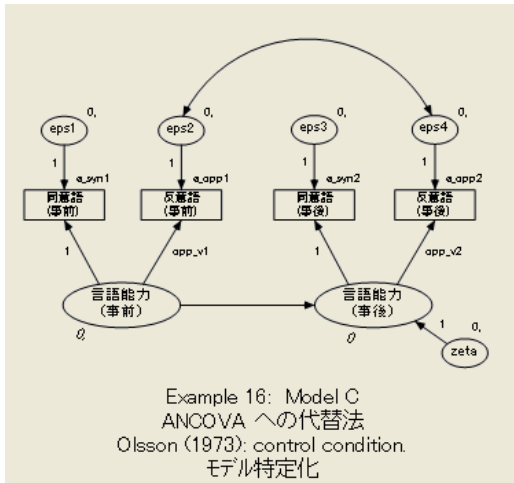
<b>修正指数 (control - Default model)</b>			
<b>共分散: (control - Default model)</b>			
		修正指数	改善度
eps2 <-->	eps4	4.727	2.141
eps1 <-->	eps4	4.086	-2.384
<b>分散: (control - Default model)</b>			
		修正指数	改善度
<b>係数: (control - Default model)</b>			
		修正指数	改善度
<b>平均値: (control - Default model)</b>			
		修正指数	改善度
<b>切片: (control - Default model)</b>			
		修正指数	改善度

修正指数の最大値 (4.727) は、eps2 と eps4 を統制群で関連させることを提示しています。(eps2 と eps4 は実験群では既に相関しています。) この修正を行うとモデル C になります。

## モデル C

モデル C は、項  $\text{eps2}$  と  $\text{eps4}$  が統制群と実験群の両方で相関関係を持つという点を除いてモデル B と同様です。

モデル C を指定するには、モデル B を取り上げて、統制群で  $\text{eps2}$  と  $\text{eps4}$  の間の共分散に関する制約条件を削除するだけです。統制群の新しいパス図をここに示します。このパス図は、Ex16-c.amw ファイルにあります。

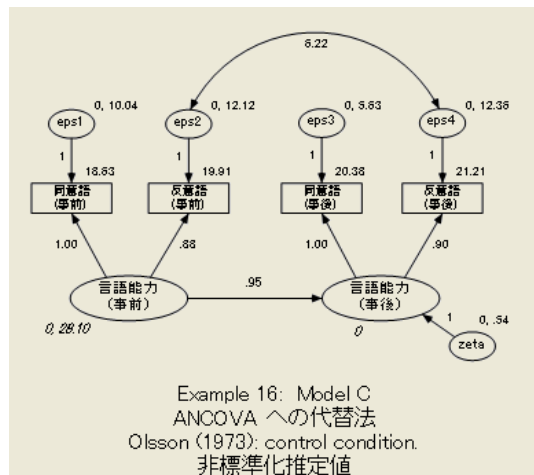


## モデル C の結果

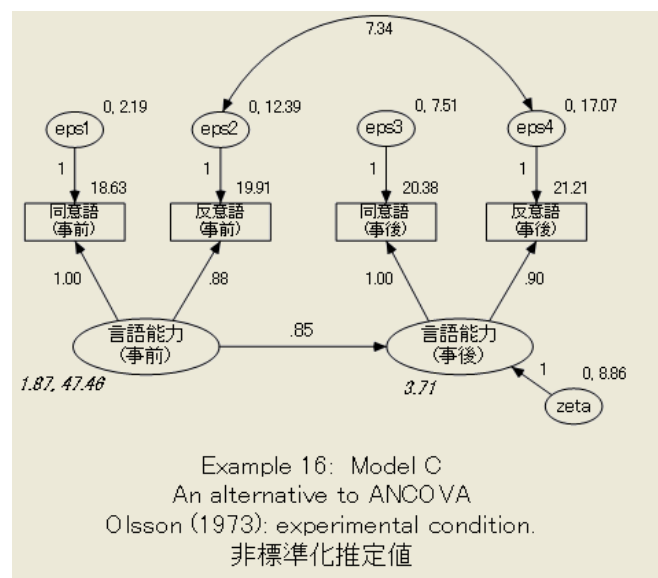
ここでついに適合するモデルを得られます。

カイ 2 乗 = 2.797
自由度 = 4
確率水準 = 0.592

統計的な適合度の観点から見ると、モデル C を棄却する理由はありません。分散の推定値がすべて正の値であることにも注意してください。105 人の統制群の被験者のパラメータ推定値を次に示します。



次のパス図は、108 人の実験被験者のパラメータ推定値を表示しています。

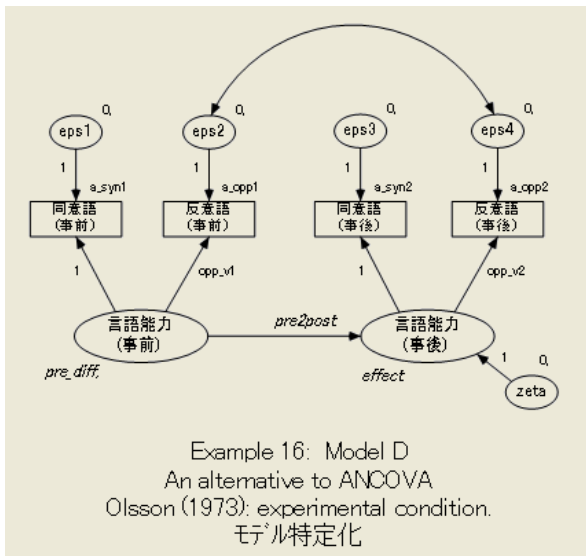


パラメータ推定値の大部分はあまり興味を引きませんが、推定値が妥当であることを確認することができます。分散の推定値が正であることは既に確認しました。測定モデルのパス係数は正であることが保証されます。測定モデルの係数に正の値と負の値が混在すると、解釈するのが困難で、モデルに疑問が生じます。eps2 と eps4 の間の共分散は、期待どおり両方のグループで正です。

ここで主に興味があるのは、pre\_verbal (言語能力(事前))に対する post\_verbal (言語能力(事後))の回帰です。切片は、統制群では 0 に固定されていますが、実験群では 3.71 と推定されます。係数の推定値は、統制群では 0.95、実験群では 0.85 です。2つのグループの係数は非常に近く、2つの母集団で同じ値であるように見えます。係数が同じ場合、2つのグループの比較を切片の比較に限定することで、試験の評価を大幅に簡略化できます。したがって、両方のグループの係数が同じであるモデルは試行する価値があります。これがモデル D になります。

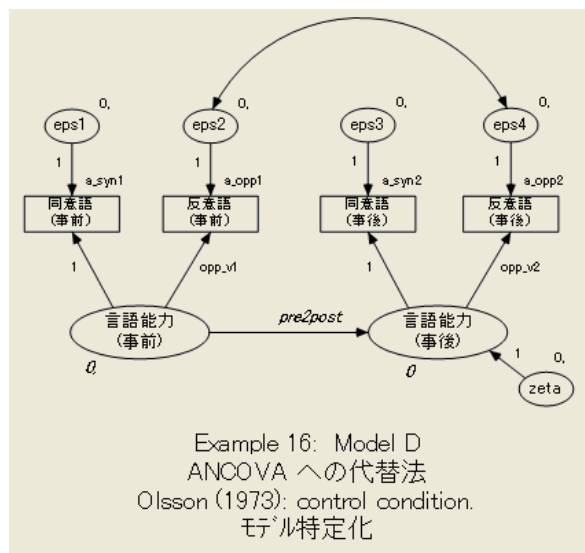
## モデル D

モデル D は、両方のグループで pre\_verbal (言語能力(事前))から post\_verbal (言語能力(事後))を予測するための係数が同じであることが要求される点を除いて、モデル C と同様です。両方のグループの係数に同じ名前 (たとえば、pre2post) を付けることで、この制約条件を指定することができます。次に示すのは、実験群についてのモデル D のパス図です。





次に、統制群についてのモデル D のパス図を示します。



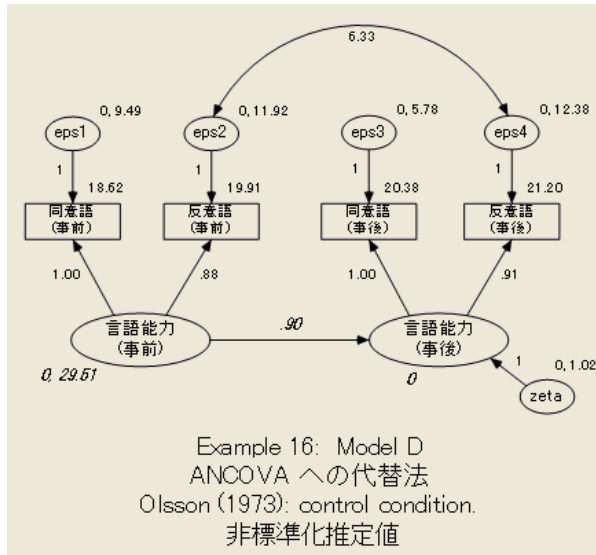
## モデル D の結果

通常の有意水準では、モデル D は適合します。

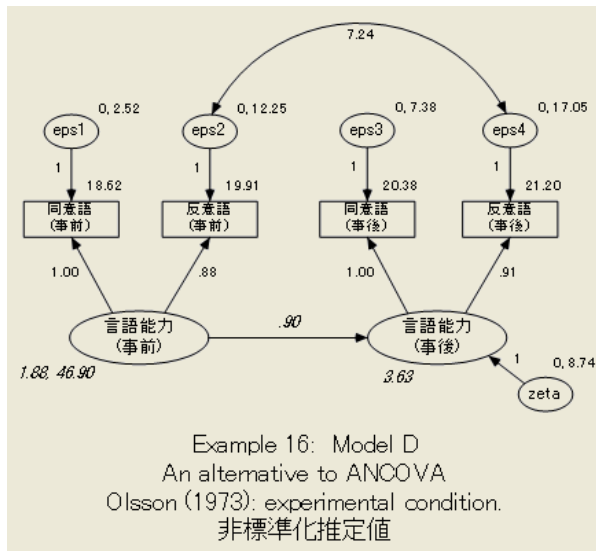
カイ 2 乗 = 3.976
自由度 = 5
確率水準 = 0.553

モデル C に対して、モデル D の検定では 1.179 (= 3.976 - 2.797) 大きいカイ 2 乗値と 1 (つまり、5 - 4) 多い自由度が得られました。ここでも、係数が等しいという仮説 (モデル D) を受け入れることができます。

係数が等しい場合、試験前と試験後の被験者の比較は、切片の差に依存します。ここに示すのは、105 人の統制群の被験者のパラメータ推定値です。



108 人の実験被験者の推定値は次のようになります。



実験群の切片は 3.63 と推定されます。テキスト出力 (ここでは示しません) によると、推定値 3.63 の検定統計量は 7.59 です。したがって、実験群の切片は統制群の切片 (0 に固定) と大きく異なります。

## モデル E

切片 `post_verbal` (言語能力(事後))の差の有意確率を検定する別の方法に、グループ間で切片が等しいという制約条件を追加してモデル D の分析を繰り返す方法があります。統制群の切片は既に 0 に固定されているので、必要な手順は実験群の切片も同様に 0 にするという条件を追加するだけです。モデル E ではこの制約を使用します。

モデル E のパス図は、`pre_verbal` (言語能力(事前))に対する回帰の切片 `post_verbal` (言語能力(事後))が両方のグループで 0 に固定されていることを除いて、モデル D のパス図と同じです。パス図はここには載せません。Ex16-e.amw にパス図が含まれています。

## モデル E の結果

モデル E は棄却されます。

カイ 2 乗 = 55.094
自由度 = 6
確率水準 = 0.000

モデル E をモデル D と比較すると、51.018 (= 55.094 - 3.976) 大きいカイ 2 乗値と 1 (= 6 - 5) 多い自由度が得られます。モデル D が支持され、モデル E は棄却されます。モデル E の適合度はモデル D の適合度より大幅に低いいため、切片が等しいという仮説は棄却されます。言い換えると、試験後の時点での統制群と実験群には、試験前の時点で存在した差からは計算できない差があります。

これが Olsson のデータに対する Sörbom (1978 年) の分析の結論です。

## モデル A からモデル E を単一の分析で当てはめる

Ex16-a2e.amw ファイルの例は、5 つすべてのモデル (モデル A からモデル E) を単一の分析で当てはめます。単一の分析で複数のモデルを当てはめる手順の詳細は、例 6 で示しました。

## Sörbom の方法と例 9 の方法の比較

共分散分析に対する Sörbom の代替案は例 9 の方法よりも適用するのが困難です。その一方で、Sörbom の方法はより一般的であるため、例 9 の方法よりも優れています。つまり、適切なパラメータ制約を用いて Sörbom の方法を使用することで、例 9 の方法を再現できます。

モデル X、モデル Y、モデル Z という 3 つのモデルを示して、この例を終わります。これらの新しいモデルの比較により、例 9 の結果を再現することができます。ただし、例 9 で使用した方法が不適切だったという証拠も見つかります。この非常に複雑な演習の目的は、例 9 の手法の制限に注目し、Sörbom の手法ではその方法の前提条件の一部を検定および緩和できることを示すことです。

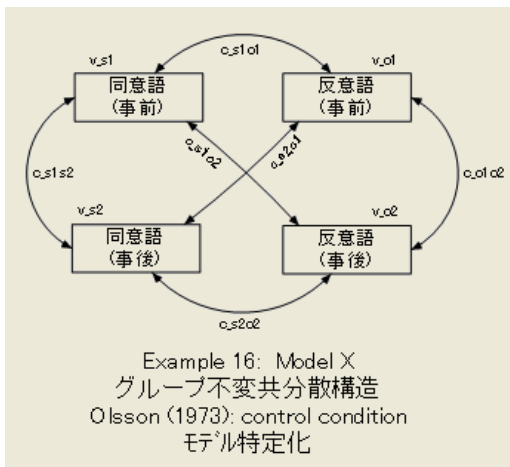
## モデル X

最初に、観測変数の分散と共分散が統制状態および実験状態で同じであることが要求される新しいモデル (モデル X) を考えます。観測変数の平均値は、2 つの母集団の間で異なる場合もあります。モデル X では、変数の間に線形従属性は指定しません。モデル X はそれ自体はあまり興味深いものではありませんが、(後から作成する) モデル Y およびモデル Z は興味深いモデルです。モデル X と比べて、これらのモデルがどれだけデータに適合するかを調べます。

## Amos Graphics のモデル作成

推定する切片や平均値がないため、[分析のプロパティ] ダイアログ ボックスの [推定] タブにある [平均値と切片を推定] にチェック マークがないことを確認してください。

次に示すのは、統制群についてのモデル X のパス図です。



実験群のパス図も同じです。両方のグループで同じパラメータ名を使用すると、2 つのグループが同じパラメータ値を持つことが要求されます。

## モデル X の結果

通常の有意水準では、モデル X は棄却されます。

カイ 2 乗 = 29.145  
自由度 = 10  
確率水準 = 0.001

実際には、モデル X が不適切であることがわかった時点で、この後の分析 (モデル Y およびモデル Z) も不適切なモデルです。例 9 で得られた結果と同じ結果になることを示すため、演習として分析を実行します。

## モデル Y

モデル D に次の制約条件を追加したモデルを考えます。

- 試験前の言語能力 (言語能力 (事前)) が、統制群と実験群で同じ分散を持つ。
- eps1、eps2、eps3、eps4、および zeta の分散が、両方のグループで等しい。
- eps2 と eps4 の間の共分散が、両方のグループで等しい。

eps2 と eps4 の相関関係を除いて、モデル D では、eps1、eps2、eps3、eps4、および zeta が、これらの変数同士とも他のすべての外生変数とも相関しないことが要求されました。これらの新しい制約条件により、すべての外生変数の分散と共分散が両方のグループで同じになることが要求されます。


要するに、新しいモデルでは次の 2 種類の制約条件が課されます。

- すべての係数と切片は両方のグループで等しい。ただし、pre\_verbal (言語能力 (事前)) から post\_verbal (言語能力 (事後)) を予測するために使用する切片は異なる場合があります (モデル D の条件)。
- 外生変数の分散と共分散は両方のグループで等しい (モデル Y で追加された条件)。

これらは例 9 のモデル B で行ったものと同じ仮定です。今回は、明示的に仮定を行い、検定できるということが違います。モデル Y のパス図を下に示します。このモデルでは平均値と切片を推定するので、次の操作をしっかりと実行してください。

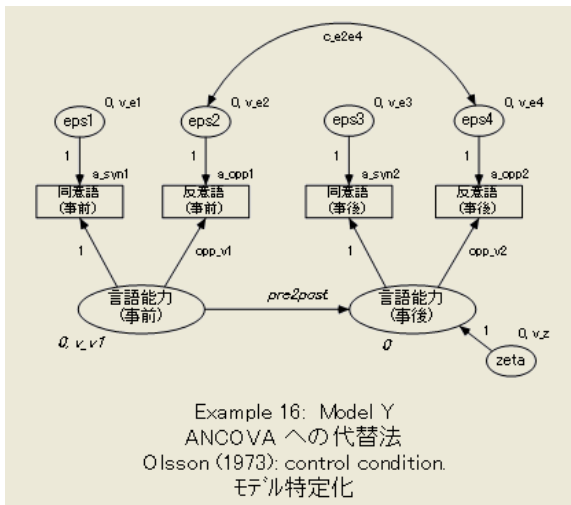
- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。

実験群のパス図をここに示します。



Example 16: Model A  
An alternative to ANCOVA  
Olsson (1973): control condition.  
Model Specification

統制群のパス図をここに示します。



Example 16: Model Y  
ANCOVA への代替法  
Olsson (1973): control condition.  
モデル特定化

## モデル Y の結果

モデル Y は棄却されます。

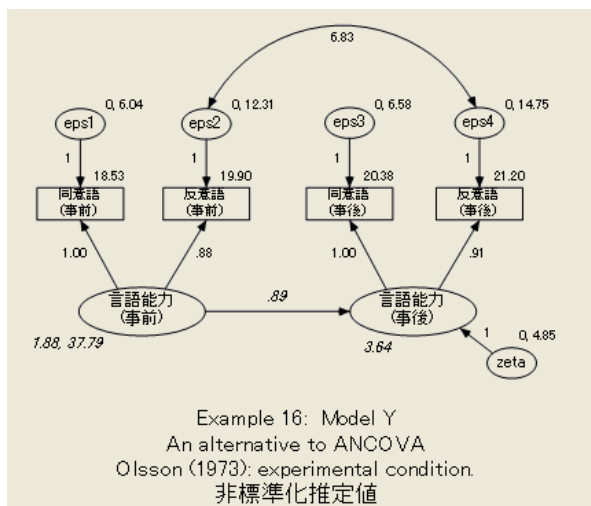
カイ 2 乗 = 31.816
自由度 = 12
確率水準 = 0.001

例 9 の分析は、モデル Y (例 9 のモデル B) が正しいということに依存しているため、適合しなかったのも当然です。振り返ってみると、例 9 のモデル B が適合することがわかります ( $\chi^2 = 2.684$ ,  $df = 2$ ,  $p = 0.261$ )。では、どうしてここでは同じモデルが棄却されるのでしょうか ( $\chi^2 = 31.816$ ,  $df = 1$ ,  $p = 0.001$ )。その答えは、帰無仮説は両方の

ケース (例9のモデル B とこの例のモデル Y) で同じですが、対立仮説が異なるためです。例9では、モデル B を検定した対立仮説には、観測変数の分散と共分散が試験変数の両方の値と同じであるという仮定が含まれています (32 ページでも仮定しています)。言い換えると、例9のモデル B の検定は、統制群と実験群の母集団で分散と共分散の等質性を暗に仮定して実行されました。これはまさに、この例のモデル X で明示的に行った仮定です。

モデル Y は、モデル X に制約を追加したモデルです。モデル Y の仮定 (2つの母集団で係数が等しく、外生変数の分散と共分散が等しい) は、モデル X の仮定 (観測変数の共分散が等しい) を包含することを示すことができます。したがって、モデル X とモデル Y は入れ子になったモデルです。そして、モデル X が正しいという仮定の下でモデル Y の条件付き検定を実行することが可能です。当然、検定が意味を持つのはモデル X が本当に正しい場合のみですが、既にモデル X は誤りだという結論が出ています。それでも、モデル X に対するモデル Y の検定を行きましょう。カイ2乗値の差は 2.671 (つまり、31.816 - 29.145)、自由度の差は 2 (= 12 - 10) です。これらの数値は、例9のモデル B の値と (丸め誤差の範囲内で) 同じです。違うのは、例9では検定が適切であると仮定したことです。ここでは、(モデル X を棄却したこと) から検定が不適切であることはよくわかっています。

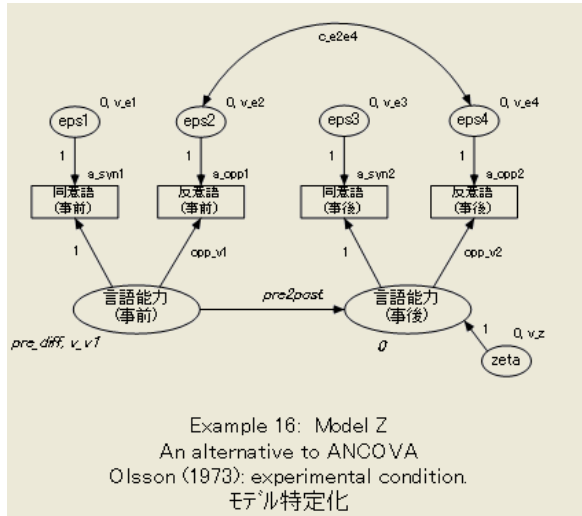
現在のモデル Y が例9のモデル B と同じであることに疑問がある場合、2つの分析のパラメータ推定値を比較してください。108 人の実験被験者のモデル Y のパラメータ推定値をここに示します。例9のモデル B から得た標準化されていないパラメータ推定値が、表示される推定値と一致するかどうか確認してください。



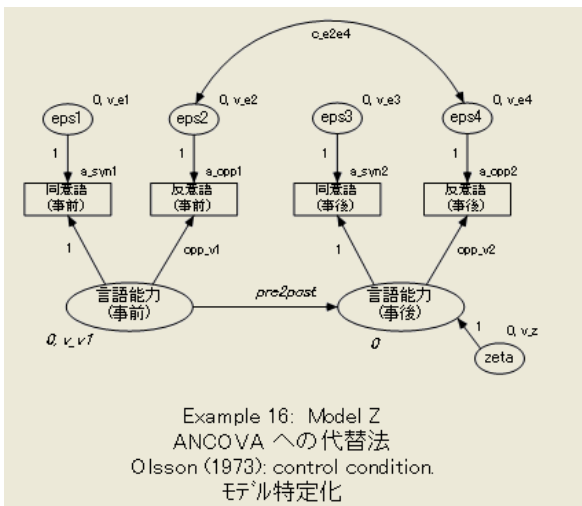
# モデル Z

最後に、pre\_verbal (言語能力(事前))から post\_verbal (言語能力(事後))を予測するための方程式の切片が、両方の母集団で等しいという条件をモデル Y に追加して、新しいモデル (モデル Z) を作成します。このモデルは例 9 のモデル C と同じものです。モデル Z のパス図は次のようになります。

モデル Z の実験群のパス図をここに示します。



統制群のパス図をここに示します。





## モデル Z の結果

このモデルは棄却されます。

カイ 2 乗 = 84.280

自由度 = 13

確率水準 = 0.000

モデル Y と比較すると、モデル Z も棄却されます ( $\chi^2 = 84.280 - 31.816 = 52.464$ 、 $df = 13 - 12 = 1$ )。丸め誤差の範囲内で、これは例 9 でモデル C をモデル B と比較したときのカイ 2 乗値と自由度の差と同じです。

## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。このプログラムは Ex16-a.vb として保存されています。

```
Sub Main()
    Dim Sem As New AmosEngine
    Try
        Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"
        Sem.TextOutput()
        Sem.Mods(4)
        Sem.Standardized()
        Sem.Smc()
        Sem.ModelMeansAndIntercepts()

        Sem.BeginGroup(dataFile, "Olss_cnt")
        Sem.GroupName("control")
        Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
        Sem.AStructure(_
            "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
        Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
        Sem.AStructure(_
            "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
        Sem.AStructure("pre_verbal = (0) + () pre_verbal + (1) zeta")

        Sem.BeginGroup(dataFile, "Olss_exp")
        Sem.GroupName("experimental")
        Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
        Sem.AStructure(_
            "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
        Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
        Sem.AStructure(_
            "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
        Sem.AStructure("pre_verbal = (effect) + () pre_verbal + (1) zeta")
        Sem.Mean("pre_verbal ", "pre_diff")

        Sem.FitModel()
    Finally
        Sem.Dispose()
    End Try
End Sub
```

## モデル B

モデル B を当てはめるには、モデル A のプログラムの実験群のモデル指定に

```
Sem.AStructure("eps2 <---> eps4")
```

という行を追加します。完成したモデル B のプログラムをここに示します。このプログラムは、Ex16-b.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "Olss_cnt")
    Sem.GroupName("control")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (0) + () pre_verbal + (1) zeta")

    Sem.BeginGroup(dataFile, "Olss_exp")
    Sem.GroupName("experimental")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (effect) + () pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <---> eps4")
    Sem.Mean("pre_verbal ", "pre_diff")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## モデル C

モデル C に適合するプログラムを次に示します。このプログラムは、Ex16-c.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"

    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "Olss_cnt")
    Sem.GroupName("control")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps2")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (0) + () pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <---> eps4")

    Sem.BeginGroup(dataFile, "Olss_exp")
    Sem.GroupName("experimental")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (effect) + () pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <---> eps4")
    Sem.Mean("pre_verbal ", "pre_diff")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## モデル D

次のプログラムはモデル D に適合します。このプログラムは、Ex16-d.vb として保存されています。

```
Sub Main()  
Dim Sem As New AmosEngine  
Try  
Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"  
Sem.TextOutput()  
Sem.Mods(4)  
Sem.Standardized()  
Sem.Smc()  
Sem.ModelMeansAndIntercepts()  
  
Sem.BeginGroup(dataFile, "Olss_cnt")  
Sem.GroupName("control")  
Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")  
Sem.AStructure(_  
    "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")  
Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")  
Sem.AStructure(_  
    "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")  
Sem.AStructure("pre_verbal = (0) + (pre2post) pre_verbal + (1) zeta")  
Sem.AStructure("eps2 <--> eps4")  
  
Sem.BeginGroup(dataFile, "Olss_exp")  
Sem.GroupName("experimental")  
Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")  
Sem.AStructure(_  
    "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")  
Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")  
Sem.AStructure(_  
    "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")  
Sem.AStructure(_  
    "pre_verbal = (effect) + (pre2post) pre_verbal + (1) zeta")  
Sem.AStructure("eps2 <--> eps4")  
Sem.Mean("pre_verbal", "pre_diff")  
  
Sem.FitModel()  
Finally  
Sem.Dispose()  
End Try  
End Sub
```

## モデル E

次のプログラムはモデル E に適合します。このプログラムは、Ex16-e.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "Olss_cnt")
    Sem.GroupName("control")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (0) + (pre2post) pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <--> eps4")

    Sem.BeginGroup(dataFile, "Olss_exp")
    Sem.GroupName("experimental")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (0) + (pre2post) pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <--> eps4")
    Sem.Mean("pre_verbal ", "pre_diff")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## 複数のモデルを適合する

次のプログラムは、モデル A からモデル E まで 5 つすべてのモデルに適合します。このプログラムは、Ex16-a2e.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Dim dataFile As String = Sem.AmosDir & "Examples\UserGuide.xls"
    Sem.TextOutput()
    Sem.Mods(4)
    Sem.Standardized()
    Sem.Smc()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(dataFile, "Olss_cnt")
    Sem.GroupName("control")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (0) + (c_beta) pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <---> eps4 (c_e2e4)")

    Sem.BeginGroup(dataFile, "Olss_exp")
    Sem.GroupName("experimental")
    Sem.AStructure("pre_syn = (a_syn1) + (1) pre_verbal + (1) eps1")
    Sem.AStructure(_
      "pre_opp = (a_opp1) + (opp_v1) pre_verbal + (1) eps2")
    Sem.AStructure("post_syn= (a_syn2) + (1) pre_verbal + (1) eps3")
    Sem.AStructure(_
      "post_opp = (a_opp2) + (opp_v2) pre_verbal + (1) eps4")
    Sem.AStructure("pre_verbal = (effect) + (e_beta) pre_verbal + (1) zeta")
    Sem.AStructure("eps2 <---> eps4 (e_e2e4)")
    Sem.Mean("pre_verbal", "pre_diff")

    Sem.Model("Model A", "c_e2e4 = 0", "e_e2e4 = 0")
    Sem.Model("Model B", "c_e2e4 = 0")
    Sem.Model("Model C")
    Sem.Model("Model D", "c_beta = e_beta")
    Sem.Model("Model E", "c_beta = e_beta", "effect = 0")
    Sem.FitAllModels()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

## モデル X、モデル Y、モデル Z

ここでは、モデル X、モデル Y、モデル Z の VB.NET のプログラムは説明しません。プログラムは、Ex16-x.vb、Ex16-y.vb、および Ex16-z.vb というファイルに保存されています。





# 欠損データ

## 概要

この例は、データの一部に欠損値があるデータセットの分析方法を示します。

## 不完全なデータ

調査を計画したときに期待したデータ値が、実際には得ることができないことがしばしば発生します。被験者が調査の一部に参加できないこともあります。または、アンケートの回答者がいくつかの質問を飛ばすこともあります。年齢を教えない人、収入を答えない人、反応時間を測定する日に現れない人などがいる場合もあります。どのような理由にせよ、しばしば欠損値のあるデータセットを処理することになります。

不完全なデータを処理する標準的な方法の 1 つは、データの一部に欠損値がある観測値を分析から除外することです。これをリストごとの削除と呼ぶことがあります。たとえばある人が収入を答えなかった場合、その人を調査から除外し、サイズは小さくなりますが、完全なデータのある標本に基づいて通常の分析を行います。この方法は、答えなかった回答のために、答えた回答に含まれる情報を捨てる必要があるため、満足のできる方法ではありません。欠損値が多いと、この方法では標本の大部分を捨てる必要がある場合もあります。

標本積率に基づく分析の場合のもう 1 つの標準的な方法は、各標本積率を個別に計算し、特定の積率の計算に必要な値が欠損している場合にのみ観測値を計算から除外する方法です。たとえば、標本の平均収入の計算では、収入がわからない人だけを除外します。同様に、標本の年齢と収入の間の共分散の計算では、年齢または収入が欠損している場合にだけ観測値を除外します。この欠損データの処理方法は、ペアごとの削除と呼ばれることもあります。

3つ目の方法はデータの代入です。これは、欠損値を何らかの推測値で置き換え、完全なデータに対する通常の分析を行う方法です。たとえば、収入を答えた人の平均収入を計算し、その平均収入を収入を答えなかった人全員の収入と考えます。Beale と Little (1975 年) は、多くの統計パッケージで実装されているデータの代入方法を解説しています。

Amos ではこれらの方法はどれも使用しません。欠損データがある場合でも、最尤法による推定値 (Anderson, 1957 年) を計算します。このため、欠損データがある場合は常に Amos を使用すれば、簡単な回帰分析 (例 4) や平均値の推定 (例 13) など、従来の分析を行うことができます。

Amos で処理できない種類の欠損データがあることにも注意してください。(上記の 3つの方法など、他の一般的な欠損データ処理方法でも処理できません。) 場合によっては、欠損値の存在自体が情報を持っていることもあります。たとえば、収入が非常に高い人は (他の人と比べて) 収入に関する質問に答えない傾向があることなどです。このように、観測データから得られる情報に加えて、質問に答えなかったことからその人の収入レベルについての確率的な情報が得られます。このような場合には、Amos が使用する欠損データの処理方法は不適切です。

Amos では、欠損したデータ値はランダムに欠損したと仮定されます。この仮定が妥当であるかどうかや、欠損データが実際に意味することがいつも簡単にわかるとは限りません (Rubin, 1976 年)。一方で、ランダムに欠損したという条件が満たされる場合、Amos では有効で堅実な推定値が得られます。対照的に、前述の方法では有効な推定値を得られません。また、欠損データが完全にランダムに欠損しているという強い条件の下でのみ推定値が一致します (Little と Rubin, 2020 年)。

## データについて

この例では、例 8 で使用した Holzinger と Swineford (1939 年) のデータを修正します。元のデータセット (SPSS Statistics ファイル Grnt\_fem.sav に格納されています) には 73 人の少女の 6 つの検定の得点が含まれ、合計 438 個のデータ値があります。欠損値のあるデータセットを得るには、Grnt\_fem.sav の 438 個のデータ値をそれぞれ 0.30 の確率で削除します。

その結果のデータセットが SPSS Statistics ファイル Grant\_x.sav に格納されています。下に示しているのは、このファイルの最初のいくつかのデータです。ピリオド (.) は欠損値を表します。

visperc	cubes	lozenges	paragraph	sentence	wordmean
33		17	8	データ	17
30		20			18
	33	36		25	41
28			10	18	11
	25		11		8
20	25	6	9		
17	21	6	5	10	10

Amos では、SPSS Statistics データ セットのピリオドを認識し、欠損データとして処理します。

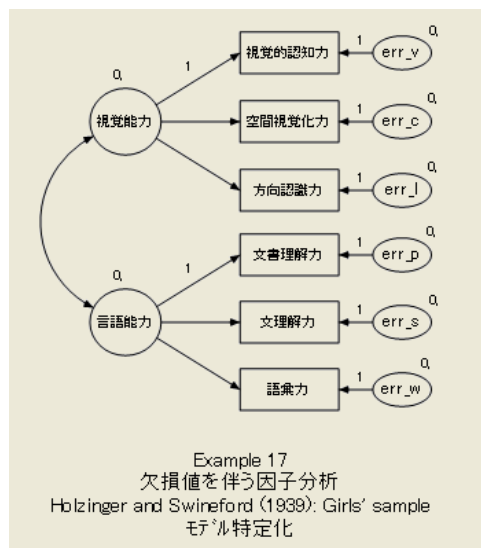
Amos は他にも多くのデータ形式で欠損データを認識できます。たとえば ASCII 形式のデータ セットでは、区切り文字が 2 つ連続すると欠損値を示します。上に示した 7 つのデータは、ASCII 形式では次のようになります。

```
visperc,cubes,lozenges,paragraph,sentence,wordmean
33,,17,8,17,10
30,,20,,,18
,33,36,,25,41
28,,,10,18,11
,,25,,11,,8
20,25,6,9,,,,
17,21,6,5,10,10
```

Grant\_x.sav のデータの約 27% が欠損しています。完全なデータが利用できるのは、7 人分のデータだけです。

## モデルを指定する

ここでは、Grant\_x.sav ファイルの Holzinger と Swineford のデータに対して、例 8 の共通因子分析モデル (251 ページで示しました) を当てはめます。この分析と例 8 の分析の違いは、今回はデータの 27% が欠損していることです。



データ ファイルに Grant\_x.sav を指定して上のパス図を描いてから、次の操作を実行します。

- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。

これにより、測定変数を予測する 6 つの回帰方程式それぞれの切片を推定することができます。欠損値がある場合の最尤法による推定は、平均値と切片を推定するときのみ機能します。そのため、推定値が必要でない場合にも平均値と切片を推定する必要があります。

## 飽和モデルおよび独立モデル

一部の適合度の計算には、ユーザーのモデルに加えて、飽和モデルと独立モデルを当てはめる必要があります。完全なデータがあればこれは問題になりませんが、欠損値がある場合には、飽和モデルと独立モデルの適合に大量の計算が必要になる場合があります。飽和モデルは特に問題になります。p 個の観測変数がある場合、飽和モデルには  $p \times (p + 3) / 2$  個のパラメータがあります。たとえば、観測変数が 10 個の場合は 65 個のパラメータ、20 個の変数の場合は 230 個のパラメータ、40 個の変数の場合は 860 個のパラメータなどとなります。パラメータの数が多くなると、飽和モデルを当てはめるのは現実的ではない場合があります。さらに、欠損値のパターンによっては、ユーザーのモデルを当てはめることは可能でも、飽和モデルを当てはめることは原理的に不可能である場合もあります。

不完全なデータの場合、Amos Graphics はユーザーのモデルに加えて、飽和モデルおよび独立モデルを当てはめようとしています。Amos が独立モデルの適合に失敗した場合、CFI など、独立モデルの適合に依存する適合度が計算できません。Amos が飽和モデルを当てはめることができない場合、通常のカイ 2 乗統計量は計算できません。

## 分析の結果

### テキスト出力

この例では、Amos は飽和モデルおよび独立モデルを両方当てはめることができます。結果として、カイ 2 乗統計量を含め、すべての適合度が示されます。適合度を見るには、次の操作を実行します。

- ▶ [Amos 出力] ウィンドウの左上のツリー図にある [モデル適合] をクリックします。

次に示すのは、因子分析モデル (デフォルト モデルと呼びます)、飽和モデル、独立モデルのカイ 2 乗統計量を示す出力の一部です。

CMIN					
モデル	NPAR	CMIN	自由度	確率	CMIN/DF
Default model	19	11.547	8	.173	1.443
飽和モデル	27	.000	0		
独立モデル	6	117.707	21	.000	5.605

カイ 2 乗値 11.547 は、例 8 の完全なデータセットで得られた値 7.853 からあまり離れていません。両方の分析で、p 値は 0.05 以上です。

パラメータ推定値、標準誤差、および検定統計量は完全なデータの分析の場合と同じ解釈ができます。

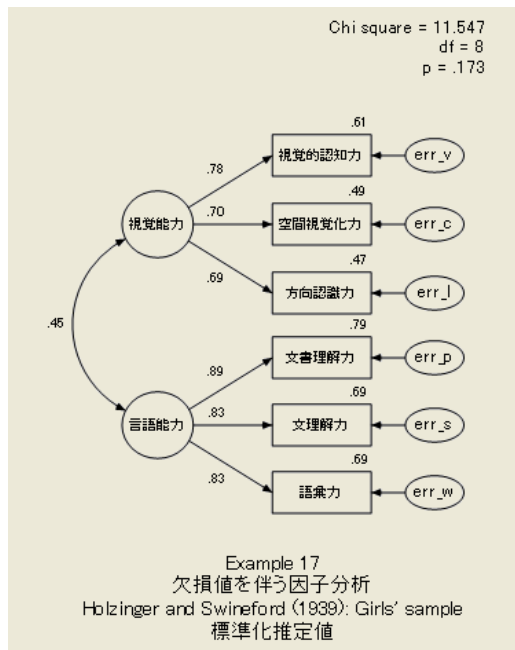
<b>係数: (Group number 1 - Default model)</b>						
		推定値	標準誤差	検定統計量	確率	ラベル
visperc	<--- spatial	1.000				
cubes	<--- spatial	.511	.153	3.347	***	
lozenges	<--- spatial	1.047	.316	3.317	***	
paragrap	<--- verbal	1.000				
sentence	<--- verbal	1.259	.194	6.505	***	
wordmean	<--- verbal	2.140	.326	6.572	***	
<b>切片: (Group number 1 - Default model)</b>						
		推定値	標準誤差	検定統計量	確率	ラベル
visperc		28.885	.913	31.632	***	
cubes		24.998	.536	46.603	***	
lozenges		15.153	1.133	13.372	***	
wordmean		18.097	1.055	17.146	***	
paragrap		10.987	.468	23.495	***	
sentence		18.864	.636	29.646	***	
<b>共分散: (Group number 1 - Default model)</b>						
		推定値	標準誤差	検定統計量	確率	ラベル
verbal <-->	spatial	7.993	3.211	2.490	.013	
<b>分散: (Group number 1 - Default model)</b>						
		推定値	標準誤差	検定統計量	確率	ラベル
spatial		29.563	11.600	2.549	.011	
verbal		10.814	2.743	3.943	***	
err_v		18.776	8.518	2.204	.028	
err_c		8.034	2.669	3.011	.003	
err_l		36.625	11.662	3.141	.002	
err_p		2.825	1.277	2.212	.027	
err_s		7.875	2.403	3.277	.001	
err_w		22.677	6.883	3.295	***	

標準化推定値と重相関係数の平方は次のようになります。

<b>標準化係数: (Group number 1 - Default model)</b>						
		推定値				
visperc	<--- spatial	.782				
cubes	<--- spatial	.700				
lozenges	<--- spatial	.685				
paragrap	<--- verbal	.890				
sentence	<--- verbal	.828				
wordmean	<--- verbal	.828				
<b>共分散: (Group number 1 - Default model)</b>						
		推定値	標準誤差	検定統計量	確率	ラベル
verbal <-->	spatial	7.993	3.211	2.490	.013	
<b>相関係数: (Group number 1 - Default model)</b>						
		推定値				
verbal <-->	spatial	.447				
<b>重相関係数の平方: (Group number 1 - Default model)</b>						
		推定値				
wordmean		.686				
sentence		.685				
paragrap		.793				
lozenges		.469				
cubes		.490				
visperc		.612				

## グラフィック出力

このパス図は、内生変数の標準化推定値と重相関係数の平方を示しています。



標準化パラメータ推定値は、例 8 で完全なデータから得られた推定値と比較できます。2 組の推定値は小数点以下 1 桁まで同じです。

## VB.NET でのモデル作成

不完全なデータを分析するために Amos プログラムを書く場合、Amos では独立モデルおよび飽和モデルは自動的に当てはめません。(Amos Graphics ではこれらのモデルを自動的に当てはめます。) Amos プログラムで独立モデルおよび飽和モデルを当てはめるには、プログラムにこれらのモデルを指定するコードを含める必要があります。特に、通常の尤度比カイ 2 乗統計量を計算するには、プログラムに飽和モデルを当てはめるコードを含める必要があります。

このセクションでは、尤度比カイ 2 乗統計量の計算に必要な次の 3 つの手順を説明します。

- 因子モデルの適合
- 飽和モデルの適合
- 尤度比カイ 2 乗統計量とその p 値の計算

最初に、この 3 つの手順を、3 つの別々のプログラムで実行します。その後、3 つの手順を単一のプログラムにまとめます。

### 因子モデルの適合 (モデル A)

次のプログラムは確認のための因子モデル (モデル A) に適合します。このプログラムは、Ex17-a.vb として保存されています。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.Title("Example 17 a: Factor Model")
    Sem.TextOutput()
    Sem.Standardized()
    Sem.Smc()
    Sem.AllImpliedMoments()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grant_x.sav")
    Sem.AStructure("visperc = () + (1) spatial + (1) err_v")
    Sem.AStructure("cubes = () + spatial + (1) err_c")
    Sem.AStructure("lozenges = () + spatial + (1) err_l")

    Sem.AStructure("paragrap = () + (1)spatial + (1) err_p")
    Sem.AStructure("sentence = () + spatial + (1) err_s")
    Sem.AStructure("wordmean= () + spatial + (1) err_w")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

ModelMeansAndIntercepts メソッドを使用して平均値と切片がモデルのパラメータとして指定されていることと、6つの回帰方程式のそれぞれに切片を表す1組の空のかけこが含まれていることに注意してください。欠損値のあるデータを分析する場合、平均値と切片はモデルの明示的なパラメータとして示す必要があります。これは完全なデータの分析とは異なります。完全なデータの分析では、平均値と切片は、推定するか制約条件を設定する場合を除いて、モデルに示す必要はありません。

モデル A の適合を要約すると、次のようになります。

対数尤度関数 = 1375.133

パラメータ数 = 19

対数尤度関数の値は、完全なデータの場合に得られるカイ 2 乗統計量の代わりに表示されます。加えて、テキスト出力のモデルの要約セクションの先頭に、Amos は次の警告を表示します。

少なくとも 1 つのグループのデータに対して飽和モデルは適合しませんでした。このため、「対数尤度関数」、AIC、BCC のみが出来されます。尤度比カイ 2 乗統計量やその他の適合度測度は出力されません。

Amos がこの注記を表示するときは常に、モデルの要約セクションの `cmin` 列の値には見慣れた適合度カイ 2 乗統計量が含まれません。因子モデルの適合度を評価するには、対数尤度関数の値を、飽和モデルなどの制約条件の少ない基準モデルの値と比較する必要があります。

## 飽和モデルの適合 (モデル B)

飽和モデルには、1 次および 2 次の積率と同じ数の自由なパラメータがあります。完全なデータを分析する場合、飽和モデルは常に標本のデータに完全に適合します (カイ 2 乗 = 0.00、df = 0)。同じ 6 つの観測変数がある構造方程式モデルはすべて、飽和モデルと同等か、飽和モデルに制約条件を指定したモデルのいずれかです。飽和モデルは、少なくとも制約条件のあるモデルと同程度には標本のデータに適合します。対数尤度関数の値は制約条件のあるモデルより大きくはなく、通常は小さくなります。



次のプログラムは飽和モデル (モデル B) に適合します。このプログラムは、Ex17-b.vb として保存されています。

```
Sub Main()
  Dim Saturated As New AmosEngine
  Try
    ' 飽和モデルの設定と推定
    Saturated.Title("Example 17 b: Saturated Model")
    Saturated.TextOutput()
    Saturated.AllImpliedMoments()
    Saturated.ModelMeansAndIntercepts()

    Saturated.BeginGroup(Saturated.AmosDir & "Examples\Grant_x.sav")
    Saturated.Mean("visperc")
    Saturated.Mean("cubes")
    Saturated.Mean("lozenges")
    Saturated.Mean("paragrap")
    Saturated.Mean("sentence ")
    Saturated.Mean("wordmean")

    Saturated.FitModel()
  Finally
    Saturated.Dispose()
  End Try
End Sub
```

BeginGroup の行以降では、Mean メソッドを 6 回使用し、6 つの変数の平均の推定値を要求しています。Amos が平均値を推定する場合、プログラムで明示的に分散と共分散を制約していない限り、自動的に分散と共分散も推定します。

次に示すのは、飽和モデル B の標準化されていないパラメータ推定値です。

平均値 : (グループ番号 1 - モデル1)						
	推定値	標準誤差	検定統計量	確率	ラベル	
visperc	28.883	.910	31.756	***		
cubes	25.154	.540	46.592	***		
lozenges	14.962	1.101	13.591	***		
paragrap	10.976	.466	23.572	***		
sentence	18.802	.632	29.730	***		
wordmean	18.263	1.061	17.211	***		
共分散 : (グループ番号 1 - モデル1)						
	推定値	標準誤差	検定統計量	確率	ラベル	
visperc <--> cubes	17.484	4.614	3.789	***		
visperc <--> lozenges	31.173	9.232	3.377	***		
cubes <--> lozenges	17.036	5.459	3.121	.002		
visperc <--> paragrap	8.453	3.705	2.281	.023		
cubes <--> paragrap	2.739	2.179	1.257	.209		
lozenges <--> paragrap	9.287	4.596	2.021	.043		
visperc <--> sentence	14.382	5.114	2.813	.005		
cubes <--> sentence	1.678	2.929	.573	.567		
lozenges <--> sentence	10.544	6.050	1.743	.081		
paragrap <--> sentence	13.470	2.945	4.574	***		
visperc <--> wordmean	14.665	8.314	1.764	.078		
cubes <--> wordmean	3.470	4.870	.713	.476		
lozenges <--> wordmean	29.655	10.574	2.804	.005		
paragrap <--> wordmean	23.616	5.010	4.714	***		
sentence <--> wordmean	29.577	6.650	4.447	***		
分散 : (グループ番号 1 - モデル1)						
	推定値	標準誤差	検定統計量	確率	ラベル	
visperc	49.584	9.398	5.276	***		
cubes	16.484	3.228	5.106	***		
lozenges	67.901	13.404	5.066	***		
paragrap	13.570	2.515	5.396	***		
sentence	25.007	4.629	5.402	***		
wordmean	73.974	13.221	5.595	***		

プログラムの中の AllImpliedMoments メソッドは、次の推定値の表を表示します。

モデルの(全変数に関する)共分散 (グループ番号 1 - モデル1)						
	wordmean	sentence	paragrap	lozenges	cubes	visperc
wordmean	73.974					
sentence	29.577	25.007				
paragrap	23.616	13.470	13.570			
lozenges	29.655	10.544	9.287	67.901		
cubes	3.470	1.678	2.739	17.036	16.484	
visperc	14.665	14.382	8.453	31.173	17.484	49.584
モデルの(全変数に関する)平均値 (グループ番号 1 - モデル1)						
	wordmean	sentence	paragrap	lozenges	cubes	visperc
	18.263	18.802	10.976	14.962	25.154	28.883

これらの推定値は、平均の推定値も含め、ペアごとまたはリストごとの削除方法を使用して計算された標本の値とは異なります。たとえば、53 人が視覚認識の検定 (visperc) を受けました。この 53 人の visperc (視覚認知力) の得点の平均は 28.245 です。Amos による視覚認識の平均得点の推定値も 28.245 だと予想するかもしれません。これらの推定値は、推定平均でさえ、ペアごとの削除またはリストごとの削除のいずれかを使用して標本の値を計算した場合と異なります。

この 53 人の visperc (視覚認知力) の得点の平均は 28.245 です。

対数尤度関数 = 1363.586  
パラメータ数 = 27

対数尤度関数の値は、入れ子になったモデルの適合度の計算に使用できます。この場合、モデル A (適合度の統計量 1375.133、パラメータ数 19) はモデル B (適合度の統計量 1363.586、パラメータ数 27) の中に入れ子になっています。強い方のモデル (モデル A) を弱いモデル (モデル B) と比較し、強い方のモデルが正しい場合、次のことが言えます。弱いモデルから強いモデルに切り替えるときの対数尤度関数の増加量は、2 つのモデルのパラメータ数の差に等しい自由度を持つ、カイ 2 乗ランダム変数の観測値です。この例では、モデル A の対数尤度関数は、モデル B の対数尤度関数を 11.547 (= 1375.133 - 1363.586) 上回っています。同時に、モデル A は 19 個のパラメータしか推定する必要がありません。一方でモデル B は 27 個のパラメータを推定する必要があります、その差は 8 です。言い換えると、モデル A が正しい場合、11.547 は 8 自由度のカイ 2 乗変数の観測値です。カイ 2 乗の表で、このカイ 2 乗統計量が有意な値かどうかを参照することができます。

## 尤度比カイ 2 乗統計量とその p 値の計算

カイ 2 乗の表を参照する代わりに、ChiSquareProbability メソッドを使用して、11.547 という大きさのカイ 2 乗値が正しい因子モデルで発生する確率を求めることができます。次のプログラムは、ChiSquareProbability メソッドの使用法を示しています。このプログラムは、Ex17-c.vb として保存されています。

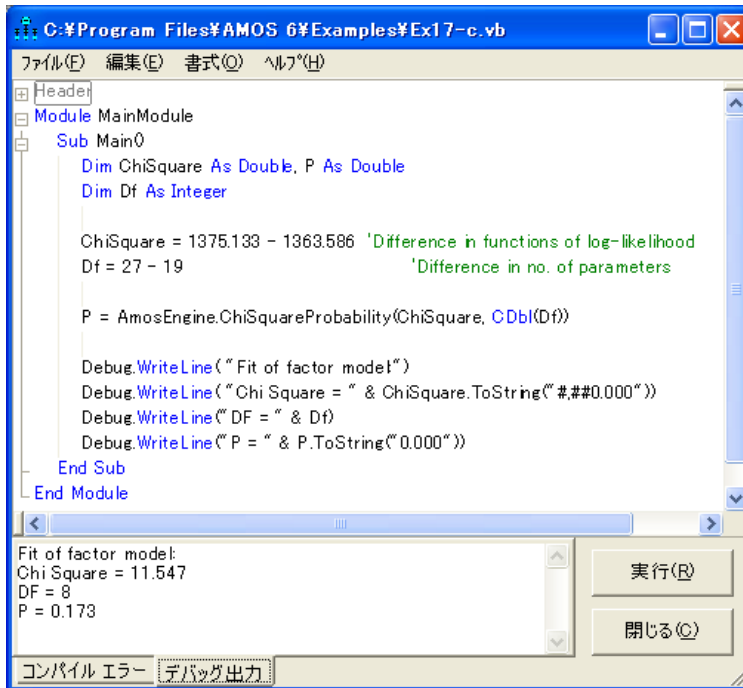
```
Sub Main()
    Dim ChiSquare As Double, P As Double
    Dim Df As Integer

    ChiSquare = 1375.133 - 1363.586 ' 対数尤度関数の差
    Df = 27 - 19 ' パラメータ数の差

    P = AmosEngine.ChiSquareProbability(ChiSquare, CDbl(Df))

    Debug.WriteLine("Fit of factor model:")
    Debug.WriteLine("Chi Square = " & ChiSquare.ToString("#.##0.000"))
    Debug.WriteLine("DF = " & Df)
    Debug.WriteLine("P = " & P.ToString("0.000"))
End Sub
```

プログラムの出力は、プログラム エディタの [デバッグ] 出力パネルに表示されます。



p 値は 0.173 です。したがって、モデル A が 0.05 レベルで正しいという仮説を受け入れることができます。

この例で説明したように、不完全なデータのモデルを検定するには、適合度を別の代替モデルの適合度と比較する必要があります。この例では、検定したいのはモデル A ですが、モデル A を比較する基準としてモデル B も当てはめる必要があります。代替モデルは 2 つの条件を満たす必要があります。1 つ目は、代替モデルが正しいことを確かめる必要があります。モデル B では明示的でない積率に制約条件を課してはいませんし、誤りである可能性がないため、モデル B は確かにこの条件を満たします。2 つ目は、検定するモデルよりも一般的である必要があります。検定するモデルのパラメータに対する制約条件の一部を削除することで得られたモデルは、この 2 つ目の条件を満たします。代替モデルを考え出すことができない場合は、ここで使用したように、いつでも飽和モデルを使用できます。

## 単一プログラムでの全手順の実行

両方のモデル（因子モデルおよび飽和モデル）を適合する単一のプログラムを書き、カイ 2 乗統計量とその p 値を計算することができます。Ex17-all.vb ファイルのプログラムでこの方法を示します。

# 欠損データについてのその他の情報

## 概要

この例では、一部の値を故意に欠損させたデータを分析した後、不完全なデータを意図的に収集する際の利点について調べます。

## 欠損データ

通常、データの欠損を歓迎する研究者はいません。普通は可能な限り、細心の注意を払ってデータの欠損による誤差を回避しようとします。しかし実際には、各状況におけるすべての変数を観察しない方がいい場合もあります。Matthai(1951)とLord(1955)は、特定のデータ値を意図的に観察しないというデザインを設計しました。

このデザインで採用されている基本原則とは、ある変数について十分な観察が得られない、またはコストがかかり過ぎるという場合には、相関関係のある他の変数を別に観察することで、より精度の高い推定値が得られるというものです。

このデザインは非常に便利ですが、計算が難しいという理由から、以前はごく単純な条件下でしか用いられませんでした。ここでは、一部のデータが意図的に収集されなかったデザインについて、考えられる多数の例の中から一例を紹介します。分析の方法は、例17と同じです。

## データについて

この例では、Attig によるデータ (例 1 を参照) から一部のデータ値を除去し、欠損として扱っています。以下に、SPSS Statistics データ エディタで表示した、若年層における変更済みデータ ファイル Atty\_mis.sav の一部を示します。このファイルには、40 名の若年被験者が、Attig による v\_short および vocab という 2 種類の語彙検定を受けた際の得点が記載されています。変数 vocab は、WAIS 語彙の得点です。V\_short は、WAIS 語彙検定での、項目の小規模なサブセットにおける得点です。Vocab 得点では、ランダムに抽出した 30 名の被験者のデータを削除してあります。

vocab_short	vocabulary
6	51
9	52
8	60
5	48
13	
12	
14	
4	
5	

2 番目のデータ ファイル Atto\_mis.sav には、40 名の老年被験者による語彙検定の得点が記載されています。ここでも、ランダムに抽出した 30 名分の vocab 得点が削除されています。

vocab_short	vocabulary
10	67
6	47
4	47
0	40
12	
14	
13	
6	
7	

もちろん、常識的な人間ならば、収集済みのデータを削除したりしません。ここでは、例を説明するにあたり、このデータ欠損パターンが次のような状況下で発生したとします。

vocab は、自分が知る限り最良の語彙検定であると仮定します。この検定は非常に信頼性が高く有効なので、あなたはこの語彙検定を実施したいと考えています。ただ残念なことに、実施には費用が高くつきます。実施には長時間を要するでしょうし、被験者ごとに個別に実施する必要があります。また、採点には訓練を積んだ人間が当たる必要があるかもしれません。一方、V\_short は、語彙検定として良いものとは言えませんが、短時間で済み、コストも抑えられ、一回で多数の被験者に対して簡単に実施できます。若年層と老年層それぞれ 40 名ずつに対して廉価な検定である v\_short を実施します。その後で、若年層と老年層からそれぞれランダムに 10 名を抽出し、高価な検定である vocab を受けてもらいます。

この研究の目的は、次のとおりであるとします。

- 若年層の母集団における vocab 検定の得点の平均値を推定する。
- 老年層の母集団における vocab 検定の得点の平均値を推定する。
- vocab の得点における平均値は、若年層と老年層で等しいという仮説を検定する。

このシナリオでは、あなたは v\_short の得点の平均値には関心を持っていません。ただし、次に示すとおり、この得点には vocab の得点についての仮説を推定して検定するために役立つ情報が含まれているため、v\_short の得点はここでも有用です。

意図的に欠損値を発生させたという事実が、分析の方法に影響することはありません。このデータには、2つのモデルが適用されます。両方のモデルで、2つの語彙検定間の平均値、分散、共分散が、若年層だけでなく、老年層においても推定されます。モデル A では、グループ間でのパラメータ推定値が等しい必要があるという制約条件はありません。モデル B では、vocab の平均値が、両方のグループで等しくなることが求められます。

## モデル A

vocab と v\_short 間の平均値、分散、および共分散を推定するには、若年層と老年層の2つのグループモデルを設定します。

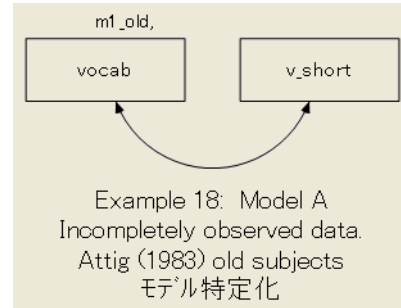
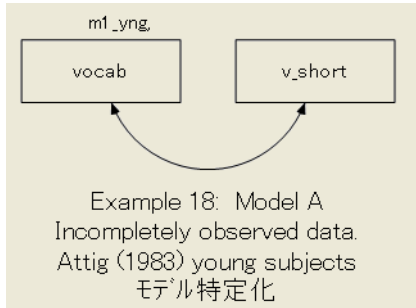
- ▶ パス図を作成します。この図では、vocab と v\_short を、双方向矢印でつながれた2つの四角形で表します。
- ▶ メニューから [表示]→[分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスで、[推定] タブをクリックします。
- ▶ [平均値と切片を推定] を選択します (横にチェック マークが表示されます)。
- ▶ [分析のプロパティ] ダイアログ ボックスが開いている状態で、[出力] タブをクリックします。
- ▶ [標準化推定値] と [差に対する検定統計量] を選択します。

この例では、グループ間における vocab の平均値の差に注目しているため、若年層グループと老年層グループのそれぞれの平均値に名前を付けておくとう便利です。若年層グループの vocab 平均値に名前を付ける方法は、次のとおりです。

- ▶ 若年層グループのパス図内にある vocab 四角形を右クリックします。
- ▶ ポップアップ メニューから [オブジェクトのプロパティ] を選択します。
- ▶ [オブジェクトのプロパティ] ダイアログボックスで、[パラメータ] タブをクリックします。

- ▶ [平均値] テキスト ボックスで、m1\_yng などの名前を入力します。
- ▶ 老年層グループについても同様の手順をとります。老年層グループの平均値にも、m1\_old などの一意の名前を付けてください。

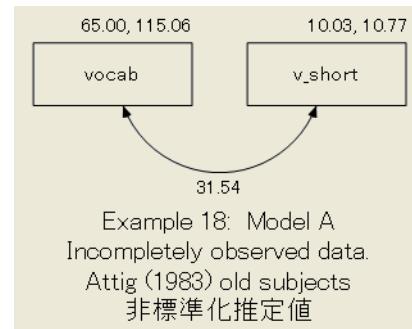
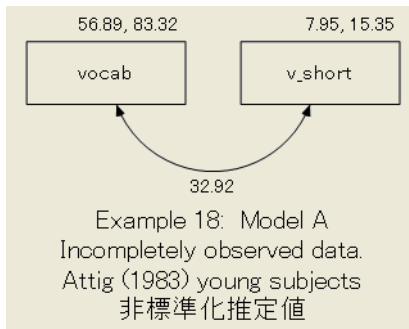
それぞれの名前が一意であれば、名前を付けたことで平均値の値が制約されることはありません。平均値に名前が付くと、この 2 つのグループのパス図は次のようになります。



## モデル A の結果

### グラフィックス出力

若年被験者と老年被験者のそれぞれに平均値、分散、および共分散が表示された 2 つのパス図です。





## テキスト出力

- ▶ [Amos 出力] ウィンドウの左上隅のウィンドウ枠にある [モデルについての注釈] をクリックします。

モデル A は飽和状態にあるということがテキスト出力されます。つまり、このモデルは検定できないということです。

異なる標本の積率の数	10
推定される異なるパラメータの数	10
自由度 (10 - 10)	0

若年被験者のパラメータ推定値と標準誤差は、次のとおりです。

平均値 : (young subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab	56.891	1.765	32.232	***	m1_yng	
v_short	7.950	.627	12.673	***	par_4	
共分散: (young subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab <--> v_short	32.916	8.694	3.786	***	par_3	
相関係数: (young subjects - Default model)						
	推定値					
vocab <--> v_short	.920					
分散: (young subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab	83.320	25.639	3.250	.001	par_7	
v_short	15.347	3.476	4.416	***	par_8	

老年被験者のパラメータ推定値と標準誤差は、次のとおりです。

平均値 : (old subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab	65.001	2.167	29.992	***	m1_old	
v_short	10.025	.526	19.073	***	par_6	
共分散: (old subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab <--> v_short	31.545	8.725	3.616	***	par_5	
相関係数: (old subjects - Default model)						
	推定値					
vocab <--> v_short	.896					
分散: (old subjects - Default model)						
	推定値	標準誤差	検定統計量	確率	ラベル	
vocab	115.063	37.463	3.071	.002	par_9	
v_short	10.774	2.440	4.416	***	par_10	

vocab の平均値における推定値は、若年層の母集団では 56.891、老年層の母集団では 65.001 です。これらの値が、vocab 検定を受けた若年層と老年層各 10 名から得られるとした標本の平均値とは異なる点に注意してください。標本の平均値である 58.5 と 62 は母集団の平均値としては良い推定値です (サイズが 10 の 2 つの標本から得られるとされる最良の値)。ただし、Amos による推定値 (56.891 と 65.001) には、v\_short の得点に関する情報が使用されているという利点があります。

それでは、v\_short の得点における情報を含む推定値は、どの程度精度を増していることになるのでしょうか。これは、標準誤差の推定値に注目すると大体わかります。若年被験者では、表中の 56.891 に対する標準誤差は約 1.765 です。これに対し、標本の平均値 58.5 に対する標準誤差は、約 2.21 です。老年被験者では、65.001 に対する標準誤差は約 2.167 です。これに対し、標本の平均値 62 に対する標準誤差は、約 4.21 です。ここで取り上げた標準誤差は近似値に過ぎませんが、おおよその比較基準になります。若年被験者のケースでは、v\_short で得点に含まれる情報を使用することで、vocab 平均値の推定値における標準誤差が約 21% 減少しています。老年被験者の例では、約 49% の標準誤差が減少しています。

v\_short で得点から得られる追加情報を評価するには、標本サイズの要件を評価するという方法もあります。v\_short で得点に関する情報を使用しなかったと仮定します。平均値における標準誤差を 21% 減少させるには、あと何名の若年被験者が vocab 検定を受ける必要があったでしょうか。同様に、平均値における標準誤差を 49% 減少させるには、あと何名の老年被験者が vocab 検定を受ける必要があったでしょうか。この平均値における標準誤差は標本サイズの平方根に反比例するため、答えは、若年層で約 1.6 倍、老年層で約 3.8 倍の被験者が必要だったことになります。つまり、各層で 10 名ずつが両方の検定を受け、30 名ずつが短時間の検定のみを受けるのではなく、若年層で約 16 名、老年層では約 38 名の被験者が vocab 検定を受ける必要があったということです。もちろん、この計算で扱っているのはあくまでも標準誤差の推定値であり、正確な標準誤差の値ではありません。このため、ここでわかることは、v\_short 検定の得点を使用することで得られる精度についての概略に過ぎません。

若年層と老年層の各母集団では、vocab の得点における平均値が異なるのでしょうか。この平均値の差における推定値は、8.110(65.001 - 56.891) です。この有意確率の差を検定するにあたっての検定統計量を、次のテーブルに示します。

パラメータ間の差に対する検定統計量 (Default model)										
	ml_yng	ml_old	par_3	par_4	par_5	par_6	par_7	par_8	par_9	par_10
ml_yng	.000									
ml_old	2.901	.000								
par_3	-2.702	-3.581	.000							
par_4	-36.269	-25.286	-2.864	.000						
par_5	-2.847	-3.722	-.111	2.697	.000					
par_6	-25.448	-30.012	-2.628	2.535	-2.462	.000				
par_7	1.028	.712	2.806	2.939	1.912	2.858	.000			
par_8	-10.658	-12.123	-2.934	2.095	-1.725	1.514	-2.877	.000		
par_9	1.551	1.334	2.136	2.859	2.804	2.803	.699	2.650	.000	
par_10	-15.314	-16.616	-2.452	1.121	-3.023	.300	-2.817	-1.077	-2.884	.000

「ml\_yng」および「ml\_old」というラベルがついた上からの 2 行と左からの 2 列は、vocab 検定のグループ平均値を参照します。長時間の検定では、老年層の母集団の得点は若年層の母集団よりも高く、両者の平均値には 0.05 レベルでの有意差がみられます。これによって、この平均値の差に対する検定統計量は 2.901 となっています。

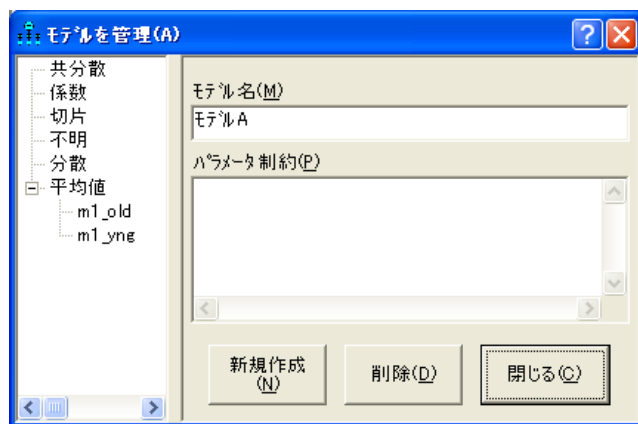
また、vocab でグループ平均値が等しいという仮説の検定は、両者の平均値に設けた同等性の制約条件をモデルに対して最適化することでも得られます。次にこの方法について説明します。

## モデル B

モデル B では、vocab の平均値が、若年層と老年層とで等しくなることが求められます。この制約条件を設けるには、2つの方法があります。1つは、平均値の名前を変更するという方法です。モデル A では、各平均値には一意の名前が付けられています。この名前は変更することができ、両方の平均値に同じ名前を付けることができます。これによって、2つの平均値は同じ値である必要が生じることになります。

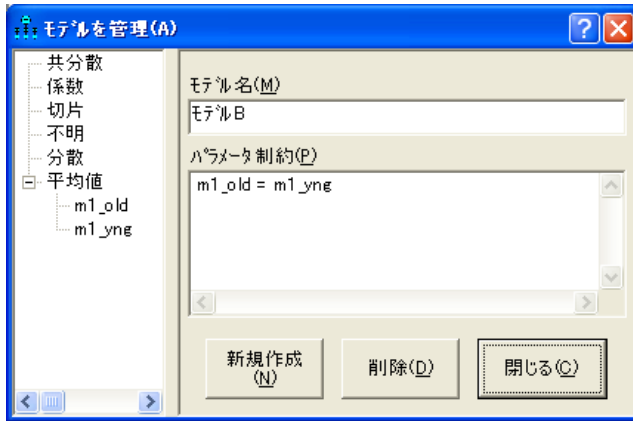
ここでは、別の方法を使用して平均値を制約します。平均値の名前 ml\_yng および ml\_old は変更されません。Amos では [モデルを管理] を使用して、単一の分析にモデル A とモデル B の両方を適合させます。この手法を使用するには、次の手順を実行します。

- ▶ モデル A から開始します。
- ▶ メニューから [分析] → [モデルを管理] の順に選択します。
- ▶ [モデル管理] ダイアログ ボックスの [モデル名] テキスト ボックスに「モデル A」と入力します。
- ▶ [パラメータ制約] ボックスは空白のまま残しておきます。



- ▶ モデル B を指定するには、[新規作成] をクリックします。
- ▶ [モデル名] テキスト ボックスで、「モデル番号 2」を「モデル B」に変更します。

- ▶ [パラメータ制約] テキスト ボックスに、「m1\_old = m1\_yng」と入力します。



- ▶ [閉じる] をクリックします。

Ex18-b.amw というファイルに、モデル A とモデル B の両方に適合するパス図が保存されます。

## モデル A およびモデル B からの出力

- ▶ モデル A とモデル B の両方における適合度を調べるには、[Amos 出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で、[モデルの適合度] をクリックします。

カイ 2 乗の値のある出力部分を次に示します。

CMIN					
モデル	NPAR	CMIN	自由度	確率	CMIN/DF
Model A	10	.000	0		
Model B	9	7.849	1	.005	7.849
飽和モデル	10	.000	0		
独立モデル	4	33.096	6	.000	5.516

モデル B が正しい (若年層と老年層の両方の母集団において vocab の得点の平均値が等しい) 場合、7.849 は、自由度 1 のカイ 2 乗分布がみられる乱数変数における観測値となります。7.849 と同じ大きさの値を偶然に得る確率は低いので ( $p = 0.005$ )、モデル B は棄却されます。この結果、若年被験者と老年被験者では、vocab の得点における平均値が有意に異なると言えます。

## VB.NET でのモデル作成

### モデル A

モデル A に適合するプログラムを次に示します。両方の被験者グループにおける両方の語彙検定について、制約を設けずに平均値、分散、および共分散を推定します。このプログラムは、Ex18-a.vb ファイルとして保存されます。

```
Sub Main()  
Dim Sem As New AmosEngine  
Try  
    Sem.TextOutput()  
    Sem.Crdiff()  
    Sem.ModelMeansAndIntercepts()  
  
    Sem.BeginGroup(Sem.AmosDir & "Examples%atty_mis.sav")  
    Sem.GroupName("young_subjects")  
    Sem.Mean("vocab", "m1_yng")  
    Sem.Mean("v_short")  
    Sem.BeginGroup(Sem.AmosDir & "Examples%atto_mis.sav")  
    Sem.GroupName("old_subjects")  
    Sem.Mean("vocab", "m1_old")  
    Sem.Mean("v_short")  
    Sem.FitModel()  
Finally  
    Sem.Dispose()  
End Try  
End Sub
```

Crdiff メソッドは、前述したパラメータの差に対する検定統計量を表示します。後で参照するために、モデル A の対数尤度関数の値を控えておいてください。

```
対数尤度関数 = 429.963  
パラメータ数 = 10
```

## モデル B

モデル B に適合するプログラムは次のとおりです。このプログラムでは、若年層グループの **vocab** 平均値と老年層グループの **vocab** 平均値とで同じパラメータ名 (*mn\_vocab*) が使用されています。この方法では、若年層グループと老年層グループにおける **vocab** 平均値が同じである必要があります。このプログラムは、Ex18-b.vb ファイルとして保存されます。

```
Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Crdiff()
    Sem.ModelMeansAndIntercepts()

    Sem.BeginGroup(Sem.AmosDir & "Examples¥atty_mis.sav")
    Sem.GroupName("young_subjects")
    Sem.Mean("vocab", "mn_vocab")
    Sem.Mean("v_short")
    Sem.BeginGroup(Sem.AmosDir & "Examples¥atto_mis.sav")
    Sem.GroupName("old_subjects")
    Sem.Mean("vocab", "mn_vocab")
    Sem.Mean("v_short")
    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub
```

Amos が報告するモデル B の適合度は、次のとおりです。

```
対数尤度関数 = 437.813
パラメータ数 = 9
```

モデル B とモデル A との適合度の差は  $7.85 (= 437.813 - 429.963)$ 、パラメータ数の差は  $1 (= 10 - 9)$  です。これらの数値は、先に Amos Graphics で得た数値と同じです。

# ブートストラップ

## 概要

この例では、ブートストラップ法によって頑健な標準誤差の推定値を得る方法について示します。

## ブートストラップ法

ブートストラップ (Efron, 1982) は、パラメータ推定値の標本分布の推定に汎用できる方法です。特に、標準誤差の近似を求める場合に使用することができます。先に示した例のとおり、Amos は推定対象のパラメータについて、標準誤差の近似を自動表示します。Amos では、こうした近似値の計算に、32 ページでの仮定に依存した公式を使用します。

ブートストラップでは、標準誤差の推定における問題に対し、まったく異なる手法をとります。別の手法が必要とされる理由とは何でしょうか。第一に、Amos には、重相関の 2 乗における標準誤差など、必要とされる標準誤差のすべてに公式が備わっているわけではありません。ただし、ブートストラップでは、標準誤差に対する公式を使用できなくてもまったく問題ありません。ブートストラップを使用すれば、標準誤差に対する公式がわかっているかどうかにかかわらず、Amos が計算するすべての推定値に対する標準誤差の近似を生成することができます。標準誤差に対する公式が Amos に備わっている場合でも、公式が役立つのは 32 ページでの仮定においてのみです。加えて、公式が機能するのは、正しいモデルを使用している場合にに限られます。ブートストラップによって求められた標準誤差の近似は、こうした制限を受けることはありません。

ブートストラップには、かなり大きな標本を必要とするなど、特有の欠点もあります。ブートストラップについて初めて学習する場合は、『Scientific American』誌に掲載の、Diaconis と Efron(1983) による論文を一読されることをお勧めします。

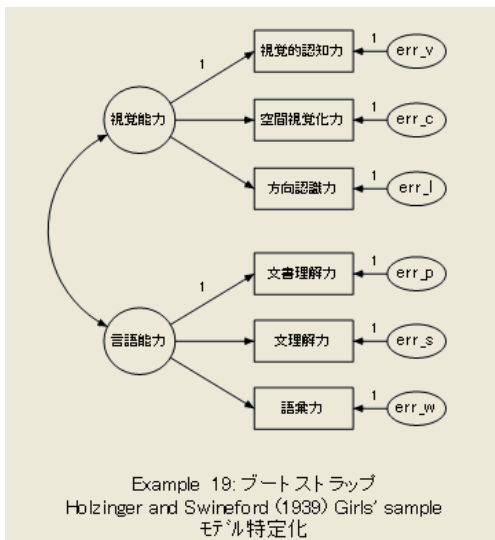
この例では因子分析モデルを適用したブートストラップについて紹介しますが、もちろん任意のモデルを使用してもかまいません。なお、Amos は例 1 のような単純な推定における問題を解決できることを覚えていてください。Amos のブートストラップ機能を使用できるようになることだけを目的に、こうした単純な問題にあえて Amos を使用してみるのもいいでしょう。

## データについて

この例では、例 8 で紹介した Holzinger と Swineford(1939) のデータを使用します。このデータは、Grnt\_fem.sav ファイルに入っています。

## 因子分析モデル

このモデルのパス図 (Ex19.amw) は、例 8 と同じです。



- ▶ 500回のブートストラップ反復を求めるには、メニューから [表示] → [分析のプロパティ] の順に選択します。
- ▶ [ブートストラップ] タブをクリックします。
- ▶ [ブートストラップの実行] を選択します。



- ▶ [ブートストラップ標本の数] テキスト ボックスに「500」と入力します。



## ブートストラップの進行状況の監視

パス図の左側にある [計算の要約] パネルを見ることで、ブートストラップ アルゴリズムの進行状況を監視できます。

```
反復 7  
最小値に達しました。  
出力の書込み  
カイ 2 乗 = 7.9、自由度 = 8  
ブートストラップ  
標本 500
```

## 分析の結果

モデルの適合度は、もちろん 例 8 と同じです。

```
カイ 2 乗 = 7.853  
自由度 = 8  
確率水準 = 0.448
```

パラメータ推定値も、例 8 と同じです。ただし、ここでは最尤法の理論に基づく標準誤差の推定値に注目し、ブートストラップによって得られた標準誤差と比較します。このため、最尤法によるパラメータの推定値と標準誤差は次のようになります。

<b>係数: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
visperc	<---	spatial	1.000			
cubes	<---	spatial	.610	.143	4.250	***
lozenges	<---	spatial	1.198	.272	4.405	***
paragrap	<---	verbal	1.000			
sentence	<---	verbal	1.334	.160	8.322	***
wordmean	<---	verbal	2.234	.263	8.482	***
<b>標準化係数: (Group number 1 - Default model)</b>						
			推定値			
visperc	<---	spatial	.703			
cubes	<---	spatial	.654			
lozenges	<---	spatial	.736			
paragrap	<---	verbal	.880			
sentence	<---	verbal	.827			
wordmean	<---	verbal	.841			
<b>共分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial	<-->	verbal	7.315	2.571	2.846	.004
<b>相関係数: (Group number 1 - Default model)</b>						
			推定値			
spatial	<-->	verbal	.487			
<b>分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial			23.302	8.123	2.868	.004
verbal			9.682	2.159	4.485	***
err_v			23.873	5.986	3.988	***
err_c			11.602	2.584	4.490	***
err_l			28.275	7.892	3.583	***
err_p			2.834	.868	3.263	.001
err_s			7.967	1.869	4.263	***
err_w			19.925	4.951	4.024	***
<b>重相関係数の平方: (Group number 1 - Default model)</b>						
			推定値			
wordmean			.708			
sentence			.684			
paragrap			.774			
lozenges			.542			
cubes			.428			
visperc			.494			

ブートストラップ出力は、診断情報が以下のとおりのテーブルから開始されます。

共分散行列が特異なため、0 個のブートストラップ標本が利用されませんでした。  
 解を求めることができなかったため、0 個のブートストラップ標本が利用されませんでした。  
 500 個の利用可能なブートストラップ標本が得られました。

特異な分散共分散行列が、1 つ以上のブートストラップ標本に見られることがあります。また、Amos が一部のブートストラップ標本の解を求められないこともあります。上記のいずれかの標本が出現した場合、Amos は出現について報告し、ブートストラップ分析からこの標本を除外します。この例では、特異な分散共分散行列が見られるブートストラップはなく、500 のブートストラップ標本すべての解が求められました。標準誤差のブートストラップ推定値は、次のとおりです。

<b>係数: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
visperc	<---	spatial	1.000			
cubes	<---	spatial	.610	.143	4.250	***
lozenges	<---	spatial	1.198	.272	4.405	***
paragrap	<---	verbal	1.000			
sentence	<---	verbal	1.334	.160	8.322	***
wordmean	<---	verbal	2.234	.263	8.482	***
<b>標準化係数: (Group number 1 - Default model)</b>						
			推定値			
visperc	<---	spatial	.703			
cubes	<---	spatial	.654			
lozenges	<---	spatial	.736			
paragrap	<---	verbal	.880			
sentence	<---	verbal	.827			
wordmean	<---	verbal	.841			
<b>共分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial	<-->	verbal	7.315	2.571	2.846	.004
<b>相関係数: (Group number 1 - Default model)</b>						
			推定値			
spatial	<-->	verbal	.487			
<b>分散: (Group number 1 - Default model)</b>						
			推定値	標準誤差	検定統計量	確率 ラベル
spatial			23.302	8.123	2.868	.004
verbal			9.682	2.159	4.485	***
err_v			23.873	5.986	3.988	***
err_c			11.602	2.584	4.490	***
err_l			28.275	7.892	3.583	***
err_p			2.834	.868	3.263	.001
err_s			7.967	1.869	4.263	***
err_w			19.925	4.951	4.024	***
<b>重相関係数の平方: (Group number 1 - Default model)</b>						
			推定値			
wordmean			.708			
sentence			.684			
paragrap			.774			
lozenges			.542			
cubes			.428			
visperc			.494			

- 「S.E.」というラベルが付いた 1 列目には、標準誤差のブートストラップ推定値が表示されています。これらの推定値は、最尤法によって得られた標準誤差の近似と比較されます。
- 「S.E.-S.E.」というラベルが付いた 2 列目には、ブートストラップにおける標準誤差の推定値自身に対する標準誤差の近似が表示されています。
- 「Mean」というラベルが付いた列にある値は、ブートストラップ標本に対して計算されたパラメータ推定値の平均値です。ブートストラップ平均値は、元の推定値と同じである必要はありません。
- 「Bias」というラベルが付いた列にある値は、元の推定値と、ブートストラップ標本に対する推定値の平均との差です。ブートストラップ標本に対する推定値の平均が元の推定値よりも大きい場合、「Bias」は正の値となります。
- 「S.E.-Bias」というラベルが付いた最後の列には、推定値の偏りに対する標準誤差の近似が表示されています。

## VB.NET でのモデル作成

次のプログラム (Ex19.vb) は例 19 のモデルに適合し、500 のブートストラップ標本でブートストラップを実行します。これは、Bootstrap 行が追加されている点以外は例 8 のプログラムと同じです。

```

Sub Main()
  Dim Sem As New AmosEngine
  Try
    Sem.TextOutput()
    Sem.Bootstrap(500)
    Sem.Standardized()
    Sem.Smc()

    Sem.BeginGroup(Sem.AmosDir & "Examples\Grnt_fem.sav")

    Sem.AStructure("visperc = (1) spatial + (1) err_v")
    Sem.AStructure("cubes = spatial + (1) err_c")
    Sem.AStructure("lozenges = spatial + (1) err_l")

    Sem.AStructure("paragrap = (1)spatial + (1) err_p")
    Sem.AStructure("sentence = spatial + (1) err_s")
    Sem.AStructure("wordmean= spatial + (1) err_w")

    Sem.FitModel()
  Finally
    Sem.Dispose()
  End Try
End Sub

```

Sem.Bootstrap(500) という行で、500 のブートストラップ標本に基づくブートストラップの標準誤差を求めています。

# ブートストラップでのモデル比較

## 概要

この例では、ブートストラップをモデル比較に使用する方法について示します。

## モデル比較におけるブートストラップ手法

この方法で扱うのは、個々のモデルを絶対的に評価する際の問題ではなく、競合する2つ以上のモデルからモデルを選択する際の問題です。Bollen と Stine の共同研究(1992) および、Bollen(1982)、Stine(1989) の各研究では、積率構造分析でのモデル選択におけるブートストラップ使用の可能性について述べられています。Linhart と Zucchini の共同研究(1986) では、構造モデリングなどの大きなモデルクラスに適したブートストラップとモデル選択に向けた、一般的なスキーマについて述べられています。ここでは、この Linhart と Zucchini による手法を採用しています。

モデル比較におけるブートストラップ手法について要約すると、次のようになります。

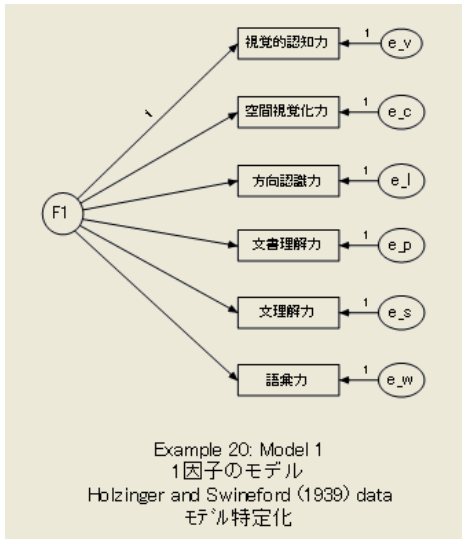
- 元の標本を置換して標本を抽出することで、複数のブートストラップ 標本を生成します。つまり、元の標本 が、ブートストラップの標本抽出のための 母集団となります。
- 競合するすべてのモデルを各ブートストラップ標本に当てはめます。 個々の分析が済んだら、ブートストラップ標本から得られたモデルの積率と、ブートストラップ母集団の積率との乖離度を計算します。
- 先述の手順における各モデルについて、乖離度の (ブートストラップ標本に対する) 平均値を計算します。
- 乖離度の平均値が最も小さいモデルを選択します。

## データについて

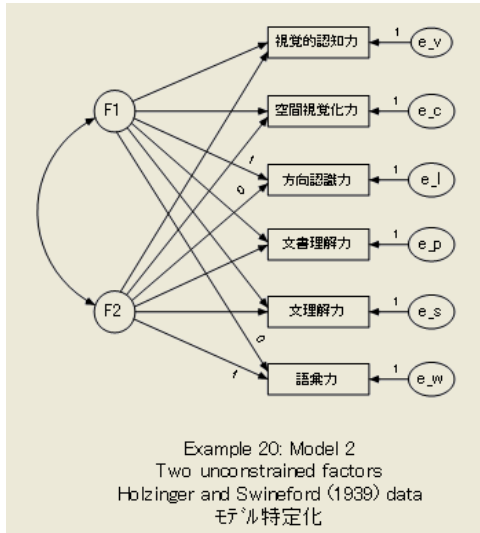
この例では、先に例 8、例 12、例 15、例 17、および例 19 で紹介した Holzinger と Swineford による研究 (1939) における、Grant-White 高校の男子生徒と女子生徒が混ざった標本を使用します。男子生徒と女子生徒を合わせて 145 の観測値が、Grant.sav ファイルに入っています。

## 5 つのモデル

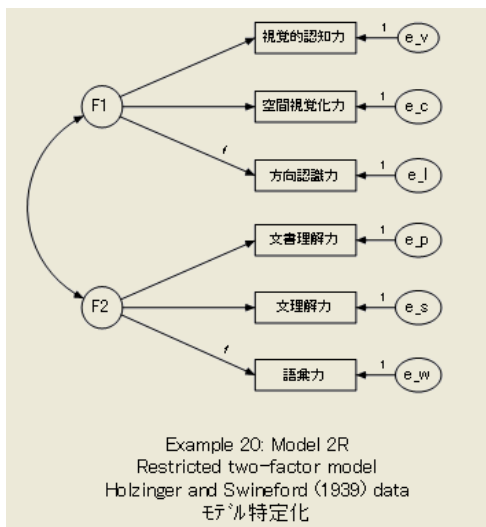
5 つの尺度モデルが、6 種類の心理検定に適用されます。モデル 1 は、因子数が 1 の因子分析モデルです。



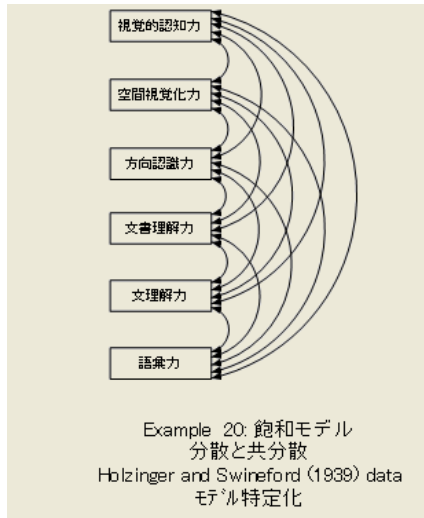
モデル 2 は、制約のない因子分析です。因子数は 2 です。回帰ウェイトのうちの 2 つを 0 に固定することでモデルを制約するのではなく、モデルを特定するだけであることに注意してください (Anderson, 1984; Bollen および Jöreskog, 1985; Jöreskog, 1979)。



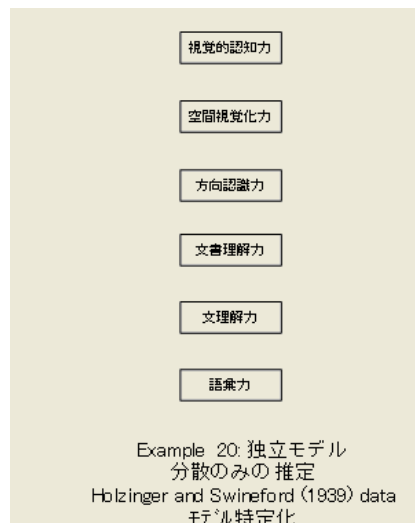
モデル 2R は、制限付きの因子分析モデルで、因子数は 2 です。このモデルでは、最初の 3 つの検定は因子のうちの 1 つのみに依存していて、残りの 3 つの検定はもう一方の因子のみに依存しています。



残る 2 つのモデルからは、先述のモデルの適合度を評価するための、慣例による基準点を設定することができます。飽和モデルでは、観測変数の分散と共分散は制限されません。



独立モデルでは、観測変数の分散は制限されませんが、共分散は 0 になることが求められます。




分析のたびに、Amos によってこの 2 つのモデルの適合度が自動的に報告されるため、通常、飽和モデルと独立モデルを別々に当てはめることはありません。ただし、この 2 つのモデルについてのブートストラップ結果を得るには、飽和モデルと独立モデルを明示的に指定する必要があります。異なる 5 つのブートストラップ分析は、1 つのモデルに対して 1 つずつ実施する必要があります。この 5 つの分析を実施する方法は、いずれも次のとおりです。

- ▶ メニューから [表示] → [分析のプロパティ] の順に選択します。




- ▶ [分析のプロパティ]ダイアログボックスで、[ブートストラップ]タブをクリックします。
- ▶ [ブートストラップの実行]を選択します(横にチェックマークが表示されます)。
- ▶ [ブートストラップ標本の数]テキストボックスに「1000」と入力します。



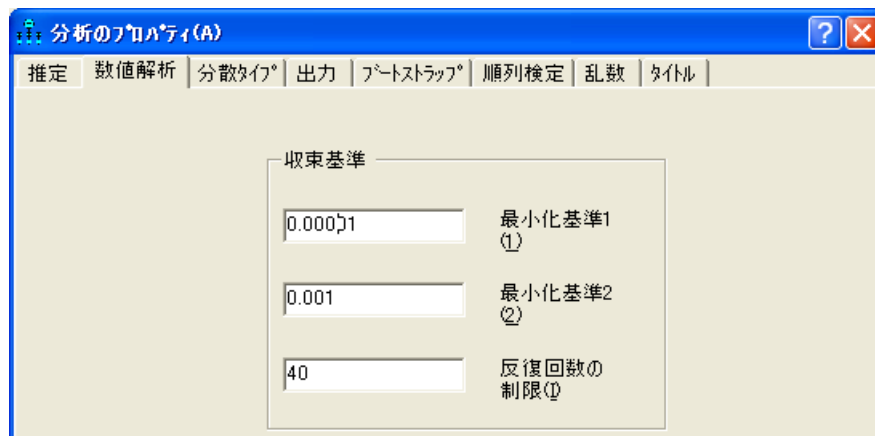
- ▶ [乱数]タブをクリックしてから、[乱数のシード]に値を入力します。

シードには任意の値を設定できますが、複数ある Amos の各セッションとまったく同じ標本群を抽出するには、毎回同じシード数を設定する必要があります。この例では、シード数を 3 に設定します。



場合によっては、ブートストラップ標本に対し、最小化アルゴリズムが収束しなくなることがあります。全体の計算時間を抑制する方法は、次のとおりです。

- ▶ [数値解析]タブをクリックしてから、[反復回数の制限]フィールドで、反復回数を 40 などの現実的な数に制限します。



この 5 つのモデルに対する Amos Graphics の入力ファイルは、それぞれ Ex20-1.amw、Ex20-2.amw、Ex20-2r.amw、Ex20-sat.amw、Ex20-ind.amw という名前で作成されています。

## テキスト出力

- ▶ モデル 1 のテキスト出力の表示を表示するには、[Amos 出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で [ブートストラップ反復の要約] をクリックします。

次のメッセージは、いずれのブートストラップ 標本についても破棄する必要はないということを表しています。1,000 のブートストラップ 標本すべてが利用されました。

共分散行列が特異なため、0 個のブートストラップ標本が利用されませんでした。解を求めることができなかったため、0 個のブートストラップ標本が利用されませんでした。  
1000 個の利用可能なブートストラップ標本が得られました。

- ▶ ツリー図で [ブートストラップ分布] をクリックして、次のヒストグラムを表示します。

$$C_{ML}(\hat{\alpha}_b, \mathbf{a}) = C_{KL}(\hat{\alpha}_b, \mathbf{a}) - C_{KL}(\mathbf{a}, \mathbf{a}), \quad b = 1, \dots, 1000$$

$\mathbf{a}$  には、Grant-White 高校の生徒 145 名分の元の標本からの標本積率 (ブートストラップ母集団の積率) が含まれています。 $\hat{\alpha}_b$  には、モデル 1 を  $b$ -th ブートストラップ標本に当てはめることで得られたモデルの積率が含まれています。したがって、 $C_{ML}(\hat{\alpha}_b, \mathbf{a})$  は、母集団の積率が、モデル 1 を使用した  $b$ -th 標本から推定した積率からどの程度離れているかを表す測度であることとなります。

ML乖離度 (モデル対母集団) (Default model)	
	-----
	**
	*****
	*****
	*****
	*****
	*****
	*****
	*****
	*****
N = 1000	*****
平均 = 64.162	***
標準誤差 = .292	*
	**
	**
	**
	*
	*
	*
	*
	-----

1,000 を超えるブートストラップ 標本に対する  $G_{ML}(\hat{\alpha}_b, \mathbf{a})$  の平均値は 64.162、標準誤差は 0.292 でした。残りの 4 つのモデルについても、同様のヒストグラムが平均値と標準誤差とともに表示されていますが、ここでは再現していません。5 つの競合モデルにおける乖離度の平均値は、BCC、AIC、および CAIC という値とともに下記のテーブルに表示されています。このテーブルから、5 つの競合モデルにおけるモデルの適合度 (かっこ内は標準誤差) がわかります。

モデル	失敗	乖離度の平均値	BCC	AIC	CAIC
1	0	64.16 (0.29)	68.17	66.94	114.66
2	19	29.14 (0.35)	36.81	35.07	102.68
2R	0	26.57 (0.30)	30.97	29.64	81.34
Sat.	0	32.05 (0.37)	44.15	42.00	125.51
Indep.	0	334.32 (0.24)	333.93	333.32	357.18

このテーブルの「失敗」列は、モデル 2 の尤度関数が、1,000 個のブートストラップ 標本中 19 個で最大化されなかったことを示しています。少なくとも、反復回数の制限値 40 は適用されていません。ブートストラップ 標本の総数をターゲットの 1,000 に合わせるため、モデル 2 には新たに 19 個のブートストラップ 標本が生成されました。モデル 2 を正常に適合できなかった 19 個の標本は、残りの 4 つのモデルでは問題となりませんでした。したがって、5 つのモデルすべてに共通するブートストラップ 標本は 981 個でした。

19 個のブートストラップ 標本においてモデル 2 の推定値を計算できなかった理由については、特に調べられていません。一般に、積率構造分析でのアルゴリズムは、適合が不十分なモデルに対して失敗しがちです。たとえば、開始値を厳密に設定したり、優れたアルゴリズムを使用するなど、モデル 2 をこの 19 個の標本に正常に適合させる方法を見つけられたとしても、乖離度が大きくなるものと予想されます。この理由から、推定に失敗したブートストラップ 標本を破棄すれば、乖離度の平均値における偏りを減少させることができると考えられます。このため、ブートストラップ実行中における推定の失敗について考慮する必要があります。乖離度の平均値が最も小さいモデルに対してこの失敗が起きた場合には、特に注意します。

この例では、モデル 2R で乖離度の平均値が最小 (26.57) となり、BCC、AIC、CAIC 基準に基づいたモデル選択が確認されます。乖離度の平均値における差は、標準誤差に比べて大きいです。すべてのモデルが同一のブートストラップ 標本に適合していたため (モデル 2 を正常に適合できなかった標本を除く)、ブートストラップ 標本において、同一モデルに対する乖離度間で正の相関が見られるだろうと予想することもできるでしょう。しかしあいにくながら、Amos からこの相関が報告されることはありません。この相関を手計算してみると、ほぼ 1 近くになります。このため、全体的にテーブル内の平均値の差における標準誤差は、平均値の標準誤差よりもかなり小さいと言えます。

## 要約

ブートストラップは、積率構造分析でのモデル選択において実際に役立ちます。Linhart と Zucchini (1986) の手法では、モデル比較の基準として、モデルの積率と母集団の積率との間で予測される乖離度を使用します。この方法は理論上は単純で、適用しやすいものです。この方法では、有意確率などの特別な数を任意に使用することはできません。もちろん、競合モデルの理論的な妥当性や、モデルに関連付けられたパラメータ推定値の合理性は、ブートストラップ手続きでは考慮されません。また、モデル評価プロセスでの別の段階では、適切な重みを指定する必要があります。

## VB.NET でのモデル作成

この例が記述された Visual Basic プログラムは、Ex20-1.vb、Ex20-2.vb、Ex20-2r.vb、Ex20-ind.vb、および Ex20-sat.vb ファイルに入っています。

# ブートストラップによる比較推定方法

## 概要

この例では、競合する推定基準をブートストラップによって選択する方法について示します。

## 推定方法

母集団の積率とモデルの積率との乖離度は、モデルだけではなく推定方法にも依存します。モデルを比較するために例20で使用した手法は、推定方法の比較にも適用できます。この手法が特に必要とされるのは、選択対象となる推定方法が漸近的にのみ最適となることがわかっていて、この推定方法の有限標本における相対的な利点が、モデル、標本サイズ、および母集団の分布に依存すると予測される場合です。推定方法を選択するこのプログラムを実行する際に最も問題となるのは、母集団の積率とモデルの積率との間の乖離度を測定する方法をあらかじめ決定する必要があるということです。この決定にあたっては、他の対象への推定基準を肯定するしか方法がないようです。もちろん、すべての母集団の乖離度が同じ結果となれば、適切な母集団の乖離度はどれかという問題について理論的に考察できるようになります。この例では、こうした明確な例を紹介します。

## データについて

この例では、例20 (Grant.sav ファイル) での Holzinger-Swineford(1939) データを使用します。


## モデルについて

この例では先の例とは替わり、漸近的分布非依存法 (ADF)、最尤法 (ML)、一般化最小 2 乗法 (GLS)、重み付けのない最小 2 乗法 (ULS) の 4 つの方法で、例 20 のモデル 2R のパラメータを推定します。この 4 つのモデルを比較するには、Amos を 4 回実行する必要があります。

推定方法とブートストラップパラメータを指定する方法は、次のとおりです。

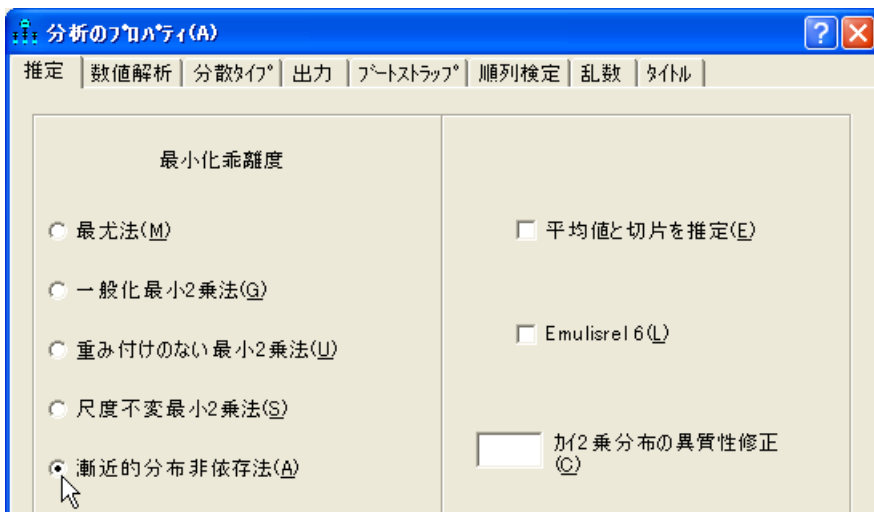
- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログボックスで、[乱数] タブをクリックします。
- ▶ [乱数のシード] に値を入力します。

例 20 で述べたとおり、シードには任意の値を選択できますが、複数ある Amos の各セッションとまったく同じ標本群を抽出するには、毎回同じシード数を設定する必要があります。この例では、シード数を 3 に設定します。



- ▶ 次に、[推定] タブをクリックします。
- ▶ [漸近的分布非依存法] 乖離度を選択します。

この乖離度は、各ブートストラップ標本へのモデル適合に、ADF による推定方法を使用することを設定します。



- ▶ 最後に、[ブートストラップ] タブをクリックします。
- ▶ [ブートストラップの実行] を選択して、[ブートストラップ標本の数] に「1000」と入力します。
- ▶ [ブートストラップ ADF]、[ブートストラップ ML]、[ブートストラップ GLS]、および [ブートストラップ ULS]。

分析のプロパティ(A)

推定 | 数値解析 | 分散タイプ | 出力 | **ブートストラップ** | 順列検定 | 乱数 | タイル

**ブートストラップの実行(R)**      1000      ブートストラップ標本の数(N)

百分位数法による信頼区間(P)      90      百分位数法による信頼区間の水準(L)

ハイアス修正済信頼区間(B)      90      ハイアス修正済信頼区間の水準(E)

ブートストラップ ADF(A)       モンテカルロパラメトリックブートストラップ(O)

ブートストラップ ML(M)       各ブートストラップ標本の詳細な報告(D)

ブートストラップ GLS(G)       Bollen-Stineブートストラップ(I)

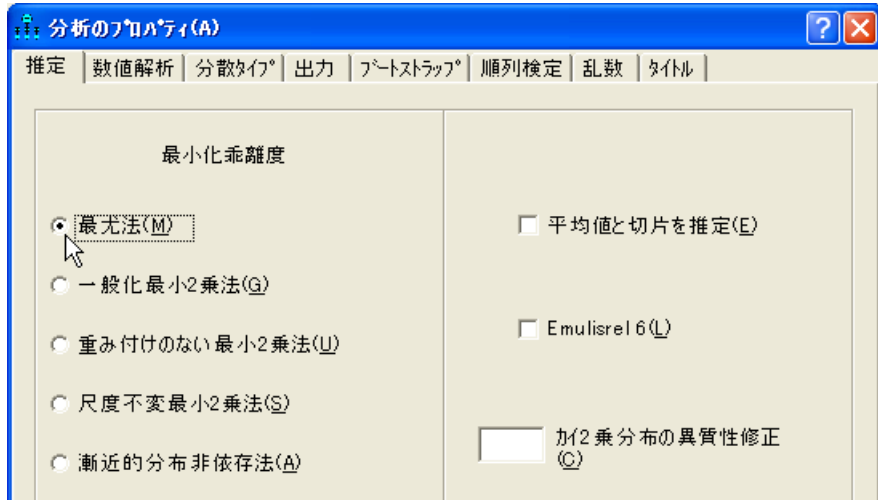
ブートストラップ SLS(S)      1      ブート因子(E)

**ブートストラップ ULS(U)**

[ブートストラップ ADF]、[ブートストラップ ML]、[ブートストラップ GLS]、[ブートストラップ SLS] および [ブートストラップ ULS] の選択によって、元の標本での標本積率と各ブートストラップ標本からのモデル積率との乖離度を測定する際に、それぞれ  $C_{ADF}$ 、 $C_{ML}$ 、 $C_{GLS}$ 、および  $C_{ULS}$  を使用することが設定されます。

集計のため、分析 ([分析]→[推定値を計算]) の実行中に、Amos は ADF 乖離度を使用している 1,000 のブートストラップ標本のそれぞれにモデルを適合します。各ブートストラップ標本について、モデル積率の母集団積率に対する近似値は、 $C_{ADF}$ 、 $C_{ML}$ 、 $C_{GLS}$ 、および  $C_{ULS}$  という異なる 4 つの方法によって測定されます。

- ▶ [最尤法] 乖離度を選択して、分析を繰り返します。



- ▶ [一般化最小2乗法] 乖離度を選択して、さらに分析を繰り返します。
- ▶ [重み付けのない最小2乗法] 乖離度を選択して、最後の分析を実行します。

この例についての Amos Graphics 入力ファイルは、Ex21-adf.amw、Ex21-ml.amw、Ex21-gls.amw、および Ex21-uls.amw の 4 ファイルです。

## テキスト出力

4 つの分析のうちの最初の分析 (Ex21-adf.amw にあります) では、ADF を使用した推定によって、次のヒストグラム出力が得られます。このヒストグラムを表示する方法は、次のとおりです。



- ▶ [Amos出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で、[ブートストラップ分布] → [ADF 乖離度 (モデル対母集団)] の順にクリックします。

ADF乖離度 (モデル対母集団) (Default model)	
	-----
7.359	*
10.817	*****
14.274	*****
17.732	*****
21.189	*****
24.647	*****
28.104	*****
N = 1000	****
平均 = 20.601	**
標準誤差 = .218	**
41.934	*
45.392	*
48.850	*
52.307	*
55.765	*
	-----

この出力部分には、1,000 個のブートストラップ 標本における母集団の乖離度の分布  $C_{ADF}(\hat{\alpha}_b, \mathbf{a})$  が表示されています。ここで、 $\hat{\alpha}_b$  には  $C_{ADF}(\hat{\alpha}_b, \mathbf{a}_b)$  の最小化によって得られたモデル積率、つまり、標本の乖離度が含まれています。1,000 個のブートストラップ 標本における  $C_{ADF}(\hat{\alpha}_b, \mathbf{a})$  の平均値は 20.601 で、標準誤差は 0.218 です。


次のヒストグラムは、 $C_{ML}(\hat{\alpha}_b, \mathbf{a})$  の分布を表しています。このヒストグラムを表示する方法は、次のとおりです。

- ▶ [Amos出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で、[ブートストラップ分布] → [ML 乖離度 (モデル対母集団)] の順にクリックします。

ML乖離度 (モデル対母集団) (Default model)	
	-----
11.272	****
22.691	*****
34.110	*****
45.530	*****
56.949	*****
68.368	***
79.787	**
N = 1000	*
平均 = 36.860	*
標準誤差 = .571	*
125.464	*
136.884	
148.303	
159.722	
171.142	*
	-----


次のヒストグラムは、 $C_{GLS}(\hat{\alpha}_b, \mathbf{a})$  の分布を表しています。このヒストグラムを表示する方法は、次のとおりです。

- ▶ [Amos出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で、[ブートストラップ分布] → [GLS 乖離度 (モデル対母集団)] の順にクリックします。



次のヒストグラムは、 $G_{\text{ULS}}(\hat{\alpha}_b, \mathbf{a})$  の分布を表しています。このヒストグラムを表示する方法は、次のとおりです。

- ▶ [Amos出力] ウィンドウの左上隅のウィンドウ枠にあるツリー図で、[ブートストラップ分布] → [ULS 乖離度 (モデル対母集団)] の順にクリックします。



次のテーブルには、1,000 個のブートストラップ 標本における  $\mathcal{C}(\hat{\alpha}_{bs}, \mathbf{a})$  の平均値が表示されています。かっこ内は標準誤差です。先ほど示した 4 つの分布は、テーブルの最初の行に集計されています。残る 3 行には、 $C_{ML}$ 、 $C_{GLS}$ 、および  $C_{ULS}$  をそれぞれ最小化した推定結果が表示されています。

		評価に使用した、母集団の乖離度： $\mathcal{C}(\hat{\alpha}_{bs}, \mathbf{a}_b)$			
		$C_{ADF}$	$C_{ML}$	$C_{GLS}$	$C_{ULS}$
推定に使用した、標本の乖離度 $\mathcal{C}(\hat{\alpha}_{bs}, \mathbf{a}_b)$	$C_{ADF}$	20.60 (0.22)	36.86 (0.57)	21.83 (0.26)	43686 (1012)
	$C_{ML}$	19.19 (0.20)	26.57 (0.30)	18.96 (0.22)	34760 (830)
	$C_{GLS}$	19.45 (0.20)	31.45 (0.40)	19.03 (0.21)	37021 (830)
	$C_{ULS}$	24.89 (0.35)	31.78 (0.43)	24.16 (0.33)	35343 (793)

「 $C_{ADF}$ 」というラベルが付いた 1 列目には、母集団の乖離度  $C_{ADF}$  に応じた 4 つの推定方法の相対的なパフォーマンスが表示されています。 $C_{ADF}$  列では、19.19 が乖離度の平均値として最小なので、 $C_{ADF}$  基準における最適な推定方法は  $C_{ML}$  であると言えます。同様に、テーブルの  $C_{ML}$  列を調べると、 $C_{ML}$  基準においても、 $C_{ML}$  が最適な推定方法であることがわかります。

テーブルの 4 つの列は 4 つの推定方法の正確な順序とは一致しませんが、すべてのケースにおいて、乖離度の平均値が最も小さいのは  $ML$  です。 $ML$  による推定と  $GLS$  による推定との差がわずかなケースもあります。当然のことながら、使用した母集団の乖離度すべてにおいて、 $ULS$  による推定はうまくいきませんでした。さらに興味深いのは、 $ADF$  による推定がうまくいかなかったことです。 $ADF$  による推定はモデル、母集団、標本サイズという組み合わせには適さないと言えます。

## VB.NET でのモデル作成

この例についての Visual Basic プログラムは、Ex21-adf.vb、Ex21-gls.vb、Ex21-ml.vb、および Ex21-uls.vb ファイルにあります。



# 探索的モデル特定化

## 概要

この例では、2種類の探索的モデル特定化を紹介します。一方は概して確認的(オプション矢印が少数)で、他方は概して探索的(オプション矢印が多数)です。

## データについて

この例では、例7で紹介した、FelsonとBohrnstedt(1979)による女子のデータを使用します。

## モデルについて

この探索的モデル特定化での初期モデルには、FelsonとBohrnstedt(1979)の研究でのモデルを使用しています。図22-1を参照してください。

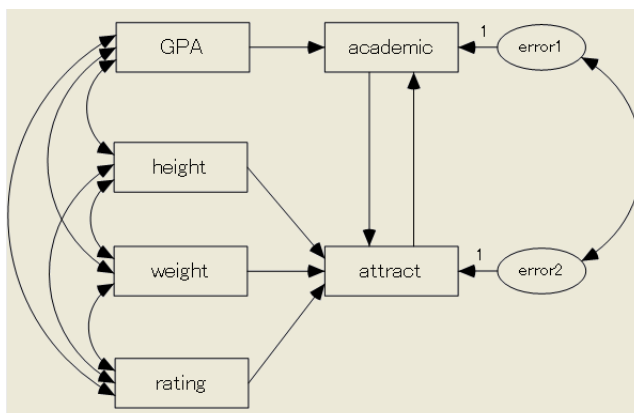


図 22-1 Felson と Bohrnstedt の研究における女子のモデル

## オプション矢印が少数の探索的モデル特定化

Felson と Bohrnstedt が主に関心を向けていたのは、academic ← attract と、attract ← academic という 2 つの一方向矢印でした。ここでの論点は、この 2 つの一方向矢印のうち、必要とされているのは片方だけなのか両方なのか、あるいはどちらも必要とされていないのかということでした。この理由から、探索的モデル特定化の実行中は、両方の矢印をオプションにします。また、誤差 1 と誤差 2 を結ぶ双方向矢印によって、一方向矢印で表示されている効果の解釈が複雑になり、これはモデルにとって望ましくない機能です。このため、この双方向矢印も省略可能にします。探索的モデル特定化は、この 3 つのオプション矢印のうち必要な矢印がある場合に、どれがモデルにとって必要なかを決定する手助けとなります。

この探索的モデル特定化では、ほとんどの矢印がモデルに必要で、オプションは 3 つだけなので、概して確認的と言えます。

### モデルの特定化


- ▶ %examples%\Ex22a.amw を開きます。

描画領域にパス図が開かれます。最初は、図 22-1 に見られるオプション矢印は表示されていません。

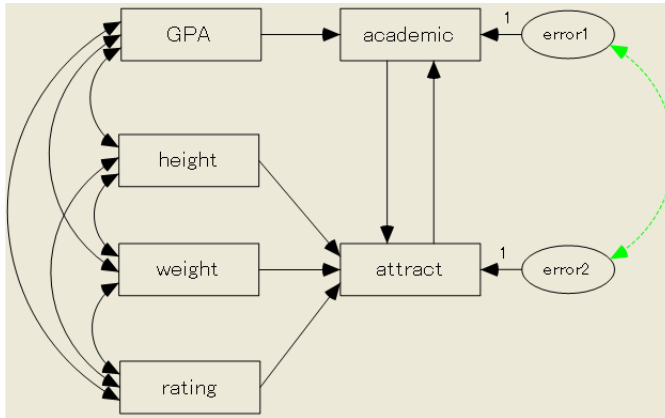
- ▶ メニューから [分析] → [探索的モデル特定化] の順に選択します。



[探索的モデル特定化] ウィンドウが表示されます。最初は、ツールバーだけが表示されています。

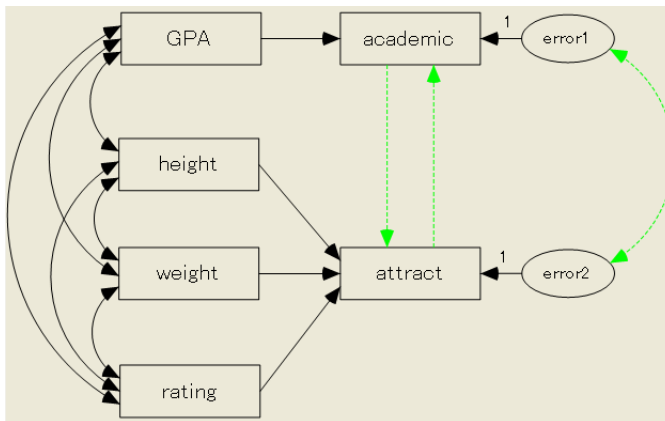


- ▶ [探索的モデル特定化] ツールバーの  をクリックしてから、誤差 1 と誤差 2 を結ぶ双方向矢印をクリックします。矢印の色が、オプションであることを表す色に変わります。

ヒント：次の図のように、オプション矢印の色を変えたり破線にしたりするには、メニューから [表示] → [インターフェイスのプロパティ] の順に選択してから、[アクセス] タブをクリックして [色の選択] チェックボックスを選択します。




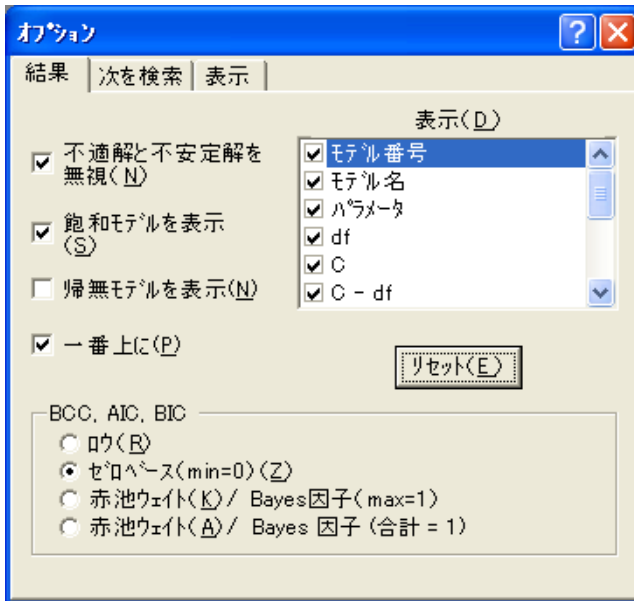
- ▶ 矢印を必須に戻すには、[探索的モデル特定化] ツールバーの  をクリックしてから目的の矢印をクリックします。ポインタを離すと、必須の矢印として矢印が再表示されます。
- ▶ 再度  をクリックしてから、パス図が次のようになるまで、図中の矢印をクリックします。



後で探索分析を実行する際に、プログラムはこの3つの色付き矢印をオプションとして扱い、これらの矢印の可能なサブグループをすべて使用してモデルを適合しようとしています。

## プログラムのオプションの選択

- ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
- ▶ [オプション] ダイアログ ボックスで、[結果] タブをクリックします。
- ▶ [リセット] をクリックして、設定したオプションがこの例と同じであることを確認します。

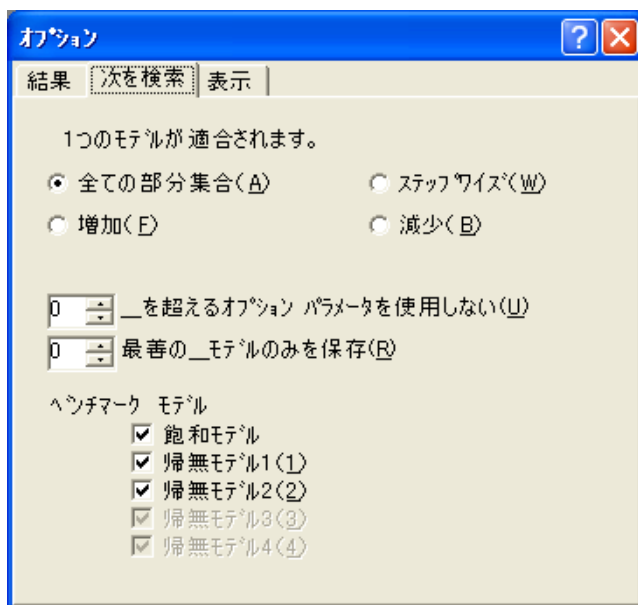


- ▶ 次に、[次を検索] タブをクリックします。先頭のテキストには、この探索分析が 8 つ (つまり  $2^3$ ) のモデルに適合することが表示されています。
- ▶ [最善の \_\_\_ モデルのみを保存] ボックスで、値を 10 から 0 に変更します。

デフォルト値 10 で探索的モデル特定化を実行すると、最大 10 の一方向矢印モデル、最大 10 の双方向矢印モデル、などが報告されます。値を 0 に設定すると、報告対象モデル数に対する制限がなくなります。




報告対象モデル数を制限することで、探索的モデル特定化が大幅に速くなります。ただし、この例での探索的モデル特定化に出現するモデルは、合計 8 つしかありません。また、[最善の \_\_ モデルのみを保存] に 0 以外の値を指定することで、後述するように、プログラムが赤池ウェイトや Bayes 因子を正規化して、すべてのモデルの合計を 1 にするということができなくなるという、望ましくない効果が生じることがあります。



- ▶ [オプション] ダイアログ ボックスを閉じます。

## 探索的モデル特定化の実行

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。

このプログラムでは、オプション矢印の各サブグループを使用して、モデルを 8 回適合させます。完了すると、[探索的モデル特定化] ウィンドウが拡張して、結果が表示されます。

次のテーブルには、この 8 つのモデルと飽和モデルについての適合度が集計されています。

モデル	パラメータ	df	C	C - df	BCC 0	BIC 0	C / df	p	注釈
1	16	5	67.342	62.342	62.201	58.929	13.468	0.000	
2	17	4	3.071	<b>-0.929</b>	<b>0.000</b>	<b>0.000</b>	<b>0.768</b>	<b>0.546</b>	
3	17	4	19.215	15.215	16.144	16.144	4.804	0.001	
4	17	4	27.911	23.911	24.840	24.840	6.978	0.000	
5	18	3	2.763	-0.237	1.761	5.034	0.921	0.430	
6	18	3	2.895	-0.105	1.894	5.167	0.965	0.408	
7	18	3	19.155	16.155	18.154	21.427	6.385	0.000	
8	19	2	2.761	0.761	3.830	10.375	1.381	0.251	
飽和モデル	21	0	0.000	0.000	5.208	18.299			

「モデル」列には、探索的モデル特定化で適合されたモデルに対する、1 から 8 までの任意の索引番号が表示されています。「飽和モデル」は、飽和モデルを表しています。最初の行を見ると、モデル 1 には 19 のパラメータと 2 の自由度があります。乖離度関数 (このケースでは尤度比カイ 2 乗統計量) は 2.761 です。Amos 出力の別の箇所では、乖離度関数における最小値を CMIN と呼びます。ここでは略して「C」というラベルが付けられています。テーブル内の列についての説明を表示するには、列の上で右クリックし、ポップアップメニューから [用語のヘルプ] を選択します。

「モデル」列と「注釈」列を除き、各列での最良の値には下線が引かれていることに注意してください。

このテーブルでは、よく知られている適合度 (CFI や RMSEA など) が多数省かれています。表示されている適合度の選択理由については、付録 E を参照してください。

## 生成されたモデルの表示

- ▶ テーブル内の任意の行をダブルクリックして (「飽和モデル」行を除きます)、描画領域にある対応するパス図を表示することができます。例として、モデル 7 の行をダブルクリックしてパス図を表示してみましょう。

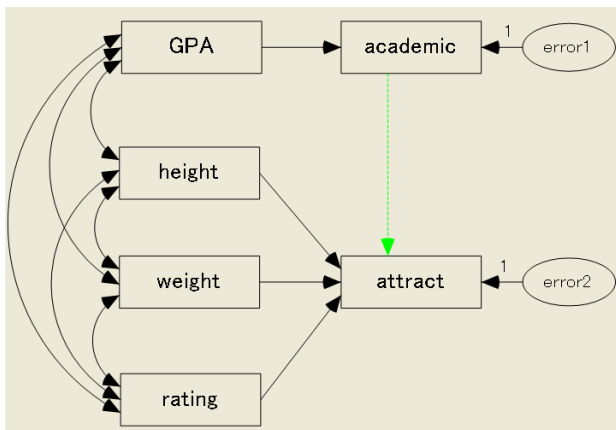



図 22-2 モデル 7 のパス図

## モデルのパラメータ推定値の表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。
- ▶ [探索的モデル特定化] ウィンドウで、モデル7の行をダブルクリックします。  
描画領域にモデル7のパラメータ推定値が表示されます。

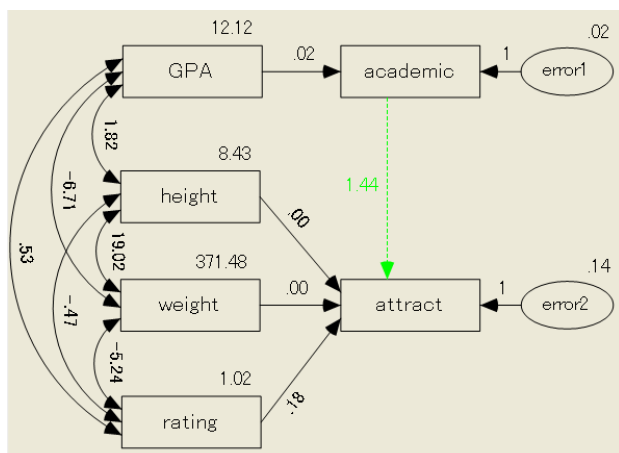


図 22-3 モデル7のパラメータ推定値

## BCC を使用したモデル比較

- ▶ [探索的モデル特定化] ウィンドウで、「BCC<sub>0</sub>」という見出しのついた列をクリックします。

「BCC」を基準にテーブルが並べ替えられ、BCCにおける最善モデル (BCC の値が最も小さいモデル) がリストの先頭に配置されます。


モデル	パラメータ	df	C	C - df	<b>BCC 0</b>	BIC 0	C / df	p	注釈
2	17	4	3.071	<b>-0.929</b>	<b>0.000</b>	<b>0.000</b>	<b>0.768</b>	<b>0.546</b>	
5	18	3	2.763	-0.237	1.761	5.034	0.921	0.430	
6	18	3	2.895	-0.105	1.894	5.167	0.965	0.408	
8	19	2	2.761	0.761	3.830	10.375	1.381	0.251	
飽和モデル	21	0	0.000	0.000	5.208	18.299			
3	17	4	19.215	15.215	16.144	16.144	4.804	0.001	
7	18	3	19.155	16.155	18.154	21.427	6.385	0.000	
4	17	4	27.911	23.911	24.840	24.840	6.978	0.000	
1	16	5	67.342	62.342	62.201	58.929	13.468	0.000	

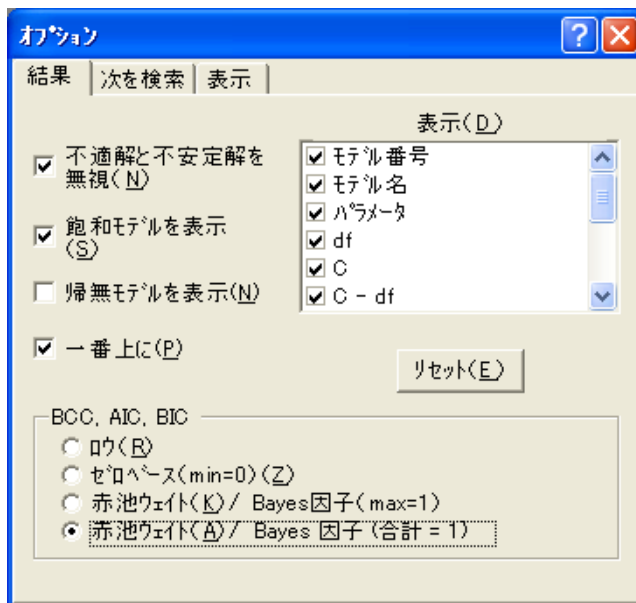
Burnham と Anderson(1998) による提言に基づき、BCC の最小値が 0 になるよう、すべての BCC 値に定数が挿入されています。BCC<sub>0</sub> の下付き文字 0 は、この再調整が行われたことを表しています。AIC (上図には表示されていません) と BIC も、同様に再調整されています。おおまかなガイドラインとして、Burnham と Anderson 1998, p. 128) は、AIC<sub>0</sub> について、次のような解釈を提言しています。BCC<sub>0</sub> についても同様に解釈できます。

AIC <sub>0</sub> または BCC <sub>0</sub>	Burnham と Anderson による解釈
0-2	このモデルを、可能な標本母集団における実際の K-L 最善モデルから除外すべき確実な証拠が何もありません (Burnham と Anderson による K-L の最善 についての定義を参照してください)。
2-4	このモデルが K-L 最善モデルではないとする証拠は弱いです。
4-7	このモデルが K-L 最善モデルではないとする確実な証拠があります。
7-10	このモデルが K-L 最善モデルではないとする強力な証拠があります。
>10	このモデルが K-L 最善モデルではないことは明らかです。

Burnham と Anderson によるガイドラインではモデル 7 が最善モデルと推定されていますが、モデル 6 とモデル 8 も除外すべきではありません。

## 赤池ウェイトの表示

- ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
- ▶ [オプション] ダイアログ ボックスで、[結果] タブをクリックします。
- ▶ [BCC, AIC, BIC] で、[赤池ウェイト / Bayes 因子 (合計 = 1)] を選択します。



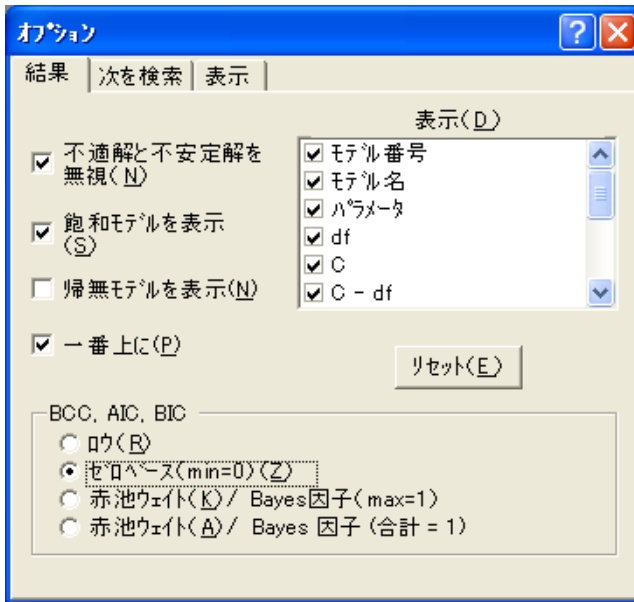
適合度のテーブルでは、「 $BCC_0$ 」というラベルが付いていた列が「 $BCC_p$ 」に替わり、値に赤池ウェイトが挿入されました。(付録 G を参照してください)。

モデル	パラメータ	df	C	C - df	$BCC_p$	BIC p	C / df	p	注釈
7	17	4	3.071	<b>-0.929</b>	<b>0.494</b>	<b>0.860</b>	<b>0.768</b>	<b>0.546</b>	
6	18	3	2.763	-0.237	0.205	0.069	0.921	0.430	
8	18	3	2.895	-0.105	0.192	0.065	0.965	0.408	
1	19	2	2.761	0.761	0.073	0.005	1.381	0.251	
飽和モデル	21	0	0.000	0.000	0.037	0.000			
3	17	4	19.215	15.215	0.000	0.000	4.804	0.001	
2	18	3	19.155	16.155	0.000	0.000	6.385	0.000	
5	17	4	27.911	23.911	0.000	0.000	6.978	0.000	
4	16	5	67.342	62.342	0.000	0.000	13.468	0.000	

赤池ウェイト (赤池, 1978; Bozdogan, 1987; Burnham および Anderson, 1998) は、データを与えられたモデルの尤度として解釈されてきました。この解釈によると、推定された K-L 最善モデル (モデル 7) の可能性は、モデル 6 の約 2.4 倍 ( $0.494 / 0.205 = 2.41$ ) に過ぎません。Bozdogan(1987) は、候補モデルに事前確率を割り当てることができれば、この事前確率を (モデルの尤度として解釈されている) 赤池ウェイトとともに使用して、事後確率を得ることができると指摘しています。同じ値の事前確率とともに、赤池ウェイト自身が事後確率となります。これによって、モデル 7 は確率 0.494 の K-L 最善モデル、モデル 6 は確率 0.205 の K-L 最善モデル、などと表すことができます。可能性が高いモデルは、モデル 7、6、8、および 1 の 4 つです。各モデルの確率を合計 ( $0.494 + 0.205 + 0.192 + 0.073 = 0.96$ ) すると、この 4 つのモデルのうちいずれかが K-L 最善モデルになる確率は 96% であると言えます (Burnham および Anderson, 1998, pp. 127-129)。 $BCC_p$  の下付き文字 p は、 $BCC_p$  を、ある状況下での確率と解釈できることを表しています。

## BIC を使用したモデル比較

- ▶ [オプション] ダイアログ ボックスの[結果] プロパティ ページで、[BCC, AIC, BIC] から [ゼロベース (min = 0)] を選択します。



- ▶ [探索的モデル特定化] ウィンドウで、「BIC<sub>0</sub>」という見出しのついた列をクリックします。

「BIC」を基準にテーブルが並べ替えられ、BIC における最善モデル (BIC の値が最も小さいモデル) がリストの先頭に配置されます。

モデル	パラメータ	df	C	C - df	BCC 0	<b>BIC 0</b>	C / df	p	注釈
2	17	4	3.071	<b>-0.929</b>	<b>0.000</b>	<b>0.000</b>	<b>0.768</b>	<b>0.546</b>	
5	18	3	2.763	-0.237	1.761	5.034	0.921	0.430	
6	18	3	2.895	-0.105	1.894	5.167	0.965	0.408	
8	19	2	2.761	0.761	3.830	10.375	1.381	0.251	
3	17	4	19.215	15.215	16.144	16.144	4.804	0.001	
飽和モデル	21	0	0.000	0.000	5.208	18.299			
7	18	3	19.155	16.155	18.154	21.427	6.385	0.000	
4	17	4	27.911	23.911	24.840	24.840	6.978	0.000	
1	16	5	67.342	62.342	62.201	58.929	13.468	0.000	

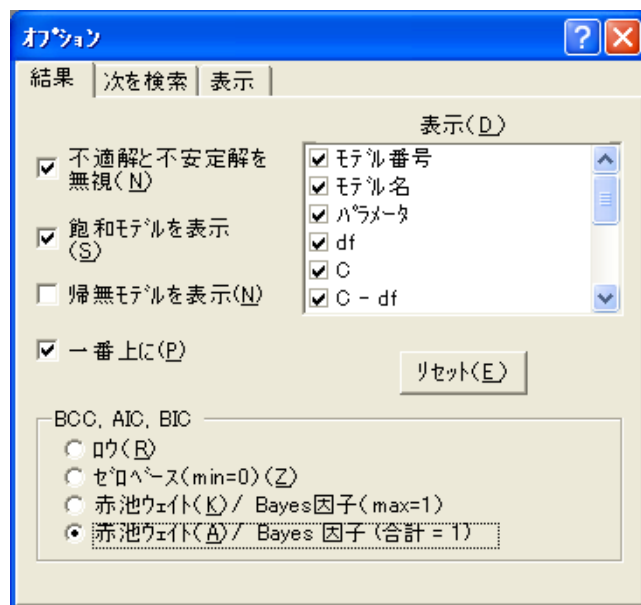
BIC の値が最も小さいモデル 7 が、事後確率の近似値 (モデル間で同じ値の事前確率を使用したうえで、個々のモデルのパラメータにおける特定の事前分布を使用) が最も高いモデルです。Raftery(1995) は、競合モデルに対するモデル 7 についての証拠の判断にあたり、 $BIC_0$  値の解釈を次のように提言しています。

$BIC_0$	Raftery(1995) による解釈
0-2	弱い
2-6	陽性
6-10	強い
>10	非常に強い

このガイドラインによると、モデル 6 と 8 では「陽性」の証拠が得られ、その他のモデルについてはモデル 7 に比べて「非常に強い」証拠が得られます。

## Bayes 因子を使用したモデル比較

- ▶ [オプション]ダイアログボックスの[結果]プロパティで、[BCC, AIC, BIC]から[赤池ウェイト / Bayes 因子 (合計 = 1)]を選択します。



適合度のテーブルでは、「 $BIC_0$ 」というラベルが付いていた列が「 $BIC_p$ 」に替わり、合計が 1 となるよう調整された Bayes 因子が値に挿入されました。

モデル	パラメータ	df	C	C - df	BCC p	<b>BIC p</b>	C / df	p	注釈
7	17	4	3.071	<b>-0.929</b>	<b>0.494</b>	<b>0.860</b>	<b>0.768</b>	<b>0.546</b>	
6	18	3	2.763	-0.237	0.205	0.069	0.921	0.430	
8	18	3	2.895	-0.105	0.192	0.065	0.965	0.408	
1	19	2	2.761	0.761	0.073	0.005	1.381	0.251	
3	17	4	19.215	15.215	0.000	0.000	4.804	0.001	
飽和モデル	21	0	0.000	0.000	0.037	0.000			
2	18	3	19.155	16.155	0.000	0.000	6.385	0.000	
5	17	4	27.911	23.911	0.000	0.000	6.978	0.000	
4	16	5	67.342	62.342	0.000	0.000	13.468	0.000	

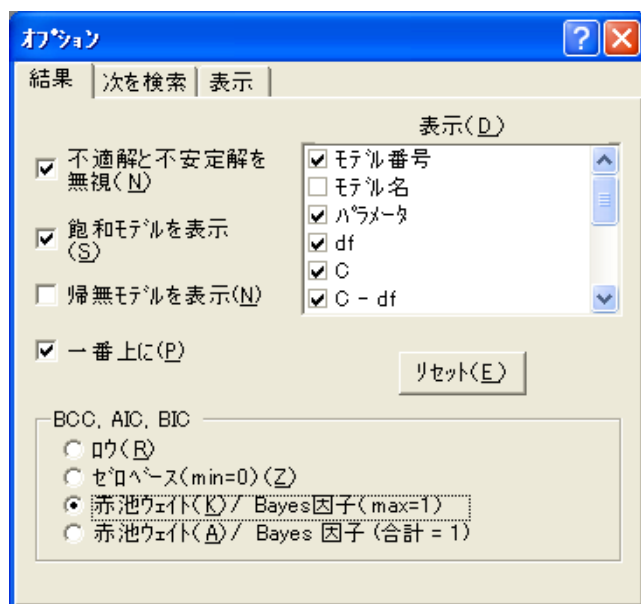
モデル間で同じ値の事前確率を使用したうえで、個々のモデルのパラメータにおける特定の事前分布を使用 (Raftery, 1995; Schwarz, 1978) した  $BIC_p$  値は、事後確率の近似値です。モデル 7 は、確率 0.860 の正しいモデルです。モデル 7、6、8 のいずれかが正しいモデルであるということは、99% ( $0.860 + 0.069 + 0.065 = 0.99$ ) 確信できます。下付き文字 p は、 $BIC_p$  値を確率と解釈できることを表しています。

Madigan と Raftery(1994) は、モデルの平均化(ここでの説明は省きます)には Occam のウィンドウにおけるモデルのみが使用されるということを提言しています。対称的な Occam のウィンドウは、最も可能性が高いモデルに比べて可能性がかなり低い (Madigan と Raftery は、およそ 20 分の 1 の可能性という例を挙げています) モデルを除外することで得られる、モデルのサブグループです。この例では、対称的な Occam のウィンドウには、モデル 7、6、8 が含まれています。これらのモデルは確率 ( $BIC_p$  値) が  $0.860/20 = 0.043$  よりも高いためです。



## Bayes 因子の再調整

- ▶ [オプション]ダイアログボックスの[結果]プロパティページで、[BCC, AIC, BIC] から [赤池ウェイト / Bayes 因子 (max = 1)] を選択します。



適合度のテーブルでは、「 $BIC_p$ 」というラベルが付いていた列が「 $BIC_L$ 」に替わり、最大値が 1 となるよう調整された Bayes 因子が値に含まれました。これにより、Occam のウィンドウを抽出しやすくなります。これは、 $BIC_L$  値が  $1/20 = 0.05$  よりも大きいモデルで構成されています。つまりはモデル 7、6、8 のことです。 $BIC_L$  の下付き文字 L は、 $BCC_L$  と似た統計量を尤度と解釈できるということを表しています。

モデル	パラメータ	df	C	C - df	$BCC_L$	$BIC_L$	C / df	p	注釈
2	17	4	3.071	<b>-0.929</b>	<b>1.000</b>	<b>1.000</b>	<b>0.768</b>	<b>0.546</b>	
5	18	3	2.763	-0.237	0.414	0.081	0.921	0.430	
6	18	3	2.895	-0.105	0.388	0.076	0.965	0.408	
8	19	2	2.761	0.761	0.147	0.006	1.381	0.251	
3	17	4	19.215	15.215	0.000	0.000	4.804	0.001	
飽和モデル	21	0	0.000	0.000	0.074	0.000			
7	18	3	19.155	16.155	0.000	0.000	6.385	0.000	
4	17	4	27.911	23.911	0.000	0.000	6.978	0.000	
1	16	5	67.342	62.342	0.000	0.000	13.468	0.000	

## モデルの短いリストについての調査

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。これにより、モデルについての短いリストが表示されます。

次の図のとおり、この短いリストには、各パラメータ数に対する最善モデルが表示されています。ここでは、パラメータ数 16 個での最善モデル、パラメータ数 17 個での最善モデル、などが表示されています。パラメータ数の固定されたモデルに対してこの比較が制限された場合、すべての基準が最善モデルについて一致するという点に注意してください。選択する基準に関係なく、このリストには全体における最善モデルが掲載されているはずですが。

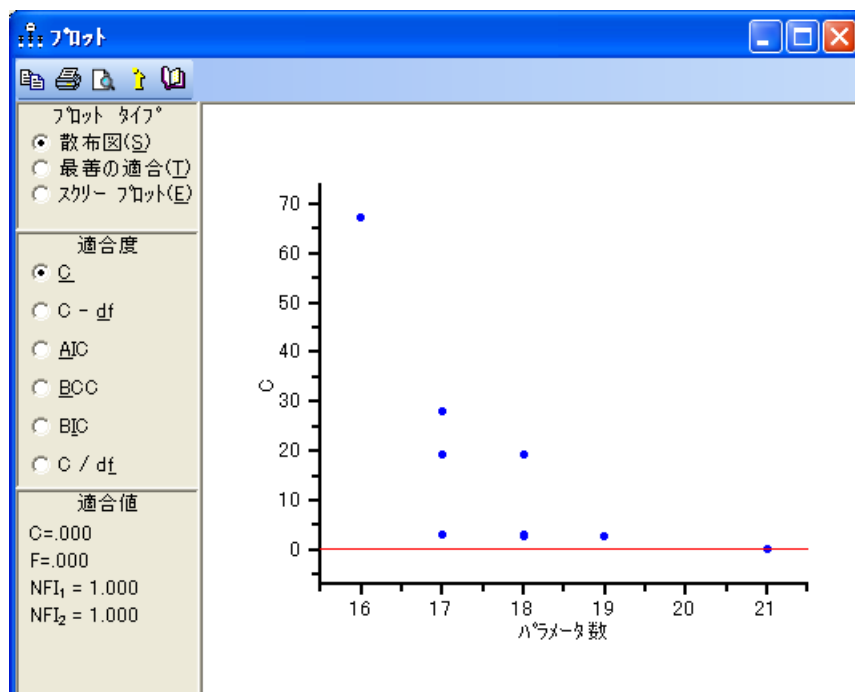
モデル	パラメータ	df	C	C - df	BCC L	BIC L	C / df	p	注釈
1	16	5	67.342	62.342	0.000	0.000	13.468	0.000	
2	17	4	3.071	<b>-0.929</b>	<b>1.000</b>	<b>1.000</b>	<b>0.768</b>	<b>0.546</b>	
5	18	3	2.763	-0.237	0.414	0.081	0.921	0.430	
8	19	2	2.761	0.761	0.147	0.006	1.381	0.251	
飽和モデル	21	0	0.000	0.000	0.074	0.000			

図 22-4 各パラメータ数に対する最善モデル

このテーブルは、パラメータ数 17 個での最善モデルが、パラメータ数 16 個での最善モデルよりも大幅に適合度が高いことを表しています。パラメータが 17 個を超すと、さらにパラメータを追加しても適合度の向上は比較的ゆるやかです。費用対効果の分析では、16 個のパラメータを 17 個に増やす場合には比較的大きな対費用効果が得られますが、パラメータが 17 個を超すと対費用効果は比較的小さいです。このことから、発見的な収穫逨減点引数の使用によって、パラメータ数 17 個での最善モデルが採用できることがわかります。パラメータ数の決定におけるこの手法については、この例の後半で詳しく紹介します (312 ページの「C における最善の適合グラフの表示」と 315 ページの「C のスクリーンプロットの表示」を参照してください)。

## 適合度と複雑度についての散布図の表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。[プロット] ウィンドウが開き、次のグラフが表示されます。

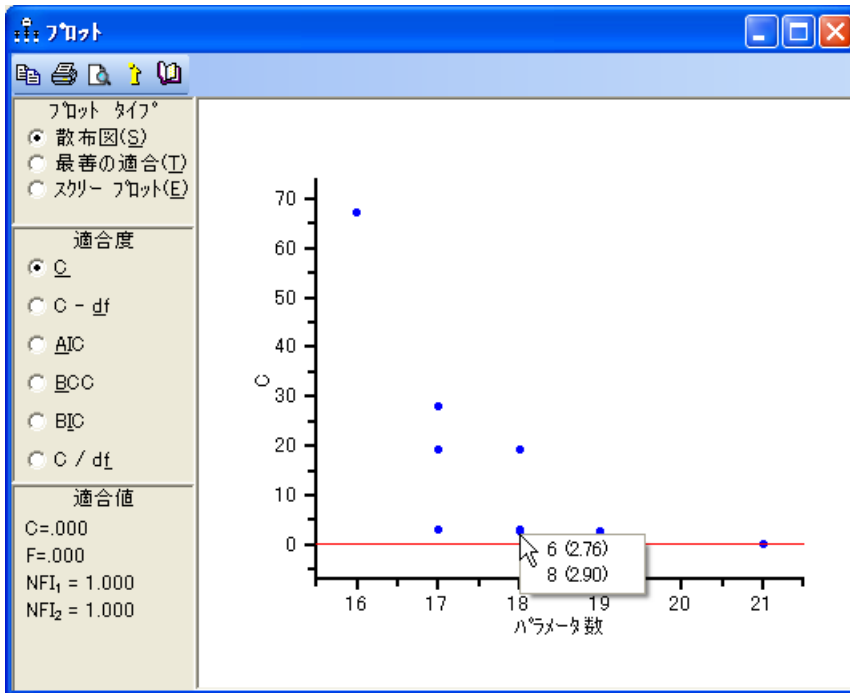


このグラフは、複雑度 (パラメータ数の測定による) に対する適合度 (C の測定による) についての散布図を表しています。各点はモデルを表します。グラフから、適合度と複雑度がトレードオフの関係にあることがわかります。この関係の特質について、Steiger は次のように述べています。

複雑度と適合度間の数値的に最良の妥協点はある程度個人の好みの問題であるため、最終分析において複雑さの測度と適合度の測度を単一の数値指標に組み合わせる 1 つの最良の方法を定義することは、ある意味では不可能であるとも言えます。モデルの選択は、嗜好についての 2 次元分析における昔からの課題です (Steiger, 1990, p. 179)。

- ▶ 散布図中の任意の点をクリックして、この点や、重なり合う点が表すモデルを示すメニューを表示します。
- ▶ ポップアップメニューからモデルを 1 つ選択し、このモデルが強調表示されているモデルの適合度統計量についてのテーブルと、同時に、描画領域でのモデルのパス図とを参照します。

次の図では、カーソルが、重なり合う 2 点を指しています。この 2 点は、モデル 6 (乖離度 2.76) とモデル 8 (乖離度 2.90) をそれぞれ表しています。

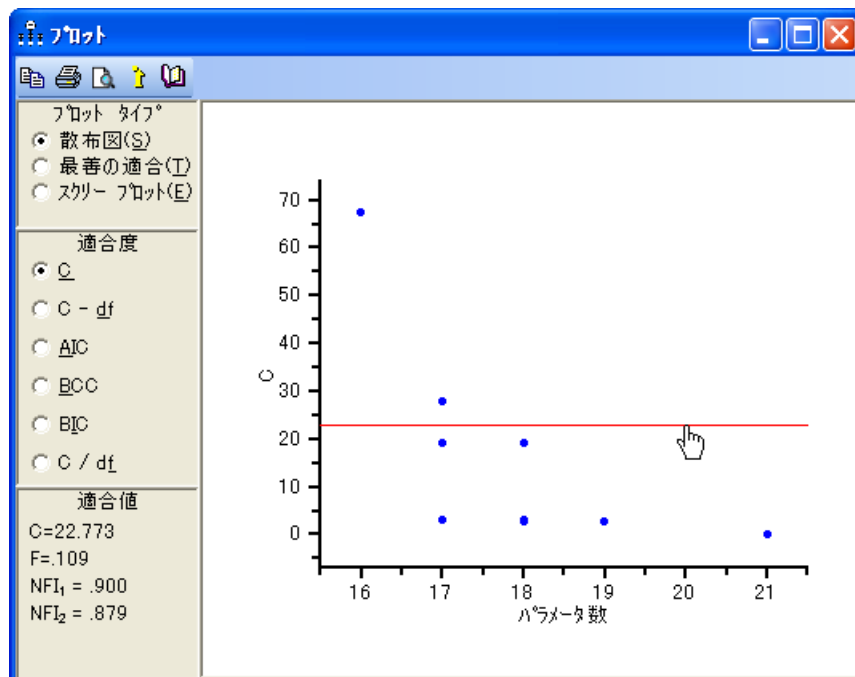


このグラフの水平線は、C の値が一定であることを表しています。最初は、この線の中心は、縦軸の 0 にあります。左下にある [適合度] パネルでは、水平線上の点が、 $C = 0$ 、および  $F = 0$  ( $F$  は、Amos 出力では FMIN と呼ばれます) と表されています。NFI<sub>1</sub> と NFI<sub>2</sub> はいずれも NFI の一種で、2 つの異なるベースライン モデルを使用します (付録 F を参照してください)。

最初は、NFI<sub>1</sub> と NFI<sub>2</sub> の両方が、水平線上の点での 1 と等しいです。水平線の位置は調整することができます。この線は、マウスでドラッグすれば移動できます。線を移動すると、左下のパネル内の適合度の値が、線の移動先の位置に変更されていることを確認できます。

## 定数の適合度を表す線の調整

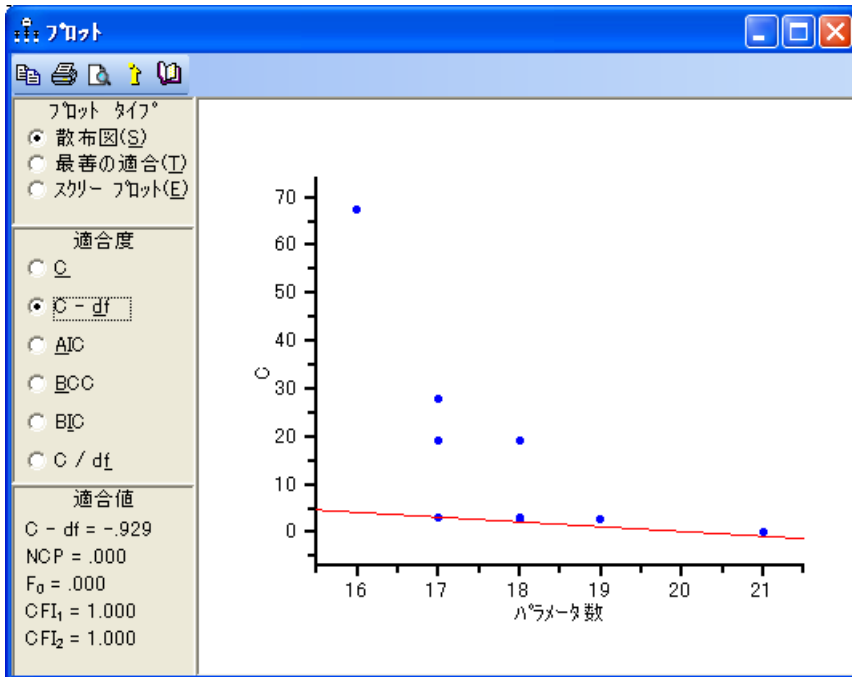
- ▶ 調整可能な線の上にマウスを移動します。ポインタが手の形になったら、 $NFI_1$  の値が 0.900 の位置まで線をドラッグします (左下のパネルで  $NFI_1$  の値を追いながら、調整可能な線を移動します)。



$NFI_1$  は、 $NFI$  統計量でよく使用される形式です。この形式におけるベースラインモデルでは、観測変数の平均値と分散に制約を設けずに、観測変数が互いに相関しないことが必要とされます。線の下にある点の値は  $NFI_1 > 0.900$  であり、線より上にある点については  $NFI_1 < 0.900$  です。このことから、調整可能な線によって、適用できるモデルが適用できないモデルと分けられていることがわかります。これは、一般に使用されている、Bentler と Bonett(1980) の発言を基にした規則によるものです。

## 定数 C - df を表す線の表示

- ▶ [プロット] ウィンドウで、[適合度] の [C - df] を選択します。次のように表示されます。



調整可能な線の位置の他には、散布図に変更はありません。ここでは、調整可能な線に、C - df の値が一定である点が含まれています。先の例ではこの線は水平でしたが、ここでは下方に傾いています。これは、C - df によって、モデルの適正の評価における複雑度に重みが付けられていることを示しています。最初は、調整可能な線は、C - df の値が最小の点を通ります。


- ▶ この点をクリックしてから、ポップアップメニューから [モデル 7] を選択します。

適合度を表すテーブルでモデル 7 が強調表示され、描画領域にはモデル 7 のパス図が表示されます。

左下隅のパネルには、C - df だけに依存する適合度の値が表示されます。したがって、これらの適合度値は、C - df 自身のように、調整可能な線に沿って一定の値をとります。CFI<sub>1</sub> と CFI<sub>2</sub> はいずれも CFI の一種で、2 つの異なるベースライン モデルを使用します (付録 G を参照してください)。最初は、CFI<sub>1</sub> と CFI<sub>2</sub> の両方が、調整可能な線上の点での 1 と等しいです。調整可能な線を移動すると、左下のパネル内の適合度の値が、線の移動先の位置に変更されます。

## 定数 C - df を表す線の調整

- ▶ 調整可能な線を、 $CFI_1$  の値が 0.950 の位置までドラッグします。



$CFI_1$  は、通常の CFI 統計量です。この CFI 統計量におけるベースライン モデルでは、平均値と分散に制約を設けずに、観測変数が互いに相関しないことが必要とされます。線の下にある点の値は  $CFI_1 > 0.950$  であり、線より上にある点については  $CFI_1 < 0.950$  です。このことから、Hu と Bentler(1999) の提言を基にした規則を基準に、調整可能な線によって、適用できるモデルが適用できないモデルと分けられていることがわかります。

## 定数の適合度を表すその他の線の表示

- ▶ [AIC]、[BCC]、[BIC] を順番にクリックします。

調整可能な線が次第に負に傾いていくことに注意してください。これには、5つの測定値(C、C - df、AIC、BCC、およびBIC)が、モデルの複雑度に対して重みを増加させているという事実が反映されています。この5つの測定値それぞれについて、調整可能な線の傾きは一定です。このことは、線をマウスでドラッグすると確認できます。一方、C / dfの調整可能な線における傾きは一定ではありません(マウスでドラッグすると線の傾きが変わります)。このため、C / dfの傾きは、C、C - df、AIC、BCC、およびBICのそれぞれの傾きと比較することができません。

## Cにおける最善の適合グラフの表示

- ▶ [プロット] ウィンドウで、[プロット タイプ]の[最善の適合]を選択します。
- ▶ [適合度] から [C] を選択します。

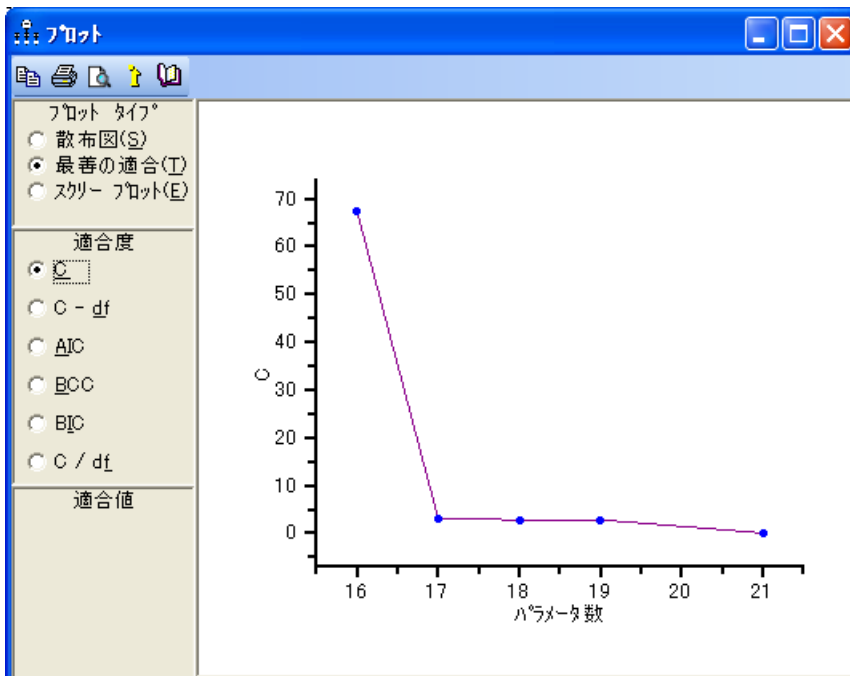



図 22-5 各パラメータ数に対する C の最小値



このグラフ上の各点は、C の値が、パラメータ数の等しい他のモデルの値以下であるモデルを表しています。グラフから、パラメータ数 16 個での最善モデルの値は  $C = 67.342$ 、グラフから、パラメータ数 17 個での最善モデルの値は  $C = 3.071$ 、などがわかります。[最善の適合] が選択されていると、適合度のテーブルに、パラメータ数ごとの最善モデルが表示されます。このテーブルは、先に 306 ページで紹介しています。

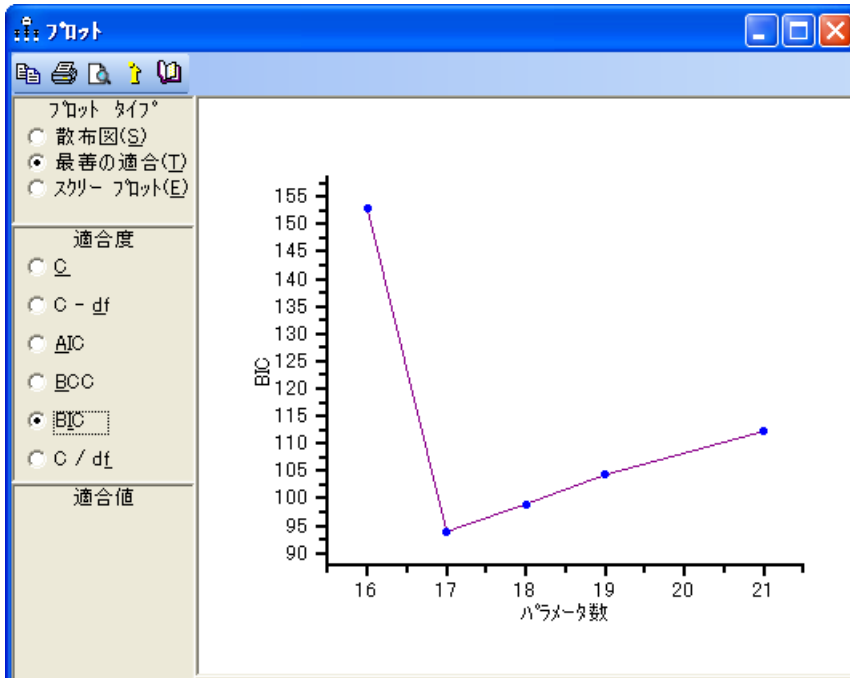
モデル	パラメータ	df	C	C - df	BCC L	BIC L	C / df	p	注釈
1	16	5	67.342	62.342	0.000	0.000	13.468	0.000	
2	17	4	3.071	<b>-0.929</b>	<b>1.000</b>	<b>1.000</b>	<b>0.768</b>	<b>0.546</b>	
5	18	3	2.763	-0.237	0.414	0.081	0.921	0.430	
8	19	2	2.761	0.761	0.147	0.006	1.381	0.251	
飽和モデル	21	0	0.000	0.000	0.074	0.000			

固定されたパラメータ数に対する最善モデルは、適合度の選択に依存しないことに注意してください。たとえばモデル 7 は、C - df だけでなく、C / df や他の各適合度を基準にしても、パラメータ数 17 個での最善モデルとなります。モデルの選択基準に使用した適合度の種類とは関係なく、最善モデルについてのこの短いリストには、全体的に判断された最善モデルが必ず含まれています。

 をクリックすれば、いつでもこの短いリストを表示することができます。最善の適合グラフから、発見的な見地においては、収穫逡減点である 17 を正しいパラメータ数として選択すべきであることがわかります。つまり、パラメータ数を 16 から 17 に増やすと  $C (67.342 - 3.071 = 64.271)$  の値は比較的大きく増加しますが、パラメータ数が 17 を超えると、その後の変化は比較的ゆるやかになります。

## その他の適合度に対する最善の適合グラフの表示

- ▶ [最善の適合] を選択している状態で、[適合度] から他の選択肢を選んでみましょう。選択肢には、C - df、AIC、BCC、BIC、および C / df があります。たとえば、[BIC] をクリックすると、次のように表示されます。



BIC は、C、C - df、AIC、BCC、および BIC のうち、複雑度に対して最も大きなペナルティを課す測定値です。複雑度に対するペナルティの高さは、パラメータ数 17 以降で急勾配を描く正の傾きに表れています。このグラフからは、BIC を基準にした場合、パラメータ数 17 個での最善モデルが他の候補モデルよりも優れているということが明らかです。

別の適合度をクリックすると、最善の適合グラフの縦軸や、点の設定内容が変更されることに注意してください。<sup>1</sup> ただし、各点の同一性は保持されます。たとえば、パラメータ数 16 個での最善モデルは常にモデル 4 であり、パラメータ数 17 個での最善モデルは常にモデル 7 である、ということです。これは、パラメータ数が固定されている場合、各適合度に対するモデルのランク順位は同じだからです。

<sup>1</sup> C / df グラフからは飽和モデルが欠損していますが、これは C / df で飽和モデルが定義されていないためです。

## Cのスクリープロットの表示

- ▶ [プロット] ウィンドウで、[プロット タイプ] の [スクリープロット] を選択します。
  - ▶ [適合度] から [C] を選択します。
- [プロット] ウィンドウに、次のグラフが表示されます。




図 22-6 Cのスクリープロット

このスクリープロットでは、横軸の座標が 17 の位置にある点の縦軸の座標は、64.271 です。これは、パラメータ数 17 個での最善モデル ( $C = 3.071$ ) は、パラメータ数 16 個での最善モデル ( $C = 67.342$ ) よりも適合度が高く、この差は  $67.342 - 3.071 = 64.271$  であることを示しています。同様に、18 個のパラメータでのグラフの高さからは、パラメータ数 17 個での最善モデルからパラメータ数 18 個での最善モデルに移動したことで得られる C の向上などがわかります。ただし、横軸の値が 21 を超える点については、別の説明が必要です。パラメータ数 21 個での最善モデルと比較できる、パラメータ数が 20 個のモデルはありません (実際、唯一のパラメータ数が 21 個のモデルは、飽和モデルです)。パラメータ数 21 個での最善モデル ( $C = 0$ ) は、これによりパラメータ数 19 個での最善モデル ( $C = 2.761$ ) と比較されます。21 個のパラメータの点の高さは、 $(2.761 - 0) / 2$  と計算されます。つまり、パラメータ数 19 個のモデルからパラメータ数 21 個のモデルに移動したことで得られる C の向上は、パラメータあたりの C の減少量として表されます。

312 ページ と 315 ページ の図はいずれも、17 個のパラメータを肯定する、発見的な収獲逓減点引数についての裏付けとして使用することができます。この 2 つの図には、次のような違いがあります。最善の適合グラフ (312 ページ) では、線が L 字になっている箇所、つまり、比較的急な傾斜から比較的ゆるやかな傾斜に変化する箇所が注目されます。ここで述べている問題により、この変化はパラメータ数 17 個で発生します。このことは、パラメータ数 17 個での最善モデルの裏付けとなります。スクリープロット (315 ページ) でも、L 字箇所が注目されますが、この例ではパラメータ数 18 個で発生します。このこともまた、パラメータ数 17 個での最善モデルの裏付けとなります。スクリープロットでは、パラメータ数  $k$  個で発生した L 字は、パラメータ数  $(k-1)$  個での最善モデルの裏付けとなります。


スクリープロットという名は、主成分分析でスクリープロットとして知られるグラフ (Cattell, 1966) と類似していることから付けられています。主成分分析で、スクリープロットは、成分を 1 つずつモデルに追加したことで得られるモデルの適合度の向上を表します。ここで紹介している SEM についてのスクリープロットは、モデルのパラメータ数を増分させることで得られるモデルの適合度の向上を表しています。この SEM についてのスクリープロットは、主成分分析についてのスクリープロットと完全に同じではありません。たとえば、主成分分析では、成分を 1 つずつ取り入れる際に、一連の入れ子モデルを得ることになります。SEM についてのスクリープロットでは、この限りではありません。パラメータ数 17 個での最善モデルやパラメータ数 18 個での最善モデルなどでは、入れ子になるかどうかは不明です (この例では入れ子になっています)。さらに、主成分分析ではスクリープロットは常に単調で、増加することはないのですが、SEM についてのスクリープロットのケースでは、入れ子モデルであったにもかかわらず、このことを確認できません。実際、この例でのスクリープロットは単調ではありません。

従来のスクリープロットとここでのスクリープロットには違いがあるのですが、新しいスクリープロットを従来のスクリープロットと同様の発見的方法で使用することが提唱されています。モデル選択における 2 段階の手法が勧められています。第 1 段階では、スクリープロットとモデルの短いリストのいずれかを調べることにより、パラメータ数が選択されます。第 2 段階では、第 1 段階で決定された数のパラメータを持つモデルの中から、最善モデルが選択されます。

## その他の適合度に対するスクリープロットの表示

- ▶ [プロットタイプ] で [スクリープロット] を選択している状態で、[適合度] から他の選択肢を選択します。選択肢には、C-df、AIC、BCC、および BIC があります (C/df はありません)。

たとえば、[BIC] を選択すると、次のように表示されます。



C - df、AIC、BCC、および BIC で、縦軸の単位と原点が C とは異なることを除き、すべて同じグラフです。このことから、スクリープロットの検定によって選択される最終モデルは、使用する適合度の種類とは独立していることがわかります (C / df を使用する場合を除く)。このことは、この例で先に紹介した (312 ページの「C における最善の適合グラフの表示」と 314 ページの「その他の適合度に対する最善の適合グラフの表示」を参照してください) 最善の適合プロットについてのスクリープロットにおける利点です。最良の適合プロットとスクリープロットには、ほぼ同じ情報が含まれます。ただし、最良の適合プロットの形が適合度の選択に依存する一方、スクリープロットではこれに依存しません (C / df を除く)。

標本積率を変更せずに標本サイズを変更しても、縦軸が再調整されるだけで何も影響しないという点で、最良の適合図とスクリープロットは標本サイズとは独立しています。

## オプション矢印が多数の探索的モデル特定化

先述の探索的因子分析は、オプション矢印が3つのみの、概して確認的なものでした。Felson と Bohrnstedt によるデータにおけるモデルを構築するにあたっては、これよりもはるかに探索的な手法をとることができます。測定された6つの変数についての唯一の仮説は次のとおりであるとします。

- academic は他の5つの変数に依存し、かつ、
- attract は他の5つの変数に依存する

図 22-7 のパス図では、この仮説が11のオプション矢印で表されています。この図では、どの変数が内生変数であるかが指定されているだけです。仮説をなす各観測変数モデルは、探索的モデル特定化に含まれています。観測変数と外生変数との共分散をオプションにすることもできますが、その場合、オプション矢印の数が11から17に増え、候補モデルは $2,048(2^{11})$ から $131,072(2^{17})$ にまで増えてしまいます。観測変数と外生変数との共分散をオプションにするとコストがかかるうえ、相関がない変数のペアを含むモデルを検索するのは、興味深い作業とは言いがたいです。

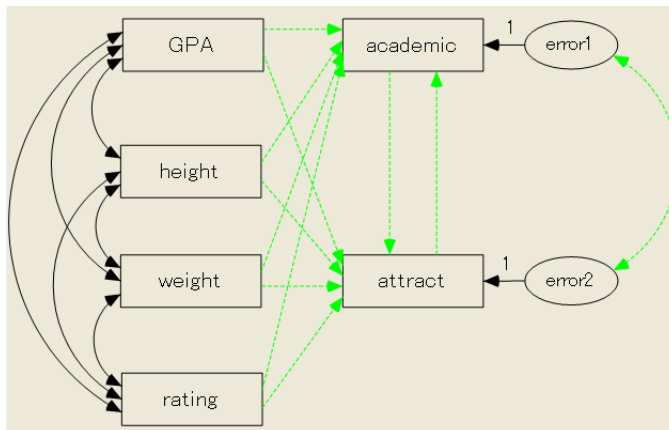
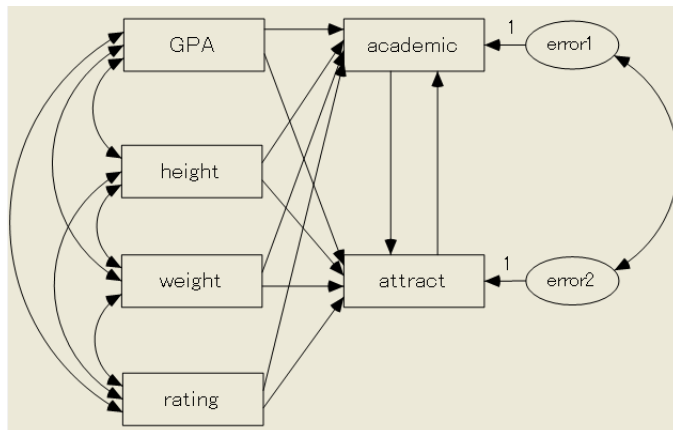


図 22-7 Felson と Bohrnstedt による女子のデータにおける、高度に探索的なモデル


## モデルの特定化

- ▶ %examples%\Ex22b.amw を開きます。

ヒント：直前に開いたファイルが Examples フォルダ内にある場合、描画領域の左側にある [ファイル] リストでファイルをダブルクリックすれば開くことができます。




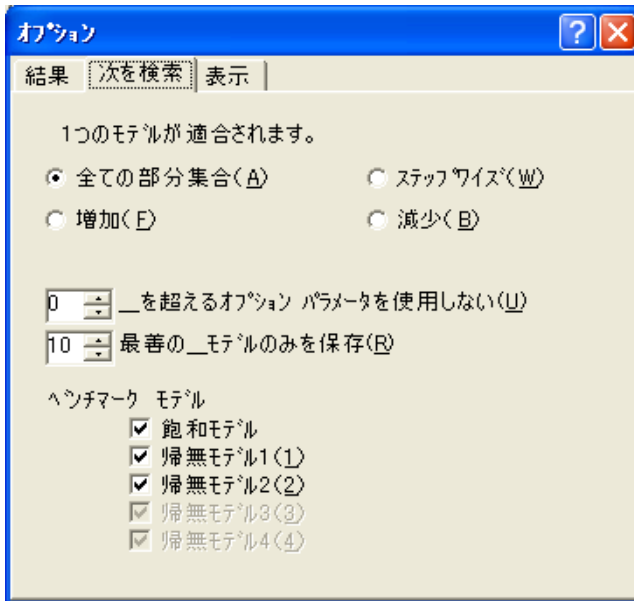
## 矢印のオプション指定

- ▶ メニューから [分析] → [探索的モデル特定化] の順に選択します。
- ▶ [探索的モデル特定化] ツールバーの  をクリックしてから、パス図が 318 ページのようになるまで、パス図内の矢印をクリックします。

ヒント：複数の矢印を一度に変更するには、マウスポインタをクリックしてから目的の矢印に向けてドラッグします。

## オプション設定のデフォルトへのリセット


- ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
- ▶ [オプション] ダイアログ ボックスで、[次を検索] タブをクリックします。
- ▶ [最善の \_\_ モデルのみを保存] ボックスで、値を 0 から 10 に変更します。



これにより、先にこの例で変更したデフォルト設定が復元されます。デフォルト設定では、プログラムはモデルリストの列の並べ替えに使用する基準に応じて、最善モデルを 10 だけ表示します。この探索的モデル特定化では多数のモデルが生成されるので、この制限は必要です。

- ▶ [結果] タブをクリックします。
- ▶ [BCC、AIC、BIC] で、[ゼロベース (min=0)] を選択します。

## 探索的モデル特定化の実行

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。

この検索には、1.8 GHz の Pentium 4 で 10 秒ほどかかります。完了すると、[探索的モデル特定化] ウィンドウが拡張して、結果が表示されます。



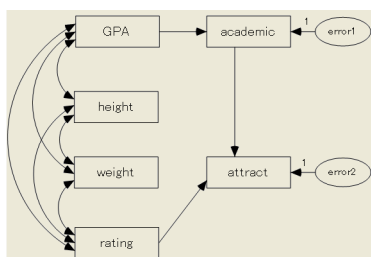
## BIC を使用したモデル比較

- ▶ [探索的モデル特定化] ウィンドウで、「BIC<sub>0</sub>」という見出しのついた列をクリックします。これによって、BIC<sub>0</sub> を基準にテーブルが並べ替えられます。


モデル	名前	パラメータ	df	C	C - df	BCC0	<b>BIC0</b>	C / df	p	注釈
22	モデル番号 1	15	6	5.156	-0.844	0.132	<b>0.000</b>	0.859	0.524	
32	モデル番号 1	16	5	2.954	-2.046	<b>0.000</b>	3.141	0.591	0.707	
33	モデル番号 1	16	5	3.101	-1.899	0.147	3.288	0.620	0.684	
34	モデル番号 1	16	5	4.623	-0.377	1.669	4.810	0.925	0.464	
35	モデル番号 1	16	5	4.623	-0.377	1.669	4.810	0.925	0.464	
36	モデル番号 1	16	5	4.623	-0.377	1.669	4.810	0.925	0.464	
38	モデル番号 1	16	5	5.055	0.055	2.101	5.242	1.011	0.409	
39	モデル番号 1	16	5	5.079	0.079	2.125	5.266	1.016	0.406	
40	モデル番号 1	16	5	5.081	0.081	2.127	5.268	1.016	0.406	
41	モデル番号 1	16	5	5.116	0.116	2.162	5.303	1.023	0.402	

図 22-8 BIC<sub>0</sub> を基準にした 10 の最善モデル

並べ替えられたテーブルから、BIC<sub>0</sub> を基準にした場合、モデル 22 が最善モデルであることがわかります（モデルの番号は、パス図にオブジェクトが描画された順序にも多少依存します。このため、独自のパス図を作成する場合、モデルの番号がここでの番号と異なることがあります）。BIC<sub>0</sub> を基準とした場合に 2 番目に適合していたモデル 32 は、BCC<sub>0</sub> を基準にすると最善モデルとなります。上記のモデルを次に示します。




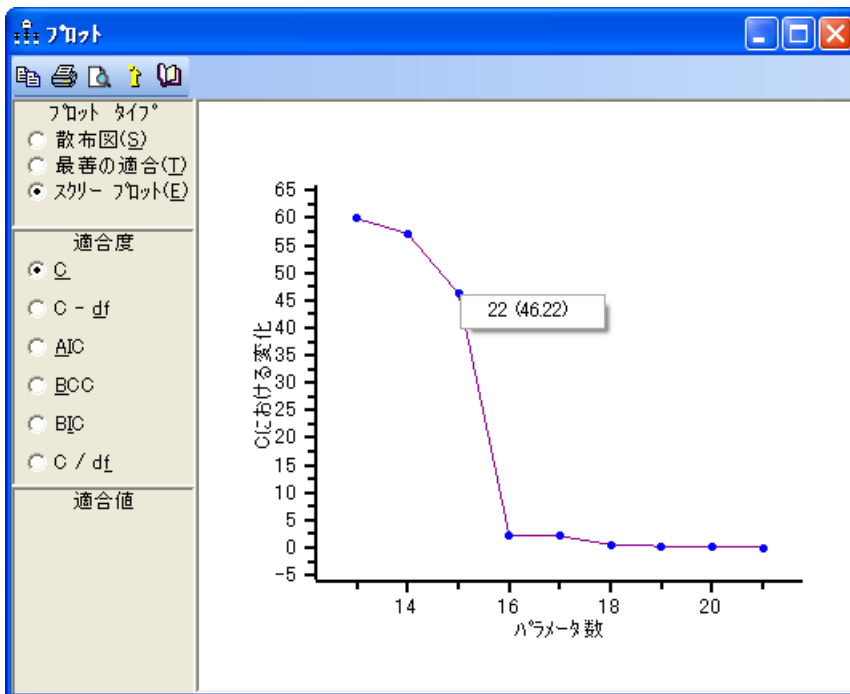
モデル 22



モデル 32

## スクリープロットの表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。
- ▶ [プロット] ウィンドウで、[プロット タイプ] の [スクリープロット] を選択します。  
スクリープロットでは、モデルの適合度と倹約性とのトレードオフが最適なモデルとして、パラメータ数 15 個のモデルを強く推奨しています。
- ▶ 横軸 15 の点をクリックするとポップアップが表示され、この点がモデル 22 を表すことが示されます。このモデルのカイ 2 乗の変化は 46.22 です。
- ▶ 22 (46.22) をクリックして、描画領域にモデル 22 を表示します。



## 制限

探索的モデル特定化手続きは、単一グループからのデータを分析する場合にのみ実行できます。

# 探索的モデル特定化による探索的因子分析

## 概要

この例では、探索的モデル特定化による探索的因子分析について説明します。ここでの探索的因子分析に向けた手法では、測定された変数は任意の因子に（オプションで）依存することができます。探索的モデル特定化は、単純性と適合度の最適な組み合わせを示す、一方向矢印のサブグループを検索するために実行します。また、モデルが多数あるために網羅的な探索的モデル特定化を実行できない場合に役立つ、発見的な探索的モデル特定化についても説明します。

## データについて

この例では、例 8 で紹介した、Holzinger と Swineford(1939) による女子のデータを使用します。

## モデルについて

初期モデルについては、324 ページの図 23-1 を参照してください。探索的モデル特定化では、因子から測定された変数に向けた一方向矢印は、すべてオプションとされます。この探索的モデル特定化では、モデルに必要な一方向矢印はどれか、つまり、ある変数がどの因子に依存しているのかということについて把握することを目的としています。

この2つの因子分散は、残差変数に関連付けられたすべての係数と同様に、どちらも1に固定されています。この制約を設けないと、探索的モデル特定化に出現する、いずれのモデルも識別できなくなります。

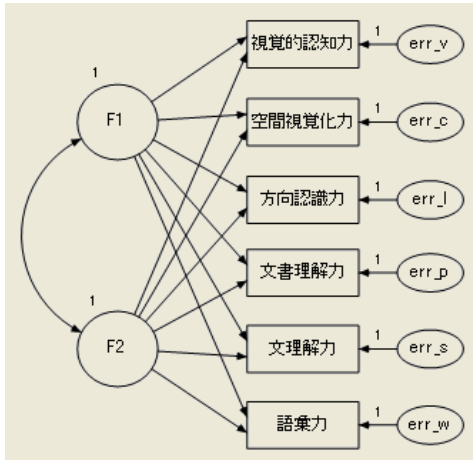


図 23-1 2 つの因子での探索的因子分析モデル

## モデルの特定化

- ▶ %examples%\Ex23.amw ファイルを開きます。

最初は、図 23-1 でのパス図が表示されます。因子分散が1に固定されていても、この状態ではモデルを識別できないため、このモデルを適合させようとしても意味がありません。


## [探索的モデル特定化] ウィンドウを開く

- ▶ [探索的モデル特定化] ウィンドウを開くには、[分析]→[探索的モデル特定化]の順に選択します。

最初は、次のようにツールバーだけが表示されています。



## すべての係数のオプション指定

- ▶ [探索的モデル特定化] ツールバーの  をクリックしてから、パス図内のすべての一方向矢印をクリックします。

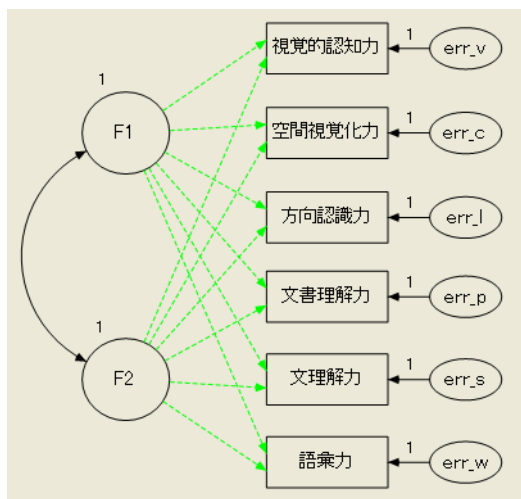



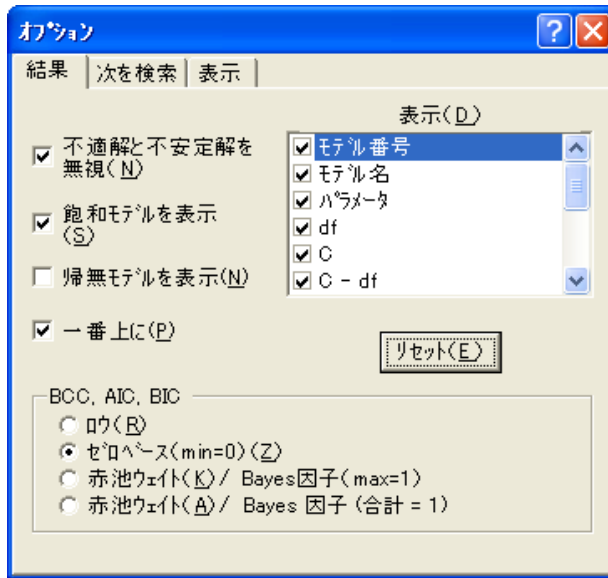
図 23-2 すべての係数をオプションにした2因子モデル

探索的モデル特定化の実行中、プログラムは、オプション矢印の可能なサブグループをすべて使用してモデルを適合しようとしています。

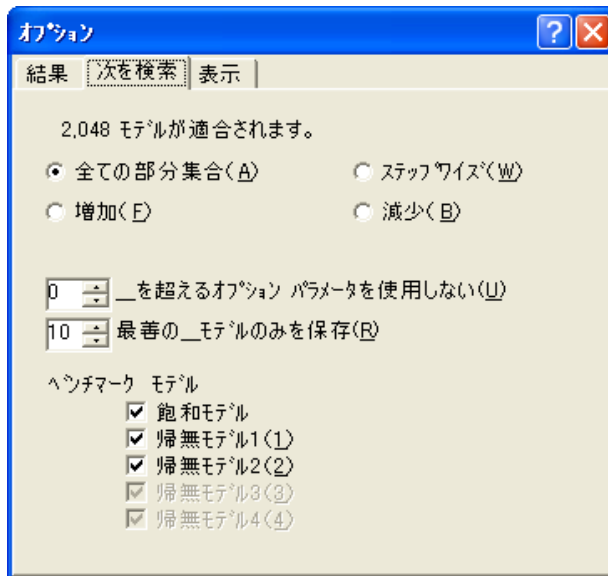
## オプション設定のデフォルトへのリセット

- ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
- ▶ [オプション] ダイアログ ボックスで、[結果] タブをクリックします。

- ▶ [リセット] をクリックして、設定したオプションがこの例と同じであることを確認します。




- ▶ 次に、[次を検索] タブをクリックします。[最善の \_\_\_ モデルのみを保存] のデフォルト値が 10 であることに注意してください。



この設定では、プログラムはモデルリストの列の並べ替えに使用する基準に応じて、最善モデルを 10 だけ表示します。たとえば、「C / df」という見出しのついた列をクリックすると、C / df を基準に並べ替えが行われ、C / df の値が小さい順に 10 のモデルがテーブルに表示されます。散布図には、上位 10 位までの 1 因子モデル、上位 10 位までの 2 因子モデルというように表示されます。オプションのパラメータが多数ある場合には、表示パラメータ数を制限しておくとう便利です。

この例ではオプションのパラメータが 12 あるので、候補モデルの数は  $2^{12} = 4096$  となります。多数のモデルに対して結果を保存していくと、パフォーマンスに影響することがあります。パラメータ数ごとに上位 10 位までのモデルを表示するという制限によって、プログラムでは、およそ  $10 \times 13 = 130$  モデル分だけのリストを保持すればいいことになります。パラメータ数ごとに上位 10 位までのモデルを検索するためには、プログラムは 130 をはるかに超えるモデルを適合させる必要はありませんが、4,096 よりは少なくても済みます。このプログラムではモデルを不必要に適合しないため、アルゴリズムに総当たり回帰 (Furnival および Wilson, 1974) で使用されているアルゴリズムと同じ、分岐限界法を使用しています。

## 探索的モデル特定化の実行

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。

この検索には、1.8 GHz の Pentium 4 で 12 秒ほどかかります。完了すると、[探索的モデル特定化] ウィンドウが拡張して、結果が表示されます。

最初は、モデルのリストはあまり詳細にわたっていません。モデルは出現した順にリストに掲載されるので、検索の早期に出現したモデルは識別されません。識別できないモデルの分類方法については、付録 D で説明されています。

モデル	名前	パラメータ	df	C	C - df	BCC 0	BIC 0	C / df	p	注釈
1	モデル番号 1	7	14							Unidentified
2	モデル番号 1	8	13							Unidentified
3	モデル番号 1	8	13							Unidentified
4	モデル番号 1	8	13							Unidentified
5	モデル番号 1	8	13							Unidentified
6	モデル番号 1	8	13							Unidentified
7	モデル番号 1	8	13							Unidentified
8	モデル番号 1	8	13							Unidentified
9	モデル番号 1	8	13							Unidentified
10	モデル番号 1	8	13							Unidentified

## BCC を使用したモデル比較

- ▶ [探索的モデル特定化] ウィンドウで、「BCC<sub>0</sub>」という見出しのついた列をクリックします。

「BCC」を基準にテーブルが並べ替えられ、BCC における最善モデル (BCC の値が最も小さいモデル) がリストの先頭に配置されます。

モデル	名前	パラメータ	df	C	C - df	BCC 0	BIC 0	C / df	p	注釈
52	モデル番号 1	13	8	7.853	-0.147	<b>0.000</b>	<b>0.000</b>	0.982	0.448	
53	モデル番号 1	13	8	7.853	-0.147	<b>0.000</b>	<b>0.000</b>	0.982	0.448	
62	モデル番号 1	14	7	5.770	<b>-1.230</b>	0.132	2.207	<b>0.824</b>	<b>0.567</b>	
63	モデル番号 1	14	7	5.770	<b>-1.230</b>	0.132	2.207	<b>0.824</b>	<b>0.567</b>	
64	モデル番号 1	14	7	7.155	0.155	1.517	3.593	1.022	0.413	
65	モデル番号 1	14	7	7.155	0.155	1.517	3.593	1.022	0.413	
66	モデル番号 1	14	7	7.608	0.608	1.971	4.046	1.087	0.368	
67	モデル番号 1	14	7	7.608	0.608	1.971	4.046	1.087	0.368	
68	モデル番号 1	14	7	7.632	0.632	1.995	4.070	1.090	0.366	
69	モデル番号 1	14	7	7.632	0.632	1.995	4.070	1.090	0.366	

図 23-3 BCC<sub>0</sub> を基準にした 10 の最善モデル

BCC<sub>0</sub> を基準にした場合の 2 つの最善モデル (モデル 52 とモデル 53) の適合度は同じです (ここでは値が 0 ですが、小数以下 3 桁まで指定されます)。このことについては、この 2 つのモデルのそれぞれのパス図からの説明を得ることができます。

- ▶ [探索的モデル特定化] ウィンドウで、モデル 52 の行をダブルクリックします。描画領域にパス図が表示されます。
- ▶ モデル 53 のパス図を参照するには、モデル 53 の行をダブルクリックします。

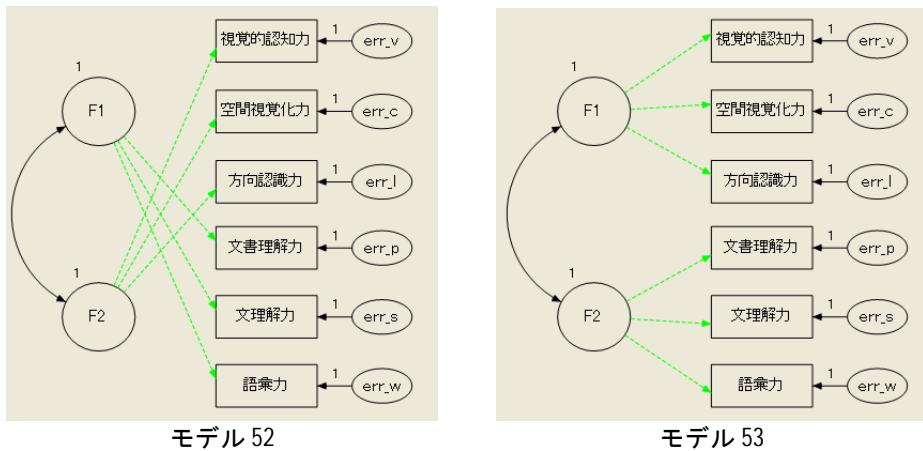


図 23-4 F1 と F2 を逆にすると、候補モデルが入れ替わる



これは、F1 と F2 の役割を逆にすると、一方のペアのメンバーが他方のペアのメンバーと入れ替わるといふ、単なる 1 組のモデルのペアに過ぎません。こうしたペアは他にもあります。モデル 52 とモデル 53 は同じものですが、4,096 の候補モデルリストでは別のもので数えられています。328 ページの図 23-3 での 10 のモデルは 5 組のペアになっていますが、図 23-5 で示すように、候補モデルが常に同じペアで出現するとは限りません。この図のモデルは、パラメータ数 6 個での上位 10 位のモデルに入らないだけでなく、識別されることもありません。ただし、このモデルからは、F1 と F2 を逆にした場合に、どのようにして 4,096 の候補モデルから別のメンバーの抽出に失敗しうるかということがわかります。

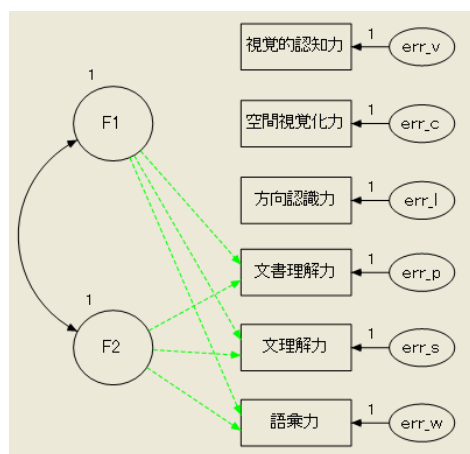


図 23-5 F1 と F2 を逆にすると、同じ候補モデルが発生する

同じ候補モデルが発生することで、この例でのモデル選択におけるベイズの計算の適用方法が不明確になります。同様に、赤池ウェイトの使用方法も不明確になります。さらに、 $BCC_0$  の解釈における Burnham と Anderson によるガイドラインは赤池ウェイトについての推論に基づいているので、このガイドラインがこの例に適用できるかどうかは明確ではありません。一方、Burnham と Anderson によるガイドラインを無視して  $BCC_0$  を使用すれば、問題が発生しないものと考えられます。モデル 52 (および、これと同じであるモデル 53) は、 $BCC_0$  を基準にした場合の最善モデルです。

BCC<sub>0</sub> は、例 8 で使用された Jöreskog と Sörbom (1996) によるモデルを基にしたモデルを選択しますが、モデル 62 (および、これと同じであるモデル 63) は BCC<sub>0</sub> の基準において僅差で 2 位であり、別の適合度を基準にした場合は最善モデルになっていることもあるということには注意すべきでしょう。モデル 63 のパス図は次のとおりです。






図 23-6 モデル 63

モデル 53 とモデル 63 の両方において、因子 F1 と因子 F2 は、それぞれ大まかに空間能力と言語能力であると解釈できます。この 2 つのモデルでは、cubes (空間視覚化力) 検定の得点における解釈が異なります。モデル 53 では、cubes (空間視覚化力) の得点は空間能力に全面的に依存しています。モデル 63 では、cubes (空間視覚化力) の得点は空間能力と言語能力の両方に依存しています。すべての基準が適合度と儉約性に基づいていることは危険性が高いため、モデルの選択基準における解釈の問題に注意することが特に必要です。ただし、次の手順でのスクリープロットの検定では、最善モデルがどれであるかが明確にわかります。


## スクリープロットの表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。
- ▶ [プロット] ウィンドウで、[プロットタイプ] の [スクリープロット] を選択します。



スクリープロットでは、パラメータ数 13 個のモデルの使用を強く推奨しています。13 番目のパラメータの直後でグラフが突然落ち込み、その後勾配がゆるやかになるためです。横軸の座標 13 にある点をクリックします。ポップアップが表示され、この点が 328 ページの図 23-4 におけるモデル 52 とモデル 53 を表すことが示されます。

## モデルの短いリストの表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。後から参照できるように、モデルの短いリストの控えをとっておきます。

## 発見的な探索的モデル特定化

オプション矢印の数が増えるにしたがって、網羅的な探索的モデル特定化で適合する必要があるモデルの数が急速に増えます。325 ページの図 23-2 には 12 のオプション矢印があります。このため、網羅的な探索的モデル特定化では、 $2^{12} = 4096$  のモデルを適合する必要があります ([オプション] ダイアログ ボックスの [次を検索] プロパティ ページにある [最善の \_\_\_ モデルのみを保存] に、小さな正の数が指定されている場合は、モデルの数は 4096 よりも少なくなります)。適合する必要があるモデルの数を減らすために、多数の発見的な検索手続きが提案されてきました (Salhi, 1998)。いずれも必ず最善モデルを検索できるとは限りませんが、オプション矢印の数が 20 を超えたあたりから網羅的な探索的モデル特定化ができなくなるという問題に対し、実際の計算に役立つという利点があります。

Amos には、発見的検索のオプションの他に、発見的検索の方略が 3 つ備わっています。特定の適合度における最小と最大の意味において、最善についての定義を選択することが必要となるため、発見的な方略では、全体における最善モデルの検索が試みられることはありません。その代わりに、発見的な方略では、乖離度が最小のパラメータ数 1 個のモデル、乖離度が最小のパラメータ数 2 個のモデル、といったモデルの検索を試みます。この手法を採り入れることで、適合度の選択から独立した検索手続きを設計することができます。[オプション] ダイアログ ボックスの [次を検索] プロパティ ページで、適用が可能な検索方略を選択できます。選択肢は、次のとおりです。

- **全ての部分集合網羅的検索**が実行されます。これがデフォルトとなります。
- **変数増加法**プログラムは、オプション矢印のないモデルを最初に適合します。その後、乖離度の減少が最も大きい矢印を常に追加しながら、オプション矢印を 1 つずつ追加していきます。
- **変数減少法**プログラムは、モデル内の矢印がすべてオプション矢印であるモデルを最初に適合します。その後、乖離度の増加が最も小さい矢印を常に削除しながら、オプション矢印を 1 つずつ削除していきます。
- **ステップワイズ法**プログラムは、変数増加法と変数減少法を切り替えながら検索を行います。最初は変数増加法から始めます。プログラムはオプション矢印 1 つの最善モデルの出現、オプション矢印 2 つの最善モデルの出現、というように経過を追います。変数増加法による検索後、変数増加法と変数減少法との切り替えアルゴリズムが、一定の規則のもとで変更されます。この規則では、プログラムは、出現したモデルの乖離度が、これより前に出現した同じ数の矢印を持つどのモデルよりも小さい場合にのみ、矢印の追加や削除を行うことになっています。たとえば、オプション矢印 5 つのモデルに対してプログラムが矢印を 1 つ追加するのは、出現したオプション矢印 6 つのモデルの乖離度が、これよりも前に出現したオプション矢印 6 つのモデルのいずれと比べても小さい場合のみです。変数増加法と変数減少法との切り替え検索では、変数増加法または変数減少法のいずれかが、改善のないままに完了した時点で一方に切り替わります。

## ステップワイズ検索の実行




- ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
- ▶ [オプション] ダイアログ ボックスで、[次を検索] タブをクリックします。
- ▶ [ステップワイズ法] を選択します。
- ▶ [探索的モデル特定化] ツールバーの  をクリックします。

図 23-7 では、パラメータ数 13 個のモデルであるモデル 7 の調査が推奨されています。このモデルの乖離度  $C$  は、パラメータ数 12 個での最善モデルの乖離度よりもはるかに小さく、パラメータ数 14 個での最善モデルを大きく上回ってもいません。モデル 7 は、BCC と BIC のどちらを基準にしても最善モデルとなります。(発見的な探索的モデル特定化アルゴリズムでの確率的要素によって、図中の数値とは異なる結果が生じる場合があります。変数増加法での検索中に矢印が追加されたり、変数減少法での検索中に矢印が削除されたりすると、最善モデルの選択が一意ではなくなることがあります。この場合、最善モデルに結び付けられた矢印から 1 本が無作為に抽出されます。)

モデル	名前	パラメータ	df	C	C - df	BCC 0	BIC 0	C / df	p	注釈
1	モデル番号 1	7	14							Unidentified
2	モデル番号 1	8	13							Unidentified
3	モデル番号 1	9	12							Unidentified
4	モデル番号 1	10	11							Unidentified
5	モデル番号 1	11	10	97.475	87.475	85.191	81.041	9.747	0.000	
6	モデル番号 1	12	9	33.469	24.469	23.401	21.326	3.719	0.000	
7	モデル番号 1	13	8	7.853	-0.147	<b>0.000</b>	<b>0.000</b>	0.982	0.448	
8	モデル番号 1	14	7	5.770	<b>-1.230</b>	0.132	2.207	<b>0.824</b>	<b>0.567</b>	
9	モデル番号 1	15	6	5.594	-0.406	2.172	6.322	0.932	0.470	
10	モデル番号 1	16	5	5.528	0.528	4.322	10.547	1.106	0.355	
11	モデル番号 1	17	4	5.476	1.476	6.485	14.785	1.369	0.242	
12	モデル番号 1	18	3							Unidentified
13	モデル番号 1	19	2							Unidentified
飽和モデル	[飽和モデル]	21	0	0.000	0.000	9.870	26.471			

図 23-7 ステップワイズ法での検索結果

## スクリープロットの表示

- ▶ [探索的モデル特定化] ツールバーの  をクリックします。
- ▶ [プロット] ウィンドウで、[プロット タイプ] の [スクリープロット] を選択します。

スクリープロットから、13 番目のパラメータを追加すると、乖離度が大幅に減少し、13 番目のパラメータを超えると、それ以上パラメータを追加してもほんの少ししか減少しないということが確認できます。

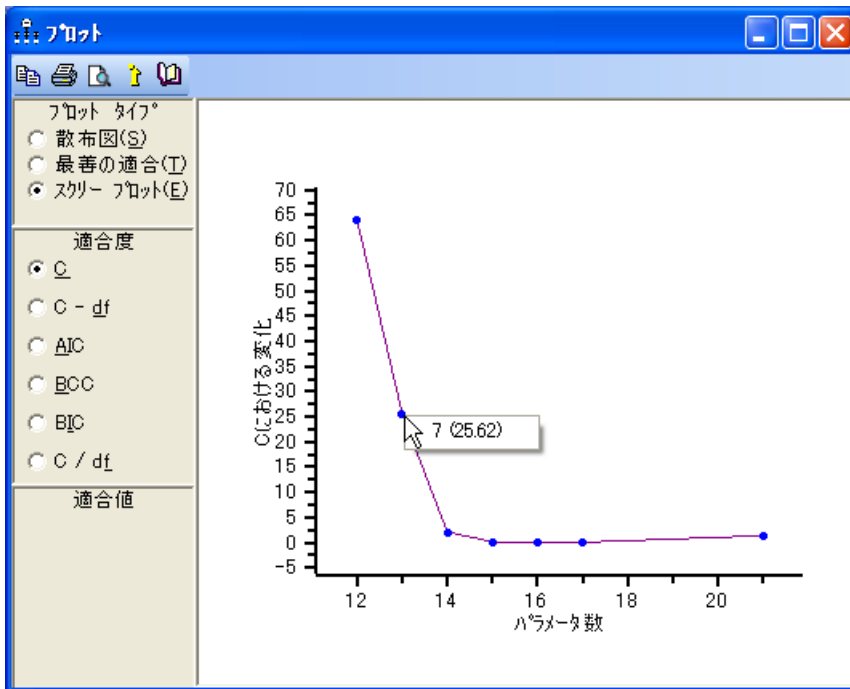


図 23-8 ステップワイズ法による検索後のスクリープロット

- ▶ スクリープロットで、横軸の座標が 13 の点 (図 23-8 を参照) をクリックします。ポップアップが表示され、モデル 7 がパラメータ数 13 個での最善モデルであることが示されます。
- ▶ ポップアップメニューから 7 (25.62) をクリックします。描画領域にモデル 7 のパス図が表示されます。

**ヒント:** [探索的モデル特定化] ウィンドウでモデル 7 の行をダブルクリックしても同じ結果が得られます。

## 発見的な探索的モデル特定化における制限

発見的な探索的モデル特定化では、特定のパラメータ数の最善モデルを検索できない場合があります。実際、この例でのステップワイズ検索では、パラメータ数 11 個での最善モデルを 1 つも検索できませんでした。333 ページの図 23-7 では、ステップワイズ検索によって検索された、パラメータ数 11 個での最善モデルの乖離度 (C) は 97.475 でした。ところが網羅的検索では、乖離度 55.382 の 2 つのモデルが検索されています。各パラメータ数に対し、ステップワイズ検索では最善モデルから 1 つが検索されました。

当然ながら、発見的検索が成功だったのかどうかはわかるのは、網羅的検索を実行して、発見的検索の結果を再調査できた場合だけです。使用できる手法が発見的検索のみである場合の問題として、各パラメータ数に対して最善モデルの 1 つを検索できるかどうか不確かであるということだけでなく、検索が成功したのかどうかを知る方法がないということも挙げられます。

発見的検索によって、特定のパラメータ数に対する最善モデルの 1 つを検索できた場合においても、適合度が同じか、差がわずかな他のモデルについての情報を得ることができません (Amos ではこのように実装されています)。





# 複数グループでの因子分析

## 概要

この例では、複数グループにまたがる制約条件の自動指定による、2つのグループでの因子分析を紹介します。

## データについて

この例では、例 12 と例 15 で紹介した、Holzinger と Swineford(1939) による女子と男子のデータを使用します。

## モデル 24a: 平均値と切片項を使用しないモデル作成

明示的なモデルパラメータに平均値と切片項が含まれていると、複数グループの分析が困難になります。平均値と切片項の処理については、追ってモデル 24b で説明します。ここでは、明示的な平均値と切片項のない次の因子分析モデルを、女子と男子のデータに適合させることについて考察します。

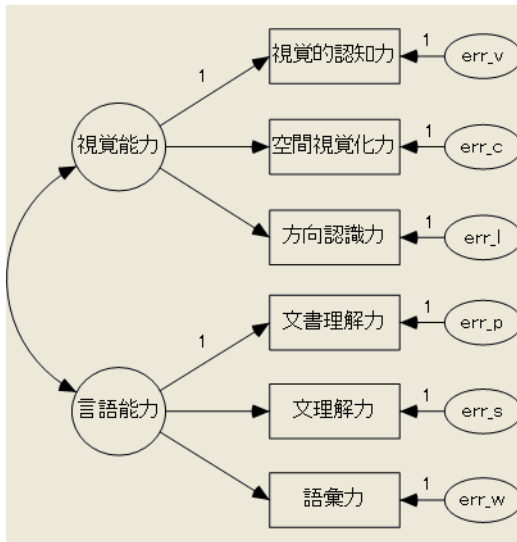


図 24-1 女子と男子の 2 因子モデル

これは、例 12 で考察した、2 つのグループでの因子分析における問題と同じです。ここでは例 12 での結果が自動的に得られます。

## モデルの特定化

- ▶ メニューから [ファイル] → [開く] の順に選択します。
- ▶ [開く] ダイアログで、ファイル名「%examples%\Ex24a.amw」を入力し、[開く] ボタンをクリックします。

パス図は図 24-1 に表示のとおりで、男子も女子も同じです。回帰ウェイトのうちいくつかは、値が 1 に固定されています。この回帰ウェイトの値は、続く分析が完了するまで 1 に固定されたままです。この補助が付いた複数グループの分析によって、指定したモデルに制約条件が設けられることはあっても、制約条件が削除されることはありません。

## [複数グループの分析] ダイアログ ボックスを開く

- ▶ メニューから [分析] → [複数グループの分析] の順に選択します。

- ▶ 表示されるダイアログボックスで [OK] をクリックします。[複数グループの分析] ダイアログボックスが開きます。

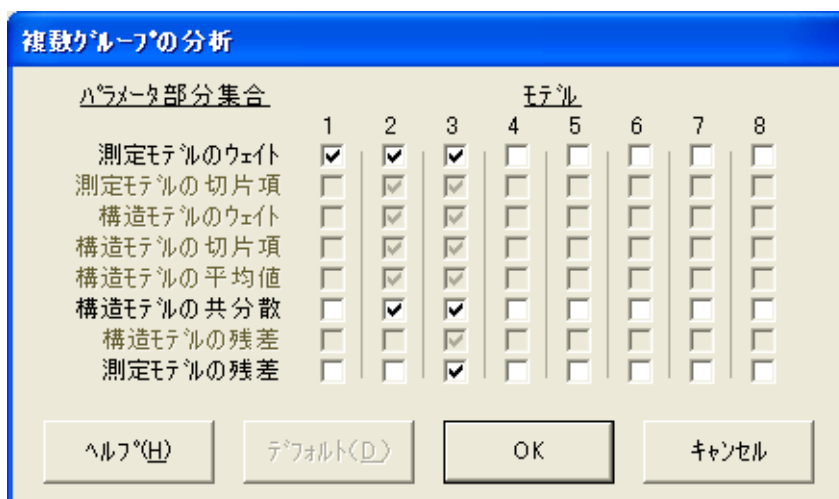


図 24-2 [複数グループの分析] ダイアログボックス

ほとんどの場合、[OK] をクリックするだけです。しかし、ここでは [複数グループの分析] ダイアログボックスの一部を見てみることにしましょう。

チェックボックスが 8 列に並んでいます。チェックボックスがオンになっているのは、[1]、[2]、および [3] というラベルが付いた列だけです。これは、プログラムによって、グループ間制約がそれぞれ異なる 3 つのモデルが生成されるということを意味しています。

列 1 では、モデルの測定部分における回帰ウェイトの略である、[測定モデルのウェイト] というラベルの付いた行だけがオンになっています。これは、因子分析モデルでの因子負荷に当たります。次の項で、測定モデルのウェイトをパス図に表示する方法について説明します。列 1 より、測定モデルのウェイトがグループ間で一定（男子と女子とで等しい）のモデルが生成されます。

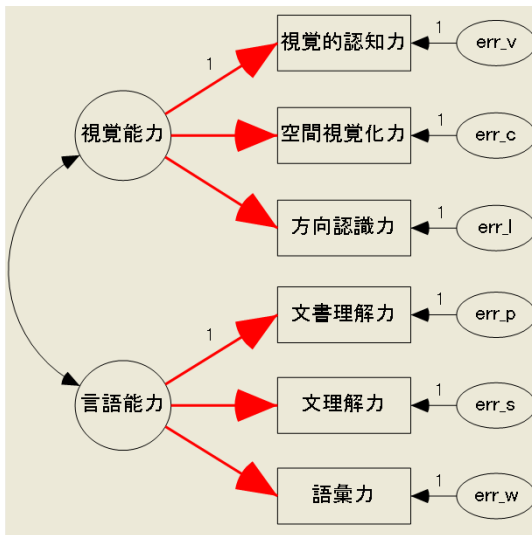
列 2 では、[測定モデルのウェイト] だけでなく、モデルの構造部分における分散と共分散の略である [構造モデルの共分散] もオンになっています。これらはそれぞれ、因子分析モデルでの因子分散と因子共分散に当たります。次の項で、構造モデルの共分散をパス図に表示する方法について説明します。列 2 より、測定モデルのウェイトと、構造モデルの共分散がグループ間で一定のモデルが生成されます。

列 3 では、列 2 でのすべてのチェックボックスに加えて、モデルの測定部分における残差（誤差）変数の分散と共分散の略である、[測定モデルの残差] チェックボックスもオンになっています。次の項で、測定モデルの残差をパス図に表示する方法について説明します。黒のフォント（灰色ではありません）で表示された 3 つのパラメータのグループは、相互に排他的かつ網羅的です。このため、列 3 により、すべてのパラメータがグループ間で一定のモデルが生成されます。

上記を要約すると、列 1 から列 3 により、モデルの階層が生成されます。この階層では、前のモデルの制約条件が各モデルに引き継がれます。最初に、因子負荷の値がグループ間で固定されます。次に、因子分散と因子共分散の値が固定されます。最後に、残差(独自)分散の値が固定されます。

## パラメータ部分集合の表示

- ▶ [複数グループの分析]ダイアログボックスの[測定モデルのウェイト]をクリックします。測定モデルのウェイトが、描画領域に色付きで表示されます。[インターフェイスのプロパティ]ダイアログボックスの[アクセス]プロパティ ページにある[色の選択]チェックボックスがオンになっている場合、測定モデルのウェイトは次のような太線で表示されます。



- ▶ [構造モデルの共分散] をクリックして、因子分散と因子共分散が強調表示されていることを確認します。
- ▶ [測定モデルの残差] をクリックして、誤差変数が強調表示されていることを確認します。グループ間制約のそれぞれが、どのパラメータに影響しているかを簡単に視覚化する方法があります。

## 生成されたモデルの表示

- ▶ [複数グループの分析] ダイアログ ボックスで [OK] をクリックします。

パス図にすべてのパラメータの名前が表示されます。パス図の左側にあるパネルから、グループ間制約が設けられていない [制約なし] モデルの他に、プログラムによって3つの新規モデルが作成されたことがわかります。

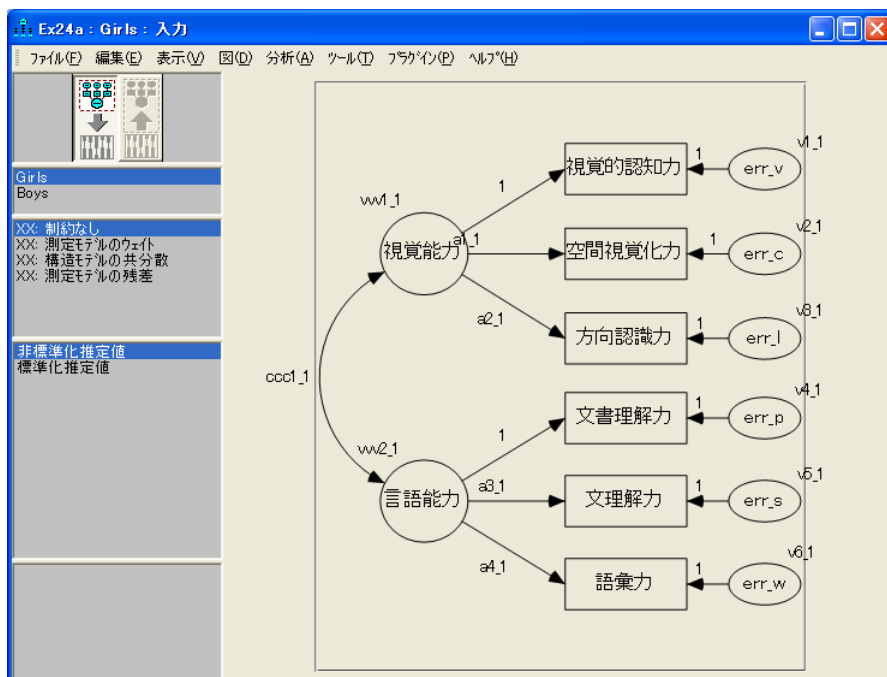
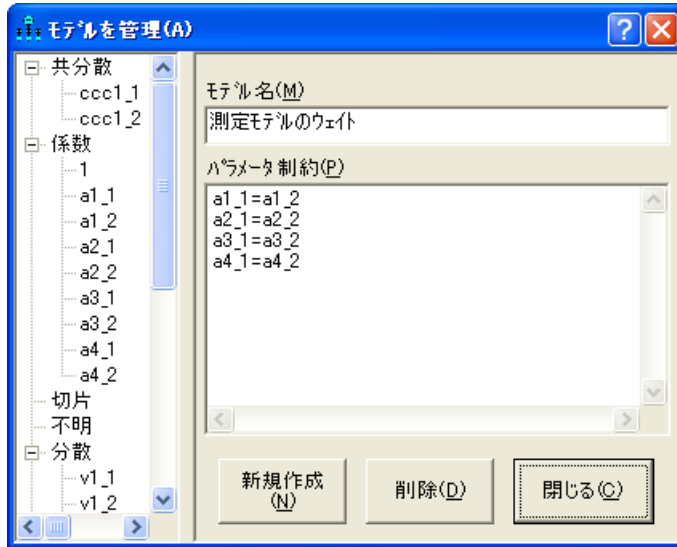


図 24-3 自動制約後の Amos Graphics のウィンドウ

- ▶ [XX: 測定モデルのウェイト] をダブルクリックします。[モデルを管理] ダイアログボックスが開き、因子負荷の値をグループ間で一定にする必要があるという制約条件が表示されます。



## すべてのモデルの適合と、出力の表示

- ▶ メニューから [分析] → [推定値を計算] の順に選択して、すべてのモデルを適合します。
- ▶ メニューから、[表示] → [テキスト出力の表示] を選択します。
- ▶ 出力ビューア の概念ツリー図で [モデルの適合度] ノードをクリックして拡張してから、[CMIN] をクリックします。

CMIN テーブルには、各適合モデルに対する尤度比カイ 2 乗統計量が表示されます。このデータは、いずれのモデルからも著しく逸脱することはありません。加えて、[制約なし] モデルから [測定モデルの残差] モデルに向けての階層において、ある段階から次の段階へのカイ 2 乗の増加分が、自由度の増加分を大きく上回ることはありません。女子のパラメータ値が男子のパラメータ値と異なることを示す有意な証拠はないようです。

CMIN テーブルを次に示します。

モデル	NPAR	CMIN	DF	P	CMIN/DF
制約なし	26	16.48	16	0.42	1.03
測定モデルのウェイト	22	18.29	20	0.57	0.91
構造モデルの共分散	19	22.04	23	0.52	0.96
測定モデルの残差	13	26.02	29	0.62	0.90
飽和モデル	42	0.00	0		
独立モデル	12	337.55	30	0.00	11.25

- ▶ 概念ツリー図で、[モデルの適合度] ノードの下にある [AIC] をクリックします。

[AIC] 値と [BCC] 値は、すべてのパラメータがグループ間で等しくなるように制約したことで ([測定モデルの残差] モデル)、モデルの適合度と儉約性における最適なトレードオフが得られたことを示しています。

AIC テーブルを次に示します。

モデル	AIC	BCC	BIC	CAIC
制約なし	68.48	74.12		
測定モデルのウェイト	62.29	67.07		
構造モデルの共分散	60.04	64.16		
測定モデルの残差	52.02	54.84		
飽和モデル	84.00	93.12		
独立モデル	361.55	364.16		

## 分析のカスタマイズ

自動生成されたグループ間制約は、次の 2 箇所において変更することもできます。339 ページの図 24-2 では、列 1、2、3 のチェックボックスのオン/オフを変更できます。また、列 4 から列 8 までのチェックボックスをオンにすることで、別のモデルを生成することもできます。その後、341 ページの図 24-3 で、パス図の左側にあるパネルに一覧表示された任意の自動生成モデルについて、名前を変更したり、モデル自体を変更することができます。

## モデル 24b: 因子の平均値の比較

明示的な平均値と切片項がモデルに加わると、どのグループ間パラメータ制約を、どのような順番で検定するべきかという問題が発生します。この例では、338 ページの図 24-1 における因子分析モデルを、女子と男子に分かれたグループのデータに適合する際に、Amos がどのように平均値と切片項を制限するかについて説明します。

これは、例 15 で考察した、2 つのグループでの因子分析における問題と同じです。ここでは例 15 での結果が自動的に得られます。

## モデルの特定化

- ▶ メニューから [ファイル] → [開く] の順に選択します。
- ▶ [開く] ダイアログで、ファイル名「%examples%\Ex24b.amw」を入力し、[開く] ボタンをクリックします。

パス図は次のとおりで、男子も女子も同じです。回帰ウェイトのうちのいくつかは、値が 1 に固定されています。観測されない変数の平均値は、すべて 0 に固定されています。次の項で、女子における因子の平均値に対する制約条件を削除します。その他の制約条件（削除しない制約条件）は、分析が完了するまで有効のままです。

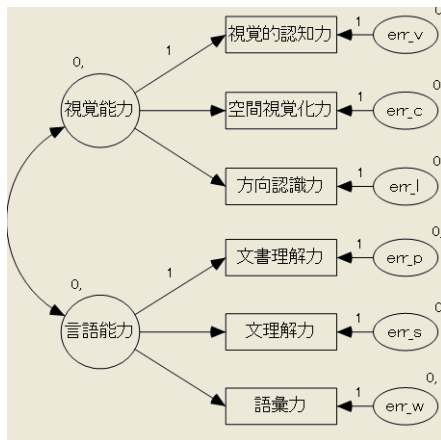


図 24-4 明示的な平均値と切片項を含む 2 因子モデル

## 制約条件の削除

最初は、因子の平均値は男子と女子の両方で 0 に固定されています。両方のグループにおける因子の平均値を推定することはできません。ただし、Sörbom (1974) は、1 つのグループの因子の平均値を一定の値に固定し、因子モデルの回帰ウェイトと切片項に適切な制約条件を設けることで、他のすべてのグループにおける因子の平均について、有意な推定値を得ることができると述べています。この例では、上記での 1 つのグループを男子とし、この因子の平均値を 0 に固定することにします。その後、残りのグループである女子における因子の平均値に対する制約条件を削除します。Sörbom による手法で必要とされる、回帰ウェイトと切片項に対する制約条件は、Amos によって自動生成されます。

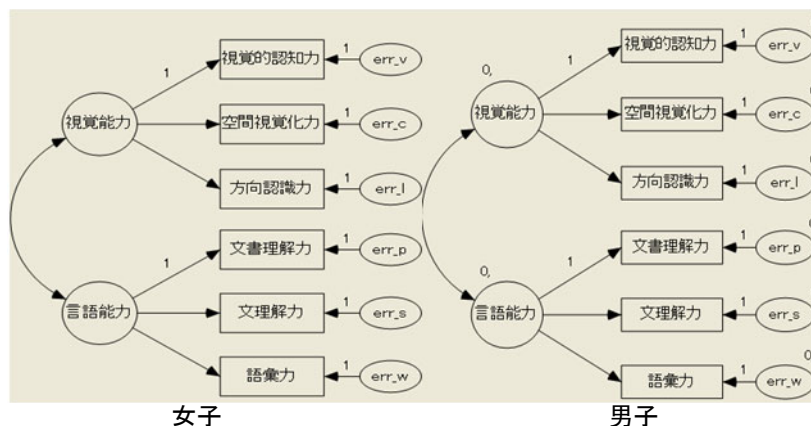
男子における因子の平均値はすでに 0 に固定されています。女子における因子の平均値に対する制約条件を削除する方法は、次のとおりです。

- ▶ Amos Graphics のウィンドウの描画領域で**視覚能力**を右クリックして、ポップアップメニューから**[オブジェクトのプロパティ]**を選択します。
- ▶ **[オブジェクトのプロパティ]**ダイアログボックスで、**[パラメータ]**タブをクリックします。
- ▶ **[平均]**ボックスで 0 を選択してから、Del キーを押します。
- ▶ **[オブジェクトのプロパティ]**ダイアログボックスが開いている状態で、描画領域の**言語能力**をクリックします。**[オブジェクトのプロパティ]**ダイアログボックスに、言語因子のプロパティが表示されます。



- ▶ [パラメータ] プロパティ ページの [平均] ボックスで 0 を選択してから、Del キーを押します。
- ▶ [オブジェクト プロパティ] ダイアログ ボックスを閉じます。

女子における因子の平均値に対する制約条件が削除され、女子と男子の各パス図は次のようになります。



ヒント：描画領域のパス図を切り替えるには、左側の [グループ] 枠で [Boys] または [Girls] をクリックしてください。

## グループ間制約の生成

- ▶ メニューから [分析] → [複数グループの分析] の順に選択します。
- ▶ 表示されるダイアログ ボックスで [OK] をクリックします。[複数グループの分析] ダイアログ ボックスが開きます。

複数グループの分析		パラメータ部分集合							
		1	2	3	4	5	6	7	8
測定モデルのウェイト		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
測定モデルの切片項		<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
構造モデルのウェイト		<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
構造モデルの切片項		<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
構造モデルの平均値		<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
構造モデルの共分散		<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
構造モデルの残差		<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
測定モデルの残差		<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

ヘルプ(H)    デフォルト(D)    OK    キャンセル

上記のデフォルト設定では、次のような 5 つのモデルについての入れ子状の階層が生成されます。


モデル	制約条件
モデル 1 (列 1)	測定モデルのウェイト (因子負荷) の値は、グループ間で同じです。
モデル 2 (列 2)	上記に加え、測定モデルの切片項 (測定変数を予測する方程式での切片項) も、グループ間で同じです。
モデル 3 (列 3)	上記に加え、構造モデルの平均値 (因子の平均値) も、グループ間で同じです。
モデル 4 (列 4)	上記に加え、構造モデルの共分散 (因子の分散と共分散) も、グループ間で同じです。
モデル 5 (列 5)	すべてのパラメータの値がグループ間で同じです。

- ▶ [OK] をクリックします。

## モデルの適合

- ▶ メニューから [分析] → [推定値を計算] の順に選択します。

パス図の左側にあるパネルに、2 つのモデルをデータに適合できなかったことが表示されます。適合できなかった 2 つのモデルとは、グループ間制約のない [制約なし] モデルと、因子負荷がグループ間で等しくなるよう固定された [測定モデルのウェイト] モデルです。この 2 つのモデルは識別されていません。



## 出力の表示

- ▶ メニューから [表示] → [テキスト出力の表示] の順に選択します。
- ▶ 出力ビューア の概念ツリー図で、[モデルの適合度] ノードを拡張します。

自動生成され、識別された 4 つのモデルについての適合度の一部が、飽和モデルと独立モデルの適合度とともに表示されます。

- ▶ [モデルの適合度] ノードの下にある [CMIN] をクリックします。

CMIN テーブルから、飽和モデルに対して検定を行った場合、いずれの生成モデルも棄却できないということがわかります。

モデル	NPAR	CMIN	DF	P	CMIN/DF
測定モデルの切片項	30	22.593	24	0.544	0.941
構造モデルの平均値	28	30.624	26	0.243	1.178
構造モデルの共分散	25	34.381	29	0.226	1.186
測定モデルの残差	19	38.459	35	0.316	1.099
飽和モデル	54	0.00	0		
独立モデル	24	337.553	30	0.00	11.252

一方、因子の平均値を等しくするという制約条件を設けたことによるカイ 2 乗値の変化 ( $30.62 - 22.59 = 8.03$ ) は、自由度の変化 ( $26 - 24 = 2$ ) に比べて大きいようです。

- ▶ 概念ツリー図で、[モデルの適合度] ノードをクリックします。

モデルの [測定モデルの切片項] が正しい場合、次のテーブルから、カイ 2 乗値の差が有意であることがわかります。

モデル	DF	CMIN	P	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
構造モデルの平均値	2	8.030	0.018	0.024	0.026	0.021	0.023
構造モデルの共分散	5	11.787	0.038	0.035	0.038	0.022	0.024
測定モデルの残差	11	15.865	0.146	0.047	0.051	0.014	0.015

上の 2 つのテーブルでは、2 つのカイ 2 乗統計量と、これに関連する自由度が特に重要です。最初のテーブルでの、 $c^2 = 22.59$  と  $df = 24$  から、測定モデルにおける切片項と回帰ウェイトがそれぞれ等しいという仮説を採択できることになりました。切片項と回帰ウェイトがそれぞれ等しくない限り、男子と女子で因子が同じ意味を持つということが不明確になり、各平均値を比較する意味がなくなるため、この仮説の信頼性を確立することは重要です。もう 1 つの重要なカイ 2 乗統計量である  $c^2 = 8.03$  と  $df = 2$  からは、男子と女子で因子の平均値が等しいという仮説が棄却されることになります。

男子と女子での因子の平均値に見られるグループ間の差は、[測定モデルの切片項] モデルでの女子の推定値から決定することができます。

- ▶ 出力ビューアの左下のウィンドウ枠で、[測定モデルの切片項] モデルを選択します。
- ▶ 概念ツリー図で、[推定値] をクリックしてから、[スカラー]、[平均値] の順にクリックします。

男子の平均値は 0 に固定されているので、次のテーブルに表されるとおり、女子の平均値だけが推定されます。

		推定値	標準誤差	検定統計量	P	ラベル
spatial (視覚能力)		-1.066	0.881	-1.209	0.226	m1_1
言語		0.956	0.521	1.836	0.066	m2_1

上記の推定値は、例 15 のモデル A において述べられています。このモデルは、ここでの [測定モデルの切片項] モデルと同じです (例 15 のモデル B は、ここでの [構造モデルの平均値] モデルと同じです)。

# 複数グループの分析

## 概要

この例では、Sörbom による代替案を、共分散の分析において自動的に実装する方法について説明します。

例 16 では、潜在変数のある共分散の分析における、Sörbom による手法の利点について紹介しています。ただし残念なことに、例 16 でも説明しているとおり、Sörbom による手法は多数の手順を必要とするため、適用が困難です。この例では、例 16 と同じ結果を自動的に取得します。

## データについて

ここでは、例 16 での Olsson(1973) によるデータを使用します。標本の積率は、UserGuide.xls というワークブックにあります。実験群での標本の積率は、Olss\_exp というワークシートにあります。統制群での標本の積率は、Olss\_cnt というワークシートにあります。

## モデルについて

モデルについては、例 16 で説明しています。Sörbom による手法では、パス図が実験群と統制群で同じであることが必要とされます。




図 25-1 Olsson のデータにおける Sörbom のモデル

## モデルの特定化

- ▶ %examples%\Ex25.amw を開きます。

パス図は図 25-1 に表示のとおりで、統制群も実験群も同じです。回帰ウェイトのうちいくつかは、値が 1 に固定されています。すべての残差 (誤差) 変数の平均値の平均値は、0 に固定されています。これらの制約条件は、分析が完了するまで有効のままです。


## 潜在変数の平均値と切片項の制限

Olsson のデータにおける Sörbom のモデルを表した、図 25-1 のモデルは識別されません。Amos によって自動生成される各グループ間制約においても識別されないままです。各グループ間制約において、pre\_verbal (言語能力(事前))の平均値と、post\_verbal (言語能力(事後))を予測する方程式での切片項は、識別されません。少なくとも一部のグループ間制約でモデルが識別されるようにするには、統制群などの 1 つのグループを抽出して、pre\_verbal (言語能力(事前))の平均値と、post\_verbal (言語能力(事後))の切片項を、0 などの数に固定する必要があります。

- ▶ パス図の左側にある [グループ] 枠で、「control」が選択されていることを確認してください。このことは、統制群のパス図が描画領域に表示されていることを示しています。
- ▶ 描画領域で pre\_verbal (言語能力(事前)) を右クリックして、ポップアップメニューから [オブジェクトのプロパティ] を選択します。

- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[パラメータ] タブをクリックします。
- ▶ [平均] テキスト ボックスに、「0」と入力します。
- ▶ [オブジェクトのプロパティ] ダイアログ ボックスが開いている状態で、描画領域の post\_verbal (言語能力(事後)) をクリックします。
- ▶ [テーブルプロパティ] ダイアログ ボックスの [切片] テキスト ボックスに、「0」と入力します。
- ▶ [オブジェクトプロパティ] ダイアログ ボックスを閉じます。

統制群のパス図が次のように表示されます。



実験群のパス図は図 25-1 のままです。

## グループ間制約の生成

- ▶ メニューから [分析] → [複数グループの分析] の順に選択します。
- ▶ 表示されるダイアログ ボックスで [OK] をクリックします。

[複数グループの分析] ダイアログ ボックスが表示されます。

パラメータ部分集合	モデル							
	1	2	3	4	5	6	7	8
測定モデルのウェイト	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
測定モデルの切片項	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
構造モデルのウェイト	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
構造モデルの切片項	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
構造モデルの平均値	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
構造モデルの共分散	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
構造モデルの残差	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
測定モデルの残差	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input checked="" type="checkbox"/>

- ▶ [OK] をクリックすると、8 つのモデルによる、次のような入れ子状の階層が生成されます。

モデル	制約条件
モデル 1 (列 1)	測定モデルのウェイト ( 因子負荷 ) の値は、グループ間で一定です。
モデル 2 (列 2)	上記に加え、測定モデルの切片項 ( 測定変数を予測する方程式での切片項 ) も、グループ間で一定です。
モデル 3 (列 3)	上記に加え、構造モデルのウェイト ( 言語能力 ( 事後 ) を予測するための回帰ウェイト ) も、グループ間で一定です。
モデル 4 (列 4)	上記に加え、構造モデルの切片項 ( 言語能力 ( 事後 ) を予測する方程式での切片項 ) も、グループ間で一定です。
モデル 5 (列 5)	上記に加え、構造モデルの平均値 ( 言語能力 ( 事後 ) の平均値 ) も、グループ間で一定です。
モデル 6 (列 6)	上記に加え、構造モデルの共分散 ( 言語能力 ( 事前 ) の分散 ) も、グループ間で一定です。
モデル 7 (列 7)	上記に加え、構造モデルの残差 ( zeta の分散 ) も、グループ間で一定です。
モデル 8 (列 8)	すべてのパラメータの値がグループ間で一定です。

## モデルの適合

- ▶ メニューから [分析] → [推定値を計算] の順に選択します。



パス図の左側にあるパネルに、2つのモデルをデータに適合できなかったことが表示されます。適合できなかったモデルは、[制約なし]モデルと、[測定モデルのウェイト]モデルです。この2つのモデルは識別されていません。

```

XX: 制約なし
XX: 測定モデルのウェイト
OK: 測定モデルの切片項
OK: 構造モデルのウェイト
OK: 構造モデルの切片項
OK: 構造モデルの平均値
OK: 構造モデルの共分散
OK: 構造モデルの残差
OK: 測定モデルの残差

```

## テキスト出力を表示する

- ▶ メニューから、[表示] → [テキスト出力の表示] を選択します。
- ▶ 出力ビューアのご概念ツリー図で [モデルの適合度] ノードを拡張してから、[CMIN] をクリックします。自動生成され、識別された7つのモデルについての一部の適合度が、飽和モデルと独立モデルの適合度とともに、CMIN テーブルに次のように表示されます。

モデル	NPAR	CMIN	DF	P	CMIN/DF
測定モデルの切片項	22	34.775	6	0.000	5.796
構造モデルのウェイト	21	36.340	7	0.000	5.191
構造モデルの切片項	20	84.060	8	0.000	10.507
構造モデルの平均値	19	94.970	9	0.000	10.552
構造モデルの共分散	18	99.976	10	0.000	9.998
構造モデルの残差	17	112.143	11	0.000	10.195
測定モデルの残差	13	122.366	15	0.000	8.158
飽和モデル	28	0.000	0		
独立モデル	16	682.638	12	0.000	56.887

このテーブルには多数のカイ2乗統計量がありますが、重要なのは2つだけです。Sörbom の手続きから、2つの基本的な問題に行き当たります。1つは、[構造モデルのウェイト]モデルを適合できるかどうかについてです。このモデルでは、pre\_verbal (言語能力(事前))から post\_verbal (言語能力(事後))を予測するための回帰ウェイトの値が、グループ間で一定になるよう指定しています。

[構造モデルのウェイト]モデルが採択されるとなると、階層での次のモデルである [構造モデルの切片項]モデルの適合度は大幅に低くなるのではないかと考えられます。一方、[構造モデルのウェイト]モデルを棄却する必要がある場合は、[構造モデルの切片項]モデルが問題に上らなくなってしまう。残念ながら、ここではこのケースが発生しています。 $c^2 = 36.34$ 、 $df = 7$ の [構造モデルのウェイト]モデルは、従来のいずれの有意水準においても棄却されます。

## 修正指数の調査

[構造モデルのウェイト] モデルの適合度を改善できるかどうかを調べる方法は、次のとおりです。

- ▶ 出力ビューアを閉じます。
- ▶ Amos Graphics メニューから、[表示] → [分析のプロパティ] の順に選択します。
- ▶ [出力] タブをクリックしてから、[修正指数] チェック ボックスを選択します。
- ▶ [分析のプロパティ] ダイアログ ボックスを閉じます。
- ▶ メニューから [分析] → [推定値を計算] の順に選択して、すべてのモデルを適合します。  
このモデルは分析に適合度が必要な唯一のモデルであるため、調査が必要となるのは [構造モデルのウェイト] モデルの修正指数だけです。
- ▶ メニューから、[表示] → [テキスト出力の表示] の順に選択してから、出力ビューアの概念ツリー図で [修正指数] を選択します。さらに、左下のパネルで [構造モデルのウェイト] を選択します。
- ▶ [修正指数] ノードを拡張して、[共分散] を選択します。

統制群における次の共分散テーブルに見られるとおり、デフォルトのしきい値である 4 を上回っている修正指数は 1 つだけです。

	M.I.	改善度
eps2 <--> eps4	4.553	2.073

- ▶ 左のパネルで、[experimental] をクリックします。実験群における次の共分散テーブルに見られるとおり、4 を上回っている修正指数は 4 つあります。

	M.I.	改善度
eps2 <--> eps4	9.314	4.417
eps2 <--> eps3	9.393	-4.117
eps1 <--> eps4	8.513	-3.947
eps1 <--> eps3	6.192	3.110

この中で、明らかな論理的調整が見られるのは、eps2 を eps4 と関連させる修正と、eps1 を eps3 と関連させる修正の 2 つだけです。この 2 つのうち修正指数が大きいのは、eps2 を eps4 と関連させる修正の方です。これにより、統制群と実験群のどちらの修正指数からも、eps2 を eps4 と関連させることが推奨されます。

## モデルの変更と分析の繰り返し

- ▶ 出力ビューアを閉じます。
- ▶ メニューから [図] → [共分散を描く] の順に選択します。
- ▶ クリックしたままドラッグして、eps2 と eps4 の間に双方向矢印を描きます。
- ▶ メニューから [分析] → [複数グループの分析] の順に選択し、表示されるメッセージボックスで [OK] をクリックします。
- ▶ [複数グループの分析] ダイアログ ボックスで [OK] をクリックします。
- ▶ メニューから [分析] → [推定値を計算] の順に選択して、すべてのモデルを適合します。
- ▶ メニューから [表示] → [テキスト出力の表示] の順に選択します。
- ▶ 出力ビューアのご概念ツリー図を使用して、[構造モデルのウェイト] モデルの適合度を表示します。

eps2 と eps4 を結ぶ双方向矢印が追加されたことで、次の CMIN テーブルに表されるように、[構造モデルのウェイト] モデルの適合度 ( $c^2 = 3.98$ 、 $df = 5$ ) が適切な値となりました。

モデル	NPAR	CMIN	DF	P	CMIN/DF
測定モデルの切片項	24	2.797	4	0.59	0.699
構造モデルのウェイト	23	3.976	5	0.55	0.795
構造モデルの切片項	22	55.094	6	0.00	9.182
構造モデルの平均値	21	63.792	7	0.00	9.113
構造モデルの共分散	20	69.494	8	0.00	8.687
構造モデルの残差	19	83.194	9	0.00	9.244
測定モデルの残差	14	93.197	14	0.00	6.657
飽和モデル	28	0.000	0		
独立モデル	16	682.638	12	0.00	56.887

[構造モデルのウェイト] モデルがデータに適合するようになったため、今度は、[構造モデルの切片項] モデルの適合度が大幅に低くなるのではないかとことが考えられます。[構造モデルのウェイト] モデルが正しい場合、次のようになります。

モデル	DF	CMIN	P	NFI Delta-1	IFI Delta-2	RFI rho-1	TLI rho2
構造モデルの切片項	1	51.118	0.000	0.075	0.075	0.147	0.150
構造モデルの平均値	2	59.816	0.000	0.088	0.088	0.146	0.149
構造モデルの共分散	3	65.518	0.000	0.096	0.097	0.139	0.141
構造モデルの残差	4	79.218	0.000	0.116	0.117	0.149	0.151
測定モデルの残差	9	89.221	0.000	0.131	0.132	0.103	0.105

[構造モデルの切片項] モデルの適合度は、確かに [構造モデルのウェイト] モデルを大きく下回っています。post\_verbal (言語能力(事後))を予測する方程式における切片項をグループ間で一定にする必要がある場合、自由度が1しか増加していないのに対し、カイ2乗統計量は51.12増加しています。つまり、実験群の切片項が統制群の切片項と大きく異なるということです。実験群の切片項は3.627と推定されます。

	推定値	標準誤差	検定統計量	P	ラベル
言語能力(事後)	3.627	0.478	7.591	<0.001	j1_2
pre_syn(同意語(事前))	18.619	0.594	31.355	<0.001	i1_1
反意語(事前)	19.910	0.541	36.781	<0.001	i2_1
同意語(事後)	20.383	0.535	38.066	<0.001	i3_1
post_opp(反意語(事後))	21.204	0.531	39.908	<0.001	i4_1

統制群の切片が0に固定されていたことを思い出すと、これによって、pre\_verbal(言語能力(事前))の得点を固定した状態では、post\_verbal(言語能力(事後))の得点は3.63増加すると推定されます。

この例から得られた結果は、例16での結果と同じです。[構造モデルのウェイト] モデルは、例16のモデルDと同じです。[構造モデルの切片項] モデルは、例16のモデルEと同じです。

# ベイズ推定

## 概要

この例は、Amos でのベイズ推定について説明します。

## ベイズ推定

最尤法の推定と仮説検定では、モデルパラメータの真の値は固定だが未知と考えられ、このようなパラメータの所定の標本からの推定はランダムだが既知と考えられます。ベイズ・アプローチと呼ばれる別の統計的推論では、未知の数量をランダムな変数と見なし、確率分布に割り当てます。ベイズ法の観点では、真のモデルパラメータは未知なのでランダムであると見なし、同時確率分布に割り当てます。この分布は、何らかの方式でパラメータが変化することを示すわけではありません。むしろこの分布は、収集した情報の状態、すなわちパラメータについて現在わかっている情報を要約するためのものです。データが観測される前のパラメータの分布を事前分布といいます。データの観測後、データから得られる証拠は、ベイズの定理という有名な公式によって事前分布と結合されます。その結果、更新されたパラメータの分布である事後分布には、事前の確信と経験的な証拠が反映されています (Bolstad および Curran, 2017)。

モデルの複数のパラメータの同時事後分布を視覚的にとらえたり解釈したりするのは、人間には難しいものです。したがって、ベイジアン解析を実行する際には、解釈が容易になるよう事後分布を要約する必要があります。はじめに各パラメータの周辺事後密度を一度に1つずつ作図するのがよい方法です。特に、データ標本が多い場合には、パラメータの周辺事後分布は正規分布に近似する傾向があります。周辺事後分布の平均は事後平均といい、パラメータ推定として報告できます。分布の標準偏差である事後の標準偏差は、従来の標準誤差に似た、不確実性を測定する有用な方法です。

周辺事後分布のパーセンタイルから信頼区間に類似する値を計算できます。2.5 パーセンタイルから 97.5 パーセンタイルの範囲の区間は、95% のベイズの信頼区間を形成します。周辺事後分布はほぼ正規分布に近似し、95% のベイズの信頼区間は事後平均  $\pm 1.96$  事後標準偏差にほぼ等しくなります。この場合、ベイズの信頼区間は、パラメータ推定値の正規標本分布を前提とする通常の信頼区間と基本的に同じになります。事後分布が正規分布でない場合、区間は事後平均に関して対称になりません。この場合、ベイズ推定の特徴のほうが従来の手法よりも適切なことがあります。

従来の信頼区間とは異なり、ベイズの信頼区間はパラメータ自体に関する確率分布として解釈されます。 $\text{Prob}((a \leq \theta \leq b) = 0.95)$  は、文字どおり、 $\theta$  の真の値が  $a$  と  $b$  の間にある確率が 95% であることを意味します。周辺事後分布の両裾の部分のベイズの  $p$  値の一種として仮説検定に使用することもできます。 $\theta$  に対する周辺事後密度の領域の 96.5% が  $a$  値の右側にある場合、帰無仮説  $\theta \leq a$  の検定のベイズの  $p$  値は対立仮説  $\theta > a$  に対して 0.045 です。この場合、「対立仮説が真である確率は 96.5% である」と言うこともできます。

ベイジアン推論の考え方は 18 世紀後半までさかのぼりますが、統計には近年までほとんど使用されていませんでした。ベイズの手法の適用に抵抗があるのは、確率を確信の状態として示すことへの哲学的な嫌悪や、事前分布の選択に主観が付きまとうことに由来しています。しかし、ベイジアン解析があまり使用されなかった理由の大半は、同時事後分布を要約する計算方法が困難であるか利用不可能であったことです。しかし、マルコフ連鎖モンテカルロ (MCMC) 法と呼ばれる新しいシミュレーション技法を使用して、高次元の同時事後分布や複合的な問題においてもパラメータのランダム値を作図できるようになりました。MCMC では、事後分布の要約の作成が、ヒストグラムの作図や標本の平均値およびパーセンタイルの計算と同様に簡単になりました。

## 事前分布の選択

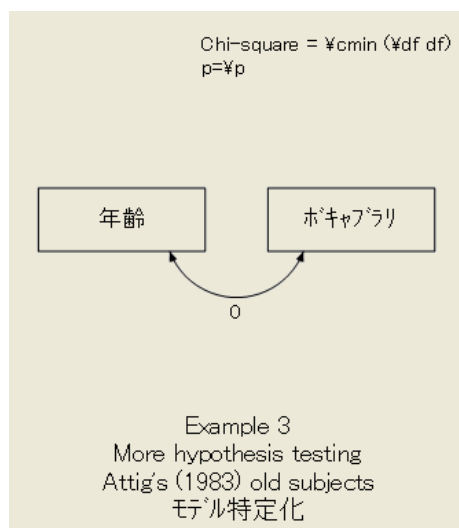
事前分布では、不明のパラメータがある場合の研究者の確信を数量化します。母集団で変数がどのように分布するか知識があると、対象となるパラメータの妥当な事前分布を選択する上で研究者の助けになることがあります。Hox (2002) は、一般的な母集団における平均が 100 で標準偏差が 15 のノルムに準拠した知能検定の例を挙げています。一般的な母集団を代表するのは誰かという調査で被験者に検定を実施する場合、検定スコアの平均が 100 で標準偏差が 15 である事前分布の中心に位置すると考えるのが妥当です。観察対象の変数に限界があることを知ると、パラメータに境界を設定する上で役立つことがあります。たとえば、リッカート法で 0、1...10 の値をとる調査項目の平均は 0 から 10 の間にあるはずであり、最大分散は 25 です。この項目の平均と分散の事前分布をこれらの限界に準拠するよう設定できます。

多くの場合、取り入れる情報ができるだけ少ない事前分布を設定し、データがそれ自体を表せるようにする傾向があります。事前分布の確率が非常に広い範囲のパラメータ値をとる場合、拡散しているといえます。Amos ではデフォルトで、各パラメータに対して  $-3.4 \times 10^{-38}$  から  $3.4 \times 10^{38}$  の一様分布を適用します。

拡散事前分布は、無情報事前分布と呼ばれることも多いので、この用語も同様に使用します。しかし、厳密な意味では、事前分布は完全に無情報であることも、許容される値の全範囲にわたる一様分布になることもありません。パラメータが変換された場合に一様でなくなってしまうためです。(たとえば、変数の分散が 0 から  $\infty$  まで均等に分布すると仮定します。このとき、標準偏差は均一に分布しません。)すべての事前分布は、少なくともなんらかの情報を伴います。データセットのサイズが大きくなると、結果的にデータからの証拠がこの情報を上回るため、事前分布の影響は小さくなります。標本が非常に少ない場合やモデルまたは事前分布がデータと矛盾している場合を除き、事前分布を変えてもベジアン解析からの解はほとんど変わらない傾向があります。Amos では、任意のパラメータの事前分布を容易に変えることができるため、このような感度のチェックが簡単に行えます。

## Amos Graphics によるベイズ推定の実行

Amos Graphics によるベイズ推定を説明するために、例 3 を再度取り上げます。この例では、2 つの変数間の共分散が、年齢とボキャブラリ間の共分散の値を 0 に固定することによって 0 になる帰無仮説の検定方法を示しています。



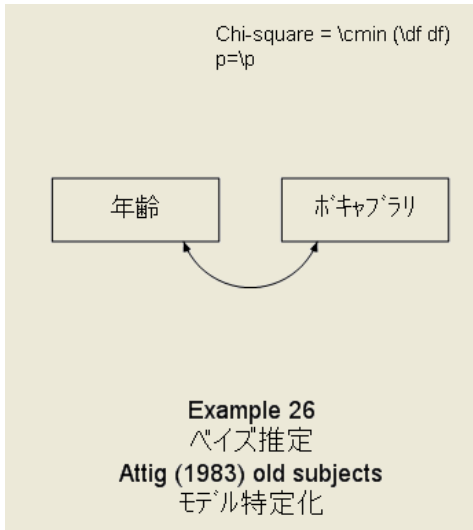
## 共分散の推定

現在の例に対して最初に行う必要があるのは、共分散を推定できるように共分散のゼロ制約を除去することです。

- ▶ %examples%\Ex03.amw を開きます。
- ▶ パス図の 2 方向の矢印を右クリックし、ポップアップメニューから [オブジェクトのプロパティ] を選択します。

- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[パラメータ] タブをクリックします。
- ▶ [共分散] テキスト ボックスで「0」を削除します。
- ▶ [オブジェクトプロパティ] ダイアログ ボックスを閉じます。

この結果得られるパス図は次のようになります (Ex26.amw でも参照できます)。



## 最尤法解析の結果

このモデルのベイジアン解析を実行する前に、比較目的で最尤法解析を実行します。

- ▶ メニューから [分析] → [推定値を計算] を選択すると、次のパラメータ推定値と標準誤差が表示されます。

共分散: (グループ番号 1 - デフォルト モデル)					
	推定値	標準誤差	検定統計量	P	ラベル
年齢 <-> ボキャブラリ	-5.014	8.560	-0.586	0.558	

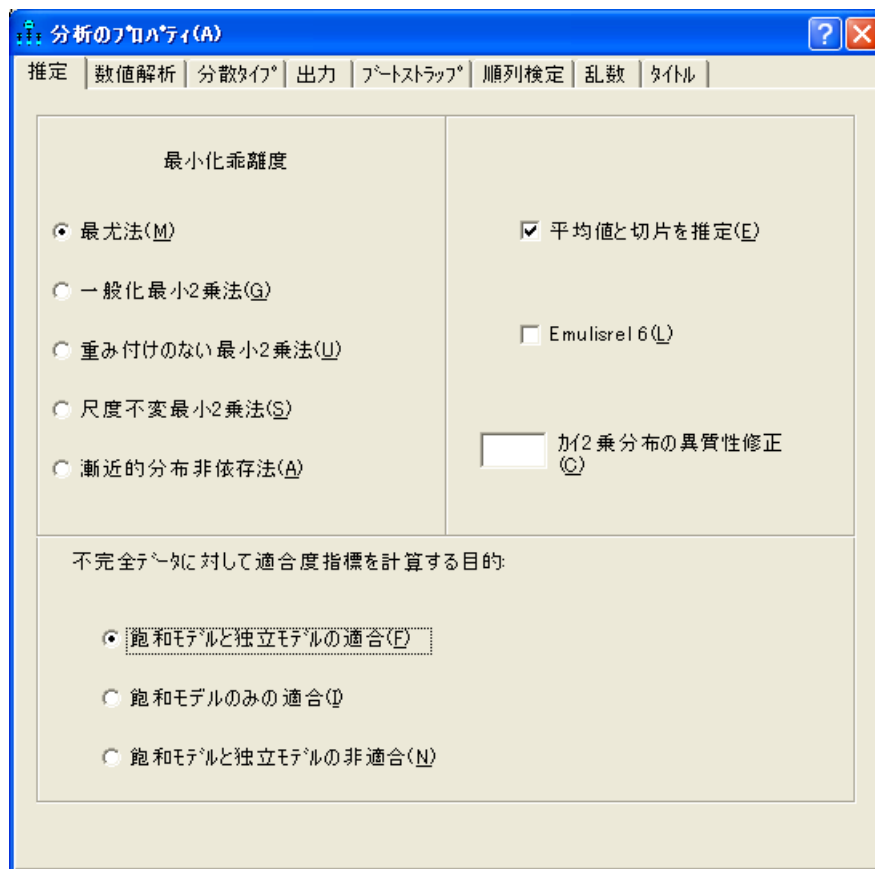
分散: (グループ番号 1 - デフォルト モデル)					
	推定値	標準誤差	検定統計量	P	ラベル
年齢	21.574	4.886	4.416	***	
ボキャブラリ	131.294	29.732	4.416	***	



## ベイジアン解析

ベイジアン解析では、明示的な平均値および切片の推定が必要です。Amos でベイジアン解析を実行するには、まず、平均値および切片を推定するよう指定します。

- ▶ メニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [平均値と切片を推定] を選択します。(横にチェック マークが表示されます。)



- ▶ ベイジアン解析を実行するには、メニューから [モデル適合度] → [ベイズ推定] を選択するか、キーボードで Ctrl+B キーを同時に押します。

[ベイジアン SEM] ウィンドウが表示され、MCMC アルゴリズムによって即座に標本が生成されます。

	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>平均値</b>												
年齢	70.999	0.034	0.770	1.001	71.009	69.403	72.474	-0.099	0.192	67.722	73.809	
ホキョバラ	62.664	0.096	2.009	1.001	62.699	58.785	66.558	0.068	0.445	55.156	71.669	
<b>共分散</b>												
年齢<->ホキョバラ	-5.717	0.364	10.914	1.001	-5.463	-27.916	15.761	-0.101	0.588	-54.600	37.981	
<b>分散</b>												
年齢	25.657	0.345	6.140	1.002	24.794	16.135	39.947	0.996	2.158	11.564	64.344	
ホキョバラ	156.291	2.795	39.432	1.003	150.262	96.083	251.691	0.959	1.429	66.526	350.580	

[ベイジアン SEM] ウィンドウには、ウィンドウ上部近くにツールバーがあり、その下に結果の要約表が表示されます。要約表の各行は、単一のモデルパラメータの周辺事後分布を表します。[平均値] というラベルの付いた最初の列には、事後分布の中央または平均である、事後平均が表示されます。これは、データと事前分布に基づく、ベイジアンのパラメータポイント推定として使用できます。データセットが大きい場合、事後平均は最尤推定値に近づく傾向があります。(この場合、2つの値はある程度近い値です。年齢 - ホキョバラの共分散の事後平均  $-6.536$  と前出の最尤推定値  $-5.014$  を比較してください。)

## ベイジアン解析とデータ代入の結果の複製

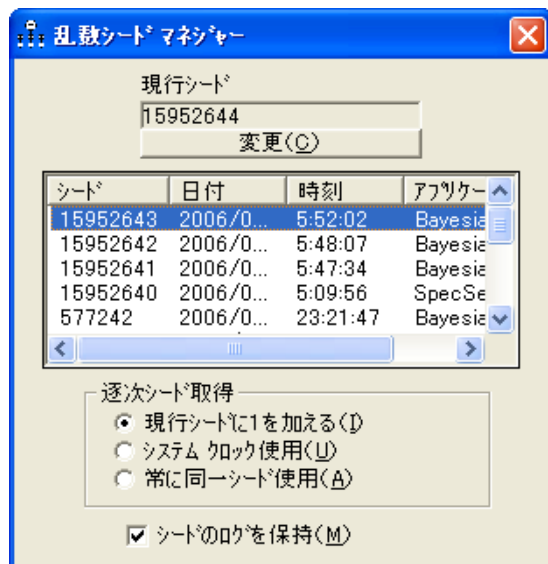
Amos に実装されている多重代入とベイジアン推定のアルゴリズムは、初期の乱数のシードによって変わる一連の乱数を多用します。Amos のデフォルトの動作では、ベイジアン推定、ベイジアン法データ代入、または確率的回帰法データ代入を実行するたびに乱数シードを変更します。その結果、このような解析のいずれかを複製すると、異なる乱数シードを使用しているため、若干異なる結果が得られることが予想できます。

何らかの理由で前の解析とまったく同じ複製が必要な場合は、前の解析で使用したものと同一乱数シードで開始します。

## 現行シードの調査

現行の乱数シードが何であるかを調べたり、値を変更したりするには、次のようにします。

- ▶ メニューから [ツール] → [乱数シード マネジャー] を選択します。



デフォルトで、Amos では、乱数を使用するシミュレーションメソッド (ベイズ SEM、確率的回帰法データ代入、またはベイズ法データ代入のいずれか) の呼び出しごとに現行の乱数シードに 1 ずつ加算します。Amos では、以前に使用したシードのログを保持しているため、前に生成した解析結果または代入されたデータセットのファイル作成日と、乱数シード マネジャーで報告された日付を突き合わせるすることができます。

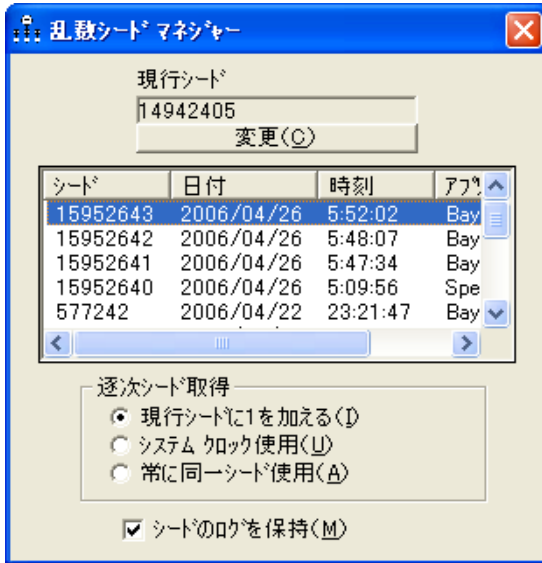
## 現行シードの変更

- ▶ [変更] をクリックし、以前に使用したシードを入力してから解析を実行します。

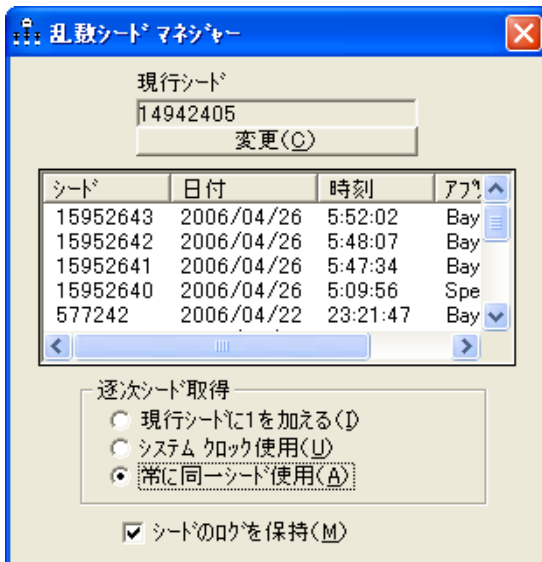
Amos では、そのシードを用いて最後に開始したときに使用したものと同一連の乱数が使用されます。たとえば、この例の解析を実行したとき、Amos が使用したシード 14942405 を調べるために乱数シード マネジャーを使用しました。その時と同じベイズ解析の結果を生成するには、次のようにします。

- ▶ [変更] をクリックし、現在のシードを 14942405 に変更します。

次の図は、変更後の [乱数シード マネジャー] ダイアログ ボックスを示しています。



先を見越して、ベイジアン解析またはデータ代入解析の実行前に固定のシード値を選択する方法もあります。[常に同一シード使用] オプションを選択すると、Amos ですべての解析に同じシード値を使用することもできます。



このシードの値を確実な場所に記録しておくこと、解析の結果を後日再現することができます。

ヒント：このガイドでは、すべての例で同じシード値 14942405 を使用しているため、この結果を再現することができます。

前述したように、Amos で採用している MCMC アルゴリズムでは、パラメータの事後分布のモンテカルロ シミュレーションを経た、高次元の同時事後分布からのパラメータの乱数値を描画します。たとえば、[平均値] 列に示される値は、厳密な事後平均ではなく、MCMC の手続きから生成される乱数の標本を平均して得られる推定値です。事後平均の不確実性がどの程度モンテカルロ法のサンプリングに起因するか、大まかにでも理解することが重要です。

[標準誤差] というラベルの付いた第 2 列は、モンテカルロ法で推定される事後平均が実際の事後平均からどの程度隔たっている可能性があるかを示唆する標準誤差の推定値を示しています。MCMC の手続きでさらに多くの標本が生成されるにつれ、事後平均の推定の精度が向上し、[標準誤差] は徐々に低下します。この標準誤差は、事後平均がパラメータの実際の未知の値からどの程度隔たっているかを推定するものではないので注意が必要です。つまり、パラメータの 95% の区間の幅として、± の標準誤差の値を使用することはありません。

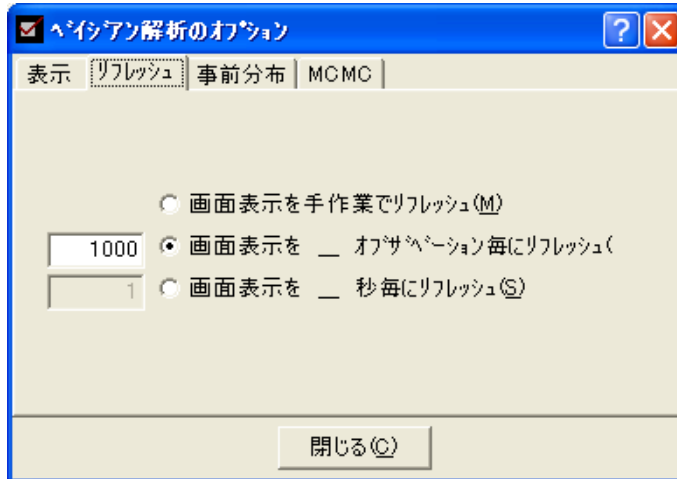
事後平均と実際の未知のパラメータの間の考えうる隔たりは、[標準偏差] というラベルの付いた第 3 列に示されます。この数値は最尤推定値の標準誤差に近くなります。そのほかの列には、[収束統計量] (C.S.)、各パラメータの中央値、各パラメータ分布の 50% の上限と下限、各パラメータの歪度、尖度、最小値、最大値が示されます。50% の上限と下限はベイズの 50% の信頼セットの終点であり、従来の手法の 50% の信頼区間に類似しています。信頼係数は 95% を使用するのが一般的なので、95% に変更する方法を後述します。

[分析] → [ベイズ推定] を選択すると、MCMC アルゴリズムによって即座にサンプリングが開始され、ユーザーが [サンプリングの一時停止] ボタンをクリックして処理を停止するまで続けられます。362 ページの図は、 $500 + 5831 = 6331$  のサンプリングが完了した後で、サンプリングが停止しています。Amos では、解析用に保存された最初の標本を描画する前に、500 のバーンイン 標本を生成して破棄しました。Amos では、MCMC 手続きが実際の同時事後分布に収束できるようにするバーンイン 標本を描画します。バーンイン標本を描画して破棄した後で、この同時事後分布の外観を際立たせるための追加の標本を描画します。362 ページに示す例では、Amos が 5,831 のこのような解析標本を描画した後で、要約表の結果が基にする解析標本の上に描画されています。実際に、表示される結果は 500 のバーンイン 標本と 5,500 の解析標本です。Amos が使用するサンプリング アルゴリズムは非常に高速なので、サンプリングのたびに要約表を更新すると、[ベイジアン SEM] ウィンドウに表示される結果は、急速に変化する意味不明のにじんだ画像になります。これは解析の速度も低下させます。2つの問題を回避するため、Amos では 1,000 回のサンプリングごとに結果をリフレッシュします。

## リフレッシュ オプションの変更

リフレッシュの間隔を変更するには

- ▶ メニューから [表示] → [オプション] を選択します。
- ▶ [オプション] ダイアログ ボックスで [リフレッシュ] タブをクリックすると、リフレッシュ オプションが表示されます。



リフレッシュの間隔をデフォルトの 1,000 オブザベーション以外の値に変更できます。あるいは、指定した一定の時間間隔で表示をリフレッシュすることもできます。


[画面表示を手作業でリフレッシュ] を選択すると、表示は自動的に更新されなくなります。[リフレッシュ] タブで何を選択するかに関わらず、[ベイジアン SEM] ツールバーの [リフレッシュ] ボタンをクリックすることによって、手作業でいつでも画面表示をリフレッシュできます。

## 収束の評価

パラメータの安定した推定を得るための十分な標本がありますか？ この質問に答える前に、手続きが収束するとはどういう意味かを簡潔に説明します。MCMC アルゴリズムの収束は、最尤法など無作為でない方法の収束とはまったく異なります。MCMC の収束を正しく理解するには、2 つの異なるタイプを区別する必要があります。

第 1 のタイプは、分布の収束といい、分析標本がパラメータの実際の同時事後分布から引き出されることを意味します。分布の収束は、アルゴリズムが徐々に初期値から離れていくバーンインの期間に発生します。この段階の標本は実際の事後分布を表していない可能性があるため、破棄されます。デフォルトの 500 のバーンイン期間は保守的な見積りなので、ほとんどの問題に必要な期間よりずっと長くなっています。バーンイン期間が終わり、Amos が分析標本の収集を開始すると、事後平均などの要約統計量を正確に推定するのに十分な標本があるかどうかの問題になります。

問題は事後分布の要約の収束と呼ばれる第2のタイプの収束に関係します。分析標本が独立しているのではなく、実際は自己相関性がある時系列になっているという事実によって、事後分布の要約の収束は複雑です。1001番目の標本は1000番目と、1000番目は999番目と、順々に相関しています。このような相関はMCMCの固有の機能で、この相関のために、5,500(または任意の数)の分析標本からの要約統計量は、5,500の標本が独立している場合よりも変動が大きくなります。しかし、分析標本を引き続き累積していくと、事後分布の要約は徐々に安定します。

Amosは、収束のチェックを支援するいくつかの診断を備えています。362ページの[ベイジアンSEM]ウィンドウのツールバー上の1.0025という値に注目してください。これは、Gelmanほか(2013)によって提唱された基準に基づく全体の収束統計量です(2004)。画面をリフレッシュするたびに、要約表で各パラメータの収束統計量が更新されます。ツールバー上の収束統計量の値は個々の収束統計量の値の最大値です。デフォルトで、収束統計量の最大値が1.002未満の場合に、Amosは手続きが収束したと判断します。この基準では、1.0025という最大収束統計量は、十分小さくはありません。全体の収束統計量が十分小さくない場合には、不機嫌な顔が表示されます。収束統計量では、分析標本の部分の範囲内の変動と、複数の部分にまたがった変動を比較します。1.000の値は完全な収束を表します。それより大きい値は、より多くの分析標本を作成することによって事後分布の要約をさらに正確にできることを示します。

[サンプリングの一時停止]ボタンを2回めにクリックすると、サンプリング処理が再開されます。[分析]メニューから[サンプリングの一時停止]を選択したり、キーボードからCtrl+Eキーを同時に押したりすることによっても、サンプリングの一時停止および再開が可能です。次の図は、しばらくの間サンプリングを再開し、再度停止した後の結果を示しています。



	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>平均値</b>												
年齢	71.005	0.014	0.813	1.000	71.008	69.392	72.569	-0.028	0.081	67.320	74.561	
ホキョウリ	62.596	0.038	2.001	1.000	62.584	58.660	66.574	0.021	0.070	54.387	71.396	
<b>共分散</b>												
年齢<->ホキョウリ	-6.450	0.301	11.398	1.000	-5.979	-30.437	15.008	-0.399	1.812	-105.794	47.272	
<b>分散</b>												
年齢	26.232	0.217	6.663	1.001	25.259	16.222	42.082	1.040	1.977	10.510	71.638	
ホキョウリ	158.383	1.016	38.135	1.000	153.323	99.161	246.824	0.838	1.127	64.440	390.503	

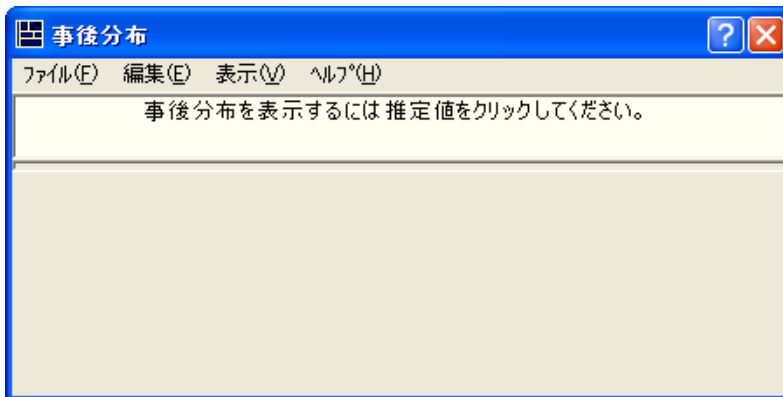
この時点で 74,501 の分析標本がありますが、表示が直近で更新されたのは 74,500 番目の標本の時点です。最大の収束統計量は 1.0005 で、許容される収束基準の 1.002 を下回っています。満足できる収束を示す上機嫌の顔 😊 が表示されています。Gelman ほか (2013) は、多くの分析において、1.10 以下の値で十分であると提言しています。デフォルト基準の 1.002 は保守的な値です。この基準によって MCMC が収束したことを判断しても、要約表の変化が停止するわけではありません。MCMC アルゴリズムを実行している限り、要約表は変化し続けます。ただし、ツールバー上の全体の収束統計量の値が 1.000 に近づくにつれて、標本を追加しても精度はそれほど上がらなくなるので、分析を停止します。

## 診断の作図

収束統計量の値に加えて、Amos はベイジアン MCMC 手法の収束のチェックを支援するいくつかの作図機能を備えています。各種の作図を表示するには、次のようになります。

- ▶ メニューから [表示] → [事後分布] を選択します。

[事後分布] ダイアログ ボックスが表示されます。

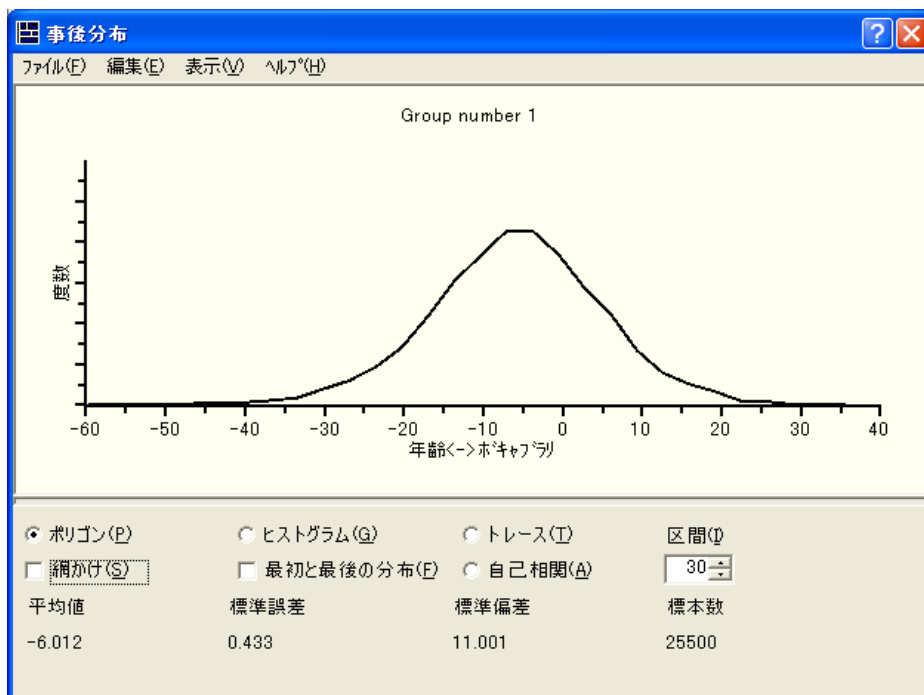




- ▶ [ベイジアンSEM] ウィンドウから [年齢<->ボキャブラリ] パラメータを選択します。

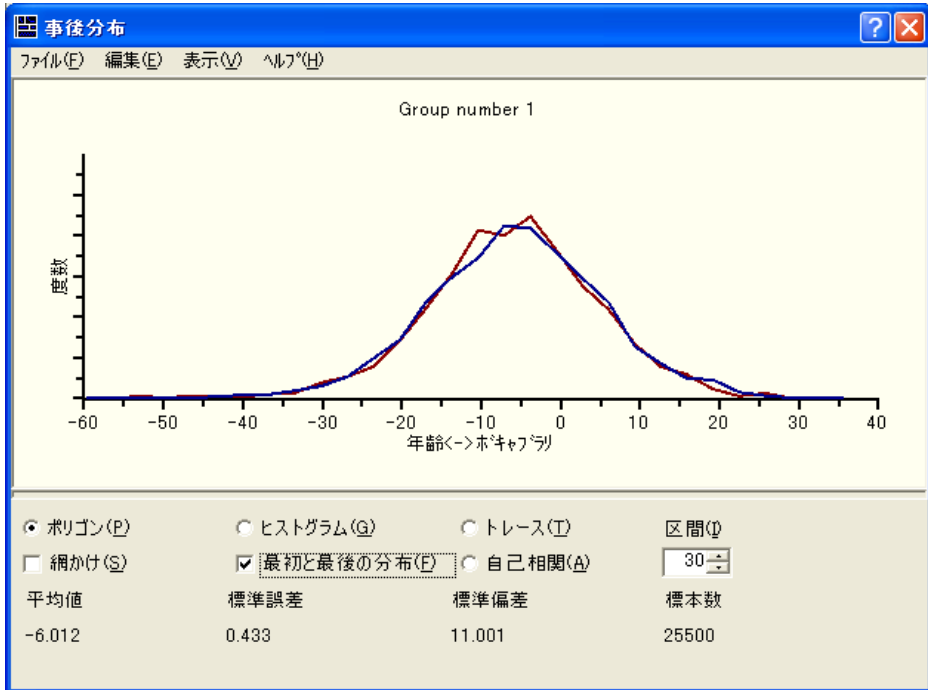
	平均値	標準誤差	標準偏差	収束統計量	50% 下限	50% 上限	歪度	尖度	最小値	最大値	名前
<b>平均値</b>											
年齢	70.968	0.019	0.792	1.000	70.438	71.500	-0.003	0.098	67.888	73.897	
ボキャブラリ	62.714	0.066	1.927	1.001	61.448	63.942	0.084	0.312	55.296	70.708	
<b>共分散</b>											
年齢<->ボキャブラリ	-6.012	0.433	11.001	1.001	-12.779	1.092	-0.258	0.766	-59.642	35.576	
<b>分散</b>											
年齢	25.979	0.180	6.166	1.000	21.556	29.707	0.783	0.953	11.786	56.839	
ボキャブラリ	157.426	1.661	40.763	1.001	128.823	178.713	1.325	4.153	69.687	455.350	

ここで、[事後分布] ダイアログ ボックスに、22,500 標本での年齢-ボキャブラリの共分散の分布を表す頻度多角形 (ポリゴン) が表示されます。



事後分布に収束した可能性を視覚的に判断するために、累積された標本の最初の 3 分の 1 から得た分布の推定と、最後の 3 分の 1 から得た分布の推定を 2 つ同時に表示する方法があります。周辺事後分布 2 つの推定を同じグラフ上に表示するには、次のようになります。

- ▶ [最初と最後の分布] を選択します。(オプションの横にチェックマークが表示されます。)




この例では、分析標本の最初の3分の1と最後の3分の1の分布はほとんど同じです。これは、年齢 - ボキャブラリの共分散の事後分布の重要な特徴を Amos でうまく特定できたことを示しています。この事後分布は、-6 に近い値を中心に見えます。これは、このパラメータの [平均値] の値に一致します。視覚的にみて、標準偏差はほぼ 10 であることがわかります。これは [標準偏差] の値に一致します。

サンプリングされた値の過半数が 0 の左側にあります。これは、共分散パラメータの真の値が負数であることの緩やかな証拠にはなりますが、0 の右側の比率もかなり大きいので、この結果が統計上有意であることにはなりません。サンプリングされた値の 0 の右側の部分に対する比率が非常に小さければ (たとえば、5% 未満)、共分散パラメータが 0 以上であるという帰無仮説を棄却できますが、この場合はできません。

収束の評価に役立つ作図として、ほかにトレース図があります。時系列図とも呼ばれるトレース図は、パラメータのサンプリングされた値を時間と共に表示します。この図では、分布で MCMC の手続きがどれだけ早く収束するか、つまり、どれだけ早く開始値に依存しなくなるかを判断する上で役立ちます。

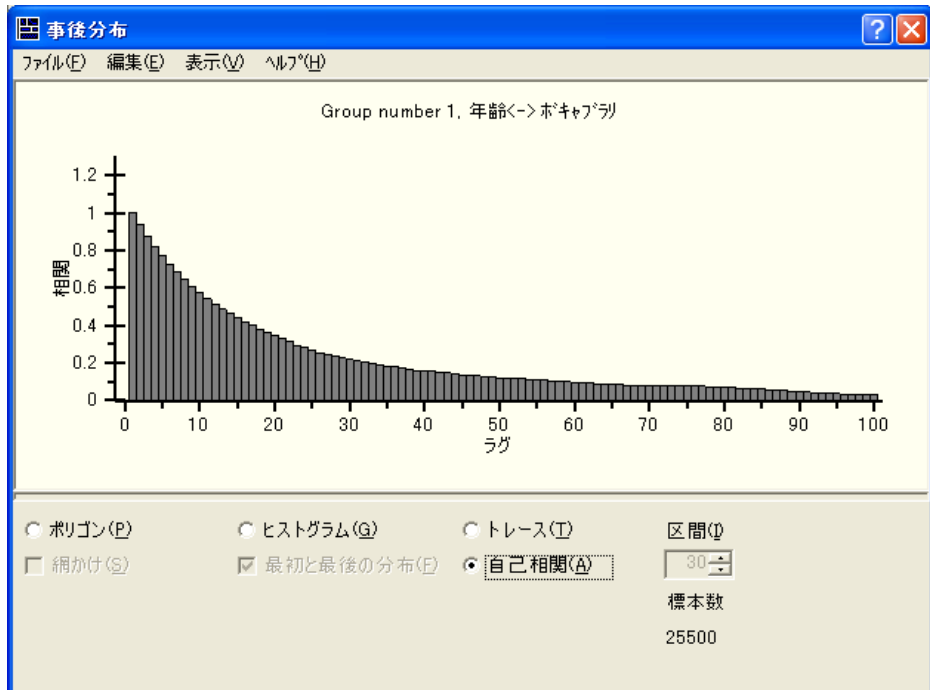
- ▶ トレース図を表示するには、[トレース]を選択します。



ここに示す図はかなり典型的なものです。急速な上下の変動を示し、長期間の傾向や動向は見られません。この図を目分量で横方向にいくつかのセクションに分けても、任意のセクションのトレースの外観は別のセクションのトレースとそれほど変わりません。これは、分布の収束が急速に起こっていることを示します。図の中に長期間の傾向や動向がある場合は、収束が遅いことを示します。(長期間とは、この図の水平方向のスケールに対して相対的なものであり、標本数に依存します。多くのサンプリングを行うと、トレース スポットはアコーディオンのように縮み、やがて、急速に上下に変動するような外観の動向または傾向が現れます。急速な上下の動きが意味するのは、 $k$  の値が標本の総数と比べて小さい場合に、任意の反復でサンプリングされる値が  $k$  回後の反復でサンプリングされる値と関連していないということです。

標本間の相関が低下するまでどれだけ長くかかるかを知るには、自己相関図と呼ぶ第3の図を調べます。この図では、任意の反復でサンプリングされる値と、 $k = 1, 2, 3, \dots$  の場合に  $k$  回後の反復でサンプリングされる値の間の推定される相関が表示されます。

- ▶ この図を表示するには、[自己相関]を選択します。



水平方向の軸に沿ったラグは、相関を推定する間隔を意味します。通常の状態では、自己相関係数が低下すると 0 に近づき、一定のラグを超えると 0 の近くに留まります。上の自己相関図では、ラグ-10 の相関 (任意のサンプリングされた値と 10 回後の反復から得られた値の相関) は、およそ 0.50 です。ラグ-35 の相関は 0.20 未満で、ラグ 90 以上では相関は実質的に 0 です。これは、少なくともこの共分散パラメータに関する限り、90 の反復によって MCMC の手続きが実質的に開始値に依存しなくなることを表しています。開始値に依存しなくなるとは、分布が収束するのと同じです。モデルの他のパラメータの自己相関図を調べると、ほぼ 90 回の反復で実質的に 0 に低下することがわかります。この事実から、500 標本のバーンイン期間は分布の収束に到達するのに十分であり、分析標本は実際の事後分布の標本であるという確信が得られます。

ある種の病理学上の条件では、MCMC の手続きは非常に緩やかに収束するか、まったく収束しないことがあります。これは、データセット内に高い比率で欠損値があり、その欠損値が特殊なパターンを形成している場合や、モデルの一部のパラメータの推定が正確でない場合などに起こります。このような状況では、モデル内の 1 つ以上のパラメータのトレース図に長期間の動向または傾向があり、標本を増やしても減少しません。トレース図がアコーディオンのように縮んでも、動向と傾向はなくなりません。このような場合、パラメータのサンプリングされた値の範囲 (トレース図の垂直方向のスケールによって、あるいは [ベイジアン SEM] ウィンドウの [標準偏差] または [最小値] と [最大値] の差によって示される) が非常に大きい可能性があります。自己相関は、大きいラグで高いままになったり、長い間、正の値と負の値の間で揺れ動く


ように見えたりすることがあります。このような現象が起こる場合は、モデルが複雑すぎて手元のデータでは対処できないことを示唆しているのです。より単純なモデルに適合させるか、さらに情報の多い事前分布を指定してパラメータに関する情報を付加することを検討します。

## 2 変量相関の周辺事後分布図

[ベイジアンSEM] ウィンドウの要約表と各 [事後分布] ダイアログ ボックスのポリゴンは、1 度に 1 つの推定値の周辺事後分布を表しています。周辺事後分布は非常に重要ですが、推定値どうしに関連があることを明らかにするものではありません。たとえば、共分散または回帰の 2 つの係数が、いずれか 1 つが 0 である可能性が高いという意味で同じ有意性を持つことはありますが、両方ということはありません。推定値のペアの間の関連性を視覚的に表すために、Amos は 2 変量相関の周辺事後分布図機能を備えています。

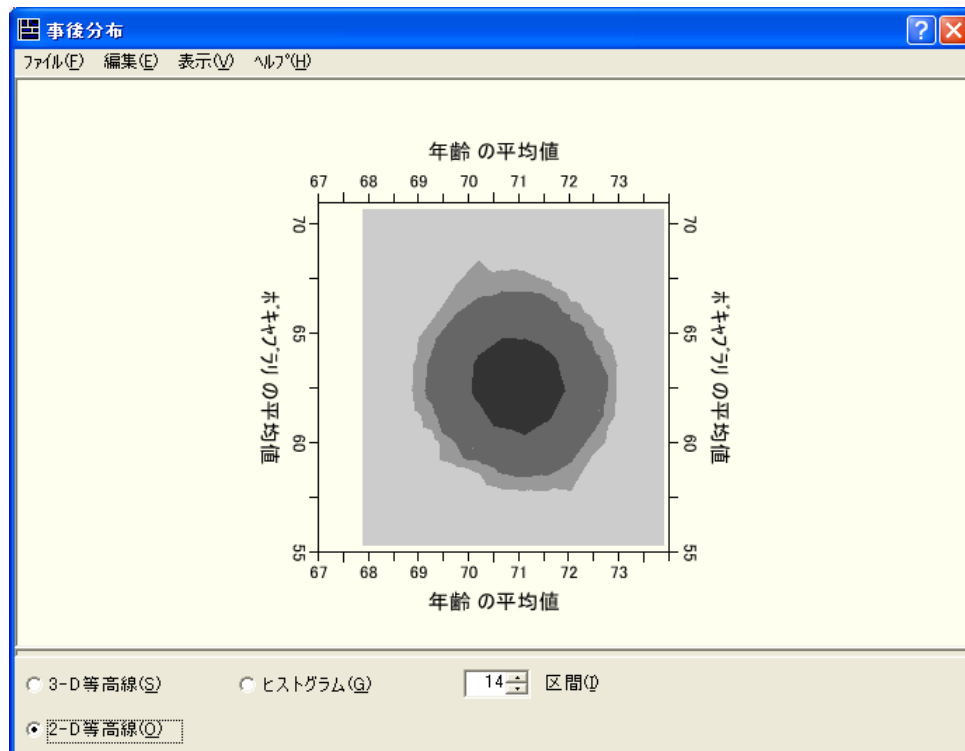
- ▶ 2 つのパラメータの周辺事後分布を表示するには、まず、パラメータのいずれか 1 つの事後分布を表示します (たとえば、年齢の分散)。
- ▶ キーボードで Ctrl キーを押しながら、要約表の第 2 のパラメータを選択します (たとえば、ボキャブラリの分散)。

すると、年齢とボキャブラリの分散の周辺事後分布を表す 3 次元面図が表示されます。



- ▶ [ヒストグラム] を選択すると、垂直方向のブロックを使用する同様の図が表示されます。

- ▶ [2-D 等高線] を選択すると、2 変量相関の周辺事後密度を表す 2 次元の図が表示されます。



3 つの灰色の網かけは、暗い色から明るい色に順にそれぞれ、50%、90%、95% の信頼領域を表します。この信頼領域は、従来の統計的推論の手法を用いた大部分のデータ分析でなじみのある 2 変量相関の信頼領域と概念的に似ています。

## ベイズの信頼区間

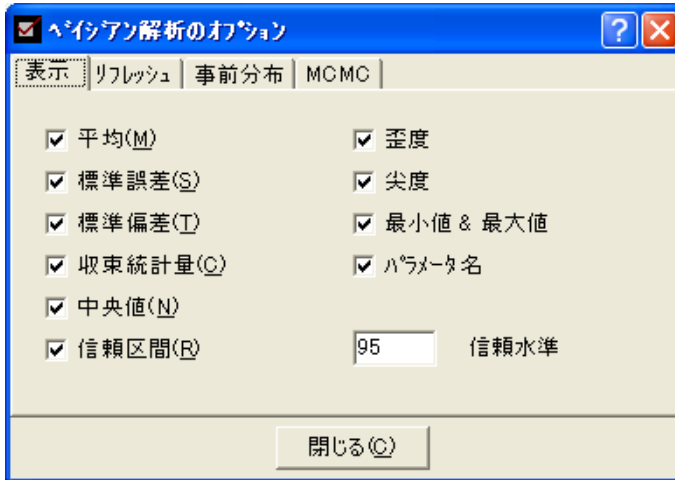
[ベジアン SEM] ウィンドウの要約表には、各推定値に対するベイズの信頼区間の上限および下限の終点が表示されます。デフォルトで、Amos は 50% の間隔を表示します。これは、従来の手法の 50% の信頼区間と同様です。

研究者は、95% の信頼区間を報告することが多いので、事後確率の内容の 95% に相当するように境界を変更することもできます。

## 信頼係数の変更

- ▶ [オプション] ダイアログ ボックスで [表示] タブをクリックします。

- ▶ [信頼係数] の値として「95」と入力します。



- ▶ [閉じる] ボタンをクリックします。これで、95% のベイズの信頼区間が表示されます。

	平均値	標準誤差	標準偏差	収束統計量	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>平均値</b>											
年齢	70.968	0.019	0.792	1.000	69.393	72.524	-0.003	0.098	67.888	73.897	
ホキョフツラ	62.714	0.066	1.927	1.001	58.931	66.635	0.084	0.312	55.296	70.708	
<b>共分散</b>											
年齢<->ホキョフツラ	-6.012	0.433	11.001	1.001	-28.955	15.429	-0.258	0.766	-59.642	35.576	
<b>分散</b>											
年齢	25.979	0.180	6.166	1.000	16.262	39.890	0.783	0.953	11.786	56.839	
ホキョフツラ	157.426	1.661	40.763	1.001	97.285	249.791	1.325	4.153	69.687	455.350	

## ベイジアン推定に関する参考資料

Gill (2004) は『Political Analysis』の特別号で、ベイジアン推定とその利点を読みやすい概要にまとめています。Jackman (2000) はジャーナルの論文で、トピックのより技術的な取り扱い方について例を挙げて提案しています。Gelman ほか (2013) による書籍では、膨大な例を持つ実際の問題を数多く取り扱っています。



# 非拡散事前分布によるベイズ推定

## 概要

この例では、非拡散事前分布を使用する例を説明します。

## 例について

例 26 では、Amos がデフォルトで使用する一様事前分布によって、単純なモデルにベイズ推定を実行する方法を示しました。この章の例では、さらに複雑なモデルについて考察し、非拡散事前分布を用います。特に、分散推定値が負の値やその他の不適切な値をとらない事前分布を設定する方法を示します。

## ベイズ推定についてのその他の情報

前章の例の説明では、ベイズ推定は分析者がデータとともに与える情報に依存することに注目しました。それに対して、最尤法の推定では、観測データ  $\psi$  が関係  $L(\theta|\mathbf{y}) \propto \pi(\mathbf{y}|q)$  を通して与えられる場合に未知のパラメータ  $q$  の尤度を最大にし、ベイズ推定では  $\mathbf{y}$  の事後密度  $\mathbf{p}(q|\mathbf{y}) \propto \pi(q)L(q|\mathbf{y})$  を見積もります。ここで、 $\mathbf{p}(q)$  は  $q$  の事前分布で、 $\mathbf{p}(q|\mathbf{y})$  は  $\mathbf{y}$  を所与とした  $q$  の事後密度です。概念として、これは  $q$  を所与とする  $\mathbf{y}$  の事後密度が  $q$  の事前分布と観測データの尤度の積であることを意味します (Jackman, 2000, p. 377)。

サンプルのサイズが大きくなるにつれ、尤度関数は ML 推定値の付近に、より高密度に集中します。その場合、拡散事前分布は尤度が高い領域ではほぼ平ら、すなわち一定になる傾向があり、事後分布の形状は主に尤度 (つまり、データそのもの) によって決定されます。

$\theta$  の一様な事前分布では、 $\pi(q)$  は完全に平らであり、事後分布は尤度を単純に再正規化したものです。一様でない事前分布でも、事前分布の影響はサンプルのサイズが大きくなるに従って小さくなります。さらに、サンプルサイズが増大すると、 $\theta$  の同時事後分布は正規分布に近似します。この理由で、ベイズ法と古典的な最尤法の分析では同等の漸近的結果が得られます (Jackman, 2000)。サンプル数が小さいと、ベイズ法の手続きに合理的な事前情報を与えられる場合は、ベイジアン解析からのパラメータ推定値のほうが正確になる可能性があります。(逆にいうと、適切でない事前情報は偏りを持ち込むことで悪い影響を及ぼします。)

## ベイジアン解析と不適解

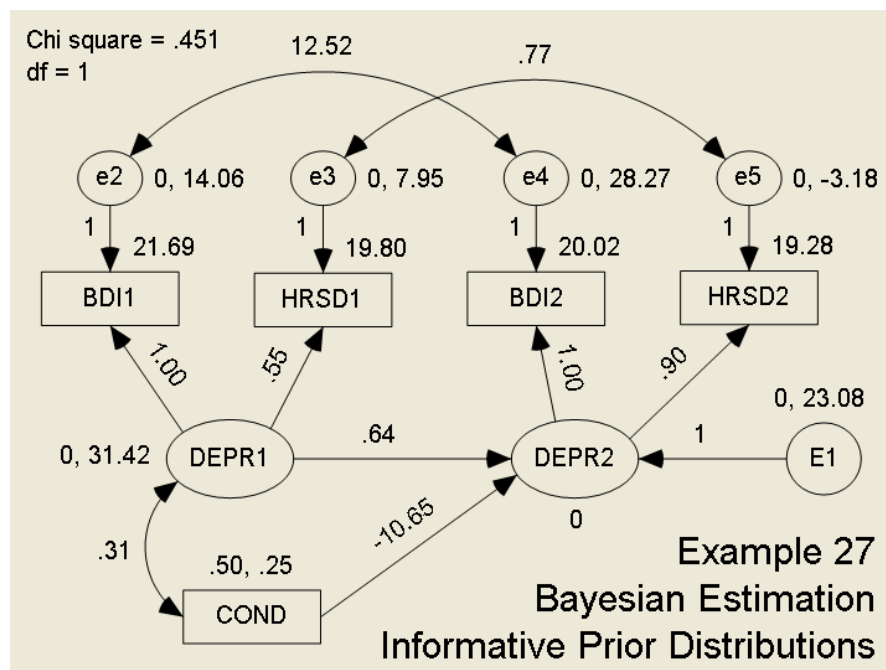
潜在変数モデルを当てはめる際によくある問題の 1 つが、不適解の出現です (Chen, Bollen, Paxton, Curran, Kirby, 2001)。たとえば、分散の推定値が負数である場合に不適解が出現します。分散が 0 より小さくなることはないため、そのような解は不適解と呼ばれます。不適解はサンプルが小さすぎるか、モデルが不適切であることを示す場合があります。ベイズ推定によって、不適切なモデルを改善することはできませんが、使用するサンプルが少ないことから生じる不適解を回避することはできます。Martin と McDonald (1975) は、探索的因子分析のためのベイズ推定について論じ、不適解にゼロの確率を割り当てる事前分布を選ぶことによって、推定を改善し、不適解を回避できると示唆しています。この章の例は、事前分布を適切に選択することにより不適解を回避する Martin と McDonald の手法を説明しています。

## データについて

Jamison と Scogin (1995) は、うつ病の被験者に自宅で課題を読んで完成させてもらう、新しい治療法の有効性についての実験的な研究を実施しました (「Feeling Good: The New Mood Therapy」(Burns, 1999, 2020))。Jamison と Scogin は、被験者に対照条件または実験条件をランダムに割り当て、被験者のうつ病のレベルを測定し、実験群に治療を施した後でレベルを再度測定しました。うつ病の測定は、1 つの測定方法には依存するのではなく、ベックうつ病評価尺度 (Beck Depression Inventory) (Beck, 1967) とハミルトンうつ病評価尺度 (Hamilton Rating Scale for Depression) (Hamilton, 1960) というよく知られた 2 つのうつ病評価尺度を使用しました。ここでは、それぞれ **BDI** および **HRSD** と略すこととします。データは、ファイル `feelinggood.sav` にあります。

## 最尤法によるモデルの適合

次の図は、最尤法の推定を用いて、時間 2 のうつ病での治療効果 (COND) にモデルを適合させた結果を表しています。時間 1 のうつ病は、共変量として使用します。時間 1 と時間 2 で、BDI および HRSD は、基礎となる単一の変数であるうつ病 (DEPR) を示す指標としてモデリングされます。



このモデルのパス図は、Ex27.amw にあります。自由度 1 のカイ 2 乗統計量 0.059 は良好な適合を示しますが、治療後の HRSD に対する負の残差分散は、解が不適であることを示します。

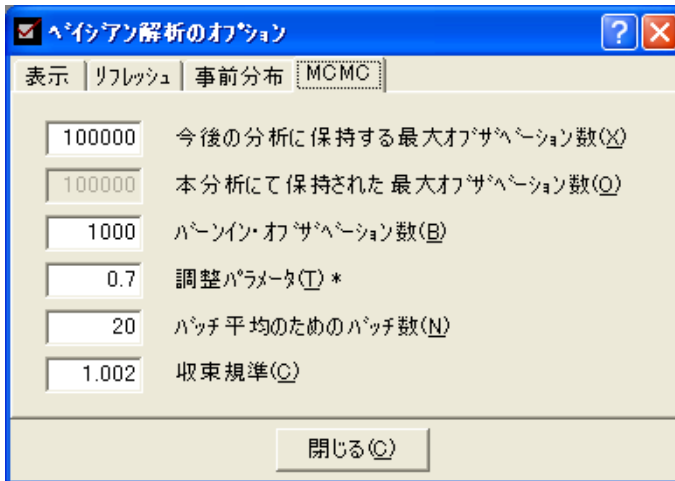
## 無情報 (拡散) 事前分布によるベイズ推定

拡散事前分布を用いたベイジアン解析では、最尤法の解と同様の結果が得られるでしょうか? これを確かめるため、同じモデルでベイジアン解析を実行します。最初に、バーンイン オブザベーション数を増やす方法について説明します。ここではデフォルトのバーンイン オブザベーション数の 500 を変更する必要はありませんが、手順のみ説明します。

## バーンイン オブザベーション数の変更

バーンイン オブザベーション数を 1,000 に変更するには、次のようにします。

- ▶ メニューから [表示] → [オプション] を選択します。
- ▶ [オプション] ダイアログ ボックスで [MCMC] タブを選択します。
- ▶ [バーンイン・オブザベーション数] を 1000 に変更します。



- ▶ [閉じる]をクリックし、不機嫌な顔が🙄上機嫌な顔に変わる😊までMCMC サンプルングを続けます。


要約表は次のようになります。

	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>係数</b>												
HRSD1<--DEPR1	0.525	0.006	0.168	1.001	0.515	0.229	0.886	0.436	0.328	0.107	1.399	
HRSD2<--DEPR2	0.919	0.003	0.105	1.000	0.907	0.745	1.154	0.681	0.833	0.617	1.464	
DEPR2<--COND	-10.383	0.043	1.595	1.000	-10.390	-13.484	-7.241	0.010	0.010	-16.973	-4.704	
DEPR2<--DEPR1	0.599	0.007	0.197	1.001	0.593	0.238	1.010	0.285	0.083	0.045	1.409	
<b>平均値</b>												
COND	0.502	0.001	0.058	1.000	0.502	0.388	0.613	-0.045	0.051	0.211	0.729	
<b>切片</b>												
BDI1	21.705	0.013	0.784	1.000	21.696	20.189	23.280	0.062	0.034	18.846	24.966	
HRSD1	19.799	0.008	0.487	1.000	19.799	18.852	20.764	0.023	0.103	17.785	22.004	
BDI2	19.902	0.024	1.244	1.000	19.890	17.446	22.375	0.009	0.229	14.632	26.166	
HRSD2	19.192	0.015	0.820	1.000	19.177	17.587	20.801	-0.003	0.141	15.507	23.146	
<b>共分散</b>												
COND<->DEPR1	0.344	0.009	0.406	1.000	0.335	-0.429	1.181	0.147	0.240	-1.212	2.203	
e2<->e4	14.123	0.146	5.250	1.000	13.738	4.805	25.660	0.487	0.688	-2.313	40.992	
e3<->e5	1.222	0.068	2.668	1.000	1.333	-4.247	6.063	-0.515	1.760	-15.785	11.580	
<b>分散</b>												
DEPR1	39.024	0.851	14.328	1.002	36.571	18.194	72.086	1.243	2.972	7.660	120.018	
COND	0.275	0.001	0.046	1.000	0.271	0.200	0.377	0.594	0.554	0.146	0.544	
E1	27.067	0.103	6.706	1.000	26.260	16.333	42.591	0.787	1.145	8.732	71.053	
e2	12.180	0.783	13.675	1.002	14.405	-20.664	33.097	-1.205	3.036	-66.065	56.616	
e3	9.506	0.142	3.805	1.001	9.471	1.863	17.038	-0.048	0.335	-6.715	25.733	
e4	32.888	0.285	8.330	1.001	32.048	18.868	51.593	0.703	1.157	6.626	78.513	
e5	-3.880	0.219	5.256	1.001	-3.324	-15.421	4.898	-0.922	2.654	-36.545	14.380	

ここでは、Amos が MCMC サンプルのデフォルトの制限である 100,000 に到達するまで解析を続けました。Amos がこの制限に達すると、細線化と呼ばれる処理が始まります。細線化とは、すべてのサンプルの代わりに、等間隔に配置したサンプルのサブセットを保持する処理です。Amos は、MCMC サンプルング処理を開始すると、100,000 サンプルの制限に達するまですべてのサンプルを保持します。制限に達した時点でデータの分析者がサンプルング処理を停止していない場合、Amos は 1 つおきにサンプルを削除することによってサンプルの半分を破棄するので、残った系列のラグ-1 の従属は、元の細線化していない系列のラグ-2 の従属と同じになります。これ以降、Amos は生成される 2 つのサンプルから 1 つを保持しながら、100,000 の上限に再び達するまでサンプルング処理を継続します。再び上限に達した時点で Amos はサンプルを再び細線化し、4 つおきに 1 つのサンプルを保持し、... と続いていきます。


Amos ではなぜ細線化を実行するのでしょうか？細線化によって連続するサンプル間の自己相関が低くなるため、細線化された連続する 100,000 のサンプルは、同じ長さの細線化されていない系列よりも多くの情報を提供します。現在の例で表示されている結果は、1,000 のバーンイン サンプルの後に収集された 53,000 サンプルを基にした、合計 54,000 サンプルの結果です。ただし、これはサンプルの系列が 3 回細線化された後であるため、保持されている 1 つのサンプルごとに 8 つのサンプルが生成されています。細線化が実行されなかったとすれば、 $1,000 \times 8 = 8,000$  のバーンイン サンプルと  $53,000 \times 8 = 424,000$  の分析サンプルがあることになります。

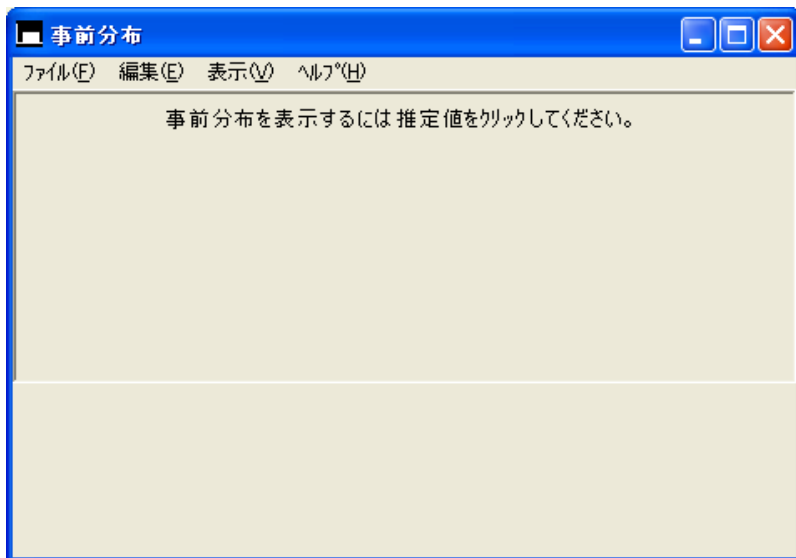
ベイジアン解析の結果は、最尤法の結果と非常によく似ています。e5 の残差分散の事後平均は、最尤法の推定値と同様に負数です。事後分布自体が 0 の左側にかなり寄っています。



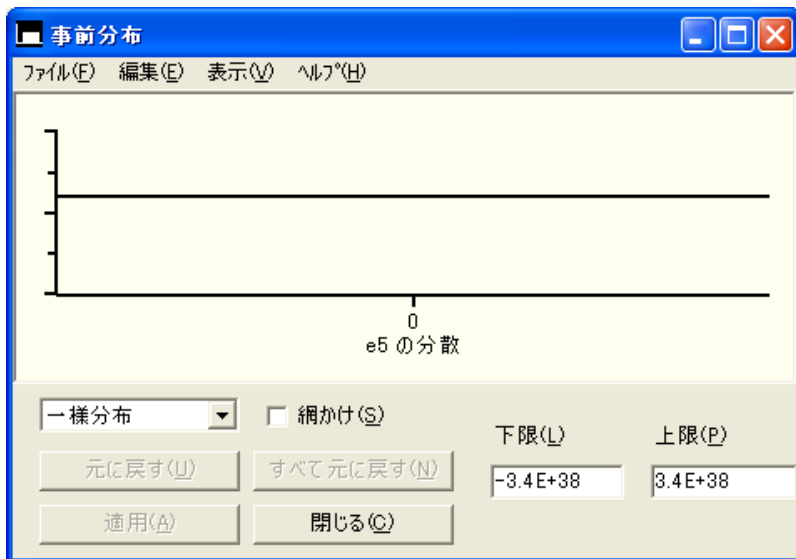
この問題には解消する方法があります。e5 の分散が負数になる任意のパラメータのベクトルに 0 の事前密度を割り当てることです。e5 の分散の事前分布を変更するには、次のようにします。

- ▶ メニューから [表示] → [事前分布] を選択します。

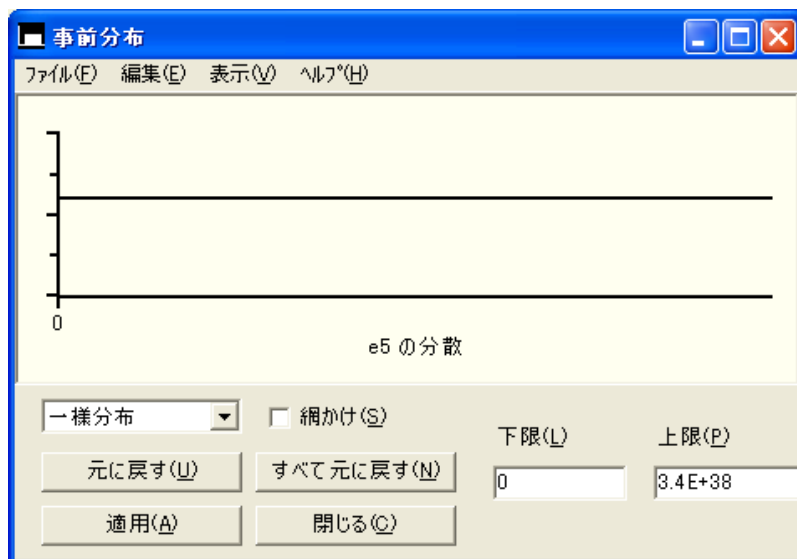
あるいは、[ベジアンSEM] ツールバーの [事前分布] ボタン  をクリックするか、キーボードで Ctrl+R キーを同時に押します。[事前分布] ダイアログボックスが表示されます。



- ▶ [ベジアンSEM] ウィンドウで e5 の分散を選択すると、e5 のデフォルトの事前分布が表示されます。



- ▶ デフォルトの下限値の  $-3.4 \times 10^{-38}$  を 0 に置き換えます。



- ▶ [適用] をクリックすると、変更が保存されます。




## 非拡散事前分布によるベイズ推定

累積された MCMC サンプルは直ちに破棄され、サンプリングは初めから再び開始されます。しばらくしたら、[ベジアン SEM] ウィンドウの表示が次のようになります。

ベジアンSEM												
ファイル(F) 編集(E) 表示(V) 分析(A) ヘルプ(H)												
1.0020												
(1,000+85,001) * 8 453 .101 (1,000+85,000) * 8												
Group number 1												
	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>係数</b>												
HRSD1<--DEPR1	0.498	0.006	0.162	1.001	0.492	0.197	0.844	0.403	0.600	0.089	1.383	
HRSD2<--DEPR2	0.827	0.001	0.066	1.000	0.823	0.706	0.967	0.350	0.483	0.563	1.213	
DEPR2<--COND	-11.280	0.028	1.455	1.000	-11.256	-14.210	-8.506	-0.137	0.241	-17.719	-5.678	
DEPR2<--DEPR1	0.584	0.007	0.193	1.001	0.583	0.208	0.972	0.155	0.135	0.045	1.625	
<b>平均値</b>												
COND	0.500	0.001	0.059	1.000	0.501	0.384	0.615	-0.038	0.045	0.244	0.746	
<b>切片</b>												
BDI1	21.685	0.010	0.794	1.000	21.689	20.113	23.247	0.003	0.128	18.220	25.137	
HRSD1	19.799	0.007	0.495	1.000	19.803	18.825	20.760	-0.047	0.121	17.558	21.918	
BDI2	20.325	0.018	1.162	1.000	20.321	18.055	22.607	0.021	0.037	15.499	25.067	
HRSD2	19.110	0.013	0.809	1.000	19.118	17.521	20.667	-0.021	0.069	15.709	22.370	
<b>共分散</b>												
COND<->DEPR1	0.272	0.006	0.414	1.000	0.260	-0.531	1.127	0.134	0.391	-1.496	2.400	
e2<->e4	10.331	0.099	4.434	1.000	10.105	2.249	19.714	0.316	0.692	-8.257	38.711	
e3<->e5	3.012	0.061	2.189	1.000	2.940	-1.139	7.557	0.194	0.425	-7.271	13.210	
<b>分散</b>												
DEPR1	41.274	1.011	16.800	1.002	37.954	18.327	86.251	1.353	2.472	3.877	123.457	
COND	0.274	0.001	0.047	1.000	0.269	0.198	0.381	0.724	0.932	0.133	0.552	
E1	27.240	0.138	6.447	1.000	26.492	16.626	41.876	0.649	0.644	6.812	62.578	
e2	8.375	1.004	16.031	1.002	11.618	-37.763	30.435	-1.526	3.207	-74.182	50.045	
e3	10.372	0.133	3.625	1.001	10.286	3.341	17.530	0.070	0.614	-8.973	25.956	
e4	25.173	0.070	5.341	1.000	24.855	15.548	36.595	0.396	0.717	4.618	63.297	
e5	2.390	0.021	1.999	1.000	1.874	0.083	7.411	1.377	2.592	0.000	18.708	

e5 の分散の事後平均が正数になっています。事後分布を調べると、サンプリングされた値に 0 以下のものがないことが確認できます。

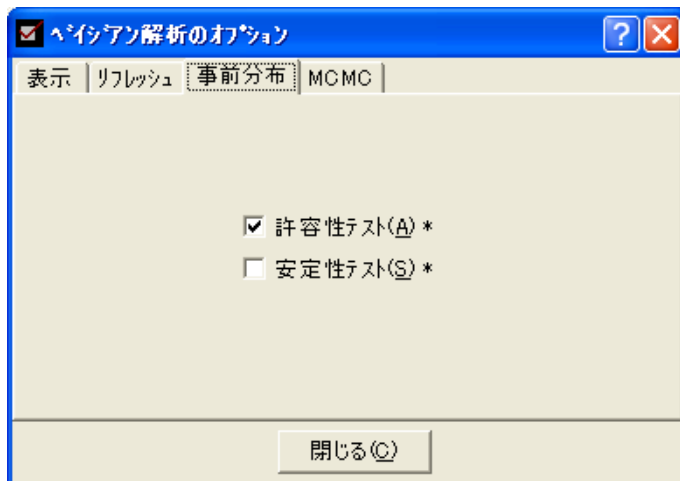


この解は適切でしょうか？各分散の事後平均は正数ですが、[最小値]列を見ると、e2 の分散と e3 の分散に対してサンプリングされた値の一部が負数であることがわかります。e2 と e3 の分散が負の値になるのを避けるため、e5 に対して実施したのと同様に事前分布を変更できます。

この例のような小規模のモデルで、パラメータ単位にこのような制約条件を設定するのはそれほど困難ではありません。しかし、不適切な値をとる任意のパラメータ値に対して自動的に事前密度を 0 に設定する方法もあります。この機能を使用するには、次のようにします。

- ▶ メニューから [表示] → [オプション] を選択します。
- ▶ [オプション] ダイアログ ボックスで、[事前分布] タブをクリックします。

- ▶ [許容性テスト] を選択します。(横にチェックマークが表示されます。)



[許容性テスト] を選択すると、任意の分散共分散行列が正値定符号でないモデルになるパラメータ値の事前密度が 0 に設定されます。特に、正の値でない分散の事前密度が 0 に設定されます。

Amos は、許容性テスト オプションと同じように機能する安定性テスト オプションも備えています。[安定性テスト] を選択すると、線型方程式の不安定な体系になるパラメータ値の事前密度が 0 に設定されます。

[許容性テスト]を選択すると、前に累積されたサンプルが破棄され、直ちにMCMCサンプリングが再び開始されます。少し経つと、次のような結果が表示されます。

ベイジアンSEM												
ファイル(F) 編集(E) 表示(V) 分析(A) ヘルプ(H)												
1.000+73,001 950 .096 1.000+73,000												
Group number 1												
	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>係数</b>												
HRSD1<--DEPR1	0.566	0.005	0.128	1.001	0.551	0.363	0.865	0.855	1.266	0.249	1.159	
HRSD2<--DEPR2	0.821	0.003	0.062	1.001	0.820	0.708	0.949	0.249	0.241	0.603	1.071	
DEPR2<--COND	-11.349	0.055	1.426	1.001	-11.343	-14.247	-8.693	-0.127	0.005	-17.180	-5.953	
DEPR2<--DEPR1	0.666	0.005	0.165	1.000	0.651	0.365	1.011	0.458	0.563	0.104	1.593	
<b>平均値</b>												
COND	0.498	0.002	0.060	1.001	0.497	0.381	0.618	0.020	0.166	0.262	0.716	
<b>切片</b>												
BD1	21.675	0.032	0.770	1.001	21.666	20.163	23.184	0.059	0.117	19.060	24.569	
HRSD1	19.793	0.017	0.485	1.001	19.790	18.889	20.754	0.098	0.035	17.910	21.869	
BD2	20.349	0.050	1.148	1.001	20.305	18.192	22.611	0.104	-0.177	16.634	24.280	
HRSD2	19.119	0.035	0.804	1.001	19.118	17.584	20.712	0.093	0.170	16.127	22.426	
<b>共分散</b>												
COND<->DEPR1	0.287	0.016	0.404	1.001	0.275	-0.495	1.092	0.067	0.188	-1.117	1.792	
e2<->e4	10.838	0.190	4.347	1.001	10.483	3.055	20.438	0.477	0.686	-3.574	31.381	
e3<->e5	2.368	0.080	1.937	1.001	2.229	-1.029	6.732	0.543	0.596	-3.067	12.234	
<b>分散</b>												
DEPR1	33.898	0.325	9.298	1.001	33.315	17.545	54.108	0.434	0.297	8.657	71.350	
COND	0.272	0.002	0.043	1.001	0.269	0.200	0.365	0.507	0.335	0.155	0.463	
E1	25.876	0.237	5.776	1.001	25.281	15.964	38.601	0.607	0.672	10.904	53.813	
e2	15.731	0.330	7.378	1.001	15.289	3.374	31.196	0.464	0.070	0.058	48.052	
e3	8.965	0.138	2.815	1.001	8.901	3.200	14.701	0.057	0.355	0.360	19.579	
e4	23.892	0.173	5.218	1.001	23.538	14.503	35.429	0.452	0.603	5.443	49.014	
e5	2.797	0.073	2.088	1.001	2.298	0.239	8.165	1.345	2.194	0.012	14.774	

解析には、すべての推定値の収束基準を満たす73,000のオブザベーションのみが使用されていることに注意してください。すべての分散推定値の最小値が正の値になっています。

# モデルのパラメータ以外の値のベイズ推定

## 概要

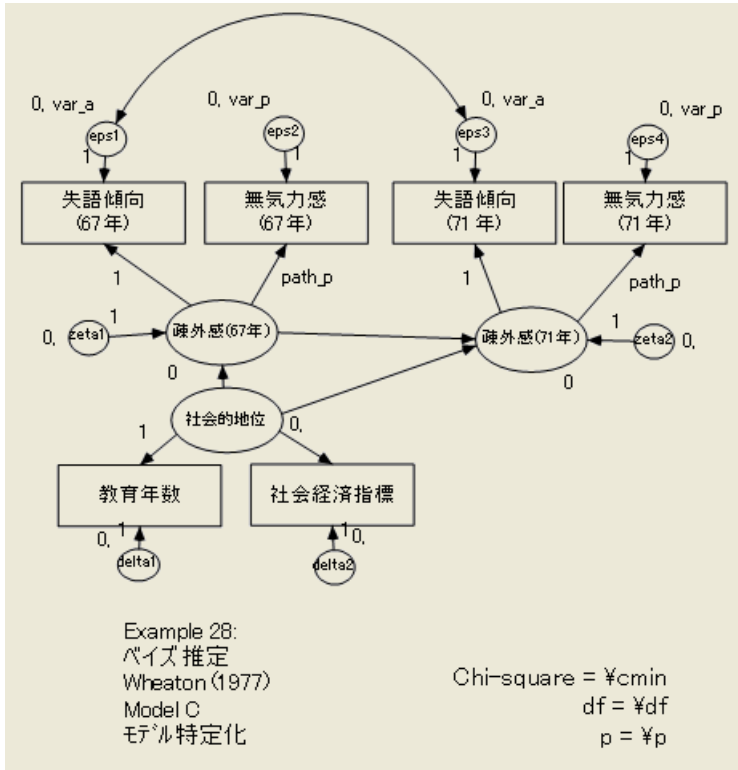
この例では、ベイズ推定でモデルのパラメータ以外の量を推定する方法について示します。

## 例について

例 26 と例 27 ではベイズ解析について説明しました。いずれの例でも、モデルのパラメータの推定のみを取り扱いました。時には、モデルパラメータの関数以外の量の推定が必要になることもあります。たとえば、構造方程式モデリングを最もよく使用するケースに、直接効果と間接効果の同時推定があります。この例では、間接効果の事後分布を推定する方法について説明します。

## Wheaton のデータの再考

例 6 で、Wheaton ほか (1977) の疎外データを紹介し、データの 3 つの代替モデルを示しました。ここでは、例 6 のモデル C を再度取り上げます。次のパス図は、ファイル Ex28.amw にあります。



## 間接効果

ここで、ある研究者が疎外感(67年)を介した社会的地位から疎外感(71年)への間接効果に着目していると仮定します。言い換えると、研究者は、社会経済的地位が1967年時点での疎外感に影響を及ぼし、その結果1971年時点での疎外感に影響を及ぼすのではないかと考えています。

## 間接効果の推定

- ▶ ベイジアン解析を開始する前に、Amos Graphics のメニューから [表示] → [分析のプロパティ] を選択します。
- ▶ [分析のプロパティ] ダイアログボックスで、[出力] タブをクリックします。

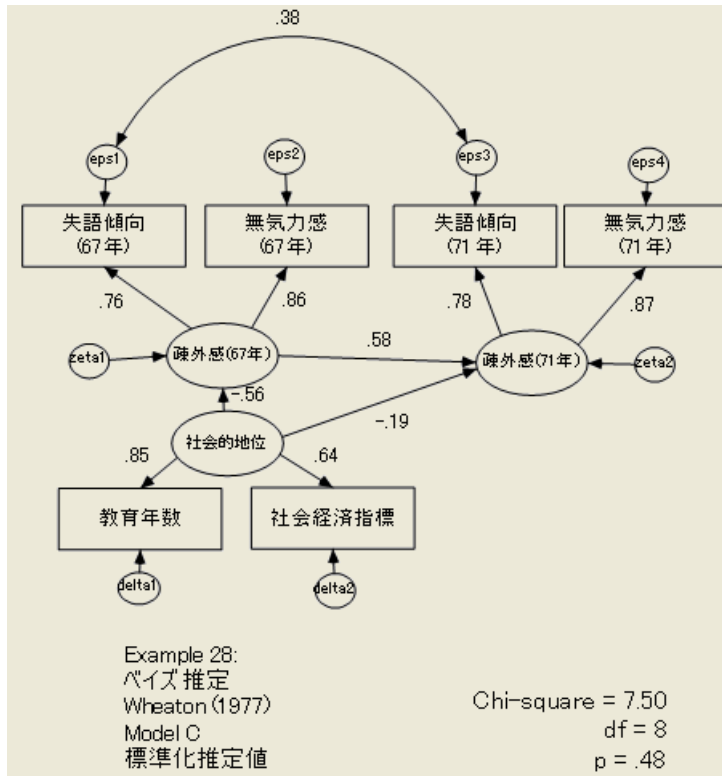
## モデルのパラメータ以外の値のベイズ推定

- ▶ [間接、直接、または総合効果] と [標準化推定値] を選択し、標準化間接効果を推定します。(オプションの横にチェック マークが表示されます。)



- ▶ [分析のプロパティ] ダイアログ ボックスを閉じます。

- ▶ メニューから [分析] → [推定値を計算] を選択すると、モデル適合度とパラメータ推定値の最尤法のカイ 2 乗検定が実行されます。



結果は、例 6-6 の Model C で示したものと同一になります。社会的地位から疎外感 (71 年) への標準化直接効果は -0.19 です。社会的地位から疎外感 (71 年) への標準化間接効果は、社会的地位から疎外感 (67 年) への標準化直接効果 (-0.56) と疎外感 (67 年) から疎外感 (71 年) への標準化直接効果 (0.58) の 2 つの標準化直接効果の積として定義されています。これらの 2 つの標準化直接効果の積は  $-0.56 \times 0.58 = -0.32$  となります。

標準化間接効果を手動で求める必要はありません。すべての標準化間接効果を表示するには、次のようにします。

- ▶ メニューから、[表示] → [テキスト出力の表示] の順にクリックします。



- ▶ [Amos出力] ウィンドウの左上隅から [推定値]、[行列]、[標準化間接効果] を選択します。


標準化間接効果 (グループ\*番号1-デフォルトモデル)

	社会的地位	疎外感(67年)	疎外感(71年)
疎外感(67年)	.00	.00	.00
疎外感(71年)	-.32	.00	.00
sei	.00	.00	.00
educatio	.00	.00	.00
powles71	-.45	.50	.00
anomia71	-.40	.45	.00
powles67	-.48	.00	.00
anomia67	-.43	.00	.00

## モデル C のベイジアン解析

モデル C のベイズ推定を開始するには、次のようにします。

- ▶ メニューから [分析] → [ベイズ推定] を選択します。



The screenshot shows the Bayesian SEM software interface with a table of parameter estimates. The table has 13 columns: 係数 (Coefficients), 切片 (Intercepts), 共分散 (Covariances), 分散 (Variances), 平均値 (Mean), 標準誤差 (Standard Error), 標準偏差 (Standard Deviation), 収束統計量 (Convergence Statistics), 中央値 (Median), 95% 下限 (95% Lower Bound), 95% 上限 (95% Upper Bound), 歪度 (Skewness), 尖度 (Kurtosis), 最小値 (Minimum), 最大値 (Maximum), and 名前 (Name). The table is divided into sections: 係数 (Coefficients), 切片 (Intercepts), 共分散 (Covariances), and 分散 (Variances).

	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>係数</b>												
powles67<--疎外感(67年)	0.993	0.002	0.041	1.001	0.992	0.915	1.076	0.200	-0.095	0.871	1.139	path_p
疎外感(71年)<--社会的地位	-0.206	0.003	0.049	1.002	-0.207	-0.302	-0.111	-0.021	-0.115	-0.380	-0.028	
疎外感(67年)<--社会的地位	-0.566	0.002	0.054	1.001	-0.565	-0.678	-0.467	-0.277	0.356	-0.799	-0.394	
sei<--社会的地位	5.233	0.021	0.424	1.001	5.214	4.450	6.090	0.192	-0.232	3.925	6.841	
疎外感(71年)<--疎外感(67年)	0.607	0.003	0.047	1.002	0.606	0.518	0.699	0.070	-0.159	0.443	0.779	
<b>切片</b>												
anomia67	13.603	0.006	0.113	1.001	13.599	13.388	13.835	0.153	0.052	13.283	13.983	
powles67	14.753	0.003	0.100	1.001	14.749	14.562	14.974	0.234	0.136	14.444	15.115	
anomia71	14.134	0.007	0.115	1.002	14.133	13.916	14.370	0.041	-0.045	13.710	14.483	
powles71	14.895	0.006	0.107	1.002	14.889	14.686	15.112	0.116	0.081	14.570	15.277	
educatio	10.895	0.006	0.102	1.002	10.896	10.701	11.103	0.003	0.069	10.537	11.297	
sei	37.487	0.037	0.685	1.001	37.484	36.220	38.814	0.051	-0.286	35.274	40.347	
<b>共分散</b>												
eps1<->eps3	1.894	0.011	0.256	1.001	1.888	1.384	2.447	0.168	0.077	1.097	2.769	
<b>分散</b>												
eps1	4.957	0.015	0.298	1.001	4.953	4.369	5.536	0.046	-0.028	3.937	6.005	var_a
eps2	2.486	0.011	0.226	1.001	2.486	2.052	2.942	0.084	-0.046	1.728	3.271	var_p
社会的地位	6.842	0.037	0.633	1.002	6.830	5.649	8.102	0.172	0.046	5.012	9.486	
zeta1	4.838	0.019	0.413	1.001	4.839	4.044	5.672	0.147	0.142	3.557	6.335	
zeta2	3.831	0.019	0.322	1.002	3.812	3.258	4.499	0.323	0.198	2.868	5.161	
delta1	2.792	0.030	0.513	1.002	2.810	1.768	3.798	-0.119	0.054	0.517	4.620	
delta2	266.200	1.161	19.037	1.002	265.892	231.099	303.334	0.125	0.059	202.504	338.135	


MCMC アルゴリズムは、MCMC サンプル 22,000 以内に非常に急速に収束します。

## 追加推定値

要約表には、モデルパラメータのみの結果が表示されます。間接効果など、モデルパラメータから求められた数量の事後分布を推定するには、次のようにします。

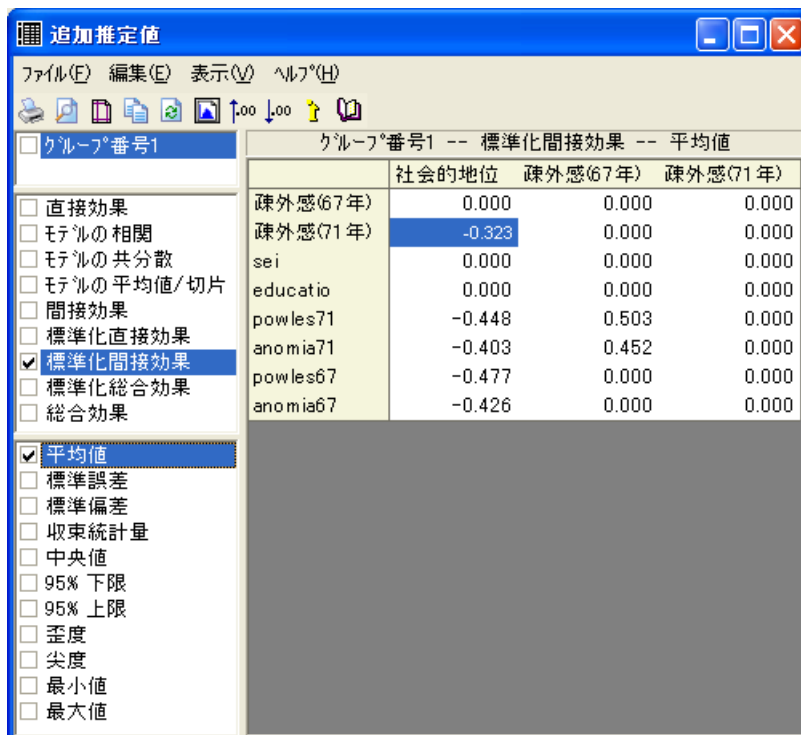
- ▶ メニューから [表示] → [追加推定値] を選択します。

追加推定値の周辺事後分布を推定するには、少し時間がかかることがあります。ステータス ウィンドウに進行状況が表示されます。



結果は [追加推定値] ウィンドウに表示されます。標準化間接効果ごとの事後平均を表示するには、次のようにします。

- ▶ ウィンドウの左側のパネルから [標準化間接効果] と [平均値] を選択します。



- ▶ 結果を印刷するには、印刷する項目を選択します。(横にチェック マークが表示されます。)

- ▶ メニューから [ファイル] → [印刷] を選択します。

大量の印刷出力が生成される可能性があるので注意してください。この例ですべてのチェック ボックスにチェック マークを付けると、 $1 \times 8 \times 11 = 88$  の行列が印刷されます。

- ▶ 標準化直接効果の事後平均を表示するには、左側のパネルから [標準化直接効果] と [平均値] を選択します。

クループ番号1 -- 標準化直接効果 -- 平均値
 社会的地位 | 疎外感(67年) | 疎外感(71年) | 直接効果 | 疎外感(67年) |  | -0.557 | 0.000 || モデルの相関 | 疎外感(71年) |  | -0.194 | 0.580 |
モデルの共分散	sei	0.641	0.000	0.000
モデルの平均値/切片	educatio	0.842	0.000	0.000
間接効果	powles71	0.000	0.000	0.867
標準化直接効果	anomia71	0.000	0.000	0.779
標準化間接効果	powles67	0.000	0.857	0.000
標準化総合効果	anomia67	0.000	0.765	0.000
総合効果				

社会経済的地位から 1971 年時点での疎外感への標準化直接効果および標準化間接効果の事後平均は、最尤推定値とほぼ同じです。

## 間接効果に関する推論

間接効果の信頼区間を見つけたり、間接効果の有意性検定を行ったりするには、2つの方法があります。Sobel (1982、1986) は、間接効果が正規分布すると仮定する方法を提唱しました。この仮定に異議をとなえる統計シミュレーションの論文は増えていますが、より良い (通常は非対称の) 信頼区間を構築するブートストラップの使用は支持されています (MacKinnon, Lockwood, および Williams, 2004, Shrout および Bolger, 2002)。これらの研究により、Amos で利用可能なバイアス修正済のブートストラップ信頼区間は、間接効果の信頼できる推論を導き出すことがわかりました。

Sobel の手法と信頼区間を見つけるためのブートストラップの代替手段として、Amos では、標準化間接効果または標準化されていない間接効果の (通常、非対称の) 信頼区間を求めることができます。次の図は、モデル内の各標準化間接効果の 95% の信頼区間の下限値を示します。[追加推定値] ウィンドウの左側のパネルで [95% 下限] が選択されています。(ペイジアン SEM の [オプション] ダイアログ ボックスから 95% 以外の値も指定できます。)

グループ番号1 -- 標準化間接効果 -- 95% 下限		社会的地位	疎外感(67年)	疎外感(71年)
疎外感(67年)		0.000	0.000	0.000
疎外感(71年)		-0.381	0.000	0.000
sei		0.000	0.000	0.000
educatio		0.000	0.000	0.000
powles71		-0.508	0.435	0.000
anomia71		-0.462	0.382	0.000
powles67		-0.535	0.000	0.000
anomia67		-0.485	0.000	0.000

社会経済的地位から 1971 年時点での疎外感への間接効果の 95% の信頼区間の下限値は、 $-0.382$  です。対応する上限値は、次の図が示すように  $-0.270$  です。

グループ番号1 -- 標準化間接効果 -- 95% 上限		社会的地位	疎外感(67年)	疎外感(71年)
<input type="checkbox"/> 直接効果	疎外感(67年)	0.000	0.000	0.000
<input type="checkbox"/> モデルの相関	疎外感(71年)	-0.266	0.000	0.000
<input type="checkbox"/> モデルの共分散	sei	0.000	0.000	0.000
<input type="checkbox"/> モデルの平均値/切片	educatio	0.000	0.000	0.000
<input type="checkbox"/> 間接効果	powles71	-0.384	0.571	0.000
<input type="checkbox"/> 標準化直接効果	anomia71	-0.339	0.522	0.000
<input checked="" type="checkbox"/> 標準化間接効果	powles67	-0.415	0.000	0.000
<input type="checkbox"/> 標準化総合効果	anomia67	-0.367	0.000	0.000
<input type="checkbox"/> 総合効果				
<input type="checkbox"/> 平均値				
<input type="checkbox"/> 標準誤差				
<input type="checkbox"/> 標準偏差				
<input type="checkbox"/> 収束統計量				
<input type="checkbox"/> 中央値				
<input type="checkbox"/> 95% 下限				
<input checked="" type="checkbox"/> 95% 上限				
<input type="checkbox"/> 歪度				
<input type="checkbox"/> 尖度				
<input type="checkbox"/> 最小値				
<input type="checkbox"/> 最大値				

この標準化間接効果の実際の値が  $-0.382$  と  $-0.270$  の範囲内にあることの確信は 95% です。事後分布を表示するには、次のようにします。

- ▶ [追加推定値] ウィンドウのメニューから [表示] → [事後分布] を選択します。  
最初に、空の事後分布のウィンドウが表示されます。

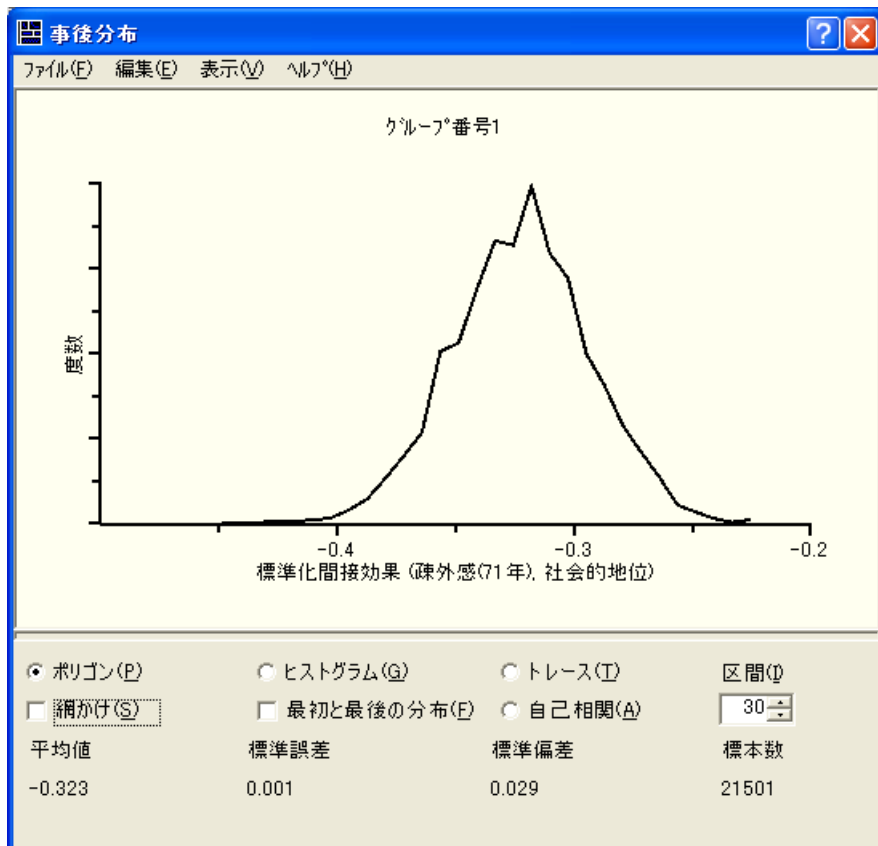


- ▶ [追加推定値] ウィンドウで [平均値] と [標準化間接効果] を選択します。

グループ番号1	標準化間接効果	平均値
	社会的地位	
	疎外感(67年)	
	疎外感(71年)	
	sei	
	educatio	
	powles71	
	anomia71	
	powles67	
	anomia67	



その後、社会経済的地位から 1971 年時点での疎外感への間接効果の事後分布が表示されます。間接効果の分布は、厳密ではありませんが、ほぼ正規分布になります。





# ベイジアンSEMにおけるユーザー定義 数量の推定

## 概要

この例では、ユーザー定義の数量（直接効果と間接効果の差異）を推定する方法を示します。

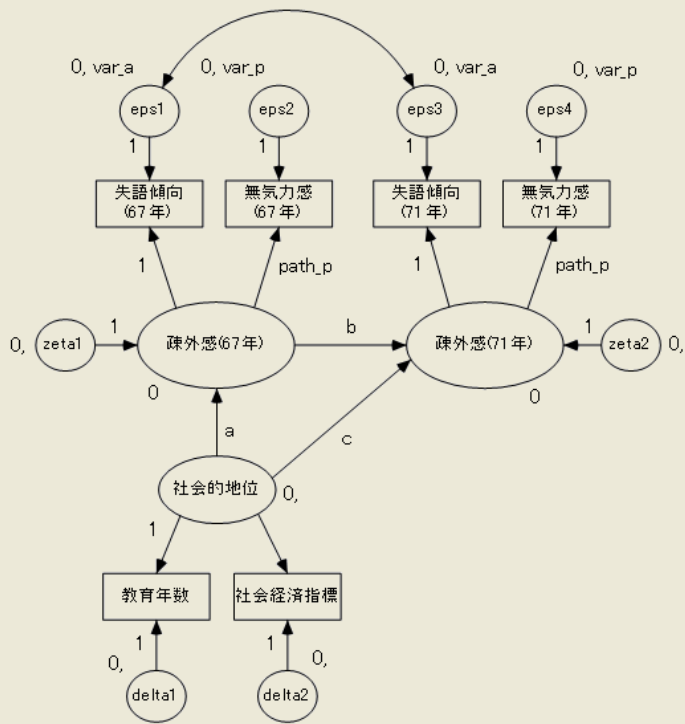
## 例について

前の例では、Amos ベイジアン分析の追加推定値機能を使用して間接効果を推定する方法を示しました。分析をもう1歩進め、「間接効果を、対応する直接効果と比較するにはどうすればよいですか」という、調査でよく聞かれる質問に対応するものと仮定します。

## 疎外感モデルの安定性

カスタム推定値機能を使用して、モデルパラメータの任意の関数について推論を導いたり推定したりできます。カスタム推定機能について説明するために、もう一度前の例に戻ってみましょう。モデルのパス図を405ページに示します。また、ファイルEx29.amwにも記載してあります。このモデルでは、1971年に見られた疎外感に対する社会経済的地位による直接効果を確認できます。また、1967年に見られた疎外感によって媒介される間接効果も確認できます。

この例の残りの部分では、直接効果、間接効果、およびこの2つの比較に焦点を当てています。直接効果に対してパラメータラベル(「c」)を指定し、間接効果の2つのコンポーネント(「a」および「b」)を指定したことに注目してください。必須ではありませんが、パラメータラベルを使用するとカスタム推定値の指定が容易になります。



Example 29:  
 パイズ推定  
 Wheaton (1977)  
 Model C  
 モデル特定化

Chi-square = ¥cmin  
 df = ¥df  
 p = ¥p

## ベジアン SEM におけるユーザー定義数量の推定

このモデルのベジアン分析を開始するには

- ▶ メニューから [分析] → [ベイズ推定] を選択します。

しばらくしたら、[ベジアン SEM] ウィンドウの表示が次のようになります。

	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>係数</b>									
powles71<--疎外感(71年)	0.996	0.000	0.041	1.000	0.140	0.078	0.820	1.172	path_p
疎外感(71年)<--疎外感(67年)	0.607	0.001	0.046	1.000	-0.001	0.002	0.422	0.804	b
疎外感(71年)<--社会的地位	-0.205	0.001	0.050	1.000	-0.147	0.045	-0.426	-0.010	c
疎外感(67年)<--社会的地位	-0.565	0.001	0.054	1.000	-0.160	0.122	-0.813	-0.371	a
SEK<--社会的地位	5.216	0.005	0.429	1.000	0.144	0.011	3.551	7.063	
<b>切片</b>									
anomia67	13.611	0.001	0.113	1.000	-0.039	0.071	13.049	14.150	
powles67	14.759	0.001	0.100	1.000	0.004	0.057	14.342	15.227	
anomia71	14.128	0.001	0.115	1.000	0.009	-0.009	13.649	14.642	
powles71	14.899	0.001	0.104	1.000	0.004	0.037	14.408	15.354	
educatio	10.903	0.001	0.104	1.000	-0.015	-0.029	10.495	11.336	
SEI	37.499	0.008	0.696	1.000	0.005	-0.009	34.723	40.323	
<b>共分散</b>									
eps1<->eps3	1.887	0.003	0.245	1.000	0.092	0.053	0.898	2.901	
<b>分散</b>									
eps1	4.966	0.003	0.295	1.000	0.054	0.045	3.698	6.231	var_a
eps2	2.469	0.003	0.228	1.000	0.048	-0.008	1.514	3.408	var_p
社会的地位	6.853	0.009	0.665	1.000	0.171	0.039	4.224	9.555	
zeta1	4.820	0.006	0.415	1.000	0.209	0.101	3.248	6.679	
zeta2	3.832	0.003	0.318	1.000	0.197	0.094	2.608	5.280	
delta1	2.796	0.007	0.525	1.000	-0.162	0.137	0.324	4.801	
delta2	267.334	0.269	18.429	1.000	0.121	0.055	191.763	343.794	

- ▶ メニューから [表示] → [追加推定値] を選択します。

- ▶ [追加推定値] ウィンドウで、[標準化直接効果] チェック ボックスおよび [平均値] チェック ボックスをオンにします。

疎外感(71年)に対する社会的地位の直接効果の事後分布平均値は、-0.195 です。

The screenshot shows the 'Additional Estimands' window with the following table of results:

グループ番号1		グループ番号1 -- 標準化直接効果 -- 平均値		
	社会的地位	疎外感(67年)	疎外感(71年)	
<input type="checkbox"/> 直接効果	疎外感(67年)	-0.558	0.000	0.000
<input type="checkbox"/> モデルの相関	疎外感(71年)	-0.195	0.579	0.000
<input type="checkbox"/> モデルの共分散	SEI	0.638	0.000	0.000
<input type="checkbox"/> モデルの平均値/切	educatio	0.844	0.000	0.000
<input type="checkbox"/> 間接効果	powles71	0.000	0.000	0.868
<input checked="" type="checkbox"/> 標準化直接効果	anomia71	0.000	0.000	0.780
<input type="checkbox"/> 標準化間接効果	powles67	0.000	0.858	0.000
<input type="checkbox"/> 標準化総合効果	anomia67	0.000	0.765	0.000
<input checked="" type="checkbox"/> 平均値				
<input type="checkbox"/> 標準誤差				
<input type="checkbox"/> 標準偏差				
<input type="checkbox"/> 収束統計量				
<input type="checkbox"/> 中央値				
<input type="checkbox"/> 95% 下限				
<input type="checkbox"/> 95% 上限				
<input type="checkbox"/> 歪度				
<input type="checkbox"/> 尖度				
<input type="checkbox"/> 最小値				
<input type="checkbox"/> 最大値				

- ▶ [標準化間接効果] チェックボックスおよび[平均値] チェックボックスをオンにします。

1971 年にけおる疎外感に対する社会経済的地位の直接効果は、 $-0.322$  です。

Additional Estimands

ファイル(F) 編集(E) 表示(V) ヘルプ(H)

グループ番号1

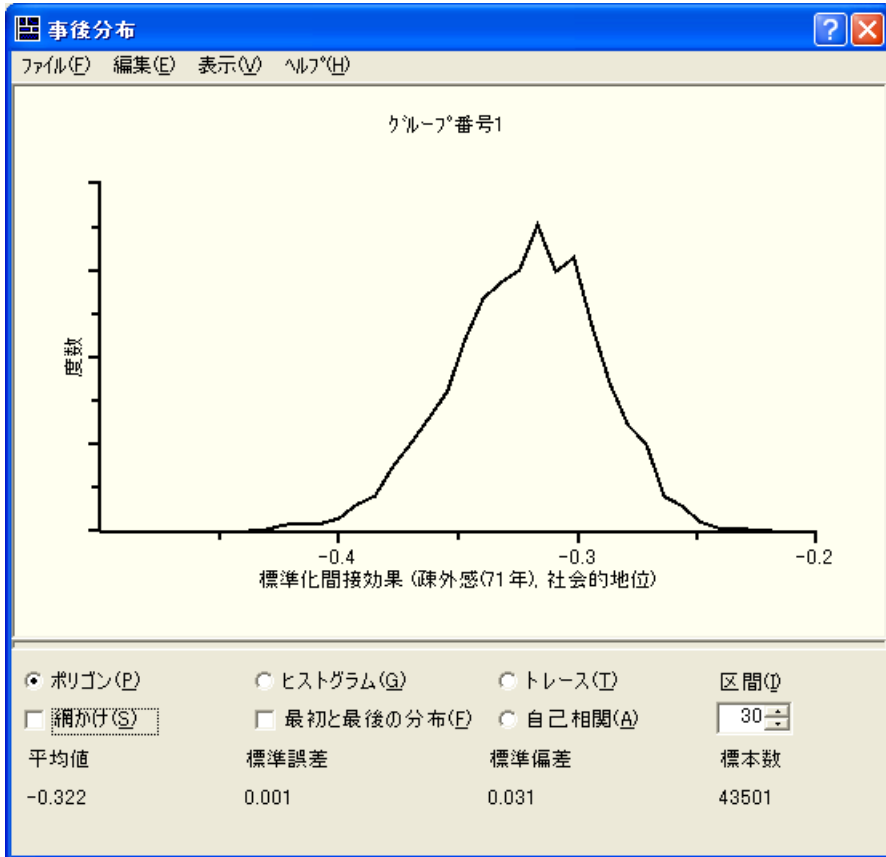
グループ番号1 -- 標準化間接効果 -- 平均値

	社会的地位	疎外感(67年)	疎外感(71年)
疎外感(67年)	0.000	0.000	0.000
疎外感(71年)	-0.322	0.000	0.000
SEI	0.000	0.000	0.000
educatio	0.000	0.000	0.000
powles71	-0.447	0.504	0.000
anomia71	-0.401	0.452	0.000
powles67	-0.476	0.000	0.000
anomia67	-0.425	0.000	0.000

直接効果  
 モデルの相関  
 モデルの共分散  
 モデルの平均値/切  
 間接効果  
 標準化直接効果  
 標準化間接効果  
 標準化総合効果  
 総合効果

平均値  
 標準誤差  
 標準偏差  
 収束統計量  
 中央値  
 95% 下限  
 95% 上限  
 歪度  
 尖度  
 最小値  
 最大値

間接効果の事後分布は完全に 0 よりも左に位置するため、間接効果は 0 未満であると考えると差し支えありません。



また、直接効果の事後分布も表示できます。ただし、このプログラムには、間接効果と直接効果の差異(またはその比率)の事後分布を確かめる機能は組み込まれていません。このケースでは、プログラムの開発者が想定していなかった数量を推定したり推論を導く必要があります。この場合、独自のカスタム推定値を定義することにより、Amos の機能を拡張する必要があります。




## 数値カスタム推定値

このセクションでは、直接効果と間接効果の数値の差異を推定する Visual Basic プログラムの記述方法を示します (Visual Basic の代わりに C# を使用することもできます)。最終的な Visual Basic プログラムは、ファイル Ex29.vb に記載されています。

カスタム推定値を定義するプログラムを記述する最初の手順では、カスタム推定値ウィンドウを開きます。

- ▶ [ベイジアン SEM] ウィンドウのメニューから [表示] → [カスタム推定値] を選択します。



```
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        'Your code goes here.
    End Sub

    Public Function CalculateEstimands(sem As AmosEngine) As String
    Implements IEstimand.CalculateEstimands
        'Your code goes here.
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```

このウィンドウには Visual Basic のスケルトンプログラムが表示されますので、Amos で推定する新しい数量を定義するコード行を追加します。

**注 :** Visual Basic の代わりに C# を使用する場合は、メニューから [ファイル] → [新規 Estimands (C#)] を選択します。

スケルトンプログラムにはサブルーチンと関数が含まれています。サブルーチンと関数の呼び出しを制御することはできません。これらは、Amos によって呼び出されます。

- Amos は、作成した DeclareEstimands サブルーチンを 1 度呼び出し、推定する新しい数量 (推定値) の数を確認します。

- Amos は、作成した CalculateEstimands 関数を繰り返し呼び出します。それは CalculateEstimands 関数を呼び出すたびに、指定されたパラメータ値についてカスタム推定値の値を計算する必要があります。

DeclareEstimands サブルーチンにおいて、プレースホルダ 'Your code goes here' を、推定する新しい数量 ( 推定値 ) の数とその名前を指定する行で置き換えます。この例として、疎外感 (71 年) に対する 社会的地位 の直接効果とこれに対応する間接効果の差異を推定します。また、直接効果と間接効果を個別に計算するコードを記述することで、直接効果と間接効果を個別に推定できます。各推定値を定義するには、次に示すように newestimand キーワードを使用します。

```

"Header"
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
    End Sub

    Public Function CalculateEstimands(sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        'Your code goes here.
        Return "" 'Return an empty string if no error occurred
    End Function
End Class

```

「direct」、「indirect」、および「difference」という語は、推定値のラベルです。別のラベルを使用することもできます。

CalculateEstimands 関数においては、プレースホルダ 'Your code goes here' を「direct」、  
「indirect」、および「difference」という推定値を評価する行で置き換える必要があります。

まず、直接効果を計算する Visual Basic コードを記述します。次の図では、Visual  
Basic ステートメントの一部である estimand(「direct」).value = が入力済みになっています。

```
"Header"  
Public Class CEstimand  
    Implements IEstimand  
  
    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands  
        newestimand("direct")  
        newestimand("indirect")  
        newestimand("difference")  
    End Sub  
  
    Public Function CalculateEstimands(sem As AmosEngine) As String Implements  
        IEstimand.CalculateEstimands  
        estimand("direct").value =  
        Return "" 'Return an empty string if no error occurred  
    End Function  
  
End Class
```

等号(=)の右側にコードを追加して、ステートメントを完成する必要があります。直接効果は、CalculateEstimands 関数の引数として指定される AmosEngine オブジェクトを介してアクセスできるパラメータ値のセットについて計算されます。AmosEngine オブジェクトの使用法を知るには Amos に精通したプログラマーである必要がありますが、必要な Visual Basic シンタックスはドラッグ アンド ドロップで簡単に取得できます。

## ドラッグアンドドロップ

- ▶ [ベイズアン SEM] ウィンドウで直接効果を見つけ、その行をクリックします(この行は次の図では強調表示されています)。
- ▶ マウス ポインタを選択した行の端に移動します。上端でも下端でもかまいません。  
ヒント : マウス ポインタを適当な位置に配置すると、マウス ポインタの横にプラス符号 (+) が表示されます。

	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値	名前
<b>係数</b>												
powles71<--疎外感(71年)	0.994	0.001	0.041	1.000	0.992	0.917	1.075	0.123	-0.025	0.833	1.147	path_p
疎外感(71年)<--疎外感(67年)	0.607	0.001	0.046	1.001	0.607	0.516	0.701	0.033	0.008	0.437	0.772	b
疎外感(71年)<--社会的地位	-0.205	0.002	0.051	1.001	-0.204	-0.309	-0.105	-0.106	0.081	-0.398	-0.031	c
疎外感(67年)<--社会的地位	-0.564	0.003	0.055	1.001	-0.563	-0.676	-0.461	-0.188	-0.135	-0.773	-0.388	a
SEK--社会的地位	5.226	0.014	0.433	1.001	5.211	4.399	6.115	0.140	0.085	3.477	6.877	
<b>切片</b>												
anomia67	13.615	0.003	0.112	1.000	13.616	13.400	13.837	0.028	-0.065	13.166	14.051	
powles67	14.761	0.003	0.097	1.001	14.760	14.572	14.960	0.033	0.076	14.404	15.112	
anomia71	14.129	0.004	0.117	1.001	14.130	13.902	14.363	-0.011	0.180	13.665	14.547	
powles71	14.901	0.003	0.103	1.001	14.902	14.695	15.099	0.021	0.025	14.515	15.267	
educatio	10.895	0.003	0.103	1.001	10.894	10.690	11.099	-0.032	0.267	10.436	11.291	
SEI	37.461	0.026	0.664	1.001	37.472	36.115	38.725	-0.078	-0.022	34.964	39.672	
<b>共分散</b>												
eps1<->eps3	1.880	0.009	0.252	1.001	1.873	1.394	2.368	0.074	0.068	1.047	2.861	
<b>分散</b>												
eps1	4.957	0.008	0.287	1.000	4.967	4.391	5.507	-0.074	-0.269	3.923	5.815	var_a
eps2	2.478	0.006	0.229	1.000	2.471	2.042	2.926	0.072	-0.112	1.692	3.317	var_p
社会的地位	6.840	0.024	0.655	1.001	6.823	5.615	8.183	0.199	0.130	4.519	9.516	
zeta1	4.848	0.020	0.433	1.001	4.828	4.034	5.736	0.241	0.271	3.419	6.983	
zeta2	3.828	0.013	0.321	1.001	3.818	3.223	4.475	0.163	-0.085	2.748	4.974	
delta1	2.790	0.018	0.525	1.001	2.801	1.738	3.828	-0.095	0.168	0.447	4.699	
delta2	266.544	0.633	18.260	1.001	266.333	231.768	302.854	0.107	0.133	203.079	341.584	

- ▶ マウスの左ボタンを押したまま、マウス ポインタを Visual Basic のウィンドウ内の、直接効果を表す式を配置する位置にドラッグします。

この操作が完了すると、次の図に示すように、適切なパラメータ式が入力されます。

```
["Header"]
Public Class CEstimand Implements IEstimand
    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
    End Sub
    Public Function CalculateEstimands(sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```

等号の右側のパラメータは、前述のパス図で使用していたラベル(「c」)で識別されます。

次に、1971年における疎外に対する社会経済的地位の間接効果の計算に目を向けてみましょう。この間接効果は、2つの直接効果の積として定義されています。1つは1967年における疎外感に対する社会経済的地位の直接効果(パラメータ a)で、もう1つは1971年における疎外感に対する1967年の疎外の直接効果(パラメータ b)です。

- ▶ 間接効果を計算する Visual Basic 割り当てステートメントの左側には、`estimand("indirect").value =` と入力します。

```
["Header"]
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
    End Sub

    Public Function CalculateEstimands(sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        estimand("indirect").value = ~
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```

上記と同じドラッグ アンド ドロップの処理を使用して、まず [ベイジアン SEM] ウィンドウから [無題.vb] ウィンドウに行をドラッグします。

- ▶ 最初に、1967 年における疎外に対する社会経済的地位の直接効果を、未完成のステートメントの等号の右側にドラッグします。


```
["Header"]
Public Class CEstimand
  Implements IEstimand

  Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
    newestimand("direct")
    newestimand("indirect")
    newestimand("difference")
  End Sub

  Public Function CalculateEstimands(sem As AmosEngine) As String Implements
  IEstimand.CalculateEstimands
    estimand("direct").value = sem.ParameterValue("c")
    estimand("indirect").value = sem.ParameterValue("a")
    Return "" 'Return an empty string if no error occurred
  End Function
End Class
```

- ▶ 次に、1971 年の疎外に対する 1967 年の疎外感の直接効果をドラッグ アンド ドロップ します。

この 2 つ目の直接効果は、[無題.vb] ウィンドウに `sem.ParameterValue(「b」)` と表示されます。



```
["Header"]
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
    End Sub

    Public Function CalculateEstimands(sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        estimand("indirect").value = sem.ParameterValue("a")sem.ParameterValue("b")
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```



- ▶ 最後に、キーボードを使用して、2つのパラメータの間にアスタリスク(\*)を挿入します。

```
"Header"  
Public Class CEstimand  
    Implements IEstimand  
  
    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands  
        newestimand("direct")  
        newestimand("indirect")  
        newestimand("difference")  
    End Sub  
  
    Public Function CalculateEstimands(sem As AmosEngine) As String Implements  
        IEstimand.CalculateEstimands  
        estimand("direct").value = sem.ParameterValue("c")  
        estimand("indirect").value = sem.ParameterValue("a") * sem.ParameterValue("b")  
        Return "" 'Return an empty string if no error occurred  
    End Function  
  
End Class
```

ヒント：複雑なカスタム推定値については、[追加推定値] ウィンドウから [カスタム推定値] ウィンドウにドラッグアンドドロップすることもできます。

直接効果と間接効果の差異を計算するには、次の図に示すように、Visual Basic シンタックスの 3 番目の行を追加します。

```

[Header]
Public Class CEstimand
    Implements IEstimand


    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
    End Sub

    Public Function CalculateEstimands(ByVal sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        estimand("indirect").value = sem.ParameterValue("a") * sem.ParameterValue("b")
        estimand("difference").value = estimand("indirect").value - estimand("direct").value
        Return "" 'Return an empty string if no error occurred
    End Function
End Class

```

- ▶ 3つのカスタム推定値すべての事後分布を確認するには、[ファイル]→[実行](または、ツールバー上の[実行]ボタン)をクリックします。

結果が表示されるまで数秒かかります。ステータス ウィンドウに進行状況が表示されます。




3つのカスタム推定値の周辺事後分布は、次の表に集計されます。

数値推定値	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値
direct	-0.206	0.002	0.051	1.001	-0.203	-0.311	-0.110	-0.260	0.021	-0.400	-0.055
indirect	-0.341	0.002	0.040	1.001	-0.339	-0.425	-0.265	-0.204	0.067	-0.492	-0.218
difference	-0.135	0.003	0.072	1.001	-0.134	-0.280	0.004	-0.052	-0.162	-0.377	0.096

directの結果は[ベイジアン SEM] 要約表でも確認できます。また、indirectの結果は[追加推計値]表でも確認できます。ここで確認する必要があるのは、differenceの結果です。差異の事後分布平均値は-0.135です。最小値は-0.377で、最大値は0.096です。

- ▶ 差異の周辺事後分布を確認するには、[表示]→[事後分布]を選択します。
- ▶ [カスタム推定値]表の difference 行を選択します。



ほとんどの領域が 0 よりも左にあるため、差異はほぼ負であると考えることができます。つまり、間接効果は直接効果よりも負であると言ってもほぼ差し支えありません。事後分布を目測してみると、おそらく 95 % 程度の領域が 0 より左に存在するように思われます。したがって、約 95% の公算で、間接効果が直接効果よりも大きいと言うことができます。しかし、事後分布を目測に頼る必要はありません。周辺事後分布の任意の領域を確認する方法、より一般的には、パラメータに関する任意の命題が真である確率を推定する方法があります。

## 二値カスタム推定値

ポリゴンを視覚的に調査してみれば、**difference** 値の大部分が負であることがわかりますが、どのくらいの比率の値が負であるのかを正確には確認できません。この比率は、間接効果が直接効果を超えるという確率の推定値です。このような確率を推定する場合、二値推定値を使用できます。**Visual Basic** (または **C#**) プログラムでは、二値推定値は、真と偽という 2 つの値のみを取るという点を除けば、数値推定値とまったく同じです。間接効果が直接効果よりも負である確率を推定するには、間接効果が直接効果よりも負である場合に真となり、それ以外の場合は偽となるモデルパラメータの関数を定義する必要があります。

## 二値推定値の定義

- ▶ DeclareEstimands サブルーチンで各二値推定値に名前を付けます。わかりやすくするために、2つの二値推定値にそれぞれ「indirect is less than zero」と「indirect is smaller than direct」という名前を付けて宣言します。

```
["Header"]
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
        newestimand("indirect is less than zero")
        newestimand("indirect is smaller than direct")
    End Sub

    Public Function CalculateEstimands(ByVal sem As AmosEngine) As String Implements
    IEstimand.CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        estimand("indirect").value = sem.ParameterValue("a") * sem.ParameterValue("b")
        estimand("difference").value = estimand("indirect").value - estimand("direct").value
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```

▶ CalculateEstimates 関数にコード行を追加して、二値推定値の計算方法を指定します。

```
"Header"
Public Class CEstimand
    Implements IEstimand

    Public Sub DeclareEstimands() Implements IEstimand.DeclareEstimands
        newestimand("direct")
        newestimand("indirect")
        newestimand("difference")
        newestimand("indirect is less than zero")
        newestimand("indirect is smaller than direct")
    End Sub

    Public Function CalculateEstimands(ByVal sem As AmosEngine) As String Implements IEstimand.
    CalculateEstimands
        estimand("direct").value = sem.ParameterValue("c")
        estimand("indirect").value = sem.ParameterValue("a") * sem.ParameterValue("b")
        estimand("difference").value = estimand("indirect").value - estimand("direct").value
        estimand("indirect is less than zero").value = (estimand("indirect").value < 0)
        estimand("indirect is smaller than direct").value = (estimand("indirect").value < estimand("direct").value)
        Return "" 'Return an empty string if no error occurred
    End Function
End Class
```

この例では、最初の二値カスタム推定値は、間接効果の値が 0 未満の場合に真となります。2 番目の二値カスタム推定値は、間接効果が直接効果よりも小さい場合に真となります。

▶ [実行] をクリックします。

Amos は、抽出された各 MCMC 標本について各論理式の真偽を評価します。分析が終了すると、各式の評価が真となった MCMC 標本の比率が報告されます。これらの比率は、[カスタム推定値] 要約表の [二値推定値] セクションに表示されます。

Custom Estimands											
ファイル(F) 編集(E) 表示(V) ヘルプ(H)											
数値推定値	平均値	標準誤差	標準偏差	収束統計量	中央値	95% 下限	95% 上限	歪度	尖度	最小値	最大値
direct	-0.206	0.002	0.051	1.001	-0.203	-0.311	-0.110	-0.260	0.021	-0.400	-0.055
indirect	-0.341	0.002	0.040	1.001	-0.339	-0.425	-0.265	-0.204	0.067	-0.492	-0.218
difference	-0.135	0.003	0.072	1.001	-0.134	-0.280	0.004	-0.052	-0.162	-0.377	0.096
二値推定値											
	P	P1	P2	P3							
indirect is less than zero	1.000	1.000	1.000	1.000							
indirect is smaller than direct	0.970	0.968	0.970	0.972							

P 列は、MCMC 標本の全系列のうち、各式が真と評価された回数の比率を示します。この例では、MCMC 標本数が 29,501 であったため、P の値はおよそ 30,000 の標本に基づいています。P1、P2、および P3 は、それぞれ、MCMC 標本の最初の 3 分の 1、真ん中の 3 分の 1、最後の 3 分の 1 で各論理式の評価が真であった回数の比率を示します。この図では、これらの各比率は、およそ 10,000 の MCMC 標本が基になっています。

[カスタム推定値] ウィンドウの [二値推定値] 領域の比率に基づいて、ほぼ間違いなく間接効果が負であるという結論を下すことができます。これは、間接効果の値が 0 以上である MCMC 標本が存在しないことを示した 408 ページのポリゴンと一致しています。

同様に、間接効果は直接効果よりも大 (負) である確率は約 0.970 であると言えます。0.970 は確率の推定に過ぎません。これは、29,501 の相関観測値の基づく比率です。ただし、最初の 3 分の 1 (0.968)、真ん中の 3 分の 1 (0.970)、最後の 3 分の 1 (0.972) の比率が近接しているため、これは適切な推定であるように思われます。





# データ代入

## 概要

この例では、因子分析モデルにおける多重代入について説明します。

## 例について

例 17 では、データに欠損値が含まれる場合に最尤法を使用してモデル適合を行う方法を示します。また、Amos では欠損値に値を代入することもできます。データ代入では、各欠損値はなんらかの推測数値に置き換えられます。各欠損値を代入値に置き換えたら、その結果得られる完全データセットを、完全データ用に設計されたデータ分析方法で分析できます。Amos には 3 つのデータ代入方法が用意されています。

- 回帰法代入では、まず最尤法を使用してモデル適合を行います。その後、モデルパラメータを最尤推定値と等しくなるように設定し、線型回帰を使用して、各ケースの未観測値を、同じケースについての観測値の線型結合として予測します。この予測値を欠損値に当てはめます。
- 確率的回帰法代入 (Little および Rubin, 2020 年) では、未知のモデルパラメータを最尤推定値と等しくなるように設定し、観測値に基づく欠損値の条件付き分布から無作為に抽出して、各ケースの値を代入します。確率的回帰法代入にはランダムな要素が存在するため、代入プロセスを繰り返すたびに、異なる完全データセットが生成されます。
- ベイジアン法代入は、確率的回帰法代入に似ていますが、パラメータ値が推定に過ぎず未知であるという事実を考慮する点が異なります。

## 多重代入

多重代入 (Schafer, 1997 年) では、非決定性の代入方法 (確率的回帰法代入またはベイジアン法代入) を使用して複数の完全データセットを作成します。観測値が変化することはありませんが、代入値は完全データセットごとに異なります。複数の完全データセットを作成したら、完全データセットごとに分析します。たとえば、 $m$  個の完全データセットがある場合、 $m$  個の異なる結果セットが存在し、それぞれの結果セットにはさまざまな数量の推定値と標準誤差の推定値が含まれます。 $m$  個の完全データセットは互いに異なるため、 $m$  個の結果セットも互いに異なります。

データ分析者は  $m$  個の完全データセットを個別に分析した後、得られた  $m$  セットの推定値と標準誤差を単一の結果セットに結合する必要があります。Rubin (1987 年) の有名な公式を使用して、複数の完全データセットの結果を結合できます。これらの公式は、例 31 で使用します。

## モデルベースの代入

この例では、因子分析モデルを使用して代入を実行します。モデルベースの代入には 2 つの利点があります。まず、モデル内の任意の潜在変数に値を代入できる点です。2 番目の利点は、モデルが的確で正の自由度を持っている場合、モデルの共分散行列と平均値は飽和モデルのそれよりも正確であると推定されることです (代入はモデルの共分散行列と平均値に基づきます)。ただし、例 1 のモデルのような飽和モデルは、他に適切なモデルが存在しない場合に代入に使用できます。

## Amos Graphics を使用した多重データ代入の実行

この例では、例 17 の確認的因子分析モデルを使用してベイジアン法多重代入を実行します。使用するデータセットは、ファイル `grant_x.sav` にある Holzinger と Swineford (1939 年) による不完全データセットです。欠損値の代入は、多重代入から有用な結果を得るための最初の手順に過ぎません。最終的には、次の 3 つの手順すべてを実行する必要があります。

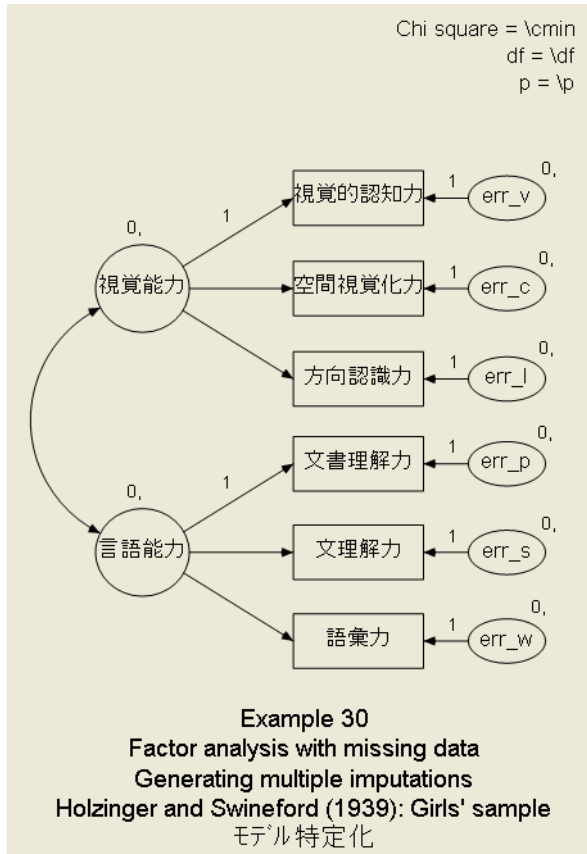
- 手順 1: Amos のデータ代入機能を使用して、 $m$  個の完全データ ファイルを作成する。
- 手順 2:  $m$  個の各完全データ ファイルを個別に分析する。

この分析は自分で行います。Amos でも分析を行うことはできますが、通常は他のプログラムを使用します。この例と次の例では、SPSS Statistics を使用して回帰分析を実行します。ここでは、1 つの変数 (Sentence) を使用して別の変数 (語彙力) を予測します。特に、回帰の重み付けとその標準誤差の推定に重点を置きます。

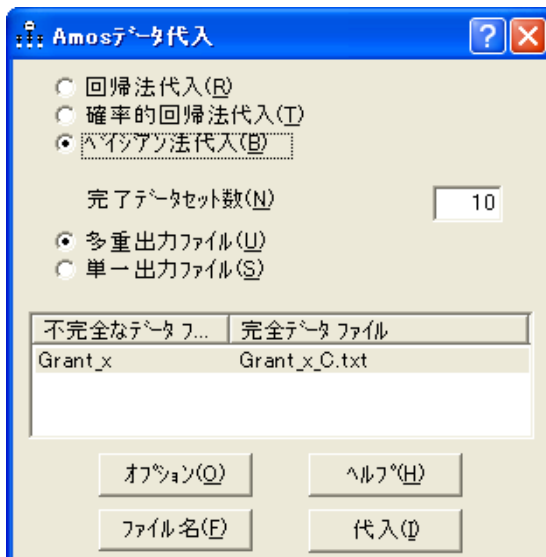
- 手順 3:  $m$  個のデータ ファイルの分析結果を結合する。

この例では、最初の手順を行います。手順 2 と 3 は、例 31 で行います。

- ▶ 完全データ ファイルを生成するには、Amos Graphics ファイル Ex30.amw を開きます



- ▶ メニューから [分析] → [データ代入] を選択します。  
[Amos データ代入] ウィンドウが表示されます。




- ▶ [ペイジアン法代入] が選択されていることを確認します。
- ▶ [完了データセット数] を「10」に設定します (これにより  $m = 10$  と設定されます)。

完全データ ファイルは多数必要と思えるかもしれませんが、ほとんどのアプリケーションでは完全データ ファイルは少ししか必要ありません。正確なパラメータ推定値と表示順誤差を得るには、通常、5 つから 10 の完全データ ファイルで十分です (Rubin, 1987 年)。10 を超える代入を使用しても問題はありますが、手順 2 と 3 での計算作業が増えてしまいます。

Amos では、完全データセットを積み重ねることにより、単一のファイル ([単一出力ファイル]) に完全データセットを保存することも、個別のファイル ([多重出力ファイル]) に各完全データセットを保存することもできます。単一グループの分析の場合、[単一出力ファイル] を選択すると、1 つの出力データファイルが生成され、[多重出力ファイル] を選択すると  $m$  個の個別データ ファイルが生成されます。

複数グループの分析の場合、[単一出力ファイル] を選択すると、分析グループごとに 1 つの出力ファイルが生成され、[多重出力ファイル] を選択するとグループごとに  $m$  個の出力ファイルが生成されます。たとえば、グループが 4 つあり、5 つの完全データセットを要求した場合、[単一出力ファイル] を選択すると 4 つの出力ファイルが生成され、[多重出力ファイル] を選択すると 20 の出力ファイルが生成されます。ここでは SPSS Statistics を使用して完全データセットを分析するので、最も簡単な方法を選択するのであれば [単一出力ファイル] ということになります。次に、手順 2 で SPSS Statistics の分割ファイル機能を使用して、完全データセットを個別に分析します。ただし、どの回歸プログラムを使用してもこの例を再現できるようにするには、次のようにします。

- ▶ [多重出力ファイル] を選択します。
- 代入データは 2 つのファイル形式 (テキスト形式と SPSS Statistics 形式) で保存できます。
- ▶ [ファイル名] をクリックし、[名前を付けて保存] ダイアログ ボックスを表示します。



- ▶ [ファイル名] ボックスで、代入データセットの接頭辞名を指定できます。ここでは、「Grant\_Imp」と指定します。

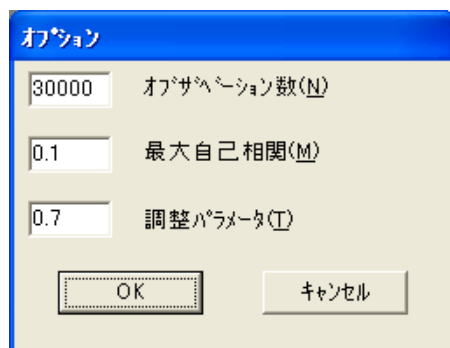
代入データ ファイルには、Grant\_Imp1、Grant\_Imp2、から以降順番に Grant\_Imp10 まで名前が付けられます。

- ▶ [名前を付けて保存] ボックスの一覧で、テキスト形式 ([.txt]) または IBM SPSS Statistics データ ファイル形式 ([.sav]) を選択します。


- ▶ [保存] をクリックします。

- ▶ [データ代入] ウィンドウの [オプション] をクリックし、使用可能な代入オプションを表示します。

これらのオプションについては、オンライン ヘルプを参照してください。オプションの説明を表示するには、対象のオプションの上にマウス ポインタを置いた状態で F1 キーを押します。下図では、観測値の数を 10,000 (デフォルト) から 30,000 に変更しています。

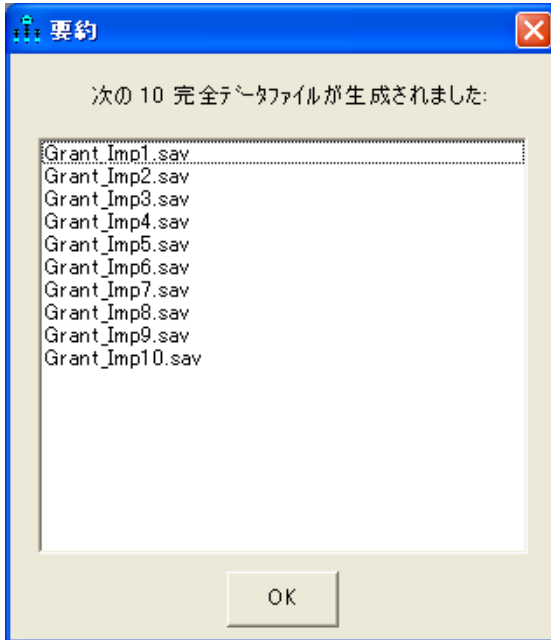


- ▶ [オプション] ダイアログ ボックスを閉じて、[データ代入] ウィンドウの [代入] をクリックします。しばらくすると、次のメッセージが表示されます。



- ▶ [OK] をクリックします。

完全データ ファイルの名前が一覧表示されます。



各完全データ ファイルには 73 の完全なケースが含まれます。最初の完全データ ファイル Grant\_Imp1.sav の先頭のレコードのいくつかを次に示します。

	visperc	cubes	lozenges	paragrap	sentence	wordmean	spatial	verbal	CaseNo	Imputation_
1	33.00	22.54	17.00	8.00	17.00	10.00	-3.63	-0.20	1.00	1.00
2	30.00	30.59	20.00	12.63	17.02	18.00	3.70	-0.74	2.00	1.00
3	38.71	33.00	36.00	16.27	25.00	41.00	7.82	4.98	3.00	1.00
4	28.00	22.98	10.95	10.00	18.00	11.00	5.57	-1.10	4.00	1.00
5	30.82	25.00	20.80	11.00	21.04	8.00	3.47	1.44	5.00	1.00
6	20.00	25.00	6.00	9.00	17.27	25.25	-2.89	-1.33	6.00	1.00

下に示してあるのは、2番目の完全データファイル Grant\_Imp2.sav の同じビューです。

	visperc	cubes	lozenges	paragrap	sentence	wordmean	spatial	verbal	CaseNo	Imputation_
1	33.00	25.34	17.00	8.00	17.00	10.00	-0.86	-3.05	1.00	2.00
2	30.00	33.61	20.00	9.67	19.98	18.00	0.50	-2.97	2.00	2.00
3	40.84	33.00	36.00	19.57	25.00	41.00	14.18	10.10	3.00	2.00
4	28.00	24.06	22.37	10.00	18.00	11.00	-1.07	-1.59	4.00	2.00
5	28.04	25.00	11.10	11.00	24.08	8.00	3.77	0.06	5.00	2.00
6	20.00	25.00	6.00	9.00	23.24	28.68	-2.84	1.13	6.00	2.00

visperc (視覚認知力) の最初の 2 つのケースの値は、元のデータ ファイルでも観測されているため、代入データ ファイル全体で同一です。これに対して、cubes (空間視覚化力) のこれらのケースの値は、元のデータ ファイル Grant\_x.sav では欠損しているため、cubes (空間視覚化力) のこれら 2 つのケースについては、代入データ ファイル全体でさまざまな値が代入されています。

元の観測変数に加え、代入データ ファイルには 4 つの新しい変数が追加されています。spatial (視覚能力) と verbal (言語能力) は、代入された潜在的変数得点です。Caseno と imputeno は、それぞれケース番号と完全データセット番号です。





# 多重代入データセットの分析

## 概要

この例では、多重代入データセットの分析について説明します。

## SPSS Statistics を使用した代入データ ファイルの分析

例 30 では 10 個の完全データセットを作成しました。これは、3 段階のプロセスのうち、Amos のデータ代入機能を使用して、 $m$  個の完全データセットを補完するという最初の手順でした (ここでは、 $m = 10$ )。残りの 2 つの手順は次のとおりです。

- 手順 2 :  $m$  個の各完全データ ファイルを個別に分析する。
- 手順 3 :  $m$  個のデータ ファイルの分析結果を結合する。

手順 2 の分析は、Amos、SPSS Statistics、または他の任意のプログラムを使用して実行できます。手順 2 と 3 を自動化するには、完全データセットの分析に使用するプログラムをあらかじめ把握しておく必要があります。

具体的な問題を解決するために、手順 2 と 3 では SPSS Statistics を使用して回帰分析を実行し、完全データセットを分析します。ここでは、1 つの変数 (Sentence) を使用して別の変数 (Wordmean) を予測します。特に、回帰の重み付けとその標準誤差の推定に重点を置きます。

## 手順 2: 10 個の個別分析

例 30 で生成した 10 個の完全データセットのそれぞれについて、回帰分析を実行する必要があります。この回帰分析では、Sentence を使用して Wordmean を予測します。まず、最初の完全データセットである Grant\_Impl.sav を SPSS Statistics で開きます。

	visperc	cubes	lozenges	paragrap	sentence	wordmean	spatial	verbal	CaseNo	Imputation_
1	33.00	22.54	17.00	8.00	17.00	10.00	-3.63	-0.20	1.00	1.00
2	30.00	30.59	20.00	12.63	17.02	18.00	3.70	-0.74	2.00	1.00
3	38.71	33.00	36.00	16.27	25.00	41.00	7.82	4.98	3.00	1.00
4	28.00	22.98	10.95	10.00	18.00	11.00	5.57	-1.10	4.00	1.00
5	30.82	25.00	20.80	11.00	21.04	8.00	3.47	1.44	5.00	1.00
6	20.00	25.00	6.00	9.00	17.27	25.25	-2.89	-1.33	6.00	1.00

- ▶ SPSS Statistics メニューから [分析] → [回帰] → [線型] を選択し、回帰分析を実行します (この手順の詳細については省略します)。

結果は次のようになります。

モデル		非標準化係数		標準化係数	t	有意確率
		B	標準誤差	ベータ		
1	(定数)	-2.712	3.110		-0.872	.386
	文理解力	1.106	.160	.634	6.908	.000

a. 従属変数: 語彙力

回帰ウェイト付けの推定値と (1.106) と標準誤差の推定値 (0.160) に注目します。先ほど実行した分析を、他の 9 個の完全データセットについても繰り返すと、回帰ウェイト付けとその標準誤差の推定値が 9 個ずつ得られます。次の表に、計 10 個の推定値と標準誤差を示します。

代入	ML 推定値	ML 標準誤差
1	1.106	0.160
2	1.080	0.160
3	1.118	0.151
4	1.273	0.155
5	1.102	0.154
6	1.286	0.152
7	1.121	0.139
8	1.283	0.140
9	1.270	0.156
10	1.081	0.157

### 手順 3: 多重代入データ ファイルの結果の結合

1 つの完全データセットの分析から得られた標準誤差は、欠損データ値を代入したために生じる不確実性が考慮されていないため正確とは言えません。完全データセットの個別分析から推定値と標準誤差を収集し、単一の要約値 ( パラメータ推定値の要約値およびパラメータ推定値の標準誤差の要約値 ) に結合する必要があります。これを実行するための公式 (Rubin, 1987 年) はさまざまな文献に記載されています。下記の公式の出典は、Schafer の論文 (1997 年、109 ページ) です。このセクションの以下の部分では、これらの公式を、上記の 10 個の推定値と標準誤差の表に適用します。以下において、

$m$  を、完全データセットの数とします (このケースでは、 $m = 10$ )。

$\hat{Q}^{(t)}$  を標本  $t$  の推定値とします。したがって、 $\hat{Q}^{(1)} = 1.106$ 、 $\hat{Q}^{(2)} = 1.080$ 、などとなります。

$\sqrt{U^{(t)}}$  を標本  $t$  の標準誤差の推定値とします。したがって、 $\sqrt{U^{(1)}} = 0.160$ 、 $\sqrt{U^{(2)}} = 0.160$ 、などとなります。

回帰ウェイト付けの多重代入推定値は、次のように 10 個の完全データセットから得られる 10 個の推定値の平均に過ぎません。

$$\bar{Q} = \frac{1}{m} \sum_{t=1}^m \hat{Q}^{(t)} = 1.172$$

結合されたパラメータ推定値の標準誤差を得るには、次の手順を実行します。

- ▶ 代入内分散の平均を計算します。

$$U = \frac{1}{m} \sum_{t=1}^m U^{(t)} = 0.0233$$

- ▶ 代入間分散を計算します。

$$B = \frac{1}{m-1} \sum_{t=1}^m (\hat{Q}^{(t)} - \bar{Q})^2 = 0.0085$$

- ▶ 全分散を計算します。

$$T = U + \left(1 + \frac{1}{m}\right) B = 0.0233 + \left(1 + \frac{1}{10}\right) 0.0085 = 0.0326$$

複数グループの標準誤差は、次のようになります。

$$\sqrt{T} = \sqrt{0.0326} = 0.1807$$

母集団において回帰ウェイト付けが 0 になるという帰無仮説の検定は、統計量

$$\frac{\bar{Q}}{\sqrt{T}} = \frac{1.172}{0.1807} = 6.49$$

に基づきます。回帰ウェイト付けが 0 の場合、この統計量は、次の式によって得られる自由度を持つ t 分布を持ちます。

$$v = (m-1) \left[ 1 + \frac{U}{\left(1 + \frac{1}{m}\right)B} \right]^2 = (10-1) \left[ 1 + \frac{0.0233}{\left(1 + \frac{1}{10}\right)0.0085} \right]^2 = 109$$

Joseph Schafer の NORM プログラムで、これらの計算を行うことができます。NORM は、<http://www.stat.psu.edu/~jls/misoftwa.html#win> からダウンロードできます。

## 参考文献

Amos には、FIML (例 17 を参照)、多重代入、ベイズ推定など、欠損データを処理する高度なメソッドがいくつか用意されています。各メソッドの詳細を確認する場合、FIML および多重代入の概要については Schafer と Graham (2002 年) の論文を参照してください。Allison は FIML と多重代入の両方を扱った簡潔でわかりやすいモノグラフ (Allison, 2002 年) を発表しています。この論文には、数多くの機能例と、多変量正規性を想定した多重代入法の文脈内で非正規変数およびカテゴリ変数を処理する方法に関する優れた論考が示されています。Schafer (1997 年) は、多重代入について詳細かつ技術的に論じています。Schafer と Olsen (1998 年) は、多重代入を実行するための、わかりやすく段階的なガイドを発表しています。

構造方程式モデルにおける FIML と多重代入の統計パフォーマンスを比較した、SEM 固有の研究も入手可能です (Olinsky, Chen, および Harlow, 2003 年)。最後に、例 26 から例 29 で説明したベイズ推定アプローチが、欠損データの処理方法において FIML に似ている点に注目しておく必要があります。Ibrahim らは、最近、不完全なデータの問題に対処するための、FIML、ベイズ推定、確率の重み付け、および多重代入の各アプローチのパフォーマンスを比較し、欠損値がランダムな欠損 (MAR) プロセスから生じる、不完全なデータの問題を処理するうえで、これら 4 つのアプローチのパフォーマンスがおおむね同様に良好であったと結論付けています (Ibrahim, Chen, Lipsitz, および Herring, 2005 年)。彼らの報告では SEM ではなく一般線型モデルが検討されていますが、彼らの調査結果と結論は、一般に、SEM を含む広範な統計モデルとデータ分析シナリオにも適用できます。

# 打ち切りデータ

## 概要

ここでは、打ち切りデータを使用したパラメータの推定、事後予測分布の推定、およびデータ代入について説明します。

## データについて

この例では、1967年から1974年の間にスタンフォード心臓移植プログラムに登録された103人の患者から得た打ち切りデータを使用します。このデータはCrowley およびHuによって収集されたもので(1977年)、Kalbfleisch およびPrenticeなどが再分析を行っています(2002年)。このデータセットはtransplant-a.savファイルに保存されています。

	開始年	年齢	経過日数	経過平方根	ステータス
17	1968	20.33	35	5.916	非打ち切り
18	1968	56.85	42	6.481	非打ち切り
19	1968	59.12	36	6.000	非打ち切り
20	1969	55.28	27	5.196	非打ち切り
21	1969	43.34	1031	32.109	非打ち切り
22	1969	42.78	50	7.071	非打ち切り
23	1969	58.36	732	27.055	非打ち切り
24	1969	51.80	218	14.765	非打ち切り
25	1969	33.22	1799	42.415	打ち切り
26	1969	30.54	1400	37.417	打ち切り
27	1969	8.79	262	16.186	非打ち切り

上の図で1番上に表示されている行を左から順に説明します。患者17は1968年にプログラムに登録され、当時の年齢は20.33才でした。この患者は35日後に死亡しました。次の数字5.916は、35の平方根です。Amosでは、打ち切り変数を正規分布と仮定します。この例では、生存期間の平方根の分布は生存期間自体の分布よりも正規分布に近くなるという前提の下に、生存期間の平方根を使用します。[非打ち切り]は、患者の生存期間がわかっていることを表します。言い換えれば、患者がすでに死亡していたということです。このことから、この患者はプログラムに登録された後35日間生存したということがわかります。

一部の患者は、最後の観察時も生存していました。たとえば、患者25は、1969年、33.22才のときにプログラムに登録されました。この患者を最後に観察したのは1,799日後です。42.415は1,799の平方根です。[ステータス]列の[打ち切り]は、この患者がプログラムに登録されてから1,799日後に生存していたこと、かつ、その日がこの患者を最後に観察したときであることを意味します。そのため、この患者の生存期間が1,799日間であるとはいえません。実際、この患者はさらに長生きをしましたが、その期間はわかりません。このようなケースは他にもあります。患者番号26を最後に観察したのはプログラムへの登録後1,400日後のことで、当時もまだ生存していました。したがって、この患者が少なくとも1,400日間は生存したことがわかります。

患者25の生存期間1,799日など、打ち切り値はどのように扱えば良いでしょうか。1,799および他の打ち切り値をすべて破棄すると、長期間生存した患者のデータを破棄することになるため、値を破棄することはできません。他方、この患者は1,799日より長く生存していたことがわかっているため、1,799のまま通常のスコアと同様に処理することもできません。

Amosでは、「患者25が1,799日より長く生存した」という情報を使用できます。この情報を破棄したり、この患者の生存期間が正確にわかっていると仮定したりする必要はありません。もちろん、生存期間が218日間だったことがわかっている患者24のように、正確な数値があるデータについては、その数値が使用されます。

## データの再コード化

データファイルは、Amos で読み込みを実行する前に再コード化する必要があります。次の図は、再コード化した後のデータセットの一部を示しています (完全なデータセットは transplant-a.sav ファイルにあります)。

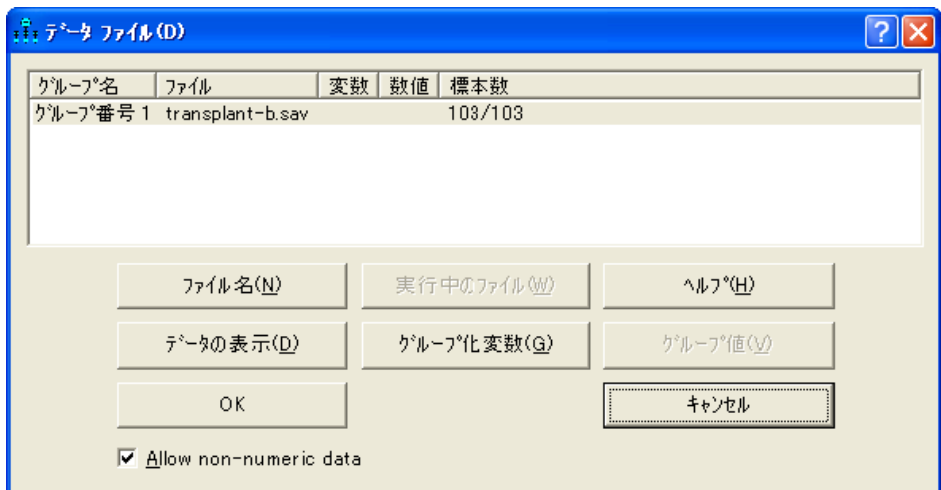
	開始年	年齢	経過日数	経過平方根
17	1968	20.33	35	5.916
18	1968	56.85	47	6.481
19	1968	59.12	36	6.000
20	1969	55.28	27	5.196
21	1969	43.34	1031	32.109
22	1969	42.78	50	7.071
23	1969	58.36	732	27.055
24	1969	51.80	218	14.765
25	1969	33.22	> 1799	> 42.415
26	1969	30.54	> 1400	> 37.417

観測値が非打ち切りのデータは、新しいデータファイルでも元のデータファイルと同じ様に表示されています。しかし、打ち切り値は、元のデータファイルとは異なるコード化処理が行われています。たとえば、患者25の生存期間(1,799日よりも長いとしかわかっていない)は、新しいデータファイルでは[>1799]とコード化されています([>1799]のような文字列中のスペースは省略可能です)。また、生存期間の平方根は42.415よりも大きいことがわかっているため、このデータファイルでは患者25の[経過平方根]列に[>42.415]と表示されています。数値変数と文字列変数を区別するデータファイル形式(SPSS Statistics形式など)のために、経過日数と経過平方根は文字列変数としてコード化する必要があります。

## データの分析

次の手順に従って、Amos Graphics でデータ ファイルを指定します。


- ▶ メニューから、[ファイル]、[データ ファイル] の順にクリックします。
- ▶ [データ ファイル] ダイアログ ボックスで、[ファイル名] ボタンをクリックします。
- ▶ データ ファイル transplant-a.sav を選択します。
- ▶ [数値でないデータを許可する] を選択します (チェック マークが表示されます)。



前述したデータの再コード化、および [数値でないデータを許可する] の有効化は、打ち切りデータを分析する場合に限り必要となる手順です。この 2 点を除けば、打ち切りデータを使用したモデルの適用と結果の解釈の方法は、データがすべて数値データの場合とまったく変わりません。

## 回帰分析の実行

それでは、年齢および登録年度 (開始年) を予測変数として、経過平方根を予測してみましょう。まず、次のようなパス図を描きます。








次のいずれかの方法でモデルを適用します。

- ▶ ツールバーの  をクリックします。

または

- ▶ メニューから、[分析]、[ベイズ推定] の順に選択します。

注：非数値データを使用する場合はベイズ推定しか実行できないため、 のボタンは無効化されています。

[ベイズ SEM] ウィンドウが開いたら、不機嫌な顔  が上機嫌の顔  に変わるまで待ちます。[ベイズ SEM] ウィンドウに、次のような推定値の表が表示されます。


	平均値	標準誤差	標準偏差	収束統計量	中央値	歪度	尖度	最小値	最大値
<b>係数</b>									
経過平方根<--年齢	-0.29	0.00	0.15	1.00	-0.29	-0.03	0.12	-0.99	0.38
経過平方根<--開始年	1.45	0.00	0.80	1.00	1.44	0.08	0.06	-1.80	4.96
<b>平均値</b>									
年齢	45.17	0.00	0.99	1.00	45.17	0.01	0.09	41.05	50.19
開始年	1970.61	0.00	0.19	1.00	1970.61	0.00	0.10	1969.57	1971.52

この図は表の一部です。[平均値] 列には、パラメータのポイント推定値が表示されています。開始年を使用して経過平方根を予測する係数は 1.45 です。つまり、登録年度が 1 年あとだと、生存期間の平方根の値が 1.45 増加すると予測できます。この予測は、調査期間中に移植プログラムが改善していった可能性があることを示唆しています。年齢を使用して経過平方根を予測する係数は -0.29 です。つまり、移植プログラム登録時の患者の年齢が 1 才上がるごとに、生存期間の平方根の値が 0.29 ずつ減少すると予測できます。-0.29 という係数推定値は、実際は係数の事後分布の平均値です。

- ▶ 事後分布全体を確認するには、推定値 -0.29 を含む行を右クリックして、ポップアップメニューから [事後分布の表示] を選択します。

	平均値	標準誤差	標準偏差	収束統計量	中央値	歪度	尖度	最小値	最大値
<b>係数</b>									
経過平方根<--年齢	-0.29	0.00	0.15	1.00	-0.28	-0.06	0.10	-0.92	0.34
経過平方根<--開始年	1.47	事後分布の表示		1.00	1.44	0.15	0.07	-1.34	5.2
		事前分布の表示							
<b>平均値</b>									
年齢	45.19	0.02	1.03	1.00	45.16	0.05	0.13	41.56	49.1
開始年	1970.62	0.00	0.19	1.00	1970.62	-0.01	-0.03	1969.86	1971.24


[事後分布] ダイアログ ボックスが表示され、係数の事後分布が表示されます。




係数の事後分布は確かに -0.29 付近が最も高くなっています。-0.75 ~ 0.25 の範囲にほとんどすべてが分布しているので、この範囲内に係数があると考えて問題ありません。さらに分布の大部分が -0.5 ~ 0 の範囲にあることから、係数は -0.5 ~ 0 の間だとほぼ確定できます。

## 事後予測分布

このデータセットには、患者 25 の生存期間のような打ち切り値が含まれていました。患者 25 の生存期間についてわかっているのは、1,799 日よりも長いこと、したがって生存期間の平方根は 42.415 よりも大きいということです。この患者の経過平方根が 42.415 よりどれだけ大きいかはわかりませんが、その事後分布を求めることはできません。経過平方根が 42.415 を超えることを考慮し、モデルが正確だという前提で、患者 25 の年齢と開始年から生存期間についてどのようなことがわかるのでしょうか。これを確かめるには、次の操作を行います。

- ▶ [事後予測分布] ボタン  をクリックします。
- または
- ▶ メニューから、[表示]、[事後予測分布] の順に選択します。

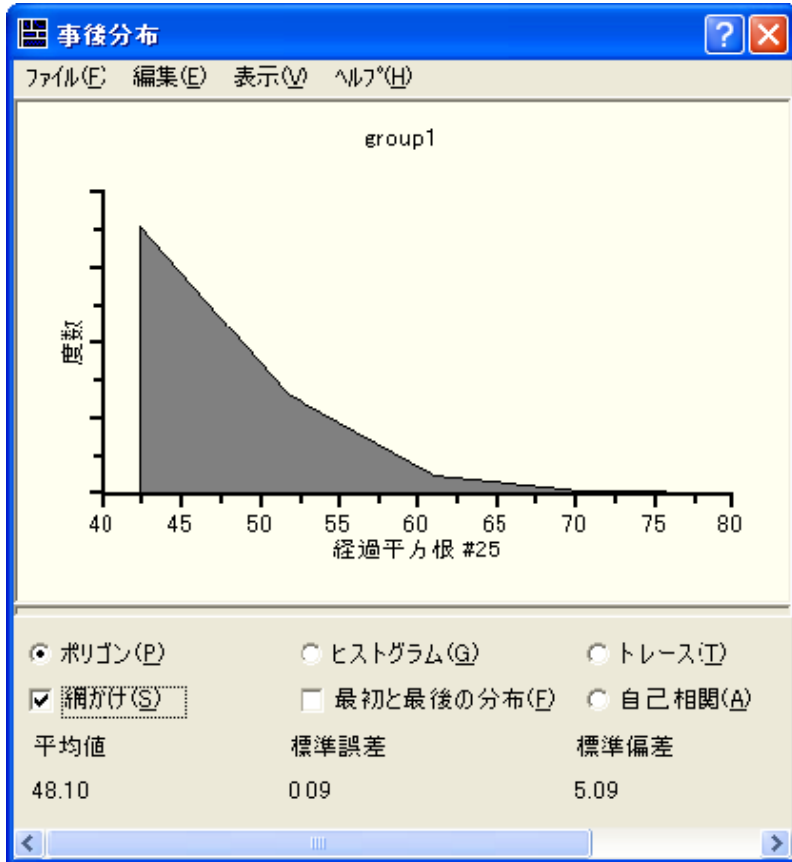


	経過平方根	年齢	開始年
17	5.916	20.33127995	1968
18	6.481	56.84873374	1968
19	6	59.12388775	1968
20	5.196	55.27991524	1969
21	32.109	43.34291581	1969
22	7.071	42.78439425	1969
23	27.055	58.35728953	1969
24	14.765	51.80013689	1969
25	<<	33.2238193	1969
26	<<	30.53524983	1969
27	16.186	8.785793176	1969

[事後予測分布] ウィンドウに表が表示されます。この表では、行が各患者に対応しており、列がモデルの観測変数に対応しています。25 行目を見ると、患者 25 の年齢と開始年のスコアがわかります。患者 25 の経過平方根には、<< という記号が表示されています。これは、このデータでは経過平方根のスコアに不等式制約が適用されていて実際の数値ではないということを表しています。

患者 25 の経過平方根の事後分布を表示するには、次のようにします。


- ▶ [<<] をクリックします。[事後分布] ウィンドウに事後分布が表示されます。



患者 25 の経過平方根の事後分布は、完全に 42.415 の右側に分布しています。データだけ見ても経過平方根が 42.415 を超えていることは明らかでしたが、この分布からは、患者 25 の経過平方根が 70 を超える可能性がほとんどないとわかります。さらに、経過平方根が 55 を超える確率が非常に低いこともわかります。

患者 25 の事後予測分布とは分布の形状が異なる場合について見てみましょう。

- ▶ 事後予測分布表の 100 行目の [<<] の記号をクリックします。

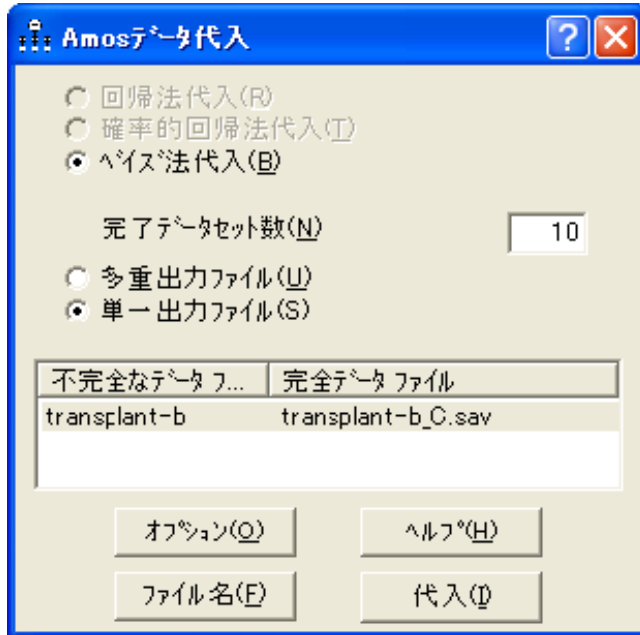


患者 100 が最後に観察されたのはプログラムに登録されてから 38 日後で、この時点でまだ生存していました。つまり、経過平方根は 6.164 以上であることがわかっています。患者の経過平方根の事後分布をみると、6.164 ~ 70 の範囲であると考えて良いし、さらには 6.164 ~ 50 の範囲内である確率が高いことがわかります。平均値は 27.36 で、経過平方根のポイント推定値となります。27.36 を 2 乗した値 748 が、患者 100 の生存期間 (日数) の推定値となります。

## 代入

このモデルを使用して、打ち切り値に値を代入することができます。

- ▶ [バイズ SEM] ウィンドウが開いている場合はこれを閉じます。
- ▶ Amos Graphics メニューから、[分析]、[データ代入]の順に選択します。

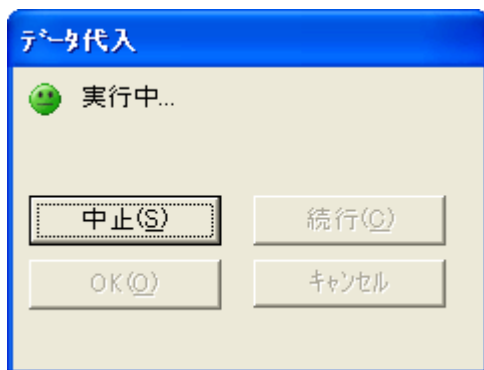


[回帰法代入]と[確率的回帰法代入]は選択できない状態になっているはずです。打ち切りデータのような非数値データを使用している場合は、[バイズ法代入]しか選択できません。


上の図に表示されている設定に従い、10個の完全データセットを作成してそのすべてを transplant-b\_C.sav という1つの SPSS Statistics データファイルに保存します。代入を開始する手順は次のとおりです。

- ▶ [代入] ボタンをクリックします。

[ベイズ SEM] ウィンドウとともに[データ代入]ダイアログボックスが表示されます。



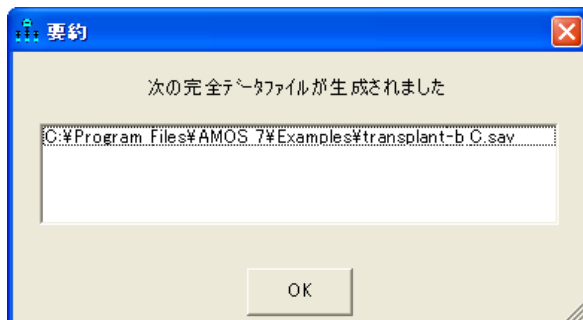
- ▶ [データ代入]ダイアログボックスに上機嫌の顔 😊 (10個の各完全データセットの間に実質的な相関がないことを示す)が表示されるまで待ちます。



注: 上機嫌の顔が表示された後 [OK] をクリックする前に、[ベイズ SEM] ウィンドウ内の任意のパラメータを右クリックして、ポップアップメニューから [事後分布の表示] を選択することもできます。これにより、トレース図や自己相関図を確認できます。

- ▶ [データ代入]ダイアログボックスで、[OK] をクリックします。

[要約] ウィンドウに、作成された完全データファイルの一覧が表示されます。ここでは、作成された完全データファイルは1つだけです。



- ▶ ファイル名をダブルクリックして、単一の完全データ ファイルの内容を表示します。このファイルには 10 個の完全データセットが含まれています。

10 個ある完全データセットのそれぞれには 103 のケースが含まれています。したがって、ファイルに含まれるケース数は 1,030 です。新しいデータ ファイルの最初の 103 行は、1 番目の完全データ セットに対応します。1 番目の完全データセットの各行の `imputeno` 変数は 1、`caseno` 変数はそれぞれ 1～103 となっています。

	経過平方根	年齢	開始年	CaseNo	Imputation_
1	7.00	30.84	1967.00	1.00	1.00
2	2.24	51.84	1968.00	2.00	1.00
3	3.87	54.30	1968.00	3.00	1.00
4	6.16	40.26	1968.00	4.00	1.00
5	4.12	20.79	1968.00	5.00	1.00
6	1.41	54.60	1968.00	6.00	1.00
7	25.96	50.87	1968.00	7.00	1.00
8	6.25	45.35	1968.00	8.00	1.00
9	9.17	47.16	1968.00	9.00	1.00
10	7.55	42.50	1968.00	10.00	1.00
11	12.33	47.98	1968.00	11.00	1.00
12	2.65	53.19	1968.00	12.00	1.00
13	8.94	54.57	1968.00	13.00	1.00
14	37.23	54.01	1968.00	14.00	1.00
15	0.00	53.82	1968.00	15.00	1.00
16	17.52	49.45	1968.00	16.00	1.00
17	5.92	20.33	1968.00	17.00	1.00
18	6.48	56.85	1968.00	18.00	1.00
19	6.00	59.12	1968.00	19.00	1.00
20	5.20	55.28	1969.00	20.00	1.00
21	32.11	43.34	1969.00	21.00	1.00
22	7.07	42.78	1969.00	22.00	1.00
23	27.06	58.36	1969.00	23.00	1.00
24	14.77	51.80	1969.00	24.00	1.00
25	49.66	33.22	1969.00	25.00	1.00
26	41.67	30.54	1969.00	26.00	1.00

完全データ ファイルの最初の行の経過平方根の値は 7 です。この値は打ち切り値ではないので、7 は代入値ではありません。この値は、元のデータ ファイルに含まれていた通常の数値です。一方、患者 25 の経過平方根は打ち切り値だったため、この患者の経過平方根の値 (この例では 49.66) は代入値です。49.66 という値は、444 ページの図にある事後予測分布から無作為に抽出された値です。



通常、この後に行う手順では、打ち切りデータを適用できない他のプログラムへの入力用に、`transplant-b_C.sav` 内の 10 個の完全データセットを使用します。この場合、そのプログラムでは、10 個の完全データセットを 1 つずつ順番に使って 10 回の分析を個別に実行することになります。その後、例 31 で行ったように、さらに計算を実行し 10 回分の分析結果を 1 つの結果セットにまとめます。この例では、これらの手順は実行しません。

## データ値に対する一般的な不等式制約

この例では、 $> 1799$  のような不等式制約だけ取り上げました。他にも不等式制約を示す文字列値があり、次のようなものが、元の数値変数の値に対する不等式制約を示す文字列値としてデータ ファイルで使用できます。

- 文字列値  $<5$  は、元になる数値が 5 未満であることを表します。
- 文字列値  $4<<5$  は、元になる数値が 4 ~ 5 の範囲内にあることを表します。



# 順序 - カテゴリカル データ

## 概要

この例では、因子分析モデルを順序 - カテゴリカル データに適合させる方法について説明します。また、カテゴリ化された回答の基礎となる数値変数の事後予測分布を求める方法や、カテゴリ化された回答に数値を代入する方法についても説明します。

## データについて

この例では、オランダ国内で 1,017 人を対象に行った環境問題に関する意識アンケート調査の回答をデータとして使用します。このデータは、European Values Study Group がまとめたものです (参考文献の一覧を参照してください)。データ ファイル environment-nl-string.sav には、6 つの質問項目に対するそれぞれの回答が保存されています。回答は、「強く同意できない」(SD)、「同意できない」(D)、「同意する」(A)、「強く同意する」(SA) のいずれかのカテゴリから選択されたものです。

	ITEM1	ITEM2	ITEM3	ITEM4	ITEM5	ITEM6
1	A		SA	SD	A	A
2	A		A	SA	SA	SA
3		A	A	A	A	A
4	A	A	A			
5	D	SD			D	
6	SA	SA	A		A	A
7	A	D		A	A	A
8	D	D		SD		SD
9	SA	SA	SA	A		A
10	SA	A	A	SA	SA	
11	A	A	A	A		A
12	SA	SA	A	A		A

これらのデータを分析する手段として、4つにカテゴリ化された回答のそれぞれに数値を割り当てることができます(1 = SD、2 = D、3 = A、4 = SA など)。この方法で各カテゴリに数値を割り当てると、environment-nl-numeric.sav のデータセットを取得できます。

	ITEM1	ITEM2	ITEM3	ITEM4	ITEM5	ITEM6
1	3	.	4	1	3	3
2	3	.	3	4	4	4
3	.	3	3	3	3	3
4	3	3	3	.	.	.
5	2	1	.	.	2	.
6	4	4	3	.	3	3
7	3	2	.	3	3	3
8	2	2	.	1	.	1
9	4	4	4	3	.	3
10	4	3	3	4	4	.
11	3	3	3	3	.	3
12	4	4	3	3	.	3

Amos の分析では、上記のような、カテゴリに数値を割り当てる方法を使用しなくても、分析は実行できます。4つにカテゴリ化された回答の順序だけを扱うこともできます。データの順序だけを扱う場合は、environment-nl-string.sav と environment-nl-numeric.sav のどちらのデータセットを使用してもかまいません。

environment-nl-numeric.sav は比較的簡単に使用できます。このデータセットを使用すると、Amos では、数値のカテゴリに対して、順位の低い方から 1、2、3、4 の順にデフォルトで番号が割り当てられるためです。この場合は、正しい順序となります。これに対し environment-nl-string.sav を使用した場合、Amos では、カテゴリがアルファベットの昇順 (A、D、SA、SD) にデフォルトで順序付けされます。この場合、順序は正しくありません。したがって、Amos におけるデフォルトのカテゴリ順序を変更する必要があります。

この例では、データ ファイル environment-nl-string.sav を使用します。これは、データの順序だけを扱うということを明瞭化するだけでなく、カテゴリの正しい順序の指定方法についても説明するためです。

## データ ファイルの指定

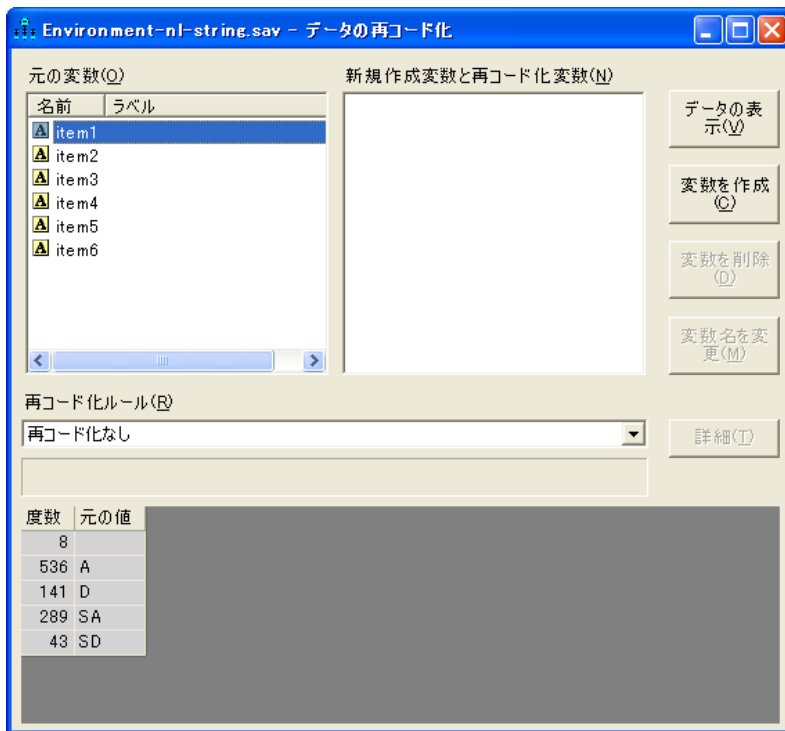
- ▶ Amos Graphics メニューから、[ファイル]→[データ ファイル]の順にクリックします。
- ▶ [データ ファイル] ウィンドウで、[ファイル名] ボタンをクリックします。
- ▶ データ ファイル environment-nl-string.sav を選択します。
- ▶ [数値でないデータを許可する] を選択します (チェック マークが表示されます)。
- ▶ [OK] をクリックします。



## Amos 内でのデータの再コード化

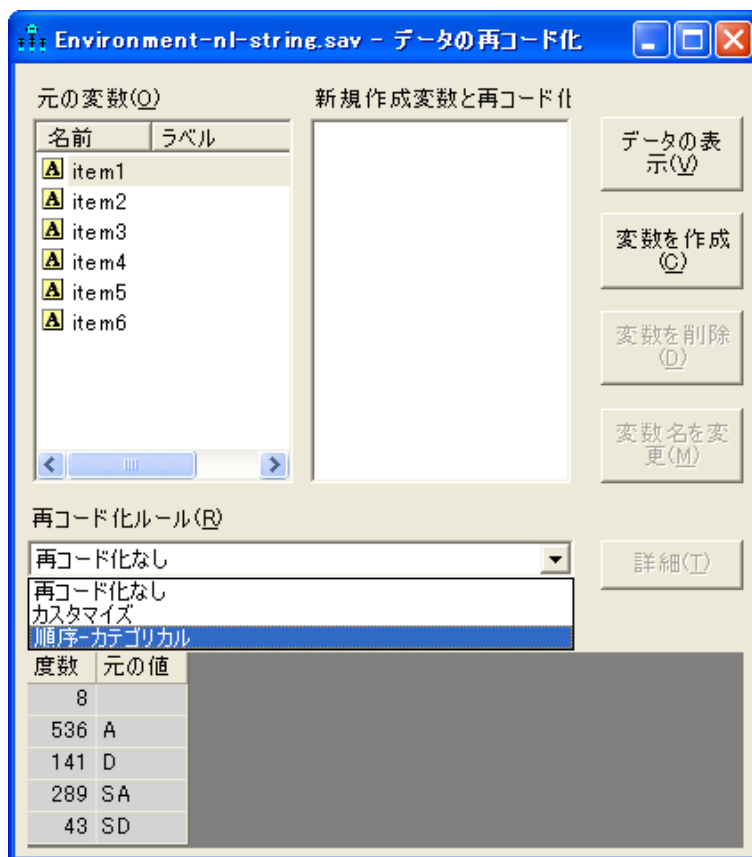
データの順序は、データ ファイルだけから特定することはできません。データの値 (SD、D、A、および SA) の解釈に必要な補足情報を Amos に対して指定する手順は次のとおりです。

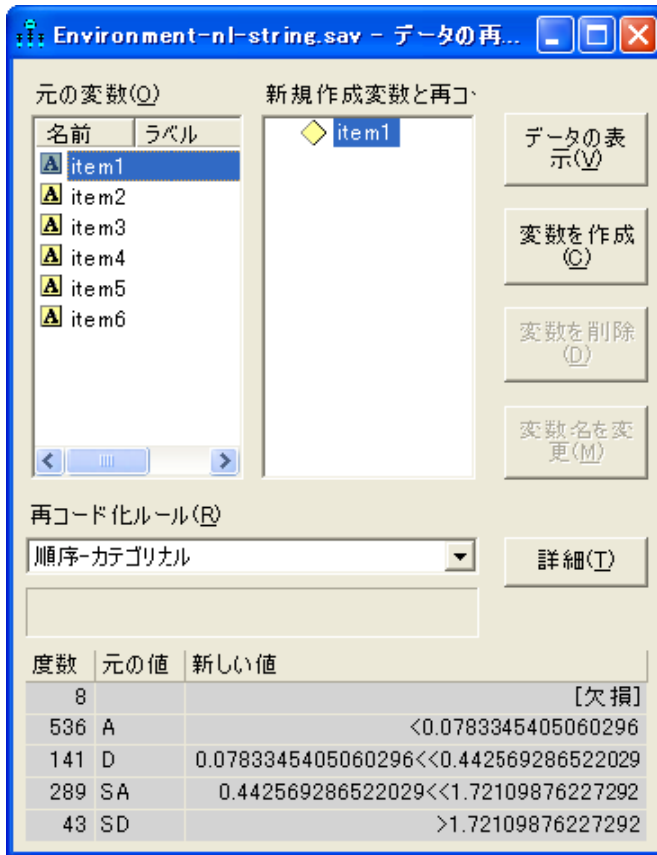
- ▶ Amos Graphics メニューから、[ツール]→[データの再コード化]の順に選択します。
- ▶ [データの再コード化] ウィンドウの左上にある変数リストから [item 1] を選択します。これにより、[item 1] に対する回答の度数分布がウィンドウの下部に表示されます。



[再コード化ルール] ボックスで [再コード化なし] を選択すると、[item 1] に対する回答がそのままの形で Amos に読み込まれます。つまり、SD、D、A、SA、空の文字列のいずれかが読み込まれます。しかし Amos は、SD や D などをもそのまま処理することができないため、なんらかの対処が必要となります。

- ▶ [再コード化なし] をクリックし、ドロップダウン リストから [順序 - カテゴリカル] を選択します。



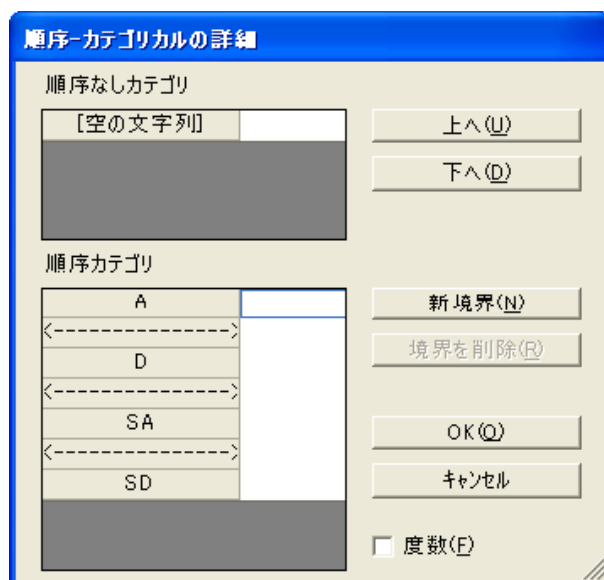


ウィンドウ下部の度数表には [新しい値] 列が作成され、データ ファイル内の [item 1] の値が、Amos に読み込まれる前にどのように再コード化されるのかが表示されます。度数表の先頭行に表示される内容は、元のデータ ファイル内に含まれる空の文字列が欠損値として処理されることを表しています。また 2 行目の内容は、回答 A が <0.0783345405060296 という文字列に変換されることを表しています。Amos ではこれを基に、[item 1] に対する回答が連続型数値変数によって表され、かつ A と回答した回答者のスコアは、基礎となる変数上では 0.0783345405060296 未満になると判断します。同様に 3 行目の内容は、回答 D が 0.0783345405060296<<0.442569286522029 という文字列に変換されることを表しており、Amos では、基礎となる変数上のスコアが 0.0783345405060296 と 0.442569286522029 の間の値になると判断します。0.0783345405060296 や 0.442569286522029 などの数値は、回答の基礎となる数値変数上のスコアが、平均値 0、標準偏差 1 の正規分布に従っていると仮定の下に、[度数] 列の度数から求められます。

[元の値] 列のカテゴリの順序は変更する必要があります。順序を変更する手順は次のとおりです。



- ▶ [詳細] ボタンをクリックします。[順序-カテゴリカルの詳細] ダイアログボックスが表示されます。



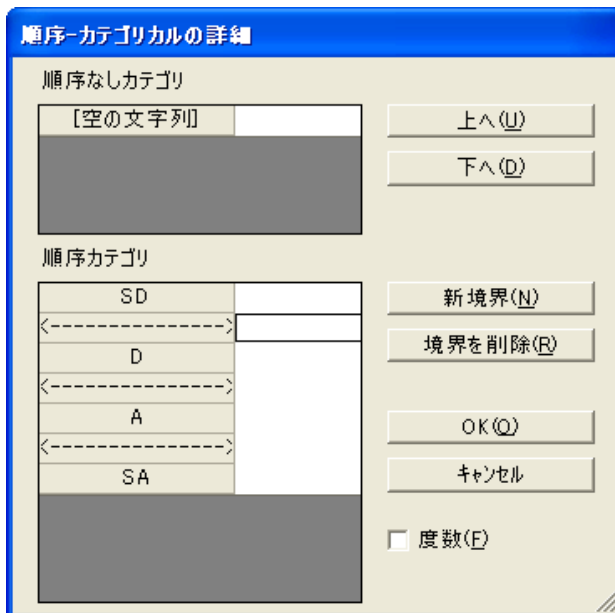
[順序カテゴリ] リストボックスには、4つの回答カテゴリがそれぞれ点線(<---->)をはさんで、A、D、SA、SDの順に表示されます。この3つの点線は、実数を、回答カテゴリに関連する4つの区間に分ける際の境界を表します。観測されない数値変数について、最も小さい境界値を下回るスコアを持つ回答者は、回答がAであると見なされます。最も小さい境界値と中央の境界値との間にスコアを持つ回答者は、回答がDであると見なされます。中央の境界値と最も大きい境界値の間にスコアを持つ回答者は、回答がSAであると見なされます。最も大きい境界値を上回るスコアを持つ回答者は、回答がSDであると見なされます。

プログラム側の処理は、カテゴリ(区間)が4つと境界が3つ存在することについては正しく行われていますが、カテゴリの順序については正しくありません。プログラムの処理では、カテゴリがアルファベット順に並べられています。そのため、これら4つのカテゴリと3つの境界はそのまま維持して、順序だけを変更する必要があります。ここでは、SDを先頭の区間(最も小さい境界値を上限とする区間)に移動するなど、順序の入れ替えをいくつか行います。

カテゴリと境界の順序は、変更することができます。手順は次のとおりです。

- ▶ マウスを使ってカテゴリまたは境界を直接ドラッグアンドドロップする。
- または
- ▶ マウスを使ってカテゴリまたは境界を選択し、[上へ]ボタンや[下へ]ボタンをクリックする。

次に示すのは、カテゴリおよび境界を正しい順序に並べ終わった時点での、[順序-カテゴリカルの詳細]ダイアログボックスの表示内容です。



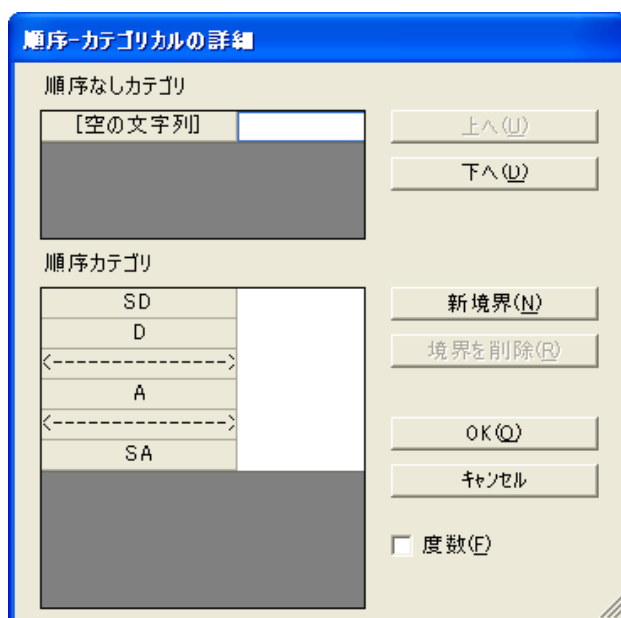
[順序なしカテゴリ] リストボックスには、Amosにより欠損値として処理される値のリストが表示されます。ここでは、ただ1つのエントリ [空の文字列] が表示されています。空の文字列は、Amosにより欠損値として処理されます。空の文字列としてコード化された回答が、実際にはSD、D、A、またはSAに対応する意味のある回答である場合には、[順序なしカテゴリ] リストボックスの [空の文字列] を選択し、[下へ] ボタンをクリックして、[空の文字列] を [順序カテゴリ] リストボックスに移動できます。

同様に、[順序カテゴリ] リストボックス内の回答(たとえばSD)が、他の回答と比較したときに意味のない回答である場合には、マウスで [SD] を選択し [上へ] ボタンをクリックすると、[順序なしカテゴリ] リストボックスに移動できます。この場合、SDは欠損値として処理されます。

**注:** [順序カテゴリ] リストボックスと [順序なしカテゴリ] リストボックスとの間でエントリを移動する場合は、ドラッグアンドドロップ操作を使用することはできません。2つのリストボックス間でカテゴリを移動するには、[上へ] ボタンまたは [下へ] ボタンを使用します。

すでに適切な数の境界とカテゴリが設定され、カテゴリが正しい順序に並べられているため、この時点で[順序-カテゴリカルの詳細]ダイアログボックスを閉じ、作業を終了してもかまいません。しかしここでは、Croon (2002) の提言に従ってさらに変更を加えます。Croon はこのデータセットを実際に使用した上で、SD カテゴリは出現の頻度が非常に低いため、D カテゴリとひとまとめにするべきであると提言しています。これら 2 つのカテゴリを 1 つのカテゴリにまとめるための手順は次のとおりです。

- ▶ まとめられる 2 つのカテゴリの境界を選択します。
- ▶ [境界を削除] ボタンをクリックします。[順序カテゴリ] リストの表示内容は次のようになります。

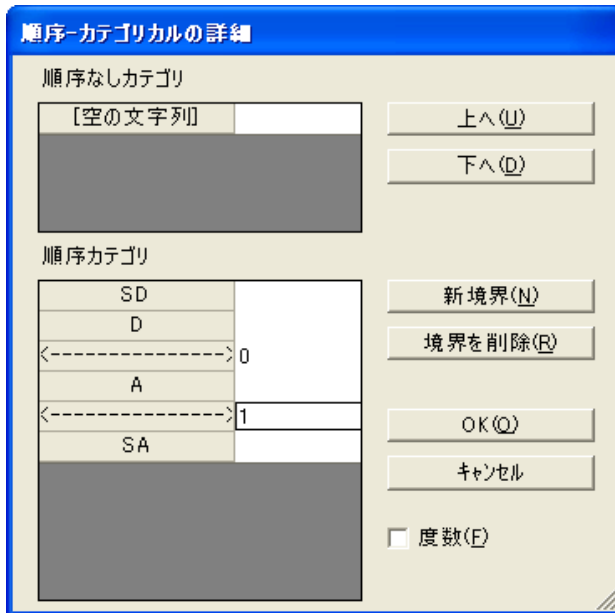


これで、回答 SD と D は区別できなくなります。どちらの回答をした回答者も、基礎となる数値変数上のスコアは、先頭の区間に属するスコアになります。

3 つある各区間を隔てている 2 つの境界には、まだ値が設定されていません。境界に値を指定しない場合は、基礎となる数値変数上のスコアが、平均値 0 および標準偏差 1 の正規分布に従っているとの仮定に基づいて、Amos で境界値が推定されます。Amos で推定を実行しない場合は、値を境界に直接割り当てることができます。値を割り当てる手順は次のとおりです。

- ▶ マウスで境界を選択します。
- ▶ テキストボックスに数値を入力します。

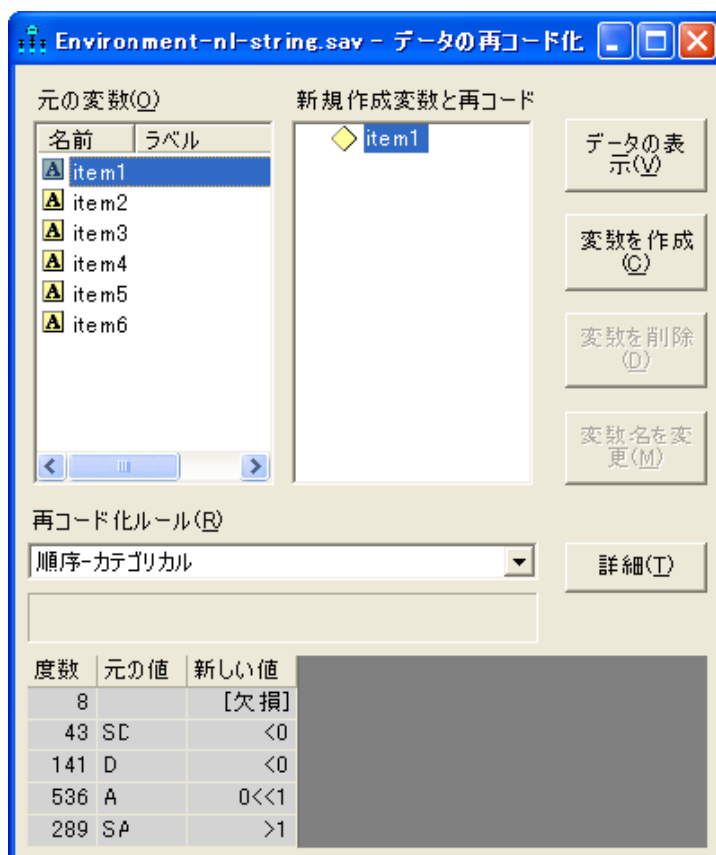
次の図は、2つの境界にそれぞれ0および1の値が割り当てられた状態を示しています。



順序が先の境界の値より順序が後の境界の値の方が大きいという条件が満たされている限り、この2つの境界には0と1でなくとも任意の1組の数値を割り当てることができます。境界の数がいくつであっても(ただし2つ以上)、そのうちの2つの境界に値を割り当てることにより、基礎となる数値変数に対して0となる点および測定単位を選択することになります。基礎となる数値変数の尺度設定については、ヘルプファイルのトピック「Choosing boundaries when there are three categories」でさらに詳しく説明します。

- ▶ [OK] をクリックして [順序-カテゴリカルの詳細] ダイアログ ボックスを閉じます。

この時点で、カテゴリおよび区間の境界に対する変更内容が、[データの再コード化] ウィンドウの度数表に反映されます。



度数表には、Amos に読み込まれる前に行われるデータ ファイルの値の再コード化方法が表示されます。度数表を上から順に説明します。

- 空の文字列は欠損値として処理されます。
- 文字列 SD と D は <0 として再コード化されます。これは、基礎となる数値スコアが 0 未満になることを表しています。
- A は  $0 << 1$  として再コード化されます。これは、基礎となる数値スコアが 0 と 1 の間の値になることを表しています。
- SA は  $> 1$  として再コード化されます。これは、基礎となる数値スコアが 1 より大きくなることを表しています。

ここまでは、[item 1] に対する処理について説明しました。[item 1] に対して行ったのと同様の処理を、残り 5 つの各観測変数に対しても行う必要があります。6 つの観測変数すべてに対して再コード化を指定したら、元のデータセットと再コード化された変数とを並べて表示することができます。手順は次のとおりです。

- ▶ [データの表示] ボタンをクリックします。

元の変数(O)							新規作成変数と再コード化変数(N)						
	item1	item2	item3	item4	item5	item6		item1	item2	item3	item4	item5	item6
1	A		SA	SD	A	A	1	0<<1	*	>1	<0	0<<1	0<<1
2	A		A	SA	SA	SA	2	0<<1	*	0<<1	>1	>1	>1
3		A	A	A	A	A	3	*	0<<1	0<<1	0<<1	0<<1	0<<1
4	A	A	A				4	0<<1	0<<1	0<<1	*	*	*
5	D	SD			D		5	<0	<0	*	*	<0	*
6	SA	SA	A		A	A	6	>1	>1	0<<1	*	0<<1	0<<1
7	A	D		A	A	A	7	0<<1	<0	*	0<<1	0<<1	0<<1
8	D	D		SD		SD	8	<0	<0	*	<0	*	<0
9	SA	SA	SA	A		A	9	>1	>1	>1	0<<1	*	0<<1
10	SA	A	A	SA	SA		10	>1	0<<1	0<<1	>1	>1	*

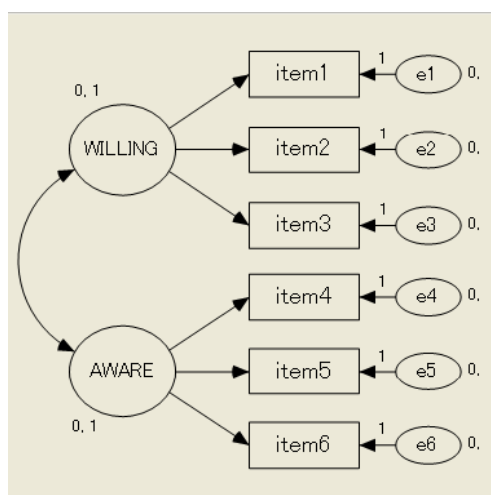
左側の表には、再コード化される前の、元のデータ ファイルの内容が表示されます。右側の表には、再コード化された後の再コード化変数が表示されます。Amos で分析が実行される際には、元の値ではなく再コード化された値が読み込まれます。

注：データの再コード化実行済みの原データ ファイルを作成できます。つまり、上図の右側に表示されているような不等号を含む原データ ファイルを作成できます。この場合、Amos の [データの再コード化] ウィンドウを使用する必要はありません。この方法は、例 32 で実際に使用しています。

- ▶ 最後に、[データの再コード化] ウィンドウを閉じ、モデルを特定化する作業に移ります。

## モデルの特定化

これまでの説明に従ってデータの再コード化ルールを指定した後は、ベイズ解析と同じ要領で分析を進めます。この例では、環境問題に関するデータセットに含まれる6つの質問事項に因子分析モデルを適合します。初めの3項目は、環境保全のために費用を負担する意志がどの程度あるかを調べるための質問です。一方、残りの3項目は、環境問題にどの程度の関心があるかを調べるための質問です。こうした質問の意図は、次に示す因子分析モデルに反映されています。この因子分析モデルは Ex33-a.amw ファイルに保存されています。




パス図は、数値データの場合とまったく同様に作成されます。これは、順序 - カテゴリカル変数ごとに最低3つのカテゴリが存在する場合の利点の1つです。つまり、変数がすべて数値型である場合と同じ方法でモデルを特定化することができ、なおかつそのモデルは数値変数と順序 - カテゴリカル変数の任意の組み合わせに対して適用できます。変数が二値変数の場合は、モデルを識別できるようにパラメータに関する制約を追加する必要があります。これについては、オンラインヘルプのトピック「Parameter identification with dichotomous variables」で詳しく説明します。

## モデルの適合

- ▶ ツールバーの  をクリックします。

または

- ▶ メニューから、[分析] → [ベイズ推定] の順に選択します。

**注**：非数値データを使用する場合はベイズ推定しか実行できないため、 のボタンは無効化されています。

[ベイズ SEM] ウィンドウが開いたら、アイコンが不機嫌な顔から上機嫌な顔に変わるまで待ちます。[ベイズ SEM] ウィンドウの表示内容が次のようになります。

	平均値	標準誤差	標準偏差	収束統計量	中央値	歪度	尖度	最小値	最大値	名前
<b>係数</b>										
item1<--WILLING	0.59	0.00	0.03	1.00	0.59	0.06	0.02	0.48	0.69	
item2<--WILLING	0.61	0.00	0.03	1.00	0.61	0.14	0.11	0.49	0.76	
item3<--WILLING	0.41	0.00	0.02	1.00	0.41	0.06	0.06	0.33	0.51	
item4<--AWARE	0.56	0.00	0.03	1.00	0.56	0.09	0.04	0.44	0.69	
item5<--AWARE	0.41	0.00	0.03	1.00	0.41	0.08	0.02	0.31	0.53	
item6<--AWARE	0.55	0.00	0.03	1.00	0.55	0.09	0.00	0.44	0.69	
<b>切片</b>										
item1	0.62	0.00	0.02	1.00	0.62	-0.01	-0.07	0.51	0.71	
item2	0.35	0.00	0.03	1.00	0.35	0.00	0.02	0.26	0.46	
item3	0.52	0.00	0.02	1.00	0.52	-0.03	-0.09	0.44	0.61	
item6	0.62	0.00	0.02	1.00	0.62	0.00	-0.05	0.52	0.71	
item4	0.35	0.00	0.03	1.00	0.35	-0.06	0.01	0.23	0.45	
item5	0.48	0.00	0.02	1.00	0.48	0.03	-0.08	0.40	0.57	
<b>共分散</b>										
AWARE<->WILLING	0.55	0.00	0.04	1.00	0.55	-0.11	0.05	0.41	0.68	

上図には、パラメータ推定値の一部だけが表示されています。[平均値]列には、各パラメータのポイント推定値が表示されます。たとえば、WILLING から項目 1 を予測する場合の係数は 0.59 です。事後分布の歪度 (0.09) および尖度 (-0.01) は 0 に近い値であり、事後分布がほぼ正規分布になっていることと一致します。標準偏差 ([S.D.]) は 0.03 であり、係数は約 67% の確率で  $0.59 \pm 0.03$  の範囲内に収まります。標準偏差を 2 倍の 0.06 にすると、係数は約 95% の確率で  $0.59 \pm 0.06$  の範囲内に収まります。

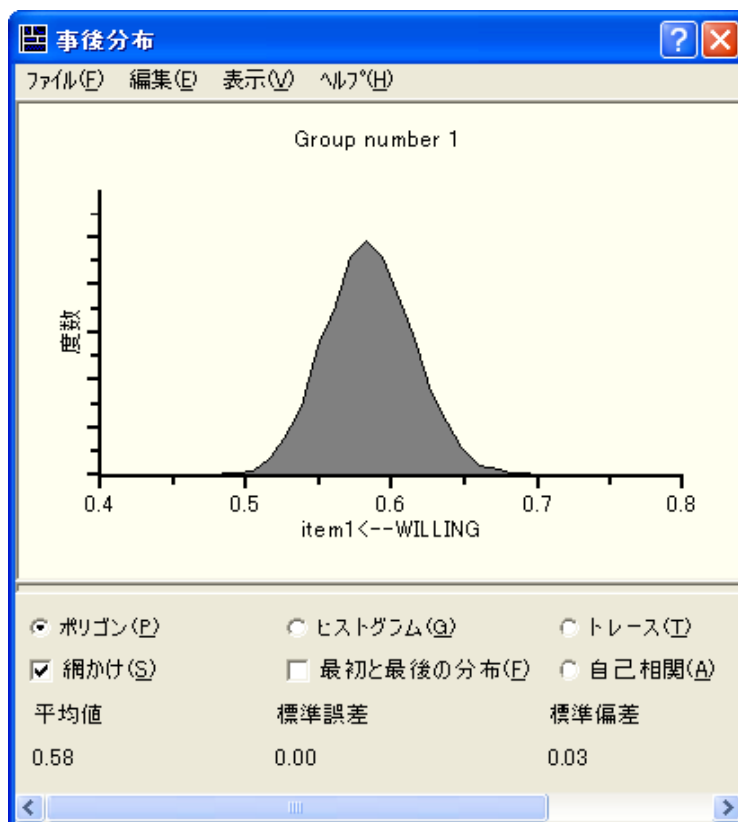
係数の事後分布を表示する手順は次のとおりです。

- ▶ 目的の行を右クリックし、ポップアップメニューから [事後分布の表示] を選択します。

	平均値	標準誤差	標準偏差	収束統計量	中央値	歪度	尖度	最小値	最大値
<b>係数</b>									
item1<--WILLING	0.58	0.00	0.03	1.00	0.58	0.11	0.24	0.47	0.70
item2<--WILLING	0.61	0.00	0.03	1.00	事後分布の表示(○)			0.51	0.73
item3<--WILLING	0.41	0.00	0.02	1.00	事前分布の表示(□)			0.34	0.50
item4<--AWARE	0.56	0.00	0.03	1.00	0.56	0.11	-0.03	0.45	0.67
item5<--AWARE	0.41	0.00	0.03	1.00	0.40	0.16	0.21	0.31	0.54
item6<--AWARE	0.55	0.00	0.03	1.00	0.55	0.16	0.01	0.45	0.68




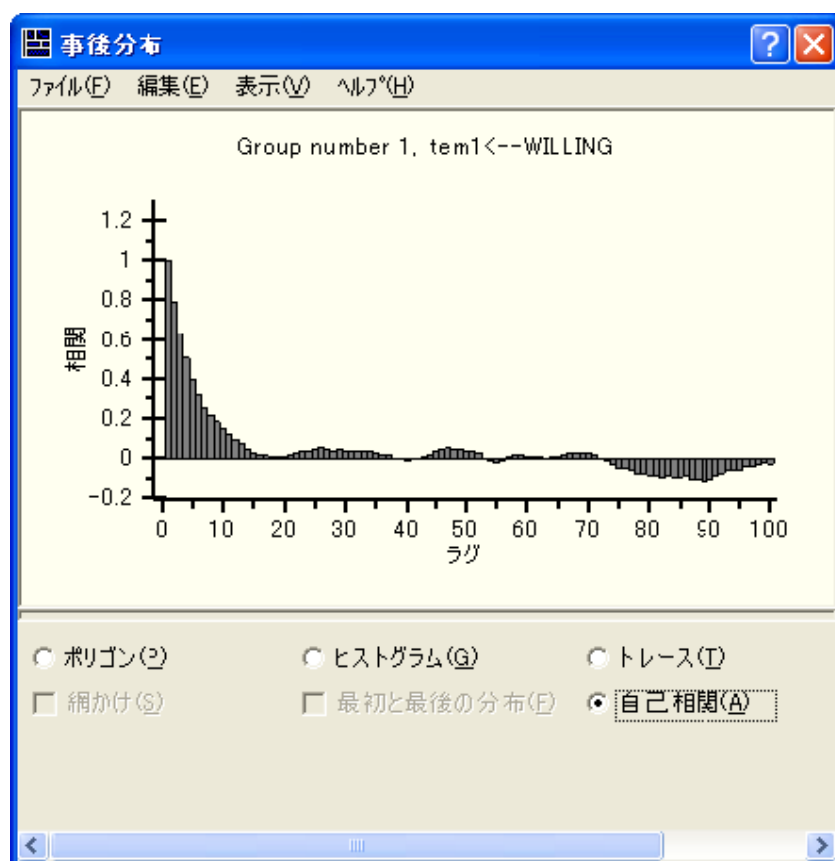
[事後分布] ウィンドウに事後分布が表示されます。分布の形状により、分布の平均値、標準偏差、歪度、および尖度を基に判断した先の結果を再確認することができます。分布の形状は正規分布に近く、領域の 95% は 0.53 と 0.65 の間 (つまり  $0.59 \pm 0.06$ ) に含まれていると考えられます。



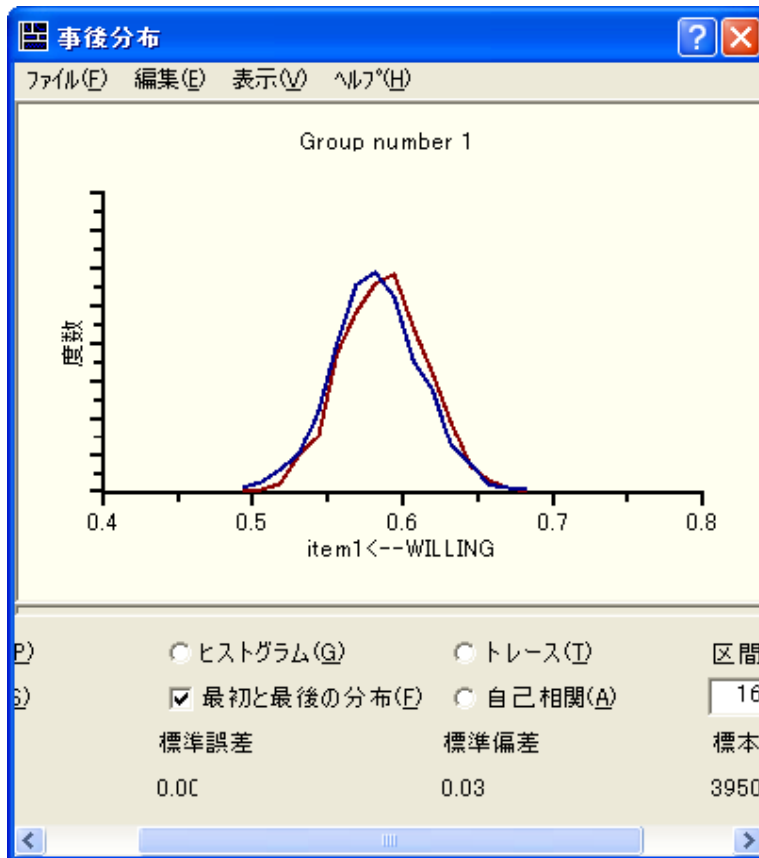
## MCMC 診断

MCMC アルゴリズム (Gelman 他 (2013) を参照) による診断の出力結果を理解する知識がある場合は、[トレース] 図や [自己相関] 図を活用することができます。





[最初と最後の分布] 図からは、別の診断内容を読み取ることができます。この図には、事後分布の 2 つの推定値 (2 つを重ね合わせた図) が表示されます。一方は MCMC 標本の最初の 3 分の 1 についての推定値、もう一方は MCMC 標本の最後の 3 分の 1 についての推定値です。




## 事後予測分布

推定と言えば通常は、標準化係数や間接効果など、モデルパラメータまたはその関数の推定を思い浮かべます。しかしこの分析では、それ以外にも未知量が存在します。452 ページにあるデータ表の各エントリは、未知の数値または一部が未知の数値を表しています。たとえば、回答者 1 は項目 2 に対して無回答であるため、回答者 1 の基礎となる数値変数上のスコアは推測 (推定) するしかありません。一方、その他の項目に関する回答者 1 の回答や、モデルが適切であるという仮定から得られる結果を考慮すれば、基礎となる数値変数については、かなり確度の高い推測が可能だと考えられます。

回答者 1 は、項目 1 に対しては回答しているため、項目 1 の基礎となる数値変数上の回答者 1 のスコアについて推測を行うことは非常に容易です。回答者 1 のスコアは、その回答から、2 つの境界の間にある中央の区間に属していると判断されます。2 つの境界にはすでに 0 および 1 という値が割り当てられているため、回答者 1 のスコアは 0 と 1 の間の値を取ることは明らかですが、さらに、その他の項目に関する回答や、モデルが適切であるという仮定を考慮することによって、より詳しい値を求めることができます。


ベイズ推定では、未知量はすべて同じ方法で処理されます。未知データの値は、未知パラメータの値を推定する場合とまったく同様に、その事後分布を与えることによって推定が行われます。未知データの値に関する事後分布は事後予測分布と呼ばれますが、解釈の方法は他の事後分布とまったく同じです。未知データの値に関する事後予測分布を表示する手順は次のとおりです。

- ▶ [事後予測分布] ボタン  をクリックします。

または

- ▶ メニューから、[表示] → [事後予測分布] の順に選択します。

[事後予測分布] ウィンドウが表示されます。




	item1	item2	item3	item4	item5	item6
1	<<	*	<<	<<	<<	<<
2	<<	*	<<	<<	<<	<<
3	*	<<	<<	<<	<<	<<
4	<<	<<	<<	*	*	*
5	<<	<<	*	*	<<	*
6	<<	<<	<<	*	<<	<<
7	<<	<<	*	<<	<<	<<
8	<<	<<	*	<<	*	<<
9	<<	<<	<<	<<	*	<<
10	<<	<<	<<	<<	<<	*
11	<<	<<	<<	<<	*	<<
12	<<	<<	<<	<<	*	<<
13	<<	<<	<<	<<	*	<<
14	<<	<<	*	<<	*	<<
15	*	*	<<	<<	<<	<<
16	<<	*	<<	<<	<<	<<
17	<<	<<	*	<<	<<	<<
18	<<	<<	*	<<	<<	<<
19	<<	<<	<<	*	<<	<<
20	*	*	*	<<	*	*
21	<<	<<	<<	<<	*	<<
22	<<	<<	<<	<<	*	<<
23	<<	<<	<<	<<	*	<<


[事後予測分布] ウィンドウには、行を各回答者、列をモデルの各観測変数とする表が表示されます。アスタリスク (\*) は欠損値であることを表します。また << は、元の数値変数に不等式制約を適用する回答であることを表します。各項目に対して事後分布を表示する手順は次のとおりです。

- ▶ 表の左上のエントリ (項目 1 に対する回答者 1 の回答) をクリックします。

[事後分布] ウィンドウが開き、回答者 1 の基礎となる数値スコアの事後分布が表示されます。事後分布は最初、起伏が激しく不規則な形状を示します。




これは、プログラムによる事後分布の推定が、MCMC サンプリングを実行しながら順次行われているためです。しかし時間が経過するにつれて、事後分布の推定値は修正されていきます。しばらくすると推定値はそれ以上変化しなくなり、次の図のような形状になります。



事後分布を見ると、回答者 1 の項目 1 に対する回答の基礎となる数値変数のスコアは 0 と 1 の間にあり (これは既知の事実)、かつ 0 よりも 1 に近い値を取る可能性が高いことがわかります。


- ▶ 次に、表の 22 行目の第 1 列にあるエントリをクリックし、回答者 22 の項目 1 に対する回答の基礎となる数値変数のスコアを推定します。

しばらくすると推定値が確定し、事後分布が次の図のような形状になります。



回答者 1 と回答者 22 はどちらも、項目 1 に対して「同意する」と回答しています。したがってどちらの回答者も、基礎となる数値変数上のスコアは 0 と 1 の間の値を取りますが、それぞれの事後分布はまったく異なっています。

事後予測分布の例をもう 1 つ見るために、欠損値 (回答者 1 の項目 2 に対する回答など) をいずれか 1 つ選択します。MCMC サンプルングが十分に実行されると、事後分布の推定値は次の図のような形状になります。



ポイント推定値が必要な場合は、事後分布の平均値 (0.52) を、基礎となる数値変数における回答者 1 のスコアの推定値として使用できます。事後分布の図を見ると、スコアはほぼ 100% の確率で -1 と 2 の間の値を取ることがわかります。また、事後分布の領域は大半が 0 と 1 の間に存在するため、スコアは 0 と 1 の間の値を取る確率が高くなります。

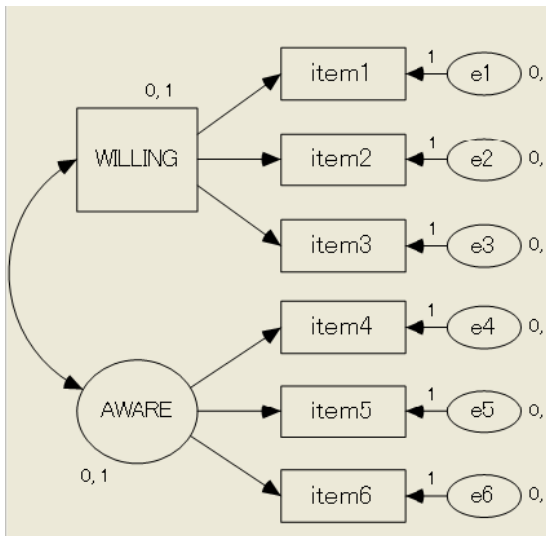
## 潜在変数の事後予測分布

WILLING 因子についての回答者 1 のスコアを推定する場合を考えます。Amos で未知スコアの事後予測分布を推定できるのは、観測変数に対してだけです。潜在変数に対するスコアの事後予測分布を推定することはできません。ただし、WILLING に対するスコアの事後予測分布を推定するための方法は存在します。WILLING を、潜在変数ではなく、ケースすべてに欠損値を持つ観測変数と見なすことにより、観測変数に変更できます。その際、パス図およびデータの 2 つを変更する必要があります。

パス図では、WILLING を囲む楕円を長方形に変更します。手順は次のとおりです。

- ▶ WILLING を囲む楕円を右クリックし、ポップアップメニューから [直接観測される / されない変数を交替] を選択します。
- ▶ WILLING を囲む楕円をクリックします。

パス図では次のように WILLING を囲む楕円が長方形に変更されます。



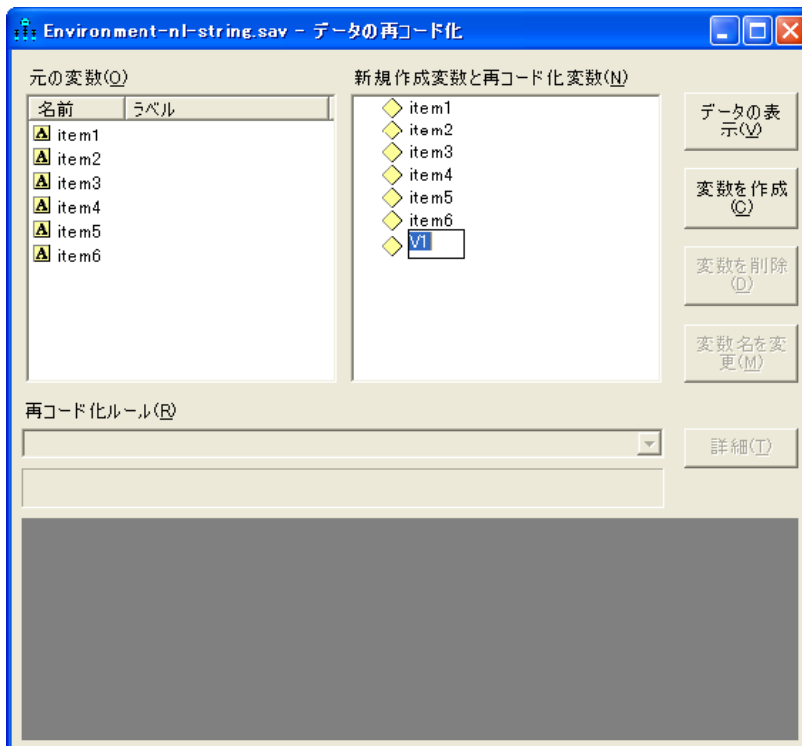
ここまでは、パス図に対する処理について説明しました。WILLING が観測変数になると、データファイル内に WILLING 列が必要になるため、データも変更する必要があります。データファイルは直接修正できます。このファイルは SPSS Statistics データファイルであるため、SPSS Statistics を使用して WILLING 変数を追加することもできます。ただし、WILLING に対するスコアがすべて欠損値になるよう注意してください。

元のデータファイルの内容を維持したままデータを変更する手順は次のとおりです。

- ▶ パス図の WILLING 変数を右クリックします。
- ▶ ポップアップメニューから [データの再コード化] を選択し、[データの再コード化] ウィンドウを開きます。



- ▶ [データの再コード化] ウィンドウで、[変数を作成] をクリックします。新しい変数とそのデフォルト名 V1 が、[新規作成変数と再コード化変数] リスト ボックスに表示されます。







- ▶ V1 を WILLING に変更します (必要であれば、[変数名を変更] ボタンをクリックします)。




- ▶ 新しい WILLING 変数を含む再コード化されたデータセットを表示する必要がある場合は、[データの表示] ボタンをクリックします。

元の変数(Q)							新規作成変数と再コード化変数(N)							
	item1	item2	item3	item4	item5	item6		item1	item2	item3	item4	item5	item6	WILLING
1	A		SA	SD	A	A	1	0<<<1	*	>1	<0	0<<<1	0<<<1	*
2	A		A	SA	SA	SA	2	0<<<1	*	0<<<1	>1	>1	>1	*
3		A	A	A	A	A	3	*	0<<<1	0<<<1	0<<<1	0<<<1	0<<<1	*
4	A	A	A				4	0<<<1	0<<<1	0<<<1	*	*	*	*
5	D	SD			D		5	<0	<0	*	*	<0	*	*
6	SA	SA	A		A	A	6	>1	>1	0<<<1	*	0<<<1	0<<<1	*
7	A	D		A	A	A	7	0<<<1	<0	*	0<<<1	0<<<1	0<<<1	*
8	D	D		SD		SD	8	<0	<0	*	<0	*	<0	*
9	SA	SA	SA	A		A	9	>1	>1	>1	0<<<1	*	0<<<1	*
10	SA	A	A	SA	SA		10	>1	0<<<1	0<<<1	>1	>1	*	*


左側の表には元のデータセットが表示されます。一方、右側の表には、Amos に読み込まれる再コード化されたデータセットが表示されます。このデータセットには、再コード化後の項目 1 から項目 6 までの各項目と、新たに追加された WILLING 変数が含まれています。

- ▶ [データの再コード化] ウィンドウを閉じます。
- ▶ Amos Graphics ツールバーの  をクリックしてベイズ解析を開始します。
- ▶ [ベイズ SEM] ウィンドウで、アイコンが不機嫌な顔  から上機嫌な顔  に変わったら、[事後予測分布] ボタン  をクリックします。



	item1	item2	item3	item4	item5	item6	WILLING
1	<<	*	<<	<<	<<	<<	*
2	<<	*	<<	<<	<<	<<	*
3	*	<<	<<	<<	<<	<<	*
4	<<	<<	<<	*	*	*	*
5	<<	<<	*	*	<<	*	*
6	<<	<<	<<	*	<<	<<	*
7	<<	<<	*	<<	<<	<<	*
8	<<	<<	*	<<	*	<<	*
9	<<	<<	<<	<<	*	<<	*
10	<<	<<	<<	<<	<<	*	*


- ▶ 表の右上にあるエントリをクリックすると、WILLING 因子に関する回答者 1 のスコアの事後分布が表示されます。



## 代入

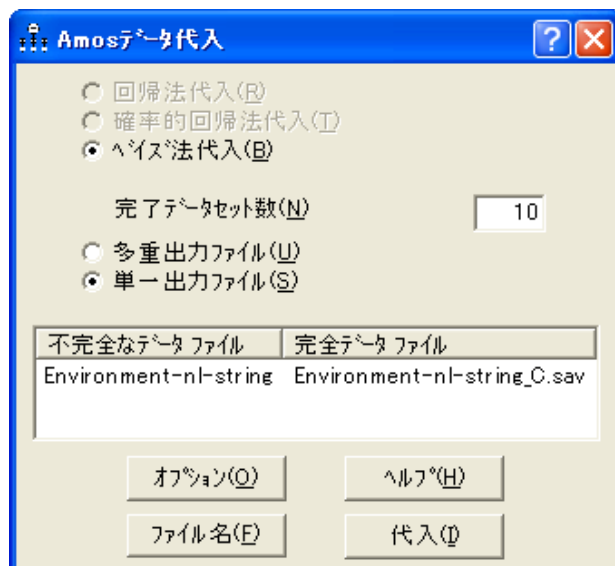
順序 - カテゴリカル データでのデータ代入は、数値データでのデータ代入と同じ方法で行われます。順序 - カテゴリカル データを使用する場合、代入できる数値は、欠損値、潜在変数のスコア、および観測される順序 - カテゴリカル測定値の基礎となる非観測数値変数のスコアの値になります。

代入を実行するにはモデルが必要です。モデルには、すでに使用した因子分析モデルを使用してもかまいません。代入に因子分析モデルを使用する場合、いくつかの長所がありますが、短所も 1 つだけあります。長所の 1 つは、モデルが適切であれば因子に値を代入できることです。つまり、**WILLING** および **AWARE** を観測変数とするデータセットを新規作成することができます。もう 1 つの長所は、モデルが適切であれば、項目 1 から項目 6 までの各項目に対し、制約が少ないモデルよりも的確な代入が期待できる点です。因子分析モデルを使用する短所は、モデルが不適切になる可能性があるという点です。この例では確実性を重視して、適切である確率が最も高い飽和モデル (下図参照) を使用します (ファイル Ex33-c.amw を参照してください)。



飽和モデルに対するパス図を作成したら、代入を開始できます。

- ▶ Amos Graphics メニューから、[分析] → [データ代入] の順に選択します。

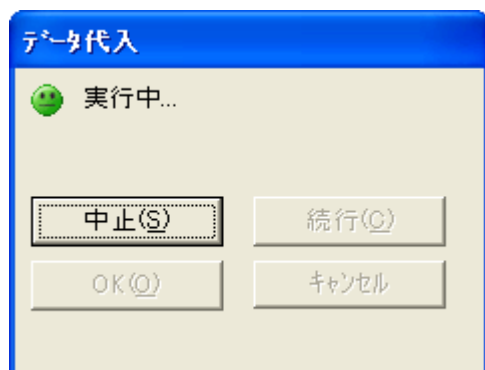


[Amos データ代入] ウィンドウでは、[回帰法代入] と [確率的回帰法代入] は無効化されていることに注意してください。非数値データを使用している場合は、[ベイズ法代入] しか選択できません。

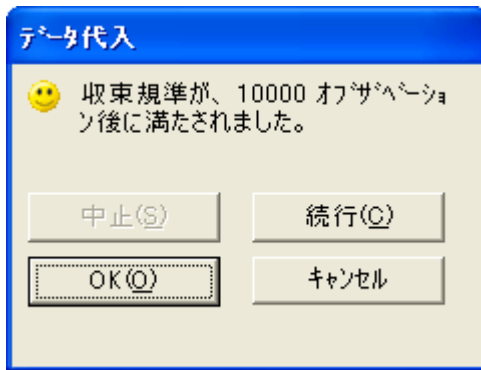
ここでは上の図に表示されている設定内容をそのまま使用します。これにより、10個の完全データセットが作成され、それらすべてが `environment-nl-string_C.sav` という1つのデータファイルに保存されます。代入を開始する手順は次のとおりです。

- ▶ [代入] ボタンをクリックします。

[ベイズ SEM] ウィンドウとともに [データ代入] ダイアログボックスが表示されます。



- ▶ [データ代入] ダイアログ ボックスに上機嫌な顔 😊 (10 個の各完全データ セットの間に実質的な相関がないことを示す) が表示されるまで待ちます。



注: 上機嫌な顔が表示された後 [OK] をクリックする前に、[ベイズ SEM] ウィンドウ内の任意のパラメータを右クリックし、ポップアップ メニューから [事後分布の表示] を選択することもできます。これにより、トレース図や自己相関図を確認できます。

- ▶ [データ代入] ダイアログ ボックスで、[OK] をクリックします。

[要約] ウィンドウに、作成された完全データ ファイルの一覧が表示されます。ここでは、作成された完全データ ファイルは 1 つだけです。



- ▶ [要約] ウィンドウでファイル名をダブルクリックして、完全データ ファイルの内容を表示します。このファイルには 10 個の完全データセットが含まれています。

10 個ある完全データセットのそれぞれには 1,017 のケースが含まれています。したがって、ファイルに含まれるケース数は 10,170 です。新しいデータ ファイルの最初の 1,017 行は、1 番目の完全データ セットに対応します。1 番目の完全データセットにおける `imputeno` 変数は各行で 1 になっています。また `caseno` 変数には 1 から 1,017 までの値が順番に並んでおり、1,017 に達すると再び 1 から繰り返されます。

	item1	item2	item3	item4	item5	item6	CaseNo	Imputation_
1	0.82	0.57	1.01	-0.45	0.78	0.10	1.00	1.00
2	0.64	-0.25	0.30	1.22	1.56	1.91	2.00	1.00
3	1.32	0.61	0.53	0.35	0.17	0.74	3.00	1.00
4	0.00	0.39	0.79	1.50	0.84	1.73	4.00	1.00
5	-0.32	-0.69	-0.46	-0.90	-0.47	0.13	5.00	1.00
6	1.63	1.26	0.61	0.73	0.74	0.44	6.00	1.00
7	0.75	-0.13	0.61	0.25	0.41	0.78	7.00	1.00
8	-0.98	-0.09	0.13	-0.63	0.52	-0.12	8.00	1.00
9	2.69	2.45	1.22	0.34	0.99	0.95	9.00	1.00
10	1.35	0.10	0.78	1.55	1.03	1.29	10.00	1.00
11	0.18	0.37	0.78	0.24	0.53	0.95	11.00	1.00
12	1.34	1.05	0.29	0.05	0.53	0.82	12.00	1.00

通常、この後に行う手順では、数値 (順序 - カテゴリカルでない) データを必要とする他のプログラムへの入力用に、`environment-nl-string_C.sav` 内の 10 個の完全データセットを使用します。この場合、そのプログラムでは、10 個の完全データセットを 1 つずつ順番に使って 10 回の分析を個別に実行することになります。その後、例 31 で行ったように、さらに計算を実行し 10 回分の分析結果を 1 つの結果セットにまとめます。この例では、これらの手順は実行しません。





# トレーニングデータを使用した 混合モデリング

## 概要

混合モデリングは、あるモデルを母集団全体に当てはめるのは不適切であるけれども、各サブグループに当てはめることができるように、母集団をサブグループに分けることができる場合に適しています。

混合モデリングは、構造方程式モデリングの分脈では、Arminger、Stein、および Wittenberg (1999 年)、星野 (2001 年)、Lee (2007 年, 11 章)、Loken (2004 年)、Vermunt および Magidson (2005 年)、Zhu および Lee (2001 年) などによって解説されています。

この例では、グループに割り当て済みのケースと割り当てられていないケースがある場合の混合モデリングについて説明します。すでに分類されているケースから学び、他のケースを分類するのは、Amos が行います。

例 10、例 11、例 12 のような通常の複数グループの分析の設定とほぼ同じなので、ここでは一部のケースがすでに分類されている例を使って混合モデリングを実行します。

混合モデリングは、事前にケースが分類されていなくても実行できます。その場合はプログラムがすべてのケースを分類する必要があります。例 35 では、このタイプの分析について説明します。


## データについて

この例のデータは Anderson (1935 年) によって収集され、Fisher (1936 年) がこのデータを使って判別分析を示しました。元のデータは、iris.sav ファイルにあります。ここではその一部を示します。

	SepalLength	SepalWidth	PetalLength	PetalWidth	Species
49	5.3	3.7	1.5	0.2	setosa
50	5.0	3.3	1.4	0.2	setosa
51	7.0	3.2	4.7	1.4	versicolor
52	6.4	3.2	4.5	1.5	versicolor
53	6.9	3.1	4.9	1.5	versicolor
54	5.5	2.3	4.0	1.3	versicolor
55	6.5	2.8	4.6	1.5	versicolor
56	5.7	2.8	4.5	1.3	versicolor
57	6.3	3.3	4.7	1.6	versicolor
58	4.9	2.4	3.3	1.0	versicolor
59	6.6	2.9	4.6	1.3	versicolor
60	5.2	2.7	3.9	1.4	versicolor
61	5.0	2.0	3.5	1.0	versicolor
62	5.9	3.0	4.2	1.5	versicolor

データセットには、150 の異なる植物の花に関する 4 つの測定値が含まれています。最初の 50 の花は、setosa (セトサ) という種類のアイリスでした。次の 50 の花は、versicolor (ベルシカラー) という種類のアイリスでした。最後の 50 の花は、virginica (ベルジニカ) という種類のアイリスでした。

PetalLength (花びらの長さ) と PetalWidth (花びらの幅) という 2 つの測定値の散布図は、種類による花の分類では、これら 2 つの測定値だけでも有用であることを示しています。



散布図の左下角にあるのは、setosa の花だけです。したがって、Amos では、PetalLength と PetalWidth を使って、他の花と setosa の花を容易に区別することができるはずです。一方、versicolor と virginica は一部が重複しているので、PetalLength と PetalWidth だけで、花の種類が versicolor なのか virginica なのかを区別するのは難しい場合があることが予想されます。

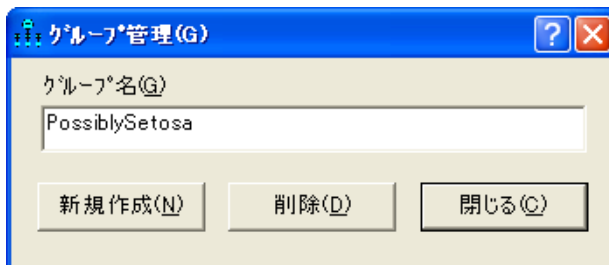
この例では、すべての花の種類が含まれている iris.sav データセットは使用しません。代わりに、数種類の花だけが含まれている iris3.sav データセットを使用します。次の図は、iris3.sav データセットの一部を示しています。

	SepalLength	SepalWidth	PetalLength	PetalWidth	Species
1	5.1	3.5	1.4	0.2	setosa
2	4.9	3.0	1.4	0.2	setosa
3	4.7	3.2	1.3	0.2	setosa
4	4.6	3.1	1.5	0.2	setosa
5	5.0	3.6	1.4	0.2	setosa
6	5.4	3.9	1.7	0.4	setosa
7	4.6	3.4	1.4	0.3	setosa
8	5.0	3.4	1.5	0.2	setosa
9	4.4	2.9	1.4	0.2	setosa
10	4.9	3.1	1.5	0.1	setosa
11	5.4	3.7	1.5	0.2	
12	4.8	3.4	1.6	0.2	
13	4.8	3.0	1.4	0.1	
14	4.3	3.0	1.1	0.1	

種類については、setosa の花 10 個、versicolor の花 10 個、virginica の花 10 個がわかっています。残りの 120 の花の種類は不明です。これらのデータを Amos で分析すると、花の種類ごとに 10 の例を使用して、残りの花の分類を行ないます。

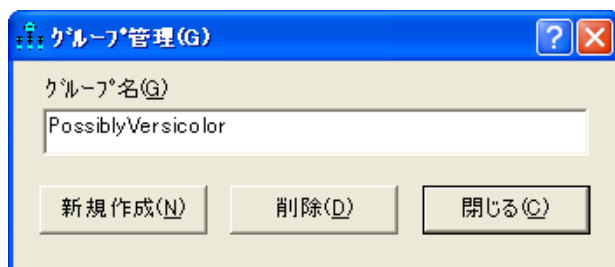
## 分析の実行

- ▶ メニューから、[ファイル]→[新規作成]を選択して新しいパス図の作成を開始します。
- ▶ メニューから [分析]→[グループ管理]を選択します。
- ▶ [グループ管理]ダイアログボックスで、[グループ名]テキストボックスの名前を「グループ番号 1」から「PossiblySetosa (セトサの可能性)」に変更します。

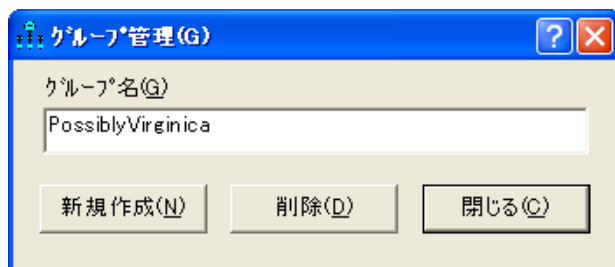


- ▶ [新規作成]をクリックして2つ目のグループを作成します。

- ▶ [グループ名] テキスト ボックスの名前を「グループ番号 2」から「PossiblyVersicolor (バーシカラーの可能性)」に変更します。



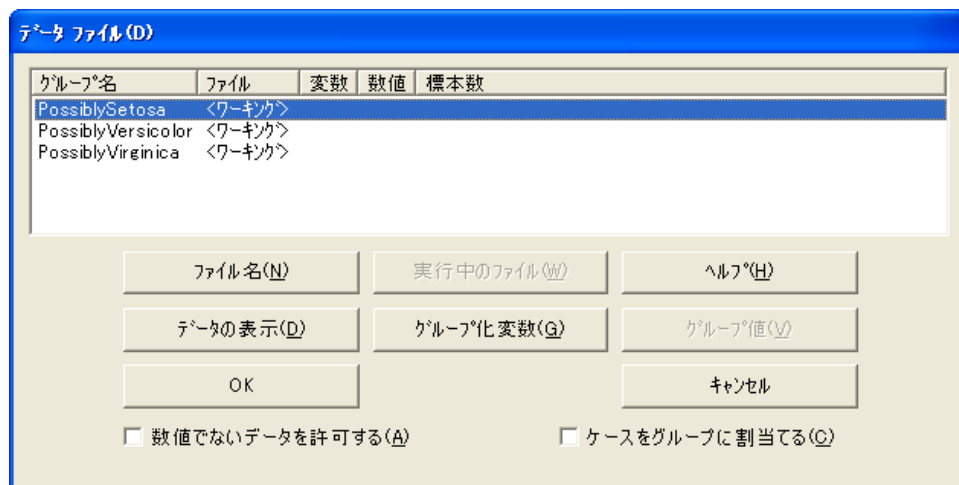
- ▶ [新規作成] をクリックして 3 つ目のグループを作成します。
- ▶ [グループ名] テキスト ボックスの名前を「グループ番号 3」から「PossiblyVirginica (バージニカの可能性)」に変更します。



- ▶ [閉じる] をクリックします。

## データ ファイルの指定

- ▶ メニューから、[ファイル] → [データ ファイル] を選択します。



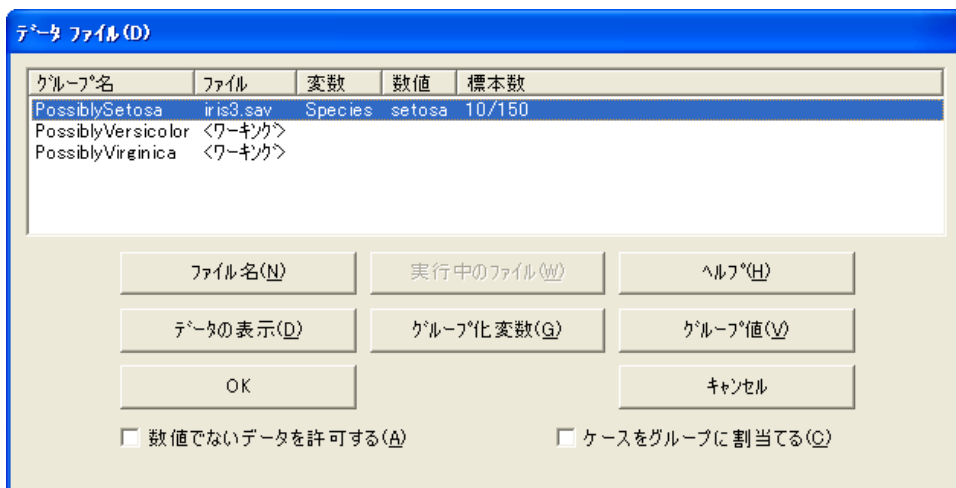
- ▶ [PossiblySetosa] をクリックして行を選択します。
- ▶ [ファイル名] をクリックし、Amos の Examples ディレクトリにある iris3.sav ファイルを選択して、[開く] をクリックします。
- ▶ [グループ化変数] をクリックし、[グループ化変数を選択] ダイアログ ボックスで [species] をダブルクリックします。これで、変数 [species] が花の分類に使用されます。



- ▶ [データファイル]ダイアログボックスで[グループ値]をクリックし、[グループの識別値の選択]ダイアログボックスで[setosa]をダブルクリックします。

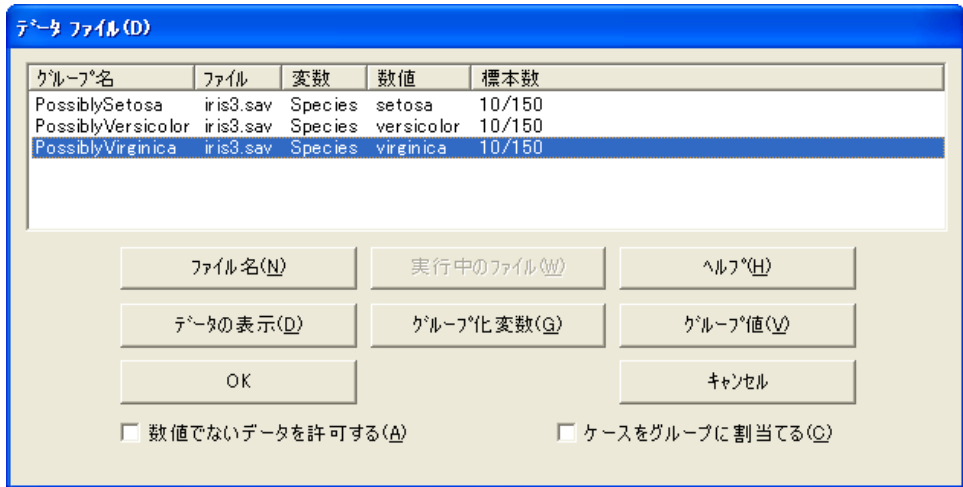


[データファイル]ダイアログボックスは、次のようになります。



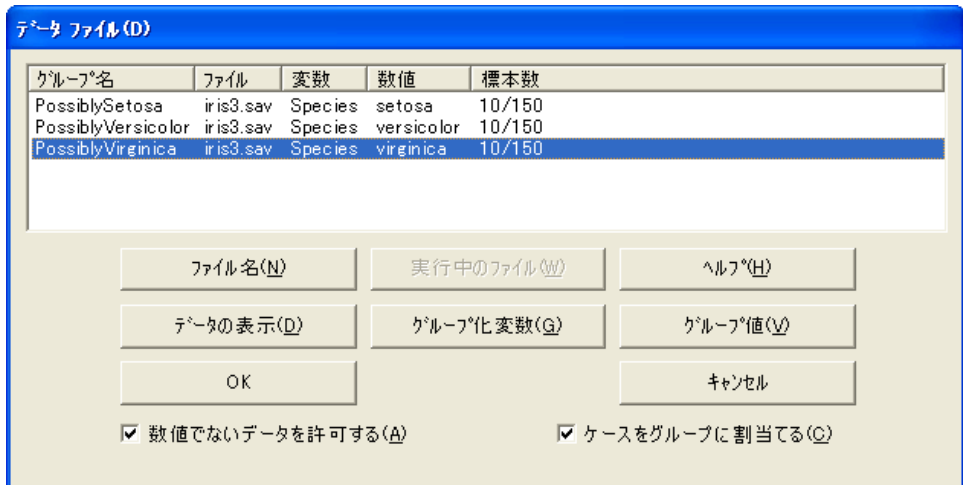
- ▶ [PossiblyVersicolor] グループについて前述の手順を繰り返しますが、今回は [グループの識別値の選択]ダイアログボックスで[versicolor]をダブルクリックします。

- ▶ [PossiblyVirginica] グループについて前述の手順をもう一度繰り返しますが、今回は [グループの識別値の選択] ダイアログ ボックスで [virginica] をダブルクリックします。[データ ファイル] ダイアログ ボックスは、次のようになります。



ここまでは、すべての花の種類が判明している、通常の 3 グループ分析のように設定してきました。次に行う手順は、混合モデリング特有のものです。

- ▶ [ケースをグループに割り当てる] を選択します (チェック マークが表示されます)。このチェック マークが表示されていると、ケースが属しているグループがデータセットで指定されていない場合、ケースはグループに割り当てられます。



- ▶ [OK] をクリックして、[データ ファイル] ダイアログ ボックスを閉じます。




## モデルの特定化

変数 [PetalLength] および [PetalWidth] の飽和モデルを使用します。先に示した散布図は、種類に基づいて花の分類を行なうのに、これら 2 つの変数が有用であることを示しています。

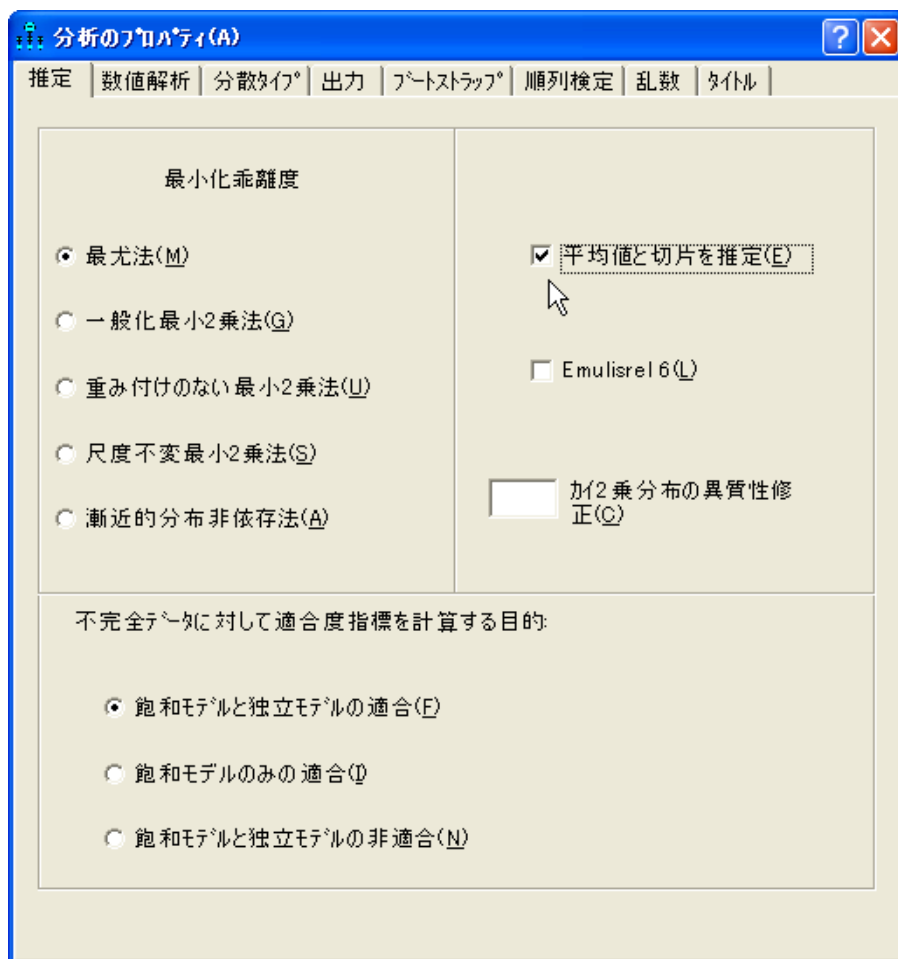
混合モデリングを行なうときには、飽和モデルに限定されないことに注意してください。因子分析モデルや回帰モデルなど、どのタイプのモデルでも使用することができます。回帰モデルを使った混合モデリングの実証については、例 36 を参照してください。

- ▶ 次のパス図を描きます (このパス図は、Ex34-a.amw として保存されています)。



- ▶ メニューから [表示] → [分析のプロパティ] の順に選択します。

- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。






## モデルの適合


- ▶ ツールバーの  をクリックします。

または

- ▶ メニューから、[分析]→[ベイズ推定]の順に選択します。

注：混合モデリングではベイズ推定しか実行できないため、 のボタンは無効化されています。

[ベイズ SEM] ウィンドウが開いたら、不機嫌な顔  が上機嫌の顔  に変わるまで待ちます。[ベイズ SEM] ウィンドウに、次のような推定値の表が表示されます。



	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>平均値</b>									
PetalLength	1.462	0.000	0.026	1.000	0.017	0.171	1.352	1.577	
PetalWidth	0.246	0.000	0.016	1.000	-0.017	0.206	0.173	0.313	
<b>共分散</b>									
PetalWidth<->PetalLength	0.007	0.000	0.003	1.000	0.561	1.034	-0.006	0.025	
<b>分散</b>									
PetalWidth	0.013	0.000	0.003	1.000	0.881	1.362	0.006	0.030	
PetalLength	0.034	0.000	0.008	1.000	0.961	1.975	0.014	0.094	
<b>PossiblySetosa の割合</b>									
割合	0.333	0.000	0.037	1.000	0.123	0.017	0.186	0.487	

[ベイズ SEM] ウィンドウに、通常の 3 グループ分析で取得されるすべてのパラメータ推定が表示されます。表には、1 度に 1 つのグループの結果が表示されます。表の上部にあるタブをクリックすると、別のグループに切り替えることができます。この例では、モデルのパラメータには平均値、分散、および共分散が含まれています。さらに複雑なモデルになると、係数と切片項の推定値も含まれます。


混合モデリング分析では、各グループの母集団における比率の推定値も取得します。前の図は、母集団での *setosa* の花の推定比率が 0.333 と示しています (ただし、標本には、意図的に *setosa*、*versicolor*、*virginica* の花がそれぞれ同じ数だけ含まれていることを指摘しておく必要があるでしょう。したがって、この例では、標本から母集団の比率について推論を導き出すことは有意ではありませんが、そのような推論を導き出す方法を示すために、ここでは *species* を確率変数として扱います)。

母集団の比率の事後分布を確認するには、比率が表示されている行を右クリックして、ポップアップメニューから [事後分布の表示] を選択します。

The screenshot shows the Mplus SEM software window. The main table displays statistical results for the 'PossiblySetosa' group. A context menu is open over the '割合' (Proportion) row, with the option '事後分布の表示' (Show Posterior Distribution) selected.


	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>平均値</b>									
PetalLength	1.462	0.000	0.026	1.000	0.017	0.171	1.352	1.577	
PetalWidth	0.246	0.000	0.016	1.000	-0.017	0.206	0.173	0.313	
<b>共分散</b>									
PetalWidth<->PetalLength	0.007	0.000	0.003	1.000	0.561	1.034	-0.006	0.025	
<b>分散</b>									
PetalWidth	0.013	0.000	0.003	1.000	0.881	1.362	0.006	0.030	
PetalLength	0.034	0.000	0.008	1.000	0.961	1.975	0.014	0.094	
<b>PossiblySetosa の割合</b>									
割合	0.333	0.000	0.037	1.000	0.123	0.017	0.186	0.487	

[事後分布] ウィンドウは、setosa の種類に属する花の比率が、ほぼ確実に 0.25 ~ 0.45 の範囲になることを示しています。比率が 0.3 ~ 0.35 の間になる確率は、半々 (約 50%) のようです。




## 個々のクラスのカテゴリ

各花のグループ所属の確率を取得するには、次のようにします。

- ▶ [事後予測分布] ボタン  をクリックします。

または

- ▶ メニューから、[表示] → [事後予測分布] の順に選択します。



	PetalLength	PetalWidth	P(setosa)	P(versicolor)	P(virginica)
47	1.6	0.2	<b>1.00</b>	0.00	0.00
48	1.4	0.2	<b>1.00</b>	0.00	0.00
49	1.5	0.2	<b>1.00</b>	0.00	0.00
50	1.4	0.2	<b>1.00</b>	0.00	0.00
51	4.7	1.4	0.00	<b>0.95</b>	0.05
52	4.5	1.5	0.00	<b>0.94</b>	0.06
53	4.9	1.5	0.00	<b>0.87</b>	0.13
54	4	1.3	0.00	<b>0.99</b>	0.01
55	4.6	1.5	0.00	<b>0.93</b>	0.07
56	4.5	1.3	0.00	<b>0.98</b>	0.02
57	4.7	1.6	0.00	<b>0.82</b>	0.18
58	3.3	1	0.00	<b>1.00</b>	0.00
59	4.6	1.3	0.00	<b>0.96</b>	0.04
60	3.9	1.4	0.00	<b>0.97</b>	0.03
61	3.5	1	0.00	<b>1.00</b>	0.00
62	4.2	1.5	0.00	<b>0.92</b>	0.08
63	4	1	0.00	<b>0.99</b>	0.01
64	4.7	1.4	0.00	<b>0.95</b>	0.05
65	3.6	1.3	0.00	<b>0.98</b>	0.02
66	4.4	1.4	0.00	<b>0.97</b>	0.03
67	4.5	1.5	0.00	<b>0.94</b>	0.06
68	4.1	1	0.00	<b>0.98</b>	0.02
69	4.5	1.5	0.00	<b>0.94</b>	0.06
70	3.9	1.1	0.00	<b>1.00</b>	0.00
71	4.8	1.8	0.00	0.26	<b>0.74</b>
72	4	1.3	0.00	<b>0.99</b>	0.01

[事後予測分布] ウィンドウでは、それぞれの花が setosa、versicolor、または virginica である確率が示されています。

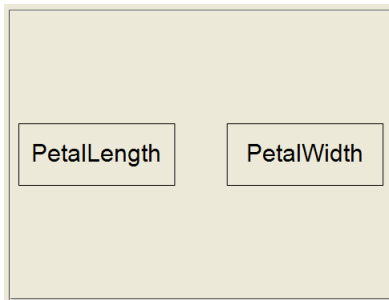
最初の 50 の花 (実際に setosa であるもの) については、setosa グループに属する確率がほぼ 1 になっています。先に示した散布図において、setosa の花は明らかに他の種類の花とは分離していたので、この結果は予想したとおりです。


versicolor の花 (ケース番号 51 以降) もほとんどが正しく分類されました。たとえば、花番号 51 が versicolor である事後確率は 0.95 になっています。しかし、分類エラーは実際に起こります。たとえば、ケース番号 71 は間違って分類されています。versicolor の花であるのに、0.75 の確率で virginica であることが推定されています。

## 潜在構造分析

混合モデリングを行なうときには、飽和モデルに限定されないことは先に述べました。因子分析モデルや回帰モデルなど、どのタイプのモデルでも使用することができます。ここで、飽和モデルの重要なバリエーションについて理解しておくことをお勧めします。潜在構造分析 (Lazarsfeld および Henry, 1968 年) は、混合モデリングが変化したもので、各グループ内において測定変数が独立している必要があります。測定変数が多変量の正規変数の場合、これらの変数は無相関である必要があります。

- ▶ 測定変数が無相関であることを要求するには、飽和モデルのパス図から双方向矢印を削除します (このパス図は Ex34-b.amw として保存されています)。



- ▶ [ペイジアン] ボタン  をクリックして、潜在構造分析を実行します。ここでは、潜在構造分析の結果は示しません。

# トレーニング データを 使用しない混合モデリング

## 概要

混合モデリングは、あるモデルを母集団全体に当てはめるのは不適切であるけれども、各サブグループに当てはめることができるように、母集団をサブグループに分けることができる場合に適しています。

Amos で混合モデリングを実行するときには、分析を開始する前に一部のケースをグループに割り当てることができます。この方法については、例 34 で説明しています。この例では、混合モデリング分析の開始時には、すべてのケースが分類されていません。

## データについて

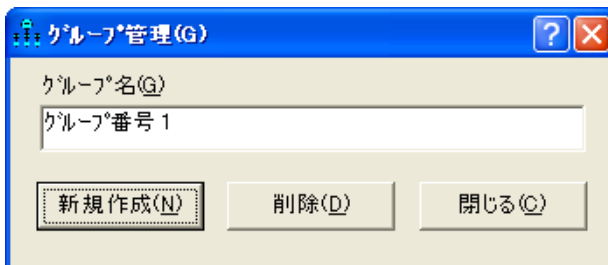
この例では、例 34 で使った Anderson (1935 年) によるアイリスのデータを使用します。ただし、今回は、150 の花のうち 30 についての種類の情報が含まれている `iris3.sav` データセットは使用しません。代わりに、種類についての情報が一切含まれていない `iris2.sav` データセットを使用します。例 34 とこの例が異なるのは、例 34 では、一部のケースがあらかじめ分類されているのに対し、この例ではあらかじめ分類されているケースがないという点です。次の図は、`iris2.sav` データセットの一部を示しています。

	SepalLength	SepalWidth	PetalLength	PetalWidth	Species
1	5.1	3.5	1.4	0.2	
2	4.9	3.0	1.4	0.2	
3	4.7	3.2	1.3	0.2	
4	4.6	3.1	1.5	0.2	
5	5.0	3.6	1.4	0.2	
6	5.4	3.9	1.7	0.4	
7	4.6	3.4	1.4	0.3	
8	5.0	3.4	1.5	0.2	
9	4.4	2.9	1.4	0.2	
10	4.9	3.1	1.5	0.1	
11	5.4	3.7	1.5	0.2	
12	4.8	3.4	1.6	0.2	
13	4.8	3.0	1.4	0.1	
14	4.3	3.0	1.1	0.1	

データセットには、[species] 列が含まれていますが、この列は空白になっています。Amos では、一部のケースの種類がすでにわかっている (例 34 のような) 場合があることを考慮するので、数値がなくても [species] 列があることが重要です。ケースの分類に使用される変数は、「species」という名前だけでなく構いません。どのような変数名でも使用できますが、文字列 (非数値) 変数でなければなりません。

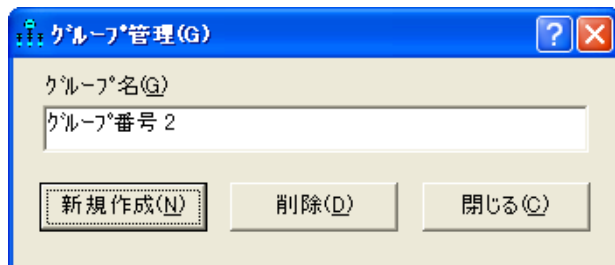
## 分析の実行

- ▶ メニューから、[ファイル]→[新規作成] を選択して新しいパス図の作成を開始します。
- ▶ メニューから [分析]→[グループ管理] を選択します。

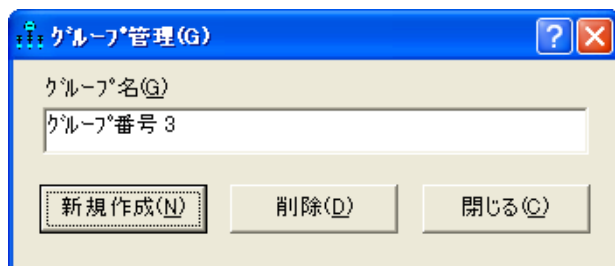




- ▶ [新規作成] をクリックして 2 つ目のグループを作成します。



- ▶ [新規作成] をもう 1 度クリックして 3 つ目のグループを作成します。

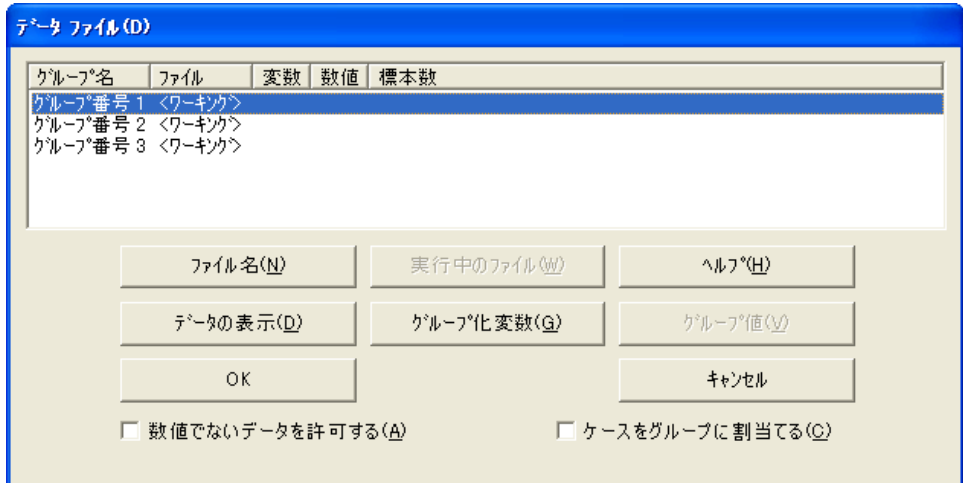


- ▶ [閉じる] をクリックします。

この例では、3 グループの混合モデルを当てはめます。存在するグループの数がわからない場合は、プログラムを複数回実行できます。プログラムを実行して 2 グループのモデルを当てはめた後、もう 1 度実行して 3 グループのモデルを当てはめたりすることができます。

## データ ファイルの指定

- ▶ メニューから、[ファイル]→[データ ファイル] を選択します。

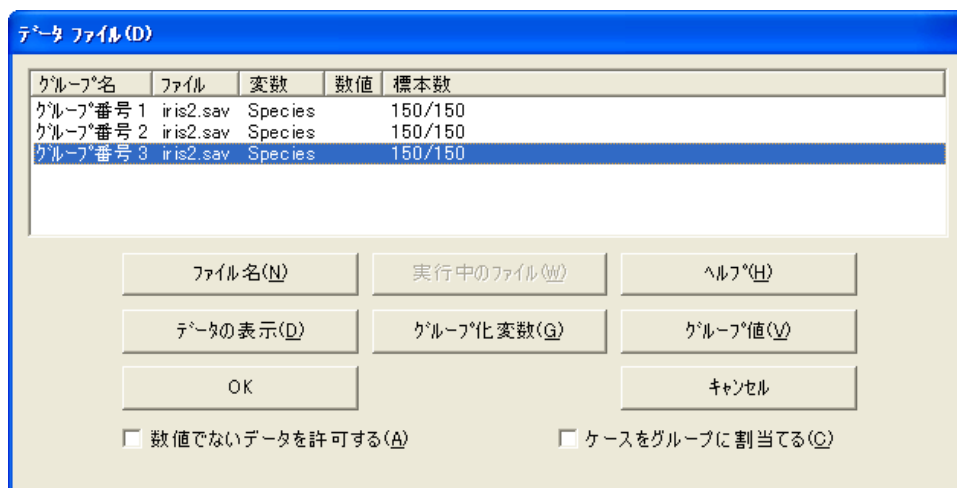


- ▶ [グループ番号 1] をクリックして 1 行目を選択します。
- ▶ [ファイル名] をクリックし、Amos の Examples ディレクトリにある iris2.sav ファイルを選択して、[開く] をクリックします。
- ▶ [グループ化変数] をクリックし、[グループ化変数を選択] ダイアログ ボックスで [species] をダブルクリックします。これで、変数 species を使ってグループが区別されます。

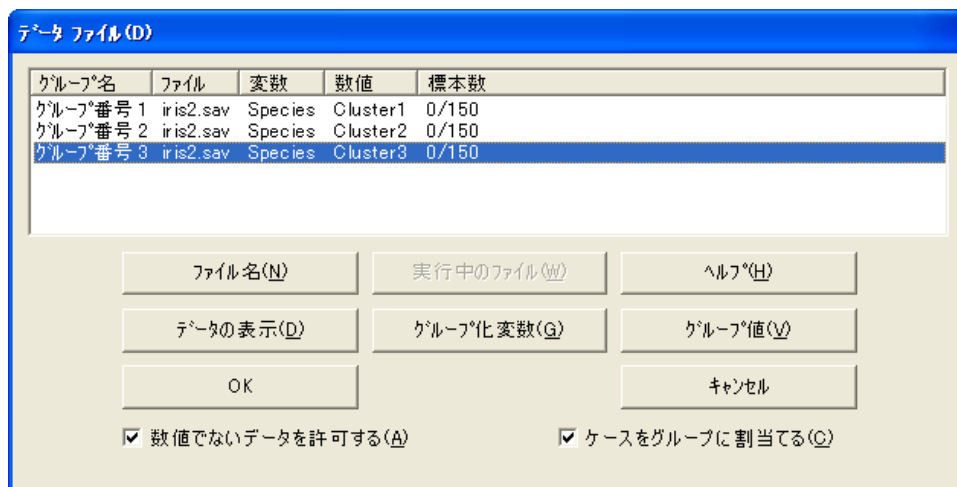


## トレーニング データを使用しない混合モデリング

- ▶ 同じデータ ファイル (iris2.sav) とグループ変数 (species) を指定し、グループ番号 2 について前述の手順を繰り返します。
- ▶ 同じデータ ファイル (iris2.sav) とグループ変数 (species) を指定し、グループ番号 3 について前述の手順をもう 1 度繰り返します。



- ▶ [ケースをグループに割り当てる] を選択します (チェック マークが表示されます)。



[ケースをグループに割り当てる] の横にチェック マークがあるのを除き、ここまでは通常の複数グループの分析と同じです。このチェック マークによって、これが混合モデリング分析になります。このチェック マークが表示されていると、データ ファイルのグループ変数がグループに割り当てられていない場合、花はグループに割り当てられます。[グループ値] をクリックしてグループ変数の値を指定する必要がなかったことに注意してください。データ ファイルには、グループ変数 (Species) の値が含まれていないので、3 つのグループの [species] の値として、Cluster1、Cluster2、Cluster3 が自動的に作成されます。


- ▶ [OK] をクリックして、[データ ファイル] ダイアログ ボックスを閉じます。

## モデルの特定化

変数 [PetalLength] および [PetalWidth] の飽和モデルを使用します。例 34 の散布図は、種類に基づいて花の分類を行なうのに、これら 2 つの変数が有用であることを示しています。

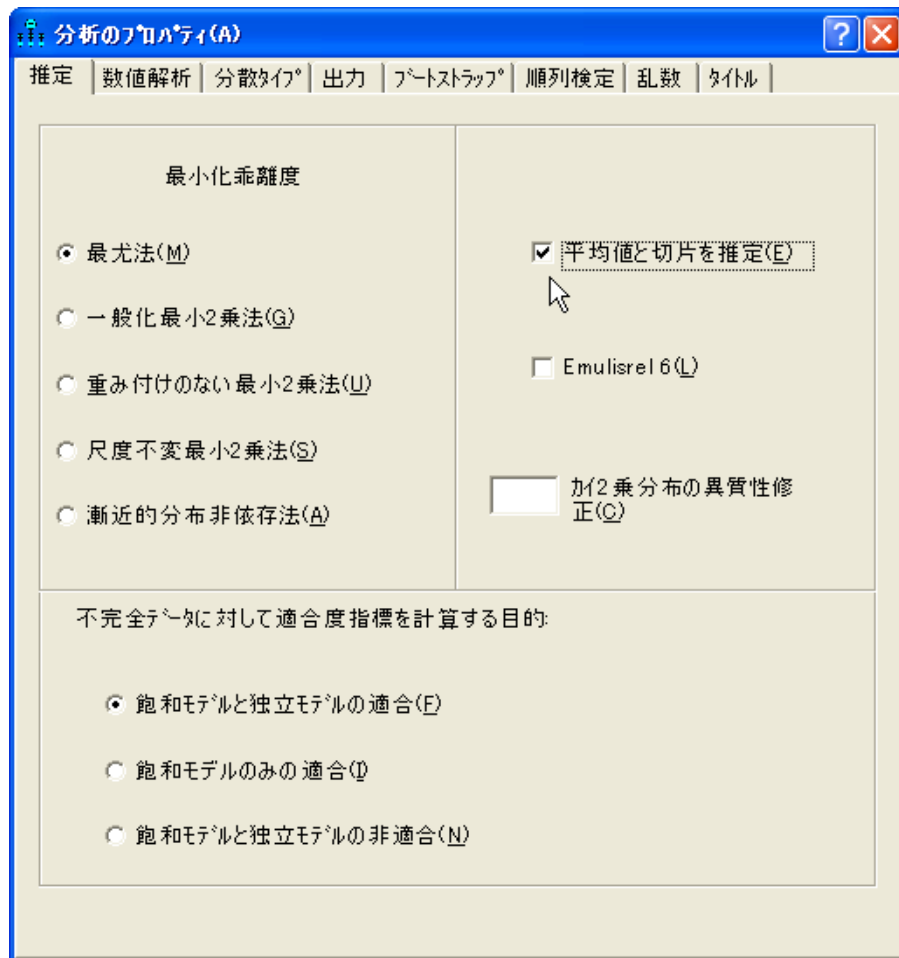
混合モデリングを行なうときには、飽和モデルに限定されないことに注意してください。因子分析モデルや回帰モデルなど、どのタイプのモデルでも使用することができます。例 36 では、回帰モデルを使用した混合モデリングを説明しています。

- ▶ 次のようなパス図を描きます。



- ▶ メニューから [表示] → [分析のプロパティ] を選択します。

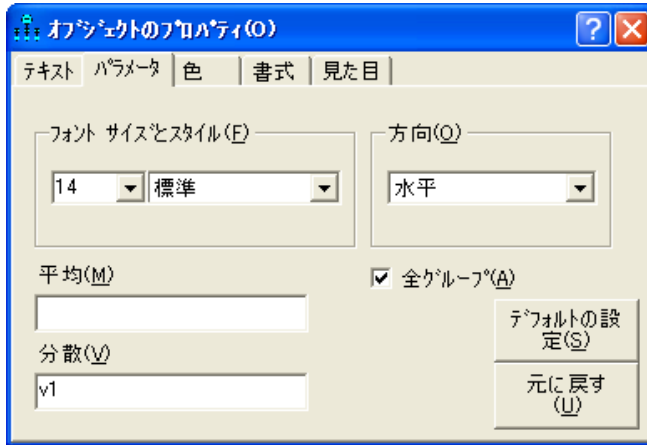
- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。



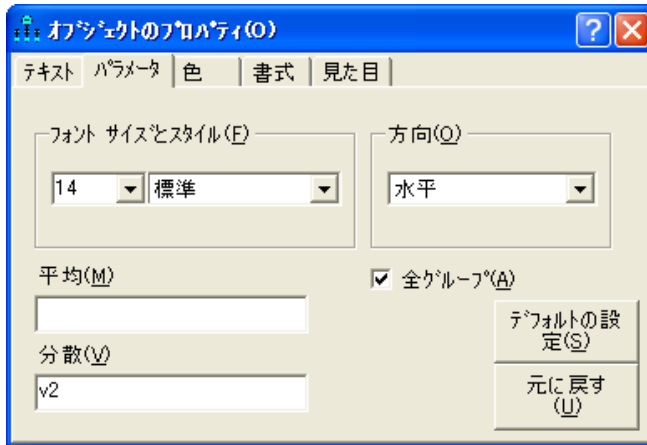
## パラメータの制約

この例では、分散と共分散がすべてのグループにおいて変わらないことが要求されます。これは、判別分析やある種のクラスタリングで多く使用される、分散および共分散の等質性の仮定です。原理上、分散および共分散の等質性の仮定は混合モデリングでは必要ありません。ここでそれを仮定するのは、この例の場合、この仮定がなければ Amos のアルゴリズムがうまくいかないからです (例 34 の散布図は、仮定が破られていることを示しています)。

- ▶ パス図の [PetalLength] を右クリックして、ポップアップメニューから [オブジェクトのプロパティ] を選択し、[分散] テキスト ボックスにパラメータ名を「v1」と入力します。

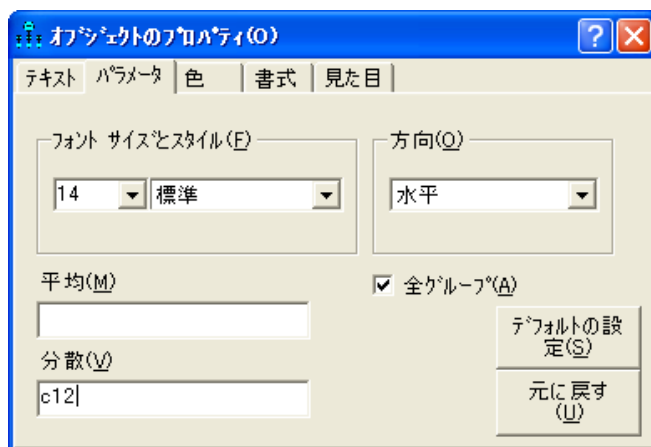


- ▶ [オブジェクトのプロパティ] ダイアログ ボックスが開いている状態で、パス図の PetalWidth をクリックします。
- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[分散] テキスト ボックスにパラメータ名を「v2」と入力します。




- ▶ [オブジェクトのプロパティ] ダイアログ ボックスが開いている状態で、PetalLength と PetalWidth の間の共分散を表す 2 方向矢印をダブルクリックします。


- ▶ [オブジェクトのプロパティ] ダイアログ ボックスで、[共分散] テキスト ボックスにパラメータ名を「c12」と入力します。




パス図は次の図のようになります。(このパス図は、Ex35-a.amw として保存されています)。




## モデルの適合

- ▶ ツールバーの  をクリックします。
- または
- ▶ メニューから、[分析]→[ベイズ推定]の順に選択します。

注：混合モデリングではベイズ推定しか実行できないため、 のボタンは無効化されています。

[ベイズ SEM] ウィンドウが開いたら、不機嫌な顔 😞 が上機嫌の顔 😊 に変わるまで待ちます。[ベイズ SEM] ウィンドウに、次のような推定値の表が表示されます。



	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>平均値</b>									
PetalLength	4.338	0.001	0.078	1.000	0.360	1.072	4.029	4.889	
PetalWidth	1.347	0.000	0.033	1.000	0.185	0.392	1.205	1.549	
<b>共分散</b>									
PetalWidth<->PetalLength	0.048	0.000	0.011	1.000	1.387	6.188	0.015	0.172	c12
<b>分散</b>									
PetalLength	0.218	0.000	0.033	1.000	1.098	3.418	0.119	0.523	v1
PetalWidth	0.039	0.000	0.006	1.000	0.677	0.990	0.022	0.082	v2
<b>Group number 1 の割合</b>									
割合	0.360	0.000	0.041	1.000	0.134	0.017	0.192	0.548	

[ベイズ SEM] ウィンドウに、通常の 3 グループ分析で取得されるすべてのパラメータ推定が表示されます。表には、1 度に 1 つのグループの推定値が表示されます。表の上部にあるタブをクリックすると、別のグループに切り替えることができます。この例では、モデルのパラメータには平均値、分散、および共分散が含まれています。さらに複雑なモデルになると、係数と切片項の推定値も含まれます。

混合モデリング分析では、各グループの母集団における比率の推定値も取得します。前の図は、母集団での *setosa* の花の推定比率が 0.360 であることを示しています。




## トレーニング データを使用しない混合モデリング

- ▶ 母集団の比率の事後分布を確認するには、比率が表示されている行を右クリックして、ポップアップメニューから [事後分布の表示] を選択します。

The screenshot shows the HysSEM software window. The main table displays statistical results for three groups. The 'Group number 1' row is highlighted in blue, and a context menu is open over it, showing options for '事後分布の表示(O)' (Show Posterior Distribution) and '事前分布の表示(Q)' (Show Prior Distribution).


	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>平均値</b>									
PetalLength	4.338	0.001	0.078	1.000	0.360	1.072	4.029	4.889	
PetalWidth	1.347	0.000	0.033	1.000	0.185	0.392	1.205	1.549	
<b>共分散</b>									
PetalWidth<->PetalLength	0.048	0.000	0.011	1.000	1.387	6.188	0.015	0.172	c12
<b>分散</b>									
PetalLength	0.218	0.000	0.033	1.000	1.098	3.418	0.119	0.523	v1
PetalWidth	0.039	0.000	0.006	1.000	0.677	0.990	0.022	0.082	v2
<b>Group number 1 の割合</b>									
割合	0.360	0.000	0.000	1.000	0.134	0.017	0.192	0.548	

[事後分布] ウィンドウの事後分布グラフは、グループ番号 1 に属する花の比率が、確実に 0.23 ~ 0.50 の範囲になることを示しています。比率が 0.30 ~ 0.40 の範囲になる確率は非常に高くなっています。



## 個々のクラスのカテゴリ

各花のグループ所属の確率を取得するには、次のようにします。

- ▶ [事後予測分布] ボタン  をクリックします。

または

- ▶ メニューから、[表示] → [事後予測分布] の順に選択します。

[事後予測分布] ウィンドウには、それぞれの花の変数 [species] の値が Cluster1、Cluster2、または Cluster3 である確率が表示されています。

	PetalLength	PetalWidth	P(Cluster1)	P(Cluster2)	P(Cluster3)
46	1.4	0.3	0.00	0.00	<b>1.00</b>
47	1.6	0.2	0.00	0.00	<b>1.00</b>
48	1.4	0.2	0.00	0.00	<b>1.00</b>
49	1.5	0.2	0.00	0.00	<b>1.00</b>
50	1.4	0.2	0.00	0.00	<b>1.00</b>
51	4.7	1.4	<b>0.99</b>	0.01	0.00
52	4.5	1.5	<b>0.99</b>	0.01	0.00
53	4.9	1.5	<b>0.96</b>	0.04	0.00
54	4	1.3	<b>1.00</b>	0.00	0.00
55	4.6	1.5	<b>0.98</b>	0.02	0.00
56	4.5	1.3	<b>1.00</b>	0.00	0.00
57	4.7	1.6	<b>0.91</b>	0.09	0.00
58	3.3	1	<b>1.00</b>	0.00	0.00
59	4.6	1.3	<b>1.00</b>	0.00	0.00
60	3.9	1.4	<b>1.00</b>	0.00	0.00
61	3.5	1	<b>1.00</b>	0.00	0.00
62	4.2	1.5	<b>0.99</b>	0.01	0.00
63	4	1	<b>1.00</b>	0.00	0.00
64	4.7	1.4	<b>0.99</b>	0.01	0.00
65	3.6	1.3	<b>1.00</b>	0.00	0.00
66	4.4	1.4	<b>1.00</b>	0.00	0.00
67	4.5	1.5	<b>0.99</b>	0.01	0.00
68	4.1	1	<b>1.00</b>	0.00	0.00
69	4.5	1.5	<b>0.99</b>	0.01	0.00
70	3.9	1.1	<b>1.00</b>	0.00	0.00
71	4.8	1.8	0.30	<b>0.70</b>	0.00
72	4	1.3	<b>1.00</b>	0.00	0.00
73	4.9	1.5	<b>0.96</b>	0.04	0.00
74	4.7	1.2	<b>1.00</b>	0.00	0.00
--	--	--	--	--	--

setosa の例であることがわかっている最初の 50 のケースは、確率が 1 でグループ番号 3 に含まれるので、グループ番号 3 には明らかに setosa の花が含まれています。ケース 51 から 100 までは、主にグループ番号 1 に含まれるので、グループ番号 1 には明らかに versicolor の花が含まれています。同様に、上の図には示されていませんが、ケース 101 から 150 までは、主にグループ番号 1 に割り当てられているので、グループ番号 2 には明らかに virginica の花が含まれています。

## 潜在構造分析


観測変数が各グループ内で独立している必要がある、潜在構造分析と呼ばれる混合モデリングのバリエーションがあります。

- ▶ PetalLength と PetalWidth が無相関、したがって (多変量の正規分布なので) 独立していることを要求するには、パス図でこれらを結んでいる 2 方向矢印を削除します。その結果得られるパス図は次のようになります (このパス図は、Ex35-b.amw として保存されています)。



- ▶ または、パラメータ名の [v1] と [v2] を削除して、分散に対する制約を削除することもできます (その結果得られるパス図は、Ex35-c.amw として保存されています)。




- ▶ 2 方向矢印を削除し、分散に対する制約を削除したら、[ベイジアン] ボタン  をクリックして潜在構造分析を実行します。ここでは、潜在構造分析の結果は報告しません。

## ラベルスイッチング


この例で分析を再現しようとする、ここで報告する結果を得ますが、グループ名の順序が変わります。ここでグループ番号 1 について報告される結果は、グループ番号 2 またはグループ番号 3 について得られる結果の場合があります。これは、ラベルスイッチング (Chung, Loken および Schafer, 2004 年) と呼ばれる場合があります。ラベルスイッチングは、1 つの分析を行っている途中で起こらない限り、特に問題ではありません。しかし残念ながら、ラベルスイッチングが分析の最中に起こることがあります。ラベルスイッチングが起こる場合、通常は個々のパラメータのトレース図によって明らかになります。ベイズ推定の実行時にトレース図を表示するには、次のようにします。

- ▶ [ベイズ SEM] ウィンドウでパラメータを右クリックし、ポップアップメニューから [事後分布の表示] を選択します。
- ▶ [事後分布] ウィンドウで、[トレース] を選択します。

この例の分析では、ラベルスイッチングは起こっていません。別の分析から得た次の図は、ラベルスイッチングに典型的なトレース図を示しています。このトレース図は、2 つのケース クラスタがあるデータの分析から得たものです。一方のクラスタでは X と呼ばれる変数の平均値は約 4、他方のクラスタでは変数 X の平均値は約 17 になっていました。このトレース図は、およそ 5,000 回目の MCMC アルゴリズムの反復までほとんどの間、グループ番号 1 と呼ばれるグループでは X の平均値のサンプリングされた値が 4 に近い数値のままだったことを示しています。およそ 5,000 回目の反復で、サンプリングされた値が 17 の辺りで変動し始めました。トレース図のこの突然の変化は、グループ ラベル (グループ番号 1 とグループ番号 2) が約 5,000 回目の反復時に入れ替わった証拠を示しています。トレース図は、MCMC アルゴリズムの最初の 20,000 回の反復中に、このラベルスイッチングが数回起こったことを示しています。



ラベルスイッチングは、1つまたは複数のパラメータの、複数モデルの事後分布によって明らかになることがあります。上のトレース図は、次の事後分布推定に対応しています。



上のグラフは、パラメータの事後分布の平均値を表したものです。ラベルスイッチングが起こったときの混合モデリング分析では、有意な推定ではない場合があります。ラベルスイッチングを防止する方法は、いくつか提案されています (Celeux, Hurn および Robert, 2000 年; Frühwirth-Schnatter, 2004 年; Jasra, Holmes および Stephens, 2005 年; Stephens, 2000 年)。Chung、Loken および Schafer (2004 年) は、1つまたは2つのケースだけでもあらかじめグループに割り当てると、ラベルスイッチングの解消に有効な場合があると提案しています。Amos では、例 34 で示したように、あらかじめケースをグループに割り当てることができます。Amos では、ラベルスイッチングを防止するための他の方法は実行されません。



# 混合回帰モデリング

## 概要

混合回帰モデリング (Ding, 2006 年) は、ある回帰モデルを母集団全体に当てはめるのは不適切であるけれども、各サブグループに当てはめることができるように、母集団をサブグループに分けることができる場合に適しています。

## データについて


2つの人為的なデータセットを使って、混合回帰について説明します。

### 1つ目のデータセット

次のデータセットは `DosageAndPerformance1.sav` ファイルに保存されています。`Dosage` (投与量) は、一部の治療の強度を指します。`Performance` (パフォーマンス) は、ある達成度の尺度です。`Group` (グループ) は、文字列 (非数値) 変数です。混合回帰分析でのこの変数の役割については後で説明します。

	dosage	performance	group
1	5.26	-0.35	
2	2.10	4.86	
3	1.93	5.20	
4	1.21	3.50	
5	1.25	2.61	
6	-0.86	6.64	
7	3.85	2.31	
8	2.51	2.60	
9	1.29	4.06	
10	0.90	6.12	
11	2.11	4.23	
12	0.42	6.68	
13	2.53	3.48	
14	0.88	6.51	

dosage と performance の散布図は、標本には 2 つの異なる被験者グループがあることを示しています。一方のグループでは、dosage が増えるにつれ、performance が向上しています。他方のグループでは、dosage が増えるにつれ、performance が低下しています。



この場合、1本の回帰直線を標本全体に当てはめようとするのは間違いです。このデータには、それぞれのグループに1本ずつ、2本の直線がうまく当てはまります。これは、混合回帰モデリングで行なうことができます。混合回帰分析では、標本をグループに分割し、それぞれのグループに別々の回帰直線を当てはめます。




## 2つ目のデータセット

DosageAndPerformance2.sav ファイルにある次のデータセットにも、dosage、performance、および group という変数についてのデータが含まれています。

	dosage	performance	group
1	6.66	21.20	
2	5.66	15.70	
3	6.06	19.20	
4	9.19	23.13	
5	6.94	20.99	
6	5.16	18.04	
7	4.18	13.96	
8	8.08	22.52	
9	4.68	14.06	
10	7.86	19.55	
11	2.76	12.97	
12	3.70	11.96	
13	5.54	15.00	
14	7.06	20.14	

また同じく、データの散布図は、グループごとに固有の回帰直線を必要とする、2つのグループが存在する証拠を示しています。どちらのグループにおいても、dosage の1単位の増加は、performance の約2単位の向上に関連しているため、各グループ内での回帰直線の傾きは約2になっています。一方、2つのグループには異なる切片があります。どの dosage レベルにおいても、一方のグループの performance は他方のグループよりも5ポイント程度高くなっています。このデータセットの混合回帰分析では、標本をグループに分割し、それぞれのグループに別々の回帰直線を当てはめます。



## データセットのグループ変数

前述したどちらのデータセットにも、**group** と呼ばれる、データが含まれていない文字列 (非数値) 変数が含まれています。Amos では、混合モデル回帰分析で **group** 変数を使って個々のケースを分類します (ここで変数が **group** と呼ばれていることは重要ではありません。文字列変数であれば、どの変数名でも使用できます)。

分析を開始する前に一部のケースがすでにグループに割り当てられている場合は、データセットの [**group**] 列にグループ名を入力できます。たとえば、混合モデル回帰分析を開始する前に、パフォーマンスの高い被験者と低い被験者が標本に含まれていて、標本の最初の 2 人が高パフォーマンス、その次の 3 人が低パフォーマンスの被験者とわかっている場合、データ表の [**group**] 列にその情報を次のように入力できます。

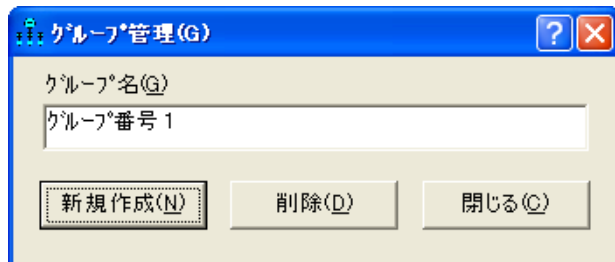
	dosage	performance	group
1	6.66	21.20	高
2	5.66	15.70	高
3	6.06	19.20	低
4	9.19	23.13	低
5	6.94	20.99	低
6	5.16	18.04	
7	4.18	13.96	
8	8.08	22.52	
9	4.68	14.06	
10	7.86	19.55	
11	2.76	12.97	
12	3.70	11.96	
13	5.54	15.00	
14	7.06	20.14	

プログラムでは、あらかじめ分類されたこの 5 つのケースを使用して、残りのケースの分類を行いません。選択した個々のケースをグループにあらかじめ割り当てる作業は、ここでは単なる可能性として述べているだけです。この例では、ケースをグループにはあらかじめ割り当てません。

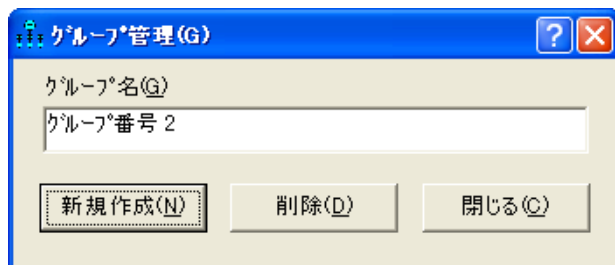
## 分析の実行

この例では、DosageAndPerformance2.sav データセットのみを分析します。

- ▶ メニューから、[ファイル]→[新規作成]を選択して新しいパス図の作成を開始します。
- ▶ メニューから [分析]→[グループ管理]を選択します。



- ▶ [新規作成] をクリックして 2 つ目のグループを作成します。

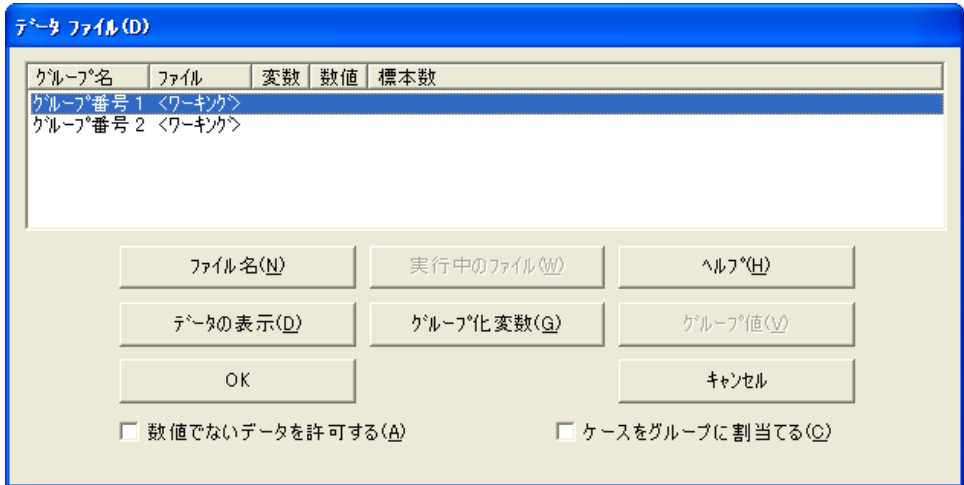


- ▶ [閉じる] をクリックします。


この例では、2 グループの混合回帰モデルを当てはめます。存在するグループの数がわからない場合は、プログラムを複数回実行できます。プログラムを実行して 2 グループのモデルを当てはめた後、もう 1 度実行して 3 グループのモデルを当てはめたりすることができます。

## データ ファイルの指定

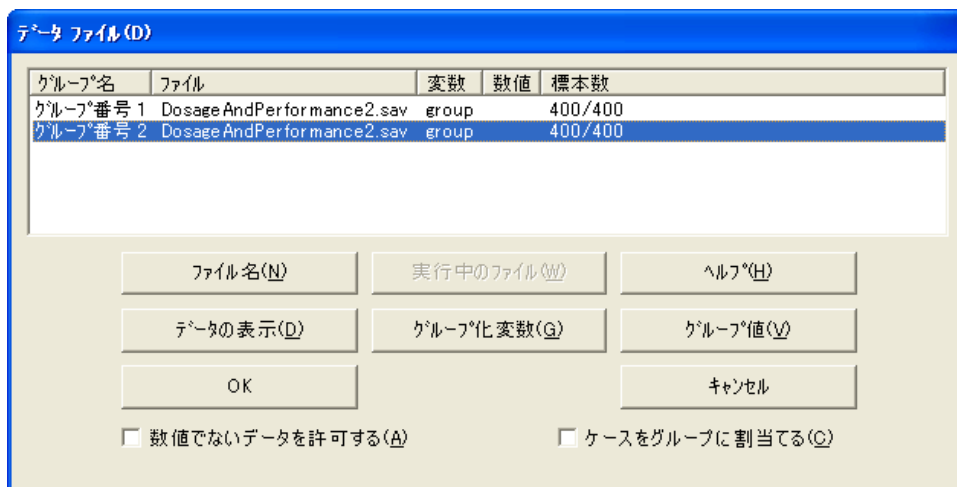
- ▶ メニューから、[ファイル]→[データ ファイル] を選択します。



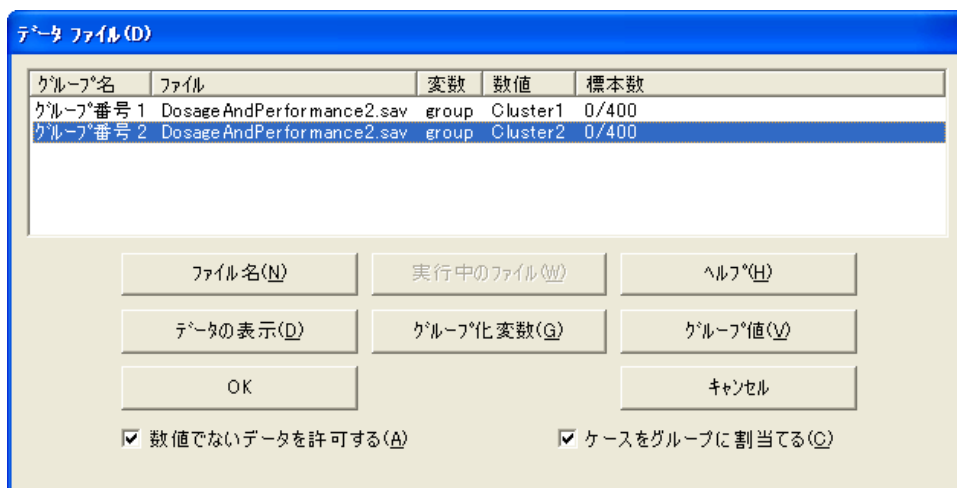
- ▶ [グループ番号 1] をクリックして行を選択します。
- ▶ [ファイル名] をクリックし、Amos の Examples ディレクトリにある DosageAndPerformance2.sav ファイルを選択して、[開く] をクリックします。
- ▶ [グループ化変数] をクリックし、[グループ化変数を選択] ダイアログ ボックスで [group] をダブルクリックします。これで、group という変数を使ってグループが区別されます。



- ▶ 同じデータ ファイル (DosageAndPerformance2.sav) とグループ変数 (group) を指定し、グループ番号 2 について前述の手順を繰り返します。



- ▶ [ケースをグループに割り当てる] を選択します (チェック マークが表示されます)。

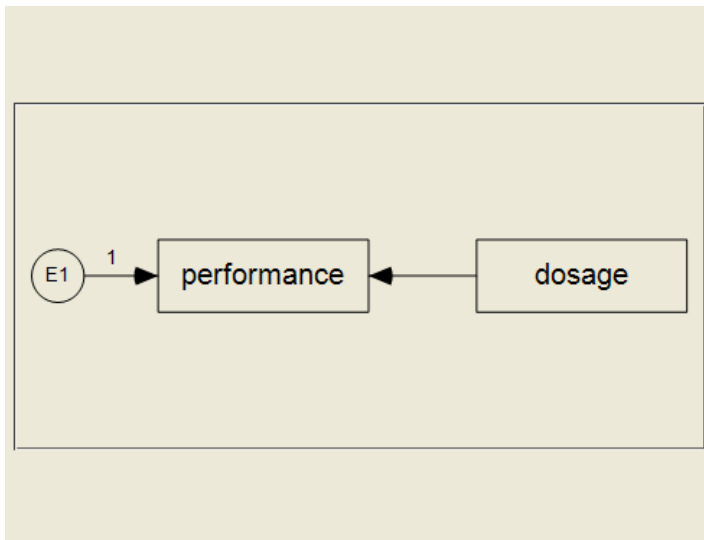


[ケースをグループに割り当てる] の横にチェック マークがあるのを除き、ここまでは通常の複数グループの分析と同じです。このチェック マークによって、これが混合モデリング分析になります。このチェック マークが表示されていると、データ ファイルのグループ変数がグループに割り当てられていない場合、ケースはグループに割り当てられます。[グループ値] をクリックしてグループ変数の値を指定する必要がなかったことに注意してください。データ ファイルには、グループ変数 (group) の値が含まれていないので、[group] 変数の値として、グループ番号 1 のケースに Cluster1、グループ番号 2 のケースに Cluster2 が自動的に作成されます。

- ▶ [OK] をクリックして、[データ ファイル] ダイアログ ボックスを閉じます。

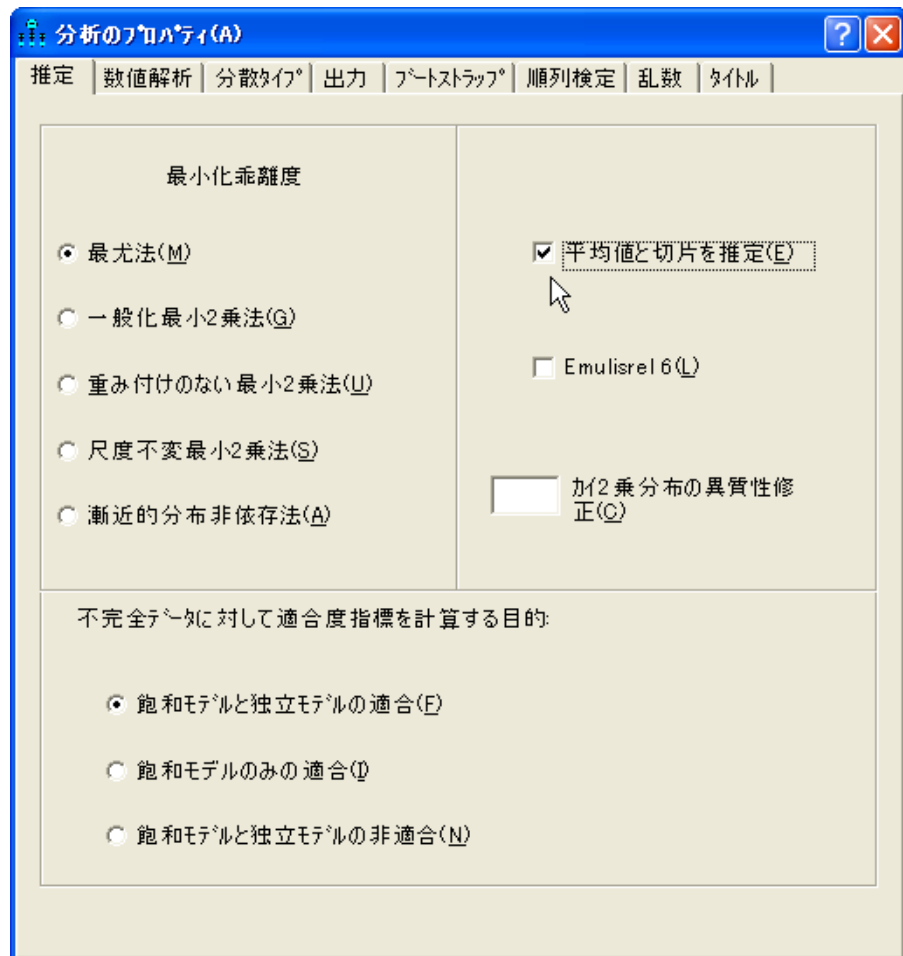
## モデルの特定化

- ▶ 回帰モデルのパス図を次のように作成します。(このパス図は Ex07.amw として保存されています)。




- ▶ メニューから [表示] → [分析のプロパティ] の順に選択します。

- ▶ [平均値と切片を推定] を選択します (隣にチェック マークが表示されます)。






## モデルの適合

- ▶ ツールバーの  をクリックします。

または

- ▶ メニューから [分析] → [ベイズ推定] を選択します。

注：混合モデリングではベイズ推定しか実行できないため、 のボタンは無効化されています。

[ベイズ SEM] ウィンドウが開いたら、不機嫌な顔  が上機嫌の顔  に変わるまで待ちます。[ベイズ SEM] ウィンドウに、次のような推定値の表が表示されます。



	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>係数</b>									
performance<--dosage	2.082	0.001	0.071	1.000	-0.035	0.150	1.724	2.372	
<b>平均値</b>									
dosage	7.114	0.002	0.180	1.000	-0.016	0.057	6.341	7.957	
<b>切片</b>									
performance	5.394	0.006	0.528	1.000	0.049	0.159	3.328	8.194	
<b>分散</b>									
dosage	2.897	0.004	0.459	1.000	0.600	0.635	1.590	5.325	
E1	1.029	0.002	0.174	1.000	0.660	0.897	0.555	2.070	
<b>Group number 1 の割合</b>									
割合	0.247	0.000	0.022	1.000	0.117	0.039	0.169	0.345	


[ベイズ SEM] ウィンドウに、通常の複数グループの回帰分析で取得されるすべてのパラメータ推定が表示されます。グループごとに個別の推定値表があります。推定値の表の上部にあるタブをクリックすると、別のグループに切り替えることができます。



表の一番下の行には、各グループの母集団における比率の推定値が表示されます。グループ番号 1 の推定値を表示している上の図では、グループ番号 1 の母集団の比率が 0.247 と推定されています。母集団の比率の推定事後分布を確認するには、比率の行を右クリックして、ポップアップメニューから [事後分布の表示] を選択します。

	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>係数</b>									
performance<--dosage	2.082	0.001	0.071	1.000	-0.035	0.150	1.724	2.372	
<b>平均値</b>									
dosage	7.114	0.002	0.180	1.000	-0.016	0.057	6.341	7.957	
<b>切片</b>									
performance	5.394	0.006	0.528	1.000	0.049	0.159	3.328	8.194	
<b>分散</b>									
dosage	2.897	0.004	0.459	1.000	0.600	0.635	1.590	5.325	
E1	1.029	0.002	0.174	1.000	0.660	0.897	0.555	2.070	
<b>Group number 1 の割合</b>									
割合	0.247			1.000	0.117	0.039	0.169	0.345	

[事後分布] ウィンドウのグラフは、グループ番号 1 の母集団の比率が実質的に 0.15 ~ 0.35 の範囲になることを保証しています。




ここで、グループ番号 1 の係数と切片をグループ番号 2 の対応する推定値と比較してみましょう。グループ番号 1 では、係数の推定値は 2.082、切片の推定値は 5.394 です。グループ番号 2 では、係数の推定値 (1.999) はグループ番号 1 とほぼ同じですが、切片の推定値 (9.955) はグループ番号 1 より大幅に大きくなっています。

The screenshot shows the 'ベイズSEM' software window. The title bar reads 'ベイズSEM'. The menu bar includes 'ファイル(F)', '編集(E)', '表示(V)', '分析(A)', and 'ヘルプ(H)'. The toolbar contains various icons for file operations and analysis. The status bar shows '500+34,486', '67', and '.305'. Below the toolbar, there are two tabs: 'Group number 1' and 'Group number 2', with 'Group number 2' selected. The main area displays a table with the following data:

	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>係数</b>									
performance<--dosage	1.999	0.000	0.033	1.000	-0.035	0.080	1.830	2.134	
<b>平均値</b>									
dosage	2.133	0.001	0.109	1.000	0.020	0.017	1.695	2.569	
<b>切片</b>									
performance	9.955	0.001	0.090	1.000	0.007	0.030	9.566	10.344	
<b>分散</b>									
dosage	3.470	0.002	0.292	1.000	0.336	0.216	2.452	4.939	
E1	1.027	0.001	0.090	1.000	0.320	0.244	0.716	1.521	
<b>Group number 2 の割合</b>									
割合	0.753	0.000	0.022	1.000	-0.117	0.039	0.655	0.831	


## 個々のクラスのカテゴリ

各ケースのグループ所属の確率を取得するには、次のようにします。

- ▶ [事後予測分布] ボタン  をクリックします。

または

- ▶ メニューから、[表示] → [事後予測分布] の順に選択します。



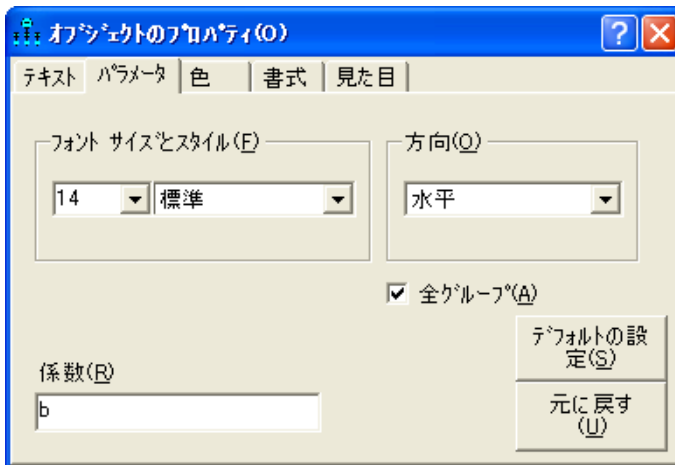
	performance	dosage	P(Cluster1)	P(Cluster2)
1	21.2031284997218	6.66331007602931	<b>0.88</b>	0.12
2	15.6987674948943	5.66102565586862	<b>1.00</b>	0.00
3	19.2048361186385	6.05921131399695	<b>0.98</b>	0.02
4	23.1294140957387	9.18741643404798	<b>1.00</b>	0.00
5	20.9890517035103	6.94140644349163	<b>1.00</b>	0.00
6	18.0430561625521	5.16054293700744	<b>0.54</b>	0.46
7	13.9604306100494	4.17650111795259	<b>1.00</b>	0.00
8	22.5151975204992	8.07913550523847	<b>1.00</b>	0.00
9	14.0616719804701	4.67521627594292	<b>1.00</b>	0.00
10	19.546086381681	7.85787684574796	<b>1.00</b>	0.00
11	12.9679285391251	2.7627255307244	0.08	<b>0.92</b>
12	11.958726583912	3.6995932072631	<b>1.00</b>	0.00
13	15.0037101134325	5.53950501114771	<b>1.00</b>	0.00
14	20.1350290402946	7.06075641893955	<b>1.00</b>	0.00

[事後予測分布] ウィンドウには、それぞれのケースの変数 [group] が Cluster1 または Cluster2 の値を取る確率が表示されています。ケース 1 は、グループ番号 1 に属する確率が 0.88、グループ 2 に属する確率が 0.12 と推定されています。1 つ目のグループの切片が約 5.394 なのに対して、2 つ目のグループの切片が約 9.955 なのを考えると、グループ番号 1 がパフォーマンスの低いグループだと言えます。したがって、標本の 1 人目の被験者がパフォーマンスの低いグループに属する確率は 88 パーセント、パフォーマンスの高いグループに属する確率は 12 パーセントです。

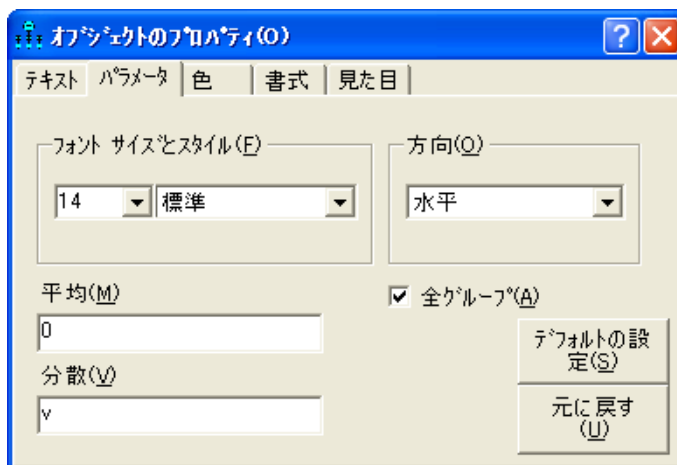
## パラメータ推定値の向上

推定に必要なパラメータの数を減らすことによって、パラメータ推定値（および Amos のクラスタ形成力）を向上できます。先に確認したように、2つのグループの回帰直線の傾きはほぼ同じです。また、各回帰直線のばらつきも、2つのグループにおいてほぼ同じに見えます。したがって、傾きと誤差分散は2つのグループで同じであるという仮説を混合モデリング分析に取り入れ、その結果、推定される異なるパラメータの数を減らすことが可能です。手順は次のとおりです。

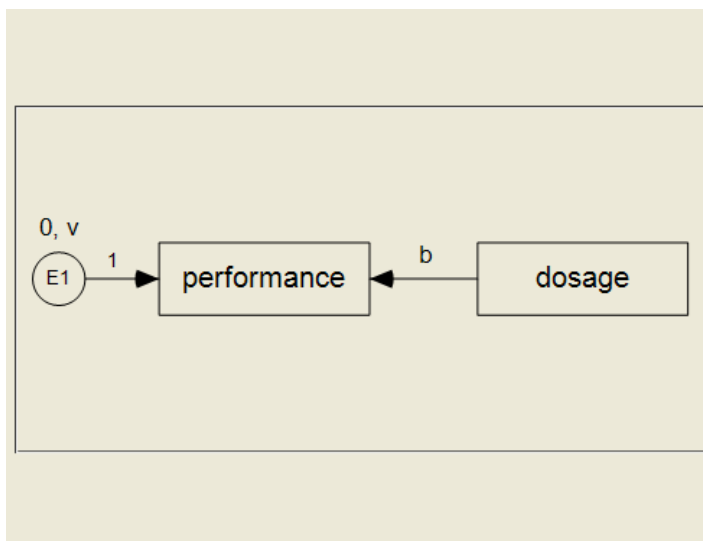
- ▶ パス図で dosage と performance を結ぶ一方向矢印を右クリックして、ポップアップメニューから [ オブジェクトのプロパティ ] を選択し、[ 係数 ] テキストボックスにパラメータ名を「b」と入力します。




- ▶ [ オブジェクトのプロパティ ] ダイアログボックスが開いている状態で、パス図の E1 をクリックします。
- ▶ [ オブジェクトのプロパティ ] ダイアログボックスで、[ 分散 ] テキストボックスにパラメータ名を「v」と入力します。



パス図は次の図のようになります。(このパス図は Ex36-b.amw として保存されています)。



傾きと誤差分散が 2 つのグループで同じになるように制約したら、[ ベイジアン ] ボタン  をクリックして混合モデリング分析を繰り返すことができます。ここでは、その分析の結果は示しません。

## グループ比率の事前分布

グループ比率の事前分布では、ユーザーが指定できるパラメータによるディリシュレ分布を使用します。デフォルトでは、ディリシュレパラメータは 4, 4, ... になっています。

- ▶ ディリシュレパラメータを指定するには、[ベイズ SEM] ウィンドウでグループ比率の推定値を右クリックし、ポップアップメニューから [事前分布の表示] を選択します。

	平均値	標準誤差	標準偏差	収束統計量	歪度	尖度	最小値	最大値	名前
<b>係数</b>									
performance<--dosage	2.083	0.000	0.069	1.000	-0.037	0.072	1.744	2.392	
<b>平均値</b>									
dosage	7.113	0.001	0.180	1.000	-0.032	0.050	6.297	7.826	
<b>切片</b>									
performance	5.390	0.002	0.519	1.000	0.046	0.091	3.172	8.000	
<b>分散</b>									
dosage	2.897	0.002	0.458	1.000	0.619	0.751	1.565	5.783	
E1	1.025	0.001	0.172	1.000	0.661	0.959	0.501	2.397	
<b>Group number 1 の割合</b>									
割合	0.247	0.000	0.022	1.000	0.114	-0.006	0.164	0.339	

## ラベルスイッチング

ここでグループ番号 1 について報告される結果が、グループ番号 2 について得られる結果と一致し、グループ 2 について報告される結果が、グループ 1 について得られる結果と一致する場合があります。つまり、ユーザーが得る結果とここで報告される結果は一致するが、グループ名が反対になっている場合があるということです。これは、ラベルスイッチング (Chung, Loken および Schafer, 2004 年) と呼ばれる場合があります。ラベルスイッチングについては、例 35 の最後に詳しく説明しています。

# パス図を描画しない場合の Amos Graphics の使用

## はじめに

Amos Graphics では、通常、パス図を描画してモデルを指定しますが、グラフィックを使用しない方法も提供されています。パス図を描画しない場合は、Visual Basic または C# プログラムの形式でテキストを指定できます。このようなプログラムでは、パス図の各オブジェクト（四角形、楕円形、片方向矢印、双方向矢印、図のキャプション）は、単一のプログラムのステートメントに対応します。通常、プログラムのステートメントは、1 行のテキストです。

以下は、パス図を描画する代わりにテキストを入力してモデルを指定する場合がある理由です。

- モデルが大きすぎるため、そのパス図を描画するのが困難である
- マウスよりもキーボードの使用を好んでいる、またはグラフィックよりもテキストでの作業を好んでいる
- 変数の数や変数名などのわずかな情報が異なる類似した多数のモデルを生成する必要がある。このようなモデルを頻繁に生成する必要がある場合、テキスト出力が、IBM SPSS Amos を当てはめる特定のモデルを指定する、カスタムの Visual Basic または C# プログラムとなるスーパープログラムを作成し、作業を自動化すると効率的です。

この例は、パス図を描画する代わりにテキストを入力して Amos Graphics でモデルを指定する方法を示します。

## データについて

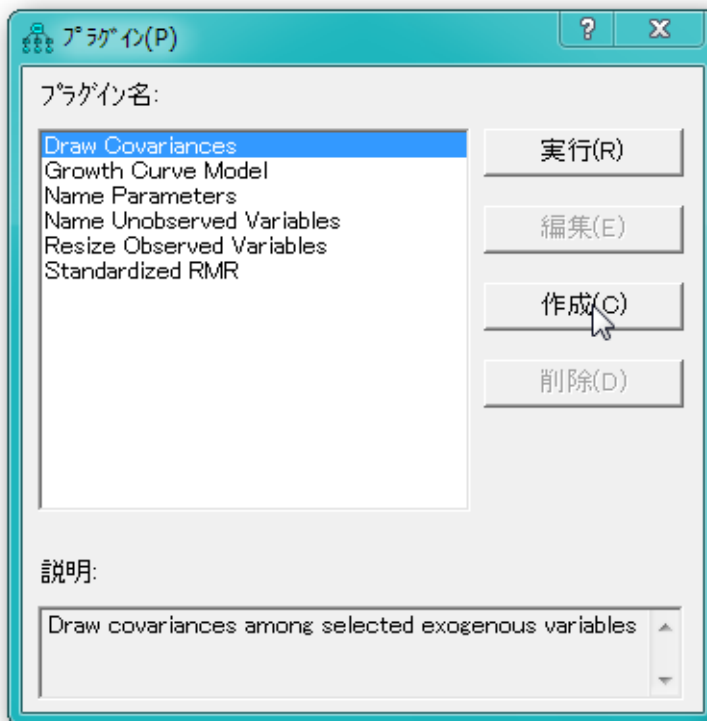
この例では、例 8 の Holzinger and Swineford (1939) データセットを使用します。

## 共通因子モデル

この例では、例 8 の因子分析モデルを使用します。例 8 ではパス図の描画によってモデルを指定しましたが、この例では Visual Basic プログラムの記述によって同じモデルを指定します。

### モデルを指定するプラグインの作成

- ▶ メニューから、[プラグイン]→[プラグイン]を選択します。
- ▶ [プラグイン]ダイアログボックスの[作成]をクリックします。





[プログラム エディタ] ウィンドウが開きます。

```

[Header]
<System.ComponentModel.Composition.Export(GetType(Amos.IPlugin))>
Public Class CustomCode
    Implements Amos.IPlugin

    Public Function Name() As String Implements Amos.IPlugin.Name
        Return ""
    End Function

    Public Function Description() As String Implements Amos.IPlugin.Description
        Return ""
    End Function

    Public Function Mainsub() As Integer Implements Amos.IPlugin.Mainsub
    End Function

```

- ▶ [プログラム エディタ] ウィンドウで、Name 関数と Description 関数を有意義な文字列を戻すように変更します。

```

[Header]
<System.ComponentModel.Composition.Export(GetType(Amos.IPlugin))>
Public Class CustomCode
    Implements Amos.IPlugin

    Public Function Name() As String Implements Amos.IPlugin.Name
        Return "Example 37a"
    End Function

    Public Function Description() As String Implements Amos.IPlugin.Description
        Return "Example 37 from the Amos User's Guide"
    End Function

    Public Function Mainsub() As Integer Implements Amos.IPlugin.Mainsub
    End Function

```

この時点では、例 8 の最初のパス図を参照すると役立ちます。パス図の各四角形、楕円形、および矢印の **Mainsub** 関数に 1 行を追加します。

## 例 37

- ▶ プログラム エディタで、次の行

```
pd.Observed("visperc")
```

を `Mainsub` 関数の最初の行に入力します。

```

"Header"
<System.ComponentModel.Composition.Export(GetType(Amos.IPlugin))>
Public Class CustomCode
    Implements Amos.IPlugin

    Public Function Name() As String Implements Amos.IPlugin.Name
        Return "Example 37a"
    End Function

    Public Function Description() As String Implements Amos.IPlugin.Description
        Return "Example 37 from the Amos User's Guide"
    End Function

    Public Function Mainsub() As Integer Implements Amos.IPlugin.Mainsub
        pd.Observed("visperc")
    End Function

```

ここでプラグインを保存すると、後で「visperc」という変数を表す四角形の描画に使用できます。この四角形は、パス図の無作為の位置に、任意の高さと幅で描画されます。高さ、幅、および位置を指定できます。例を次に示します。

```
pd.Observed("visperc", 400, 300, 200, 100)
```

これは、「visperc」という変数の四角形を描画します。四角形は、パス図の左端から 400 論理ピクセル、上端から 300 論理ピクセルの位置を中心に配置されます。また、幅 200 論理ピクセル、高さ 100 論理ピクセルの大きさです。(論理ピクセルは、1/96 インチです。)他の **Observed** 方法の種類は、オンラインヘルプをご覧ください。

この例では、パス図のオブジェクトに高さと幅を指定しません。

- ▶ プラグインが残りの 5 つの **Observed** 変数に対する四角形を描画するように、`Mainsub` 関数に以下の行を追加入力します。

```

pd.Observed("cubes")
pd.Observed("lozenges")
pd.Observed("paragrap")
pd.Observed("sentence")
pd.Observed("wordmean")

```

```

Return "Example 37a"
End Function

Public Function Description() As String Implements Amos.IPlugin.Description
Return "Example 37 from the Amos User's Guide"
End Function

Public Function Mainsub() As Integer Implements Amos.IPlugin.Mainsub
pd.Observed("visperc")
pd.Observed("cubes")
pd.Observed("lozenges")
pd.Observed("paragrap")
pd.Observed("sentence")
pd.Observed("wordmean")
End Function

```

- ▶ プラグインが 8 つの Unobserved 変数に対する 8 つの楕円形を描画するように、以下の行を入力します。

```

pd.Unobserved("err_v")
pd.Unobserved("err_c")
pd.Unobserved("err_l")
pd.Unobserved("err_p")
pd.Unobserved("err_s")
pd.Unobserved("err_w")
pd.Unobserved("spatial")
pd.Unobserved("verbal")

```

- ▶ プラグインが 12 個の片方向矢印を描画するように、以下の行を入力します。

```

pd.Path("visperc", "spatial", 1)
pd.Path("cubes", "spatial")
pd.Path("lozenges", "spatial")
pd.Path("paragrap", "verbal", 1)
pd.Path("sentence", "verbal")
pd.Path("wordmean", "verbal")

pd.Path("visperc", "err_v", 1)
pd.Path("cubes", "err_c", 1)
pd.Path("lozenges", "err_l", 1)
pd.Path("paragrap", "err_p", 1)
pd.Path("sentence", "err_s", 1)
pd.Path("wordmean", "err_w", 1)

```

上記の一部の行には、**Path** 方法に 1 と同等に設定された 3 つ目の引数がありますが、このようにして、回帰の太さを定数値 1 に固定しています。他の **Path** 方法については、オンライン ヘルプを参照してください。

## 例 37

- ▶ プラグインが双方向矢印を描画するように、以下の行を入力します。

```
pd.Cov("spatial", "verbal")
```

- ▶ パス図でのオブジェクトの位置を調整し、見栄えを改善するために、以下の行を入力します。

```
pd.Reposition()
```

前述のとおり、この例で使用されている単純な **Observed**、**Unobserved**、および **Caption** 方法は、パス図の無作為な位置にオブジェクトを配置しますが、**Reposition** 方法は、オブジェクトの位置を再調整し、パス図の見栄えを良くします。しかし、プレゼンテーション品質のパス図を生成するわけではありません。実際には、その品質に及びもしません。一方、**Reposition** は通常パス図の見栄えを大幅に改善します。パス図のオブジェクトのサイズと位置を希望どおりに変更するには、以下の手法があります。

- ▶ `pd` クラスの **Observed**、**Unobserved**、および **Caption** 方法を使用するたびに、高さ、幅、および位置を指定します。( **Observed**、**Unobserved**、および **Caption** 方法については、オンラインヘルプを参照してください。)

または

- ▶ プラグインで、**Reposition** 方法を使用して、オブジェクトの位置を調整します。プラグインを実行後、**Amos Graphics** ツールボックスの描画ツールを使用して、パス図のオブジェクトをインタラクティブに移動およびサイズの変更を行います。

## 元に戻す機能の制御

- ▶ 次の行を `Mainsub` 関数の最初の行に入力します。

```
pd.UndoToHere
```

- ▶ 次の行を `Mainsub` 関数の最後の行に入力します。

```
pd.UndoResume
```

**UndoToHere** 方法と **UndoResume** 方法は、[元に戻す] ボタンを 1 回クリックすることでプラグインの実行の効果が取り消されるように、セットで使用します。

これで、プログラム エディタの Mainsub 関数は次のようになります。

```
Public Function Mainsub() As Integer Implements Amos.IPlugin.Mainsub
    pd.UndoToHere
    pd.Observed("visperc")
    pd.Observed("cubes")
    pd.Observed("lozenges")
    pd.Observed("paragrap")
    pd.Observed("sentence")
    pd.Observed("wordmean")

    pd.Unobserved("err_v")
    pd.Unobserved("err_c")
    pd.Unobserved("err_l")
    pd.Unobserved("err_p")
    pd.Unobserved("err_s")
    pd.Unobserved("err_w")

    pd.Unobserved("spatial")
    pd.Unobserved("verbal")

    pd.Path("visperc", "spatial", 1)
    pd.Path("cubes", "spatial")
    pd.Path("lozenges", "spatial")
    pd.Path("paragrap", "verbal", 1)
    pd.Path("sentence", "verbal")
    pd.Path("wordmean", "verbal")

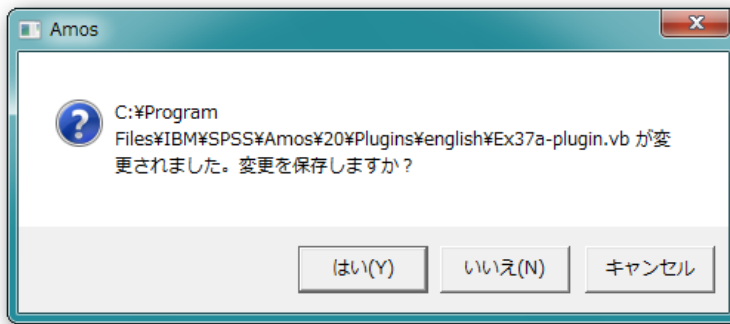
    pd.Path("visperc", "err_v", 1)
    pd.Path("cubes", "err_c", 1)
    pd.Path("lozenges", "err_l", 1)
    pd.Path("paragrap", "err_p", 1)
    pd.Path("sentence", "err_s", 1)
    pd.Path("wordmean", "err_w", 1)

    pd.Cov("spatial", "verbal")
    pd.Reposition()
    pd.UndoResume
End Function
```

これで、例 8 の因子分析モデルを指定するためのプラグインが完成しました。記述済みのプラグインは、Amos の `plugins` フォルダのフォルダにある「Ex37a-plugin.vb」というファイルにあります。このファイルの言語固有のバージョンは、`%amosplugins%\Japanese` フォルダと `%amosplugins%\English` フォルダに保存されています。事前に入力されている言語固有のプラグインの一つを、`%amosplugins%` フォルダにコピーして、使用することができます。

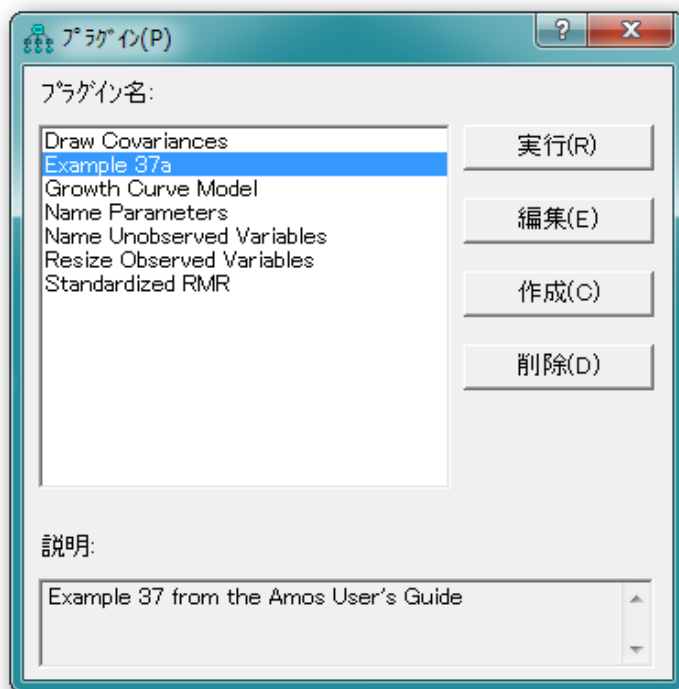
## プラグインのコンパイルと保存

- ▶ [プログラム エディタ] ウィンドウ内、ツールバー上の[シンタックス検証] ボタンをクリックします。[プログラム エディタ] ウィンドウの[シンタックス エラー] タブにコンパイル エラーが表示されます。
- ▶ コンパイル エラーを修正したら、[プログラム エディタ] ウィンドウの[閉じる] をクリックします。ファイルを保存するかどうかを問われます。



- ▶ [はい] をクリックします。[名前を付けて保存] ダイアログボックスが表示されます。
- ▶ [名前を付けて保存] ダイアログで、プラグインの名前を入力して[保存] をクリックします。プラグインは、[名前を付けて保存] ダイアログのデフォルトのフォルダに保存する必要があります。[名前を付けて保存] ダイアログでフォルダーを誤って変更してしまった場合は、フォルダー名「%amosplugins%」を入力すると、デフォルトに戻すことができます。

プラグインを保存したら、プラグイン名 Example 37a が [プラグイン] ウィンドウのプラグインリストに表示されます。(Example 37a は、プラグインの **Name** 関数を使用して戻される文字列です。)




- ▶ [プラグイン] ウィンドウを閉じます。

## プラグインの使用方法

- ▶ メニューから、[ファイル]→[新規作成] を選択します。

作業を保存するかどうかを問われた場合は、[はい] または [いいえ] を選択します。

- ▶ メニューから、[プラグイン]→[Example 37a] を選択します。プラグインによって、モデルのパス図が生成され、パス図ウィンドウにモデルが表示されます。以下は、この例の準備中に生成されたパス図です。(パス図内の要素の位置付けは乱数ジェネレータによって決定されるため、これとは異なるパス図が表示される場合があります)





## モデル指定以外のその他の分析機能

例 8 では、データ ファイル `Gmt_fem.sav` をインタラクティブに指定しました (メニューから、[ファイル]→[データ ファイル]を選択)。ここでも、同じ操作を実行できます。または、`Mainsub` 関数に以下の行を追加することによって、プラグイン内で `Gmt_fem.sav` データ ファイルを指定することもできます。

```
pd.SetDataFile(1, MiscAmosTypes.cDatabaseFormat.mmSPSS,
Environment.GetEnvironmentVariable("examples") & "\\grnt_fem.sav", "", "", "")
```

同様に、例 8 では、標準化推定値は、インタラクティブに要求されていました (メニューの [表示]→[分析プロパティ]を選択)。標準化推定値をインタラクティブに要求する代替手法として、`Mainsub` 関数に以下の行を追加することによって、プラグイン内で要求することができます。

```
pd.GetCheckBox("AnalysisPropertiesForm", "StandardizedCheck").Checked = True
```

一般的に、インタラクティブに指定できる分析の機能は、`pd` クラスの方法とプロパティを使用してプラグイン内で指定できます。

## モデル変数に対応するプログラム変数の定義

パス図にオブジェクトを作成する方法には、`Oserved`、`Unobserved`、`Path`、`Cov`、および `Caption` の 5 つがあります。これらの各方法は、それが作成するオブジェクトへの参照を返します。たとえば、`Observed` 方法は、パス図に観測変数を作成し、さらにその観測変数に参照を返します。以下の行

```
pd.Observed("wordmean")
pd.Unobserved("verbal")
```

を記述して観測変数 `wordmean` と非観測変数 `verbal` を作成する代わりに、以下の行 (Visual Basic) を記述できます。

```
Dim wordmean As PDElement = pd.Observed("wordmean")
Dim verbal As PDElement = pd.Unobserved("verbal")
```

それから、プログラム変数 `wordmean` を使用してモデル変数 `wordmean` を参照し、プログラム変数 `verbal` を使用してモデル変数 `verbal` を参照できます。`verbal` 変数から `wordmean` 変数に片方向矢印を描画するには、以下のいずれかを記述できます。

```
pd.Path(wordmean, verbal)
```

または

```
pd.Path(iwordmeanî, "verbal")
```

引用符を使用しない記述方法には、引用符を使用しない場合にプラグインをコンパイルしたとき ([プログラム エディタ] ウィンドウで [コンパイル] をクリックしたとき) に入力エラーが検出されやすいというところに、利点があります。引用符を使用すると、入力エラーがある場合に、プラグラインを使用するまでエラーは検出されません。

ファイル Ex37b-plubin.vb には、Ex37a-plugin.vb と同じ機能を持つプラグインが含まれますが、Ex37b-plugin.vb は Visual Basic 変数を使用してモデル変数を参照している点が異なります。Ex37b-plugin.vb の言語固有のバージョンは、%amosplugins%\Japanese フォルダーと %amosplugins%\English フォルダーに保存されています。事前に入力されている言語固有のプラグインの一つを、%amosplugins% フォルダーにコピーして、使用することができます。

# 単純なユーザー定義数量 I

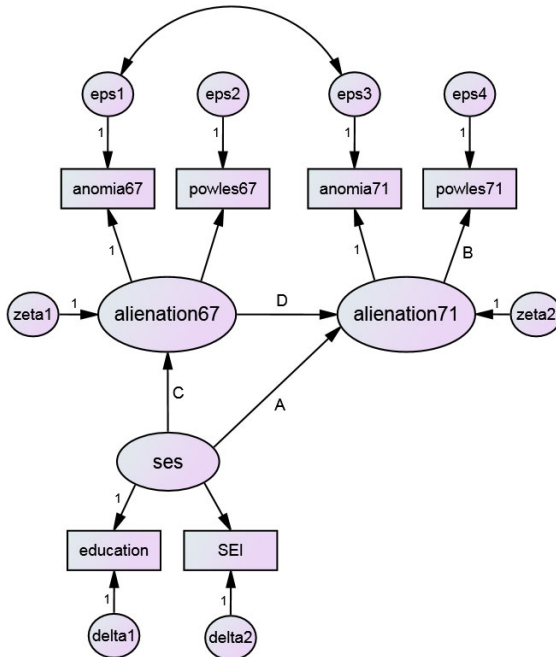
## はじめに

この例では、ブートストラップ標準誤差、信頼区間、有意検査を使用してモデルパラメータのユーザー定義関数を推定する方法を示しています。この例では、1つのユーザー定義関数が推定されます。これは間接効果です。

この例では、パラメータのユーザー定義関数を推定する簡略化された方法を示しています。簡略化された方法では、単一の式で定義できる数量も限定されます。Amosのユーザー定義数量機能のより一般的なバージョン(ここでは示していません)では、任意の長さ複雑さのプログラム1つで数量を定義できます。より一般的なバージョンについては、オンラインヘルプのトピック「CValue Class Reference (CValue クラス参照)」を参照してください。<http://amosdevelopment.com/features/user-defined/user-definedgeneral/index.html.611>では動画でも説明しています。

## Wheaton のデータの再考

例 6 では、Wheaton ら (1977) のデータの 3 つの代替モデルについて説明しました。ここでは、例 6 のモデル B を再度取り上げます。ファイル Ex38.amw にある次のパス図は、例 6 のモデル B にいくつかのパラメータ名を追加したものです。

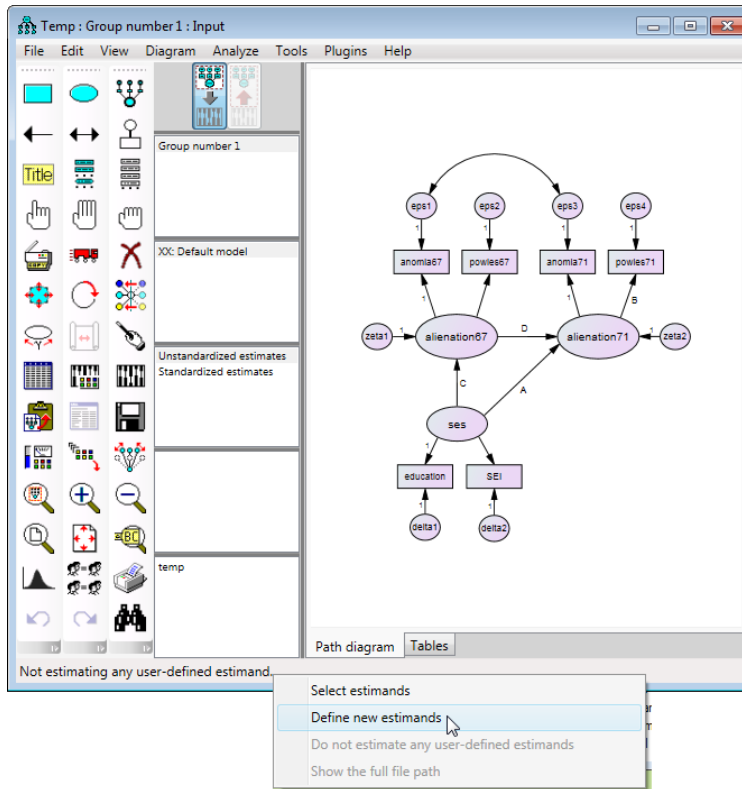


例 6 で 67alienation という名前だった潜在変数は、ここでは alienation67 という名前になっています。同様に、71alienation も alienation71 に変更されています。変数名を変更した理由は、これらの名前が、名前の先頭に数値を使用できない式で表示されることになるためです。

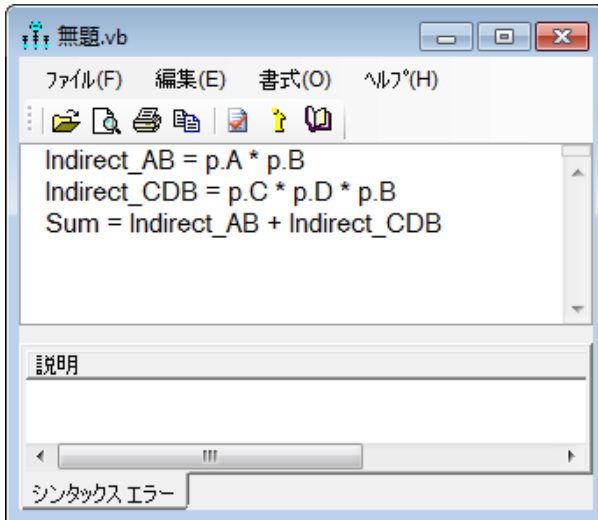
### 間接効果の推定

このモデルの 5 つの回帰の重み付けが A、B、C、D、E という名前になっているのは、powles71 に対する ses の間接効果について説明しやすくするためです。このような間接効果には、積 AB および積 CDB の 2 つがあります。2 つの間接効果の和  $AB + CDB$  は、[表示]>[分析のプロパティ]>[出力]をクリックして[間接、直接、または総合効果]の横にチェックマークを付けることで推定できます。この機能は Amos に組み込まれているため、ユーザー定義数量を指定する必要はありません。ただし、たとえば AB と CDB などの個々の間接効果をその和と共に推定したい場合もあります。これは次の方法でユーザー定義数量として推定できます。

- ▶ [Amos Graphics] ウィンドウの左下にあるステータスバーで [ユーザー定義数量を推定しない] をクリックします。次に、ポップアップメニューで [新しい数量を定義] をクリックします。

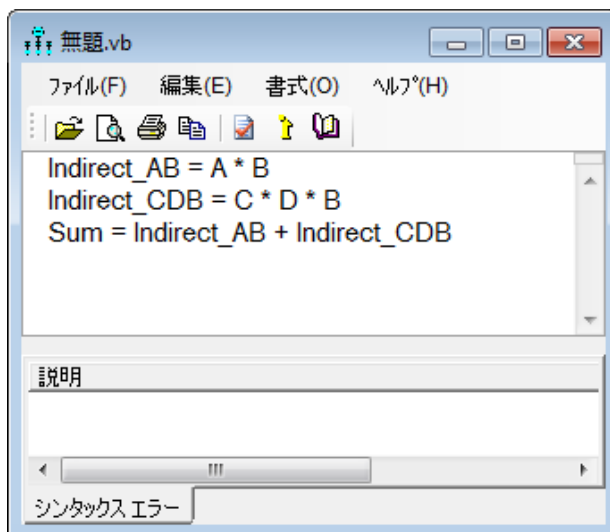


- ▶ 新しいウィンドウが開いたら、3行に入力して3つのカスタム数量を定義します。

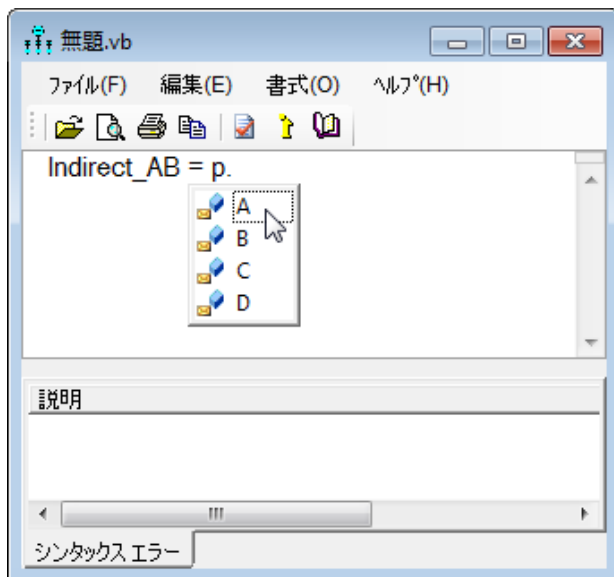


3つのカスタム数量の名前は、**Indirect\_AB**、**Indirect\_CDB**、**Sum** です。別の名前を指定することもできます。数量の名前は英数字と下線で構成する必要があります。先頭文字は英字でなければなりません。大文字小文字は区別されません。つまり、**Abc** という数量がすでにある場合、**abc** という名前は使えません。

パラメータ名には、接頭辞「p.」と1文字を組み合わせます。たとえば、「p.A」は「A」という名前のパラメータを意味します。読みやすくするために、「p.」接頭辞は省略されることもあります。

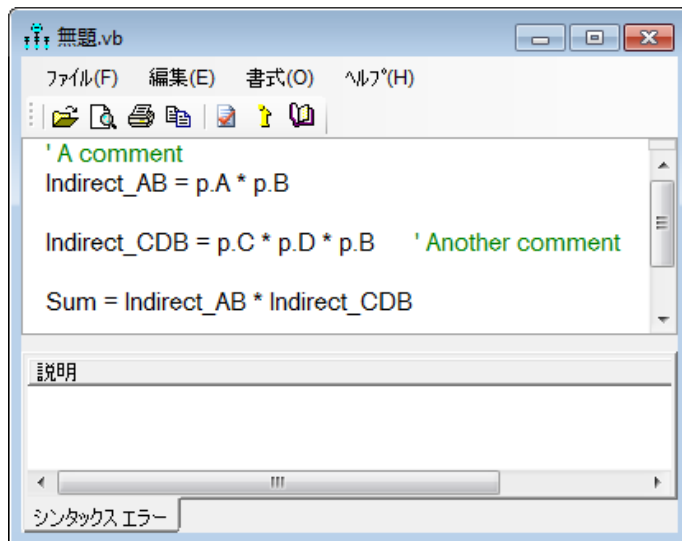


ただし、「p.」を使用すると、「p.」と入力すればパラメータ名の一覧が表示されて、簡単にパラメータを選択できるという利点があります。以下のスクリーンショットでは、パラメータリストの A をダブルクリックすると、キーボードで「A」と入力したのと同じ結果になります。




「p.」を使用する必要がある状況が 1 つあります。A という名前のパラメータと A という名前の変数の両方があると、単に「A」と入力するとあいまいになります。このような場合、「A」という名前のパラメータには「p.A」、A という名前の変数には「v.A」と入力する必要があります。

- ▶ また、次のように行とコメントを入力することもできます。

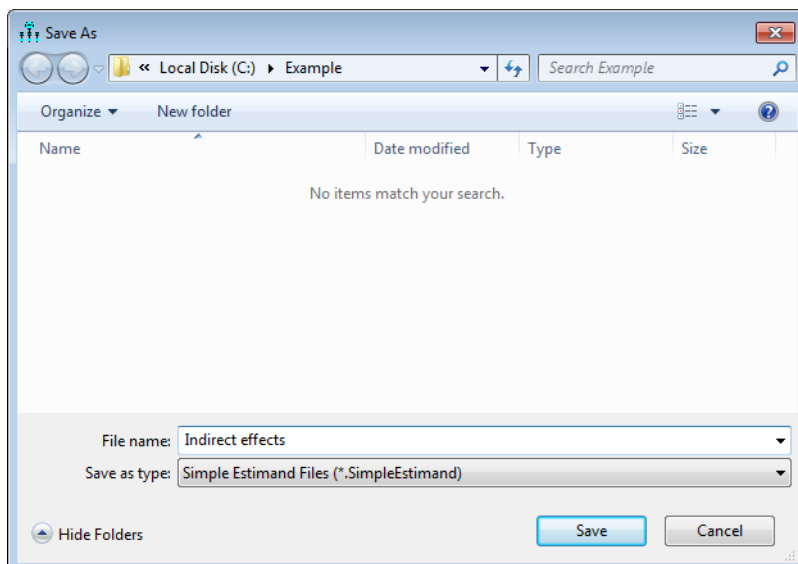


- ▶ [閉じる] ボタンをクリックします。
- ▶ 次のダイアログで [はい] をクリックします。

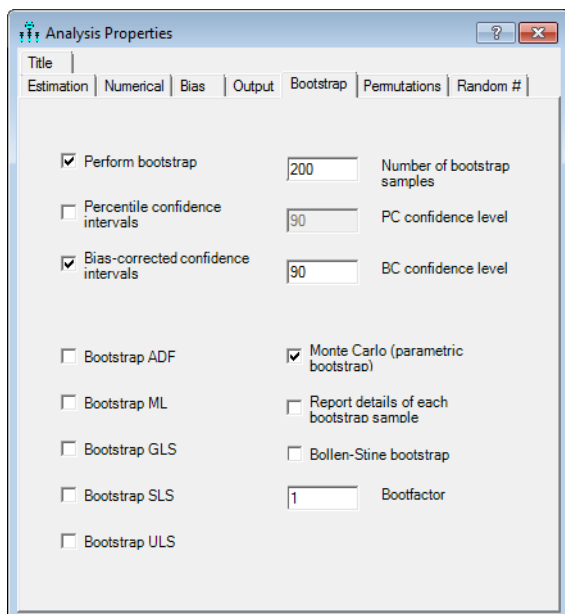




- ▶ [名前を付けて保存] ダイアログで、[ファイル名] ボックスに「indirect effects」と入力します。次に、[保存] ボタンをクリックします。

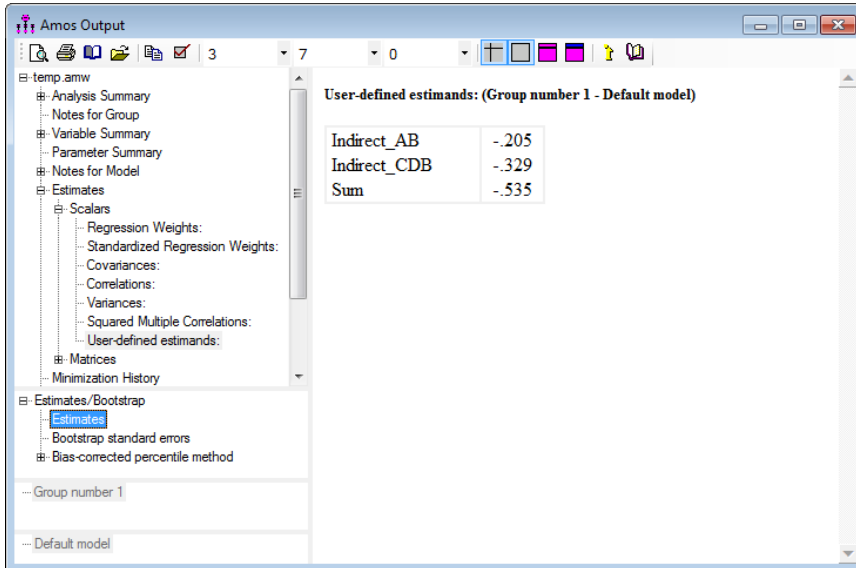


- ▶ [表示]>[分析のプロパティ]>[ブートストラップ]をクリックし、[ブートストラップの実行] および [バイアス修正信頼区間] の横にチェックマークを付けます。また、データファイルに標本積率が含まれていて生データは含まれていないため、[モンテカルロ (パラメトリックブートストラップ)] の横にもチェックマークを付けます。



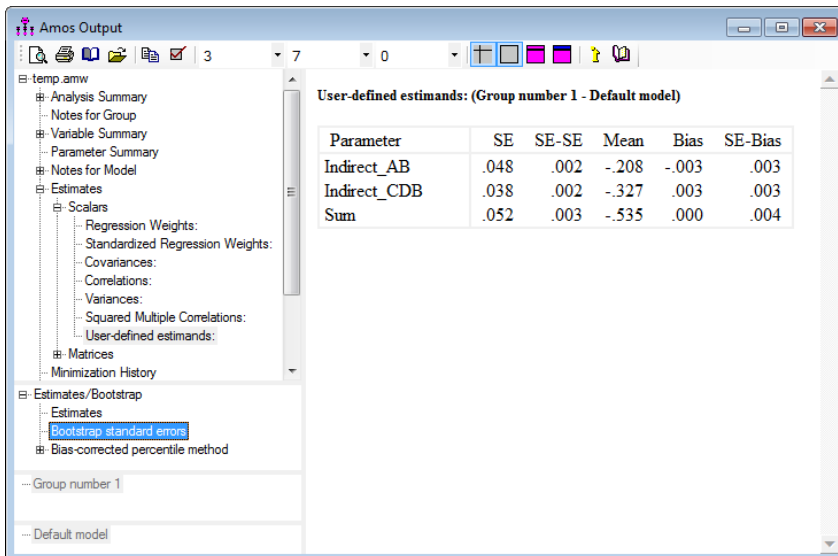
- ▶ [分析]>[推定値を計算] をクリックします。
- ▶ [表示]>[テキスト出力の表示] をクリックします。

- ▶ [Amos 出力] ウィンドウで [推定値] をダブルクリックしてから [スカラー] をダブルクリックし、[ユーザー定義数量] をクリックします。




Indirect\_AB という名前の数量は -0.205 と推定されています。これは、回帰の重み付け A (-0.212) と回帰の重み付け B (0.971) の積です。

- ▶ [ブートストラップの標準誤差] をクリックします。



Indirect\_AB は、おおよそ正規分布に従っていて、標準誤差は約 0.048 です。

- ▶ [ブートストラップの信頼度] をクリックします。



The screenshot shows the Amos Output window. The left pane displays a tree view of the model output, with 'Bias-corrected percentile method' selected under the 'Estimates' section. The right pane, titled 'User-defined estimands: (Group number 1 - Default model)', contains a table with the following data:

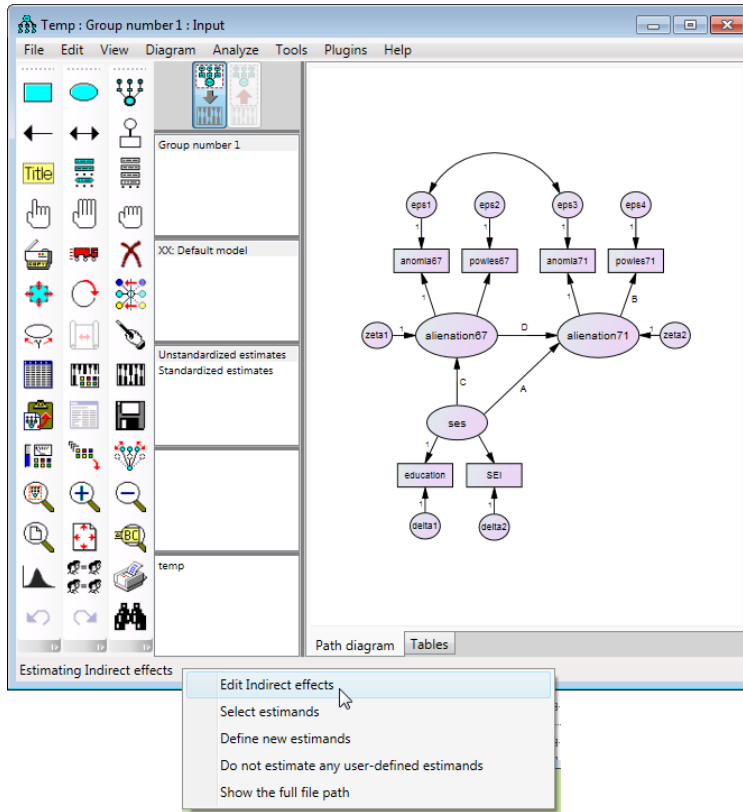
Parameter	Estimate	Lower	Upper	P
Indirect_AB	-.205	-.283	-.118	.013
Indirect_CDB	-.329	-.392	-.268	.009
Sum	-.535	-.620	-.453	.009

Indirect\_AB の母集団値は、90% の信頼度で -0.283 ~ -0.118 です。推定値が -0.205 の場合、p 値は 0.013 になります。0.05 の水準ではゼロから有意な差がありますが、0.01 の水準では有意な差はありません。

## パラメータに名前を付けない間接効果の推定

パラメータの関数を推定しようと考えている場合、上記のように、これらのパラメータに名前を付けるという方法が便利です。ただし、パラメータに名前を付ける必要があるわけではありません。次の手順は、推定したばかりの同じ間接効果を推定する方法を示していますが、パラメータ名を使用していません。

- ▶ [Amos Graphics] ウィンドウの左下にあるステータスバーで [Simple indirect effect の推定] をクリックします。次に、ポップアップ表示されるメニューで [Simple indirect effects の編集] をクリックします。

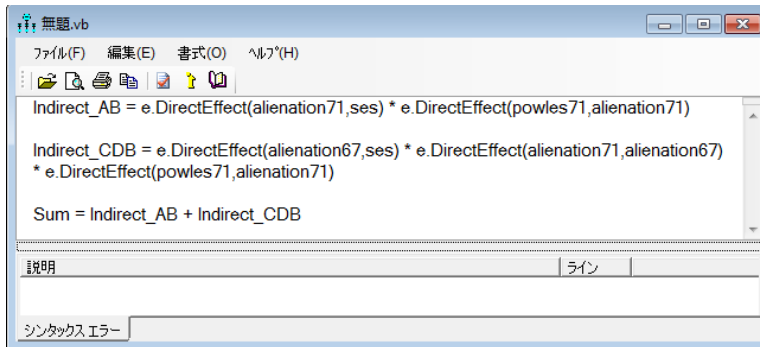


パラメータを名前で参照する場合には、パラメータの説明を次のように置き換えます。


- ▶ 「p.A」を「e.DirectEffect(alienation71,ses)」に変更します。
- ▶ 「p.B」を「e.DirectEffect(powles71,alienation71)」に変更します。
- ▶ 「p.C」を「e.DirectEffect(alienation67,ses)」に変更します。

- ▶ 「p.D」を「e.DirectEffect(alienation71,alienation67)」に変更します。

置換を終えると、カスタム数量の指定は次のようになります。



- ▶ ウィンドウを閉じます。
- ▶ 表示されるダイアログボックスで[はい]をクリックします。



- ▶ [分析]>[推定値を計算] をクリックします。
- ▶ [表示]>[テキスト出力の表示] をクリックします。(テキスト出力は、前回と同じです)。



## 単純なユーザー定義数量 II

### はじめに


この例では、ブートストラップ標準誤差、信頼区間、差の有意検査を使用して 2 つの標準化された回帰の重み付けの差を推定する方法を示しています。

### データについて


39 人の生徒がいるクラスに対して 4 回の小テストが行われました。小テストは、学期中、ほぼ一定の間隔を空けて行われました。ファイル `QuizComplete.txt` には、4 回の小テストをすべて受けた生徒 22 人の点数が記載されています。

### Markov モデル

ファイル `Ex39.amw` には、4 回の小テストの点数の Markov モデルが記載されています。

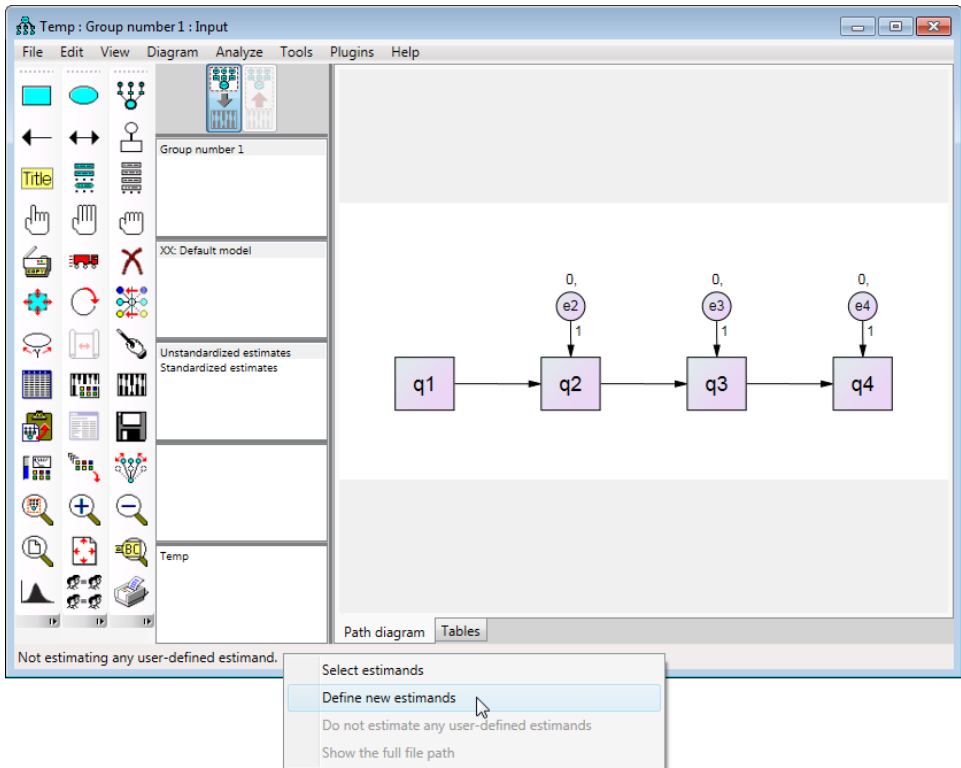


次のパス図は、このモデルについて推定される標準化された回帰の重み付けを示しています。



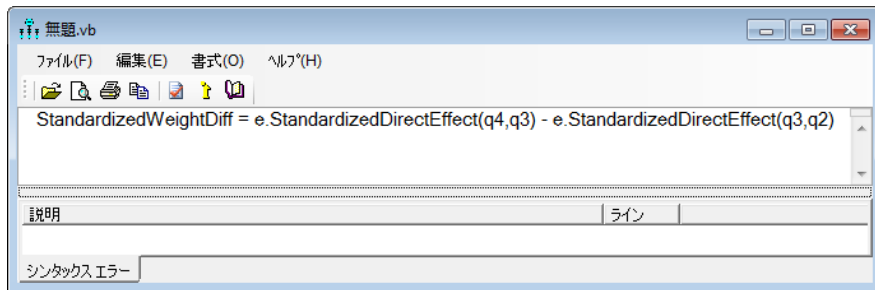
2つの標準化された回帰の重み付けを比較してみましょう。たとえば、q3を予測するためのq2を使用した重み付けとq4を予測するためのq3を使用した重み付けを比較します。2つの推定値の差は約  $.39 - 0.35 = 0.04$  です。その差の標準誤差を求め、信頼区間とその差の有意検査を求めましょう。

- ▶ [Amos Graphics] ウィンドウの左下にあるステータスバーで [ユーザー定義数量を推定しない] をクリックします。次に、ポップアップ表示されるメニューで [新しい数量を定義] をクリックします。



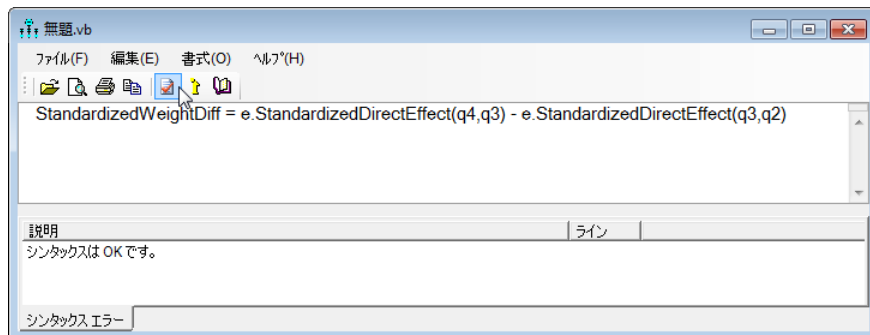


- ▶ 新しいウィンドウが開いたら、次のように 1 行に入力して新しい数量を定義します。




StandardizedWeightDiff 以外の名前を選ぶこともできます。

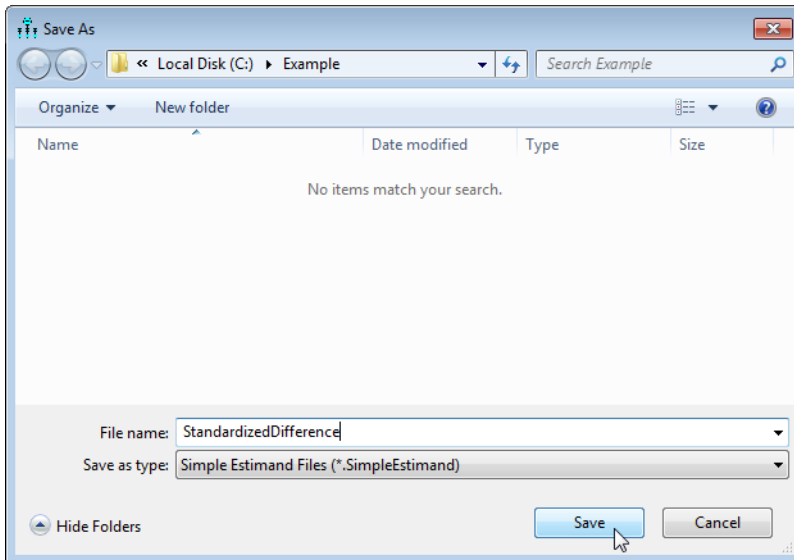
- ▶ ツールバー上の[シンタックスを検証] ボタンをクリックします。入力に間違いがなければ、[説明] ボックスに「シンタックスは OK です。」と表示されます。



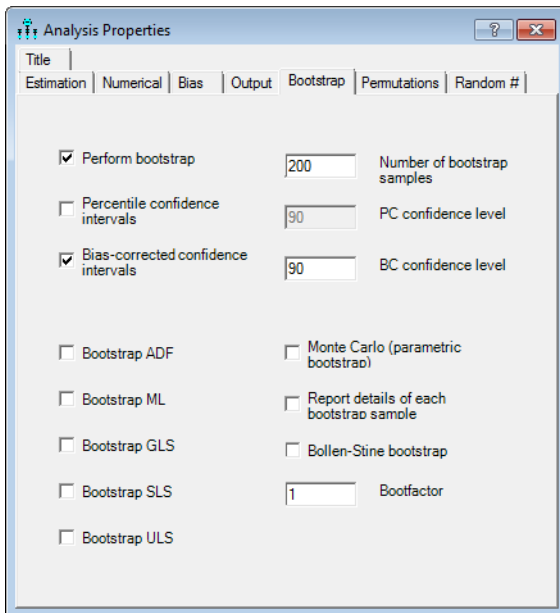
- ▶ ウィンドウを閉じます。
- ▶ 次のダイアログで[はい] をクリックします。



- ▶ [名前を付けて保存]ダイアログで,[ファイル名]ボックスに StandardizedDifference と入力します。次に,[保存] ボタンをクリックします。

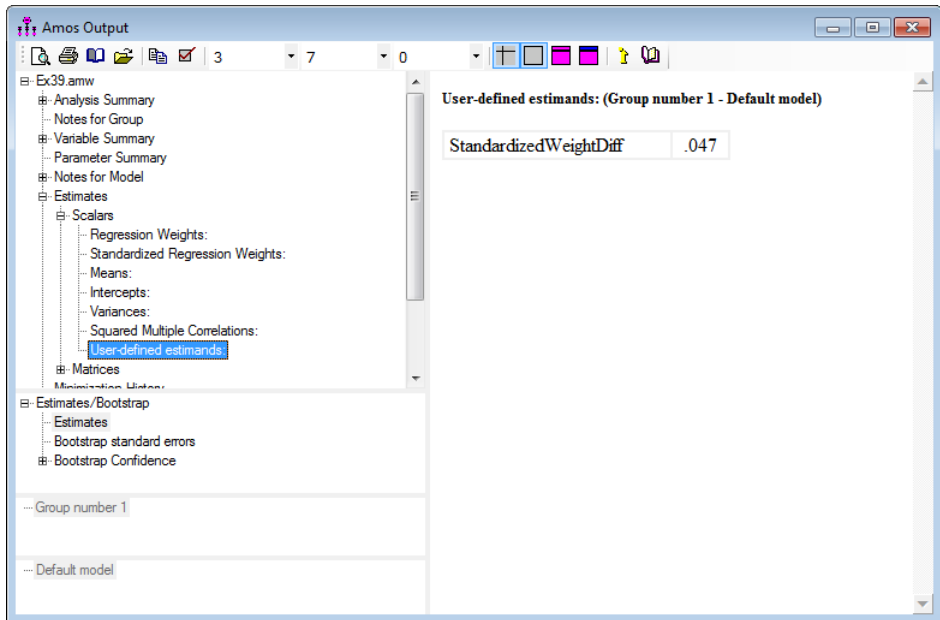


- ▶ [表示]>[分析のプロパティ]>[ブートストラップ]をクリックし,[ブートストラップの実行]および[バイアス修正済信頼区間) ]の横にチェックマークを付けます。



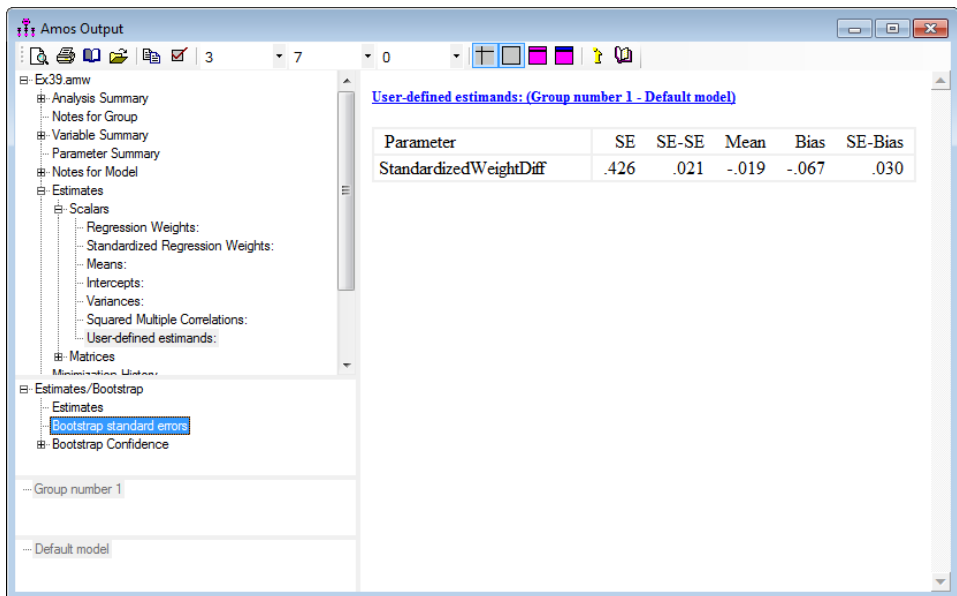
- ▶ [分析]>[推定値を計算] をクリックします。
- ▶ [表示]>[テキスト出力の表示] をクリックします

- ▶ [Amos 出力] ウィンドウで [推定値] をダブルクリックしてから [スカラー] をダブルクリックし、[ユーザー定義数量] をクリックします。




StandardizedWeightDiff という名前の数量は 0.047 と推定されています。

- ▶ [ブートストラップの標準誤差] をクリックします。



この差は、おおよそ正規分布に従っていて、標準誤差は約 0.426 です。

▶ [ブートストラップの信頼度] をクリックします。



The screenshot shows the Amos Output window for a model named 'Ex39 amw'. The left pane shows a tree view of the output, with 'Estimates/Bootstrap' expanded and 'Bias-corrected percentile method' selected. The right pane displays the 'User-defined estimands: (Group number 1 - Default model)' table.

Parameter	Estimate	Lower	Upper	P
StandardizedWeightDiff	.047	-.679	.688	.934

差の母集団値は、90% の信頼度で  $-0.679 \sim 0.688$  です。0.047 という推定値は、従来のどの有意水準でもゼロから有意な差がありません ( $p = 0.934$ )。

# 表記法

$q$  = パラメータ数

$\gamma$  = パラメータのベクトル (次の  $q$ )

$G$  = グループ数

$N^{(g)}$  = グループ  $g$  のオブザベーション数

$N = \sum_{g=1}^G N^{(g)}$  = 全グループを統合したオブザベーション総数

$p^{(g)}$  = グループ  $g$  の観測変数の数

$p^{*(g)}$  = グループ  $g$  の標本の積率数。平均と定数項が明示的なモデルパラメータである場合、関連する標本の積率は、平均、分散、および共分散であり、

$p^{*(g)} = p^{(g)}(p^{(g)} + 3)/2$  となります。それ以外の場合は、標本分散と共分散のみがカウントされ、 $p^{*(g)} = p^{(g)}(p^{(g)} + 1)/2$  となります。

$p = \sum_{g=1}^G p^{*(g)}$  = 全グループを統合した標本の積率数

$d = p - q$  = モデルの検定のための自由度の数

$x_{ir}^{(g)}$  = グループ  $g$  の  $i$  番目の変数の  $r$  番目のオブザベーション

$\mathbf{x}_r^{(g)}$  = グループ  $g$  の  $r$  番目のオブザベーション

$\mathbf{S}^{(g)}$  = グループ  $g$  の標本共分散行列

$\Sigma^{(g)}(\gamma)$  = モデルに従った、グループ  $g$  の共分散行列

$\boldsymbol{\mu}^{(g)}(\gamma)$  = モデルに従った、グループ  $g$  の平均ベクトル

$\Sigma_0^{(g)}$  = グループ  $g$  の母集団共分散行列

$\boldsymbol{\mu}_0^{(g)}$  = グループ  $g$  の母集団平均ベクトル

$\mathbf{s}^{(g)} = \text{vec}(\mathbf{S}^{(g)})$  = 単一の列ベクトルに配列された  $p^{*(g)}$  の  $\mathbf{S}^{(g)}$  の異なる要素

$\boldsymbol{\sigma}^{(g)}(\boldsymbol{\gamma}) = \text{vec}(\boldsymbol{\Sigma}^{(g)}(\boldsymbol{\gamma}))$

$r = \text{ChiCorrect}$  方式で指定された負でない整数値。デフォルトでは、 $r = G$  です。Emulisrel6 方式を使用した場合、 $r = G$  であり、ChiCorrect を使用して変更することはできません。

$$n = N - r$$

$\mathbf{a}$  = すべてのグループの標本の積率を含む、 $p$  次のベクトル、すなわち  $\mathbf{a}$  には  $\mathbf{S}^{(1)}, \dots, \mathbf{S}^{(G)}$  の要素と (平均と定数項が明示的なモデルパラメータである場合)  $\bar{\mathbf{x}}^{(1)}, \dots, \bar{\mathbf{x}}^{(G)}$  も含まれます。

$\mathbf{a}_0$  = すべてのグループの母集団の積率を含む、 $p$  次のベクトル、すなわち  $\mathbf{a}_0$  には  $\boldsymbol{\Sigma}_0^{(1)}, \dots, \boldsymbol{\Sigma}_0^{(G)}$  の要素と (平均と定数項が明示的なモデルパラメータである場合)  $\boldsymbol{\mu}_0^{(1)}, \dots, \boldsymbol{\mu}_0^{(G)}$  も含まれます。 $\mathbf{a}(\boldsymbol{\gamma})$  の要素の順序は、 $\mathbf{a}$  の要素の順序と一致している必要があります。

$\mathbf{a}(\boldsymbol{\gamma})$  = モデルに従って、すべてのグループの母集団の積率を含む、 $p$  次のベクトル、すなわち  $\mathbf{a}(\boldsymbol{\gamma})$  には  $\boldsymbol{\Sigma}^{(1)}(\boldsymbol{\gamma}), \dots, \boldsymbol{\Sigma}^{(G)}(\boldsymbol{\gamma})$  の要素と (平均と定数項が明示的なモデルパラメータである場合)  $\boldsymbol{\mu}^{(1)}(\boldsymbol{\gamma}), \dots, \boldsymbol{\mu}^{(G)}(\boldsymbol{\gamma})$  も含まれます。 $\mathbf{a}(\boldsymbol{\gamma})$  の要素の順序は、 $\mathbf{a}$  の要素の順序と一致している必要があります。

$F(\mathbf{a}(\boldsymbol{\gamma}), \mathbf{a})$  = モデルの標本への当てはめで最小化される関数 ( $\mathbf{g}$ ) の)

$\hat{\boldsymbol{\gamma}} = F(\mathbf{a}(\boldsymbol{\gamma}), \mathbf{a})$  を最小化する  $\mathbf{g}$  の値

$$\hat{\boldsymbol{\Sigma}}^{(g)} = \boldsymbol{\Sigma}^{(g)}(\hat{\boldsymbol{\gamma}})$$

$$\hat{\boldsymbol{\mu}}^{(g)} = \boldsymbol{\mu}^{(g)}(\hat{\boldsymbol{\gamma}})$$

$$\hat{\mathbf{a}} = \mathbf{a}(\hat{\boldsymbol{\gamma}})$$

# 乖離度

Amos は次の形式の乖離度 (Browne, 1982, 1984) を最小化します。

(D1)

$$C(\boldsymbol{\alpha}, \mathbf{a}) = [N - r] \left[ \frac{\sum_{g=1}^G N^{(g)} f(\boldsymbol{\mu}^{(g)}, \boldsymbol{\Sigma}^{(g)}; \bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)})}{N} \right] = [N - r] F(\boldsymbol{\alpha}, \mathbf{a})$$

$f$  の定義方法を変更することにより、さまざまな乖離度が得られます。平均と定数項に制約条件がなく、明示的モデルパラメータとして表示されない場合、 $\bar{\mathbf{x}}^{(g)}$  と  $\boldsymbol{\mu}^{(g)}$  は省略され、 $f$  は  $f(\boldsymbol{\Sigma}^{(g)}; \mathbf{S}^{(g)})$  と表されます。

乖離度  $C_{KL}$  と  $F_{KL}$  は、 $f$  を次のようにすることによって得られます。

$$f_{KL}(\boldsymbol{\mu}^{(g)}, \boldsymbol{\Sigma}^{(g)}; \bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)}) = \log |\boldsymbol{\Sigma}^{(g)}| + \text{tr}(\mathbf{S}^{(g)} \boldsymbol{\Sigma}^{(g)-1}) + (\bar{\mathbf{x}}^{(g)} - \boldsymbol{\mu}^{(g)})' \boldsymbol{\Sigma}^{(g)-1} (\bar{\mathbf{x}}^{(g)} - \boldsymbol{\mu}^{(g)})$$

標本サイズにのみ依存する付加定数を除き、 $f_{KL}$  は、Kullback-Leibler の情報量の -2 倍です (Kullback & Leibler, 1951)。厳密に言うと、 $C_{KL}$  と  $F_{KL}$  は、 $F_{KL}(\mathbf{a}, \mathbf{a}) \neq 0$  であるため、Browne の定義によると乖離度とはみなされません。

最尤法推定値 (ML) では、 $C_{ML}$  および  $F_{ML}$  は  $f$  を次のようにすることによって得られます。

(D2)

$$\begin{aligned} f_{ML}(\boldsymbol{\mu}^{(g)}, \boldsymbol{\Sigma}^{(g)}; \bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)}) &= f_{KL}(\boldsymbol{\mu}^{(g)}, \boldsymbol{\Sigma}^{(g)}; \bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)}) - f_{KL}(\bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)}; \bar{\mathbf{x}}^{(g)}, \mathbf{S}^{(g)}) \\ &= \log |\boldsymbol{\Sigma}^{(g)}| + \text{tr}(\mathbf{S}^{(g)} \boldsymbol{\Sigma}^{(g)-1}) - \log |\mathbf{S}^{(g)}| - p^{(g)} + (\bar{\mathbf{x}}^{(g)} - \boldsymbol{\mu}^{(g)})' \boldsymbol{\Sigma}^{(g)-1} (\bar{\mathbf{x}}^{(g)} - \boldsymbol{\mu}^{(g)}) \end{aligned}$$

一般化最小 2 乗法推定値 (GLS) では、 $C_{GLS}$  および  $F_{GLS}$  は  $f$  を次のようにすることによって得られます。

(D3)

$$f_{GLS}(\Sigma^{(g)}; \mathbf{S}^{(g)}) = \frac{1}{2} \text{tr} \left[ \mathbf{S}^{(g)-1} (\mathbf{S}^{(g)} - \Sigma^{(g)}) \right]^2$$

漸近的分布非依存推定値 (ADF) の場合、 $C_{ADF}$  および  $F_{ADF}$  は  $f$  を次のようにすることによって得られます。

(D4)

$$f_{ADF}(\Sigma^{(g)}; \mathbf{S}^{(g)}) = \sum_{g=1}^G \left[ \mathbf{s}^{(g)} - \boldsymbol{\sigma}^{(g)}(\boldsymbol{\gamma}) \right] \mathbf{U}^{(g)-1} \left[ \mathbf{s}^{(g)} - \boldsymbol{\sigma}^{(g)}(\boldsymbol{\gamma}) \right]$$

$\mathbf{U}^{(g)}$  の要素は、Browne (1984, Equations 3.1 - 3.4) によって次のように表されます。

$$\bar{x}_i^{(g)} = \frac{1}{N_g} \sum_{r=1}^{N_g} x_{ir}^{(g)}$$

$$w_{ij}^{(g)} = \frac{1}{N_g} \sum_{r=1}^{N_g} (x_{ir}^{(g)} - \bar{x}_i^{(g)}) (x_{jr}^{(g)} - \bar{x}_j^{(g)})$$

$$w_{ij,kl}^{(g)} = \frac{1}{N_g} \sum_{r=1}^{N_g} (x_{ir}^{(g)} - \bar{x}_i^{(g)}) (x_{jr}^{(g)} - \bar{x}_j^{(g)}) (x_{kr}^{(g)} - \bar{x}_k^{(g)}) (x_{lr}^{(g)} - \bar{x}_l^{(g)})$$

$$[\mathbf{U}^{(g)}]_{ij,kl} = w_{ij,kl}^{(g)} - w_{ij}^{(g)} w_{kl}^{(g)}$$

尺度不変最小 2 乗推定値 (SLS) では、 $C_{SLS}$  および  $F_{SLS}$  は  $f$  を次のようにすることによって得られます。

(D5)

$$f_{SLS}(\Sigma^{(g)}; \mathbf{S}^{(g)}) = \frac{1}{2} \text{tr} \left[ \mathbf{D}^{(g)-1} (\mathbf{S}^{(g)} - \Sigma^{(g)}) \right]^2$$

このとき、 $\mathbf{D}^{(g)} = \text{diag}(\mathbf{S}^{(g)})$  となります。

重み付けのない最小 2 乗法推定値 (ULS) では、 $C_{ULS}$  および  $F_{ULS}$  は  $f$  を次のようにすることによって得られます。



(D6)

$$f_{ULS}(\Sigma^{(g)}; \mathbf{S}^{(g)}) = \frac{1}{2} \text{tr}[\mathbf{S}^{(g)} - \Sigma^{(g)}]^2$$

Amos の Emulsi6 方式は、(D1) を以下で置き換えるのに使用できます。

(D1a)

$$C = \sum_{g=1}^G (N^{(g)} - 1) F^{(g)}$$

$F$  は、 $F = C / (N - G)$  として計算されます。

$G = 1$  かつ  $r = 1$  の場合、(D1) および (D1a) は等しく、次のように表されます。

$$C = (N^{(1)} - 1) F^{(1)} = (N - 1) F$$

最尤法、漸近的分布非依存、および一般化最小 2 乗法推定値では、(D1) および (D2) 共、適切な分布の仮定の下で正しく指定されたモデルに対してカイ 2 乗分布となります。漸近的には、(D1) と (D2) は等価ですが、どちらの式でも、有限標本ではある程度の不一致が見られます。

2 つの独立した標本があり、それぞれに 1 つのモデルを使用するとします。さらに、この 2 つの標本を同時に分析しますが、その場合に、1 つのモデルの任意のパラメータがもう 1 つのモデルのパラメータと等しいことを要求する制約条件を課さないこととします。次に、(D1a) を最小化した場合、両グループの同時分析から得られたパラメータ推定値は、各グループの別々の分析から得られたものと同じになります。

さらに、同時分析から得られた乖離度 (D1a) は、2 つの個別の分析から得られた乖離度の合計になります。 $r$  がゼロ以外の場合、公式 (D1) にはこのプロパティがありません。公式 (D1) を使用して 2 つのグループの同時分析を実行すると、2 つの別々の分析と同じパラメータ推定値が得られますが、同時分析からの乖離度は、個別の乖離度の合計にはなりません。

一方、Amos を使用してモデルを当てはめた単一の標本があるとします。この標本を任意にサイズの異なる 2 つのグループに分割し、それらのグループの同時分析を実行するとします。このとき、両グループの元のモデルを採用し、第 1 グループの各パラメータが第 2 グループの対応するパラメータと等しくなるように制約条件を設定します。両方の分析で (D1) を最小化した場合、両方とも同じ結果が得られます。ただし、両方の分析で (D1a) を使用した場合、2 つの分析では異なる推定値と  $F$  に対する異なる最小値が生成されます。

ここで指摘された不一致はすべて、 $r = 0$  を選択し、(D1) が次のようになるようにして (D1) を使用することによって回避できます。

$$C = \sum_{g=1}^G N^{(g)} F^{(g)} = N F$$



# 適合度

モデル評価は、構造モデリングに関連する、最も難しい未解決な問題の 1 つです。Bollen & Long (1993)、MacCallum (1990)、Mulaik 他 (1989)、および Steiger (1990) は、この問題についてさまざまな見解や推奨案を提唱しています。少なくとも乖離度の値のほかに、多数の統計量がモデルのメリットの測定値として提唱されてきました。Amos はこれらのほとんどの統計量を算出します。

適合度は、ユーザーによって指定された各モデルに対して、また、飽和モデルおよび独立モデルと呼ばれる 2 つの追加のモデルに対して使用されます。

- 飽和モデルでは、母集団の積率に制約条件が設定されません。飽和モデルは、最も一般的なモデルです。あらゆるデータ セットに完全に適合することが保障されているという意味では、空疎なモデルです。すべての Amos モデルは、飽和モデルに制約条件が付けられたものです。
- 独立モデルはこれと正反対の性格を持っています。独立モデルでは、観測変数に相関はないものと仮定されます。平均値が推定または制約されている場合、すべての観測変数の平均値は 0 に固定されます。独立モデルは信じ難いほど厳密に制約されるため、いかなる興味あるデータ セットにもあまり適合しません。

指定した各モデルが、独立モデルに等しくなるように制約される場合が良くあります。この場合、飽和モデルと独立モデルは、2 つの極値であり、提案したモデルはこの間に位置するとみなすことができます。

最尤法以外のすべての推定法の場合、Amos は、すべてのパラメータが 0 に固定されるゼロ モデルの適合度も報告します。

## 儉約性の測度

比較的パラメータの少ない(かつ、比較的自由度の多い)モデルは、儉約性、すなわち単純性が高いと考えられます。パラメータの多い(かつ、自由度の少ない)モデルは、複雑であり、儉約性に欠けていると考えられます。この単純と複雑という言葉の用法は、必ずしも日常の用法には適合していません。たとえば、飽和モデルは複雑であり、線形従属の凝ったパターンを持ち、パラメータ値が高度に制約されているモデルは単純であるということになります。

単純で、儉約性の高いモデルが好ましい(Mulaik 他、1989)という根拠を調べることはできますが、儉約性の高いモデルが複雑なモデルよりも好ましいという点では異論はないように思われます。他がすべて同じであるとすると、パラメータという点では少ない方が好ましいと言えます。同時に、適合性の高いモデルは適合性の低いモデルよりも好ましいものです。多くの適合度は、この相反する 2 つの目的、すなわち単純さと適合度のバランスをとろうとしています。

複雑度と適合度間の数値的に最良の妥協点はある程度個人の好みの問題であるため、最終分析において複雑さの測度と適合度の測度を単一の数値指標に組み合わせる 1 つの最良の方法を定義することは、ある意味では不可能であるとも言えます。モデルの選択は、嗜好についての 2 次元分析における昔からの課題です(Steiger, 1990, p. 179)。

## NPARG

**NPARG** は、推定される異なるパラメータ ( $q$ ) の数です。たとえば、相互に等しいことが求められる 2 つの係数は 1 つのパラメータとして数えられます。

注: 出力パス図にパラメータの数を表示するには、`¥npar` テキスト マクロを使用します。

## DF

**DF** はモデルの検定のための自由度の数です。

$$df = d = p - q$$

$p$  は標本の積率数であり、 $q$  は異なるパラメータの数です。Rigdon (1994a) は、自由度の計算と解釈について詳しく説明しています。

注: 出力パス図に自由度を表示するには、`¥df` テキスト マクロを使用します。

## PRATIO

検約率 (James, Mulaik, および Brett, 1982。Mulaik 他, 1989) は、評価対象のモデルの制約条件の数を、独立モデルの制約条件数の割合として表したものです。

$$\mathbf{PRATIO} = \frac{d}{d_i}$$

ここで、 $d$  は評価されるモデルの自由度を表し、 $d_i$  は独立モデルの自由度を表します。検約率は PNFI および PCFI の計算で使用されます (576 ページの「検約性修正済み測定」を参照)。

注: 出力パス図に検約率を表示するには、`¥pratio` テキスト マクロを使用します。

## 最小標本乖離度

以下の適合度は、乖離度の最小値を基にしています。

## CMIN

**CMIN** は、乖離度  $C$  の最小値、 $\hat{C}$  です (付録 B を参照)。

注: 出力パス図に乖離度  $C$  の最小値  $\hat{C}$  を表示するには、`¥cmin` テキスト マクロを使用します。

## P

**P** は、現在の標本で発生する大きさの乖離度が得られる確率です (適切な分布の仮定の下で、適正に指定されたモデルを想定した場合)。すなわち、**P** は、モデルが完全に母集団に適合しているという仮説を検定するための "p 値" です。

モデルを選択する 1 つの方法では、統計的な仮説の検定を採用して、使用可能なデータと矛盾するモデルを分析から除外します。仮説の検定は広範に受け入れられている手順であり、多くの使用経験があります。ただし、モデル選択手段としては不適切であることが、積率構造の分析の開発において早くから指摘されています (Jöreskog, 1969)。母集団に完全には適合しないほとんどのモデルが有効な近似値であることは、一般的に認められています。言い換えると、完全適合という帰無仮説から始めることは信頼性が低く、最終的には標本の過度の肥大化が許可されていない場合にのみ使用されます。

モデルの当てはめにおいて、仮説の検定の役割についての上記のような見解に抵抗があった場合、次の引用が便利でしょう。最初の 2 つは構造モデリングの開発以前のものです、他のモデル当てはめ問題を指しているのです。

理論とデータの基本的な食い違いを検出する検定の検出力は、主に標本のサイズによって制御されます。標本のサイズが小さい場合、帰無仮説から著しく逸脱している代替仮説でも、有意値の  $\chi^2$  が得られる可能性はわずかながらあります。標本が非常に大きくなると、帰無仮説からの小さな、重要でない逸脱も、ほぼ間違いなく検出されます。(Cochran, 1952)

標本が小さい場合、 $\chi^2$  検定では、データが広範囲の多様な理論から "著しく逸脱していない" ことが示されますが、標本が大きい場合、 $\chi^2$  検定では、差が他の基準では無視できるか取るに足らないほどわずかなものであっても、特定の理論で期待されたデータから著しく逸脱しているという結果が示されます。(Gulliksen & Tukey, 1958, p. 95 ~ 96)

このような "完全に適合する" 仮説は、検定データでの経験作業においては極めて非現実的です。十分に大きなサイズの標本が得られた場合、この  $\chi^2$  統計によれば、間違いなく、このような自明でない仮説は統計的に受け入れ難いものであることが示されます。(Jöreskog, 1969, p. 200)

...非常に大きな標本では、実質的にすべてのモデルが、統計的に受け入れ難いとして棄却すべきであるとみなされる... 実際は、有意でないカイ 2 乗値が望まれ、モデルとデータ間の差がないという仮説の有効性を推定しようとする。このような論理は、各種の統計的な見せかけにおいて、帰無仮説を証明しようとする試みとしてよく知られています。カイ 2 乗分布  $v$  は、標本のサイズを単純に小さくするだけで小さくできるため、この試みは一般的には正当化できません。(Bentler & Bonett, 1980, p. 591)

ここでは、この帰無仮説 (完全適合) は極めて信頼性が乏しいものであり、統計検定で偽であることを検出できたかどうかを把握してもそれほど役に立たないものであるという立場を支持します。(Browne & Mels, 1992, p. 78).

570 ページの「PCLOSE」も参照してください。

注: 出力パス図にこの  $p$  値を表示するには、 $\%p$  テキスト マクロを使用します。

## CMIN/DF

CMIN/DF は、最小乖離度  $\hat{C}$  (付録 B を参照) を自由度で割った値です。

$$\frac{\hat{C}}{d}$$

一部の著者は、この比率を適合度として使用することを提言しています。ULS と SLS 以外のすべての推定基準では、この比率は正しいモデルでは 1 に近くなります。問題は、この比率が 1 からどの程度逸脱した値になれば、モデルが十分でないと結論付けることができるかが明確でないことです。

## 経験則

...Wheaton 他 (1977) は、研究者が相対的なカイ 2 乗 ( $\chi^2/df$ ) も計算するよう勧めました。彼らは、妥当な値として最初約 5 以下の比率を提案しました。ただし、弊社では、2 ~ 1 または 3 ~ 1 の範囲の自由度の比率までの  $\chi^2$  が仮説モデルと標本 データ間で許容可能な適合度であることが示されています。(Bentler & Bonett, 1981, p. 80)

...別の研究者は、2 という低い比率、あるいは 5 という高い比率が妥当な適合を示すとして提唱しています。(Marsh & Hocevar, 1985).

...2.00 より大きい  $\chi^2/df$  比率は、不十分な適合を示すことは明らかようです (Byrne, 1989, p. 55)。

注: 出力パス図に CMIN/DF の数を表示するには、`¥cmindf` テキスト マクロを使用します。

## FMIN

**FMIN** は、乖離度 F の最小値、 $\hat{F}$  です (付録 B を参照)。

注: 出力パス図に乖離度 F の最小値  $\hat{F}$  を表示するには、`¥fmin` テキスト マクロを使用します。

## 母集団の乖離度に基づく測度

Steiger & Lind (1980) は、モデルの妥当性の測度として母集団の乖離度を使用することを提唱しました。母集団の乖離度、 $F_0$  は、モデルを標本の積率ではなく、母集団の積率に当てはめて得られる乖離度の値です。すなわち、次の式のようになります。

$$F_0 = \min_{\gamma} [F(\alpha(\gamma), \alpha_0)]$$

に対して

$$\hat{F} = \min_{\gamma} [F(\alpha(\gamma), \mathbf{a})]$$

Steiger, Shapiro, および Browne (1985) は、一定の条件下では、 $\hat{C} = n\hat{F}$  は、自由度が  $d$  で非心度パラメータが  $\delta = C = nF$  の非心度カイ 2 乗分布になることを示しました。Steiger-Lind のモデル評価の手法は、 $F_0$  および関連する数量の推定を中心に行っています。

ここでは、主に、Steiger & Lind (1980) および Steiger, Shapiro, Browne (1985) を基に行っています。表記法は、Browne & Mels (1992) のものを採用しています。

## NCP

$NCP = \max(\hat{C} - d, 0)$  は非心度パラメータの推定値です。 $\delta = C_0 = nF_0$  .

LO90 および HI 90 というラベルの付いた列には、 $\delta$  の 90% の信頼区間の下限値 ( $\delta_L$ ) と上限値 ( $\delta_U$ ) が含まれています。 $\delta_L$  は、 $\delta$  について次を解くと得られ、

$$\Phi(\hat{C} | \delta, d) = .95$$

$\delta_U$  は、 $\delta$  について次を解くと得られ、

$$\Phi(\hat{C} | \delta, d) = .05$$

$\Phi(x | \delta, d)$  は、非心度パラメータが  $\delta$  で自由度  $d$  の非心度カイ 2 乗分布の分布関数です。

注: パス図に非心度パラメータ推定値を表示するには、`¥ncp` テキスト マクロを使用し、90% 信頼下限値を表示するには `¥ncplo` を使用し、90% 信頼上限値を表示するには `¥ncphi` を使用します。

## F0

$F0 = \hat{F}_0 = \max\left(\frac{\hat{C} - d}{n}, 0\right) = \frac{NCP}{n}$  は  $\frac{\delta}{n} = F_0$  の推定値です。

LO 90 および HI 90 というラベルの付いた列には、 $F_0$  の 90% の信頼区間の下限値と上限値が含まれています。

$$LO\ 90 = \sqrt{\frac{\delta_L}{n}}$$

$$HI\ 90 = \sqrt{\frac{\delta_U}{n}}$$

注: 出力パス図に  $\hat{F}_0$  の値を表示するには、`¥f0` テキスト マクロを使用し、90% の信頼下限推定値を表示するには `¥f0lo` を使用し、90% の信頼上限推定値を表示するには `¥f0hi` を使用します。



## RMSEA

$F_0$  は、モデルの複雑度に対してペナルティを含まず、多数のパラメータを持つモデルが有利になりやすい傾向があります。2つの入れ子モデルを比較した場合、 $F_0$  では単純なモデルの方が有利にはなりません。Steiger & Lind (1980) は、モデルの検定において、 $F_0$  を自由度の数で割ることによって、モデルの複雑度の効果を補正することを提案しています。結果の比率の平方根をとると、母集団の近似誤差平均平方根 (Steiger & Lind) によれば **RMS**、Browne & Cudeck (1993) によれば **RMSEA** が生成されます。

$$\text{population RMSEA} = \sqrt{\frac{F_0}{d}}$$

$$\text{estimated RMSEA} = \sqrt{\frac{\hat{F}_0}{d}}$$

LO 90 および HI 90 というラベルの付いた列には、RMSEA の 90% の信頼区間の下限値と上限値が含まれています。これらの上下限値は、次の式で求められます。

$$\text{LO 90} = \sqrt{\frac{\delta_L/n}{d}}$$

$$\text{HI 90} = \sqrt{\frac{\delta_U/n}{d}}$$

## 経験則

実際の経験から、RMSEA の値が約 0.05 以下であれば、自由度に関してモデルの高い適合性を示しているように思われます。この数字は主観的判断に基づくものです。絶対確実または正確であるとみなすことはできませんが、RMSEA = 0.0 の厳密な適合の要件に比べれば妥当な値です。また、RMSEA が約 0.08 以下の値は妥当な近似誤差を示すものであると考え、RMSEA が 0.1 を超えるモデルは採用しないこととします。(Browne & Cudeck, 1993)

注: 出力パス図に推定近似誤差平均平方根を表示するには、`%rmsea` テキスト マクロを使用し、90% 信頼下限推定値を表示するには `%rmsealo` を使用し、90% 信頼上限推定値を表示するには `%rmseahi` を使用します。

## PCLOSE

PCLOSE =  $1 - \Phi(\hat{C} | .05^2 nd, d)$  は、母集団 RMSEA が 0.05 以下の帰無仮説検定用の p 値です。

$$H_0 : \text{RMSEA} \leq .05$$

これに反して、P 列の p 値 (565 ページの「P」を参照) は、母集団 RMSEA が 0 の仮説の検定用です。

$$H_0 : \text{RMSEA} = 0$$

RMSEA の使用経験に基づき、Browne & Cudeck (1993) は、RMSEA が 0.05 以下の場合には高い適合度を示すことを提唱しています。高適合度のこの定義に従うと、PCLOSE は高適合度の検定となり、P は厳密な適合の検定となります。

注: 出力パス図に母集団 RMSEA の高適合度用の p 値を表示するには、`%pclose` テキスト マクロを使用します。

## 情報理論的測度

Amos は複数の統計量を  $\hat{C} + kq$  または  $\hat{F} + kq$  の形式で報告します。k は正の定数です。これらの各統計量から、適合性 ( $\hat{C}$  または  $\hat{F}$ ) と複雑さ (q) の重み付き合計を求めることによって、両者の合成測度が形成されます。適合性の高い単純なモデルは、このような基準に従うとスコアが低くなります。複雑で、適合性の低いモデルのスコアは高くなります。定数 k は、適合性と複雑さに付加される相対的ペナルティを決定します。

この項で述べる統計量は、モデルの比較のためのものであり、分離モデルの評価のためのものではありません。

これらのすべての統計量は、最尤法推定で使用するために開発されたものです。Amos は GLS および ADF 推定も報告しますが、それらを使用することが適切であるかどうかは不明です。

## AIC

赤池情報量基準 (Akaike, 1973, 1987) は次の式で表されます。

$$\text{AIC} = \hat{C} + 2q$$

572 ページの「ECVI」も参照してください。

注: 出力パス図に赤池情報量基準の値を表示するには、`%aic` テキスト マクロを使用します。

## BCC

Browne-Cudeck (1989) 基準は次の式で表されます。

$$\text{BCC} = \hat{C} + 2q \frac{\sum_{g=1}^G b^{(g)} \frac{p^{(g)}(p^{(g)} + 3)}{N^{(g)} - p^{(g)} - 2}}{\sum_{g=1}^G p^{(g)}(p^{(g)} + 3)}$$

ここで `Emulisrel6` コマンドが使用された場合  $b^{(g)} = N^{(g)} - 1$  であり、使用されなかった場合、 $b^{(g)} = n \frac{N^{(g)}}{N}$  です。

BCC ではモデルの複雑さに対し、AIC よりもわずかに大きなペナルティが課されま  
す。BCC は、特に積率構造分析のために開発された、この項で唯一の測度です。Browne  
と Cudeck は、BCC がより一般的に適用可能な測度に比べて優れていることを示す、  
経験的証拠を提供しました。Arbuckle (準備中) は、BCC の正当性についての代替的根  
拠を示し、複数のグループに対して上記の式を導き出しました。

572 ページの「MECVI」も参照してください。

注: 出力パス図に Browne-Cudeck 基準の値を表示するには、`¥bcc` テキスト マクロを使用  
します。

## BIC

ベイズ情報量基準 (Schwarz, 1978, Raftery, 1993) は、次の式で表されます。

$$\text{BIC} = \hat{C} + q \ln(N^{(1)})$$

AIC、BCC、および CAIC に比べて、BIC はモデルの複雑さに大きなペナルティを与  
えるため、倏約性の高いモデルを採用する傾向が強くなります。BIC は、平均と定数  
項が明示的なモデル パラメータでない単一のグループの場合にのみ報告されます。

注: 出力パス図にベイズ情報量基準の値を表示するには、`¥bic` テキスト マクロを使用  
します。

## CAIC

Bozdogan (1987) の CAIC (consistent AIC) は次の式で表されます。

$$\text{CAIC} = \hat{C} + q(\ln N^{(1)} + 1)$$

CAIC はモデルの複雑さに AIC や BCC よりも大きなペナルティを課しますが、BIC ほ  
ど大きくはありません。CAIC は、平均と定数項が明示的なモデル パラメータでない  
単一のグループの場合にのみ報告されます。

注: 出力パス図に一致 AIC 統計量の値を表示するには、¥caic テキスト マクロを使用します。

## ECVI

一貫した目盛りの単位以外、ECVI は AIC と同じです。

$$\text{ECVI} = \frac{1}{n}(\text{AIC}) = \hat{F} + \frac{2q}{n}$$

LO 90 および HI 90 というラベルの付いた列には、ECVI の 90% の信頼区間の下限値と上限値が含まれています。

$$\text{LO 90} = \frac{\delta_L + d + 2q}{n}$$

$$\text{HI 90} = \frac{\delta_U + d + 2q}{n}$$

570 ページの「AIC」も参照してください。

注: 出力パス図に期待交差確認指標の値を表示するには、¥ecvi テキスト マクロを使用し、90% 信頼下限期待値を表示するには ¥ecvilo を使用し、90% 信頼上限期待値を表示するには ¥ecvihi を使用します。

## MECVI

スケール因子以外、MECVI は BCC と同じです。

$$\text{MECVI} = \frac{1}{n}(\text{BCC}) = \hat{F} + 2q \frac{\sum_{g=1}^G a^{(g)} \frac{p^{(g)}(p^{(g)} + 3)}{N^{(g)} - p^{(g)} - 2}}{\sum_{g=1}^G p^{(g)}(p^{(g)} + 3)}$$

ここで Emulisrel6 コマンドが使用された場合、 $a^{(g)} = \frac{N^{(g)} - 1}{N - G}$  であり、使用されなかった場合、 $a^{(g)} = \frac{N^{(g)}}{N}$  です。

571 ページの「BCC」も参照してください。

注: 出力パス図に変更された ECVI 統計量を表示するには、¥mecvi テキスト マクロを使用します。

## ベースライン モデルとの比較

いくつかの適合度では、どれほどモデルが適合していても、事態は常に悪化する可能性があるという事実について熟考を促されます。

Bentler と Bonett (1980) および Tucker と Lewis (1973) は、独立モデルまたはその他の非常に適合性の低いベースライン モデルの適合を、乖離度がどれほど大きくなるかを調べる課題として提案しました。この課題の目的は、独自のモデルの適合性に何らかの見通しを持たせることです。どのモデルもうまく適合しない場合、真に不良なモデルを確認することは勇気付けられることです。たとえば、次の出力が示しているように、例 6 のモデル A は自由度に関して大きな乖離度 ( $\hat{C} = 71.544$ ) を持っています。これに反して、71.544 は 2131.790 (独立モデルの乖離度) と比べるとそれほど悪くないように見えます。

モデル	NPAR	CMIN	DF	P	CMIN/DF
モデル A: 自己相関なし	15	71.544	6	0.000	11.924
モデル B: 最も一般的	16	6.383	5	0.271	1.277
モデル C: 時間不変	13	7.501	8	0.484	0.938
モデル D: A と C の合成	12	73.077	9	0.000	8.120
飽和モデル	21	0.000	0		
独立モデル	6	2131.790	15	0.000	142.119

この、モデル評価における「状況はさらに悪化する可能性がある」という原理は、多数の適合度に組み入れられています。すべての測度は 0 ~ 1 の範囲になる傾向があり、1 に近い値は適合度が高いことを示します。NFI (下記) のみが、0 ~ 1 の範囲になることが保証されており、1 は完全な適合を示します。(1 より大きい値も 1 として報告され、0 未満の値も 0 として報告されるため、CFI も 0 ~ 1 の範囲になることが保証されています。)

独立モデルは最も多く使用され、Amos でも使用していますが、ベースラインモデルとして選択できるモデルの唯一の例です。Sobel と Bohrnstedt (1985) は、ベースラインモデルとして独立モデルを選択することは、不適切な場合が多いと主張しています。彼らは代替案を提案し、Bentler と Bonett (1980) が行ったように、いくつかの例を挙げてベースラインモデルの選択に対する NFI の感度を示しました。

## NFI

Bentler-Bonett (1980) 標準適合指標 (NFI) または Bollen (1989b) の表記法では  $\Delta_1$  は、次のように表されます。

$$NFI = \Delta_1 = 1 - \frac{\hat{C}}{\hat{C}_b} = 1 - \frac{\hat{F}}{\hat{F}_b}$$

ここで  $\hat{C} = n\hat{F}$  は、評価されるモデルの最小乖離度であり、 $\hat{C}_b = n\hat{F}_b$  はベースラインモデルの最小乖離度です。

例 6 では、他の任意のモデルに制約条件を付加することによって、独立モデルが得られます。すべてのモデルは、飽和モデルに制約を設けることによって得られます。たとえば、モデル A は、 $\chi^2 = 71.544$  であり、完全に適合する飽和モデル ( $\chi^2 = 0$ ) と独立モデル ( $\chi^2 = 2131.790$ ) との明らかに中間に位置します。

モデル	NPAR	CMIN	DF	P	CMIN/DF
モデル A: 自己相関なし	15	71.544	6	0.000	11.924
モデル B: 最も一般的	16	6.383	5	0.271	1.277
モデル C: 時間不変	13	7.501	8	0.484	0.938
モデル D: A と C の合成	12	73.077	9	0.000	8.120
飽和モデル	21	0.000	0		
独立モデル	6	2131.790	15	0.000	142.119

このように見ると、モデル A の適合度は、独立モデルの適合度よりも飽和モデルの適合度に近いと言えます。事実、モデル A の乖離度は、(適合度の低い) 独立モデルと (完全に適合する) 飽和モデルとの間の 96.6% であることがわかります。

$$\text{NFI} = \frac{2131.790 - 71.54}{2131.790} = 1 - \frac{71.54}{2131.790} = .966$$

### 経験則

適合度の目盛りは必ずしも解釈が容易ではない (指標が重相関の 2 乗ではない) ため、結果のさまざまな度合いの優位性に関連付けられる指標の値を定義するには、経験が必要です。弊社の経験では、全体の適合指標が 0.9 未満のモデルは、通常、実質的に改善されます。これらの指標や先に説明した一般的な階層的比較については、例を挙げることによってよく理解されます。(Bentler & Bonett, 1980, p. 600、NFI と TLI の両方を参照)

注: 出力パス図に標準適合指標の値を表示するには、`%nfi` テキスト マクロを使用します。

### RFI

Bollen (1986) の相対適合指標 (RFI) は次の式で表されます。

$$\text{RFI} = \rho_1 = 1 - \frac{\hat{C}/d}{\hat{C}_b/d_b} = 1 - \frac{\hat{F}/d}{\hat{F}_b/d_b}$$

ここで  $\hat{C}$  と  $d$  は評価されるモデルの自由度であり、 $\hat{C}_b$  および  $d_b$  は、ベースラインモデルの乖離度と自由度です。

RFI は、F の代わりに  $F/d$  を置き換えることによって、NFI から得られます。1 に近い RFI 値は、適合度が非常に高いことを示しています。

注: 出力パス図に相対適合指標を表示するには、`%rfi` テキスト マクロを使用します。

## IFI

Bollen (1989b) の増分適合指標 (IFI) は次の式で表されます。

$$\text{IFI} = \Delta_2 = \frac{\hat{C}_b - \hat{C}}{\hat{C}_b - d}$$

ここで  $\hat{C}$  および  $d$  は評価されるモデルの乖離度と自由度であり、 $\hat{C}_b$  および  $d_b$  は、ベースラインモデルの乖離度と自由度です。1 に近い IFI 値は、適合度が非常に高いことを示しています。

注: 出力パス図に増分適合指標を表示するには、`%ifi` テキスト マクロを使用します。

## TLI

Tucker-Lewis 係数 (Bollen, 1989b の表記法では  $\rho_2$ ) については、Bentler と Bonett (1980) によって積率の構造の分析の文脈で解説されており、Bentler-Bonett 非標準適合指標 (NNFI) とも呼ばれます。

$$\text{TLI} = \rho_2 = \frac{\frac{\hat{C}_b}{d_b} - \frac{\hat{C}}{d}}{\frac{\hat{C}_b}{d_b} - 1}$$

TLI の一般的な範囲は 0 ~ 1 の間ですが、この範囲には限定されません。1 に近い TLI 値は、適合度が非常に高いことを示しています。

注: 出力パス図に Tucker-Lewis 指標の値を表示するには、`%li` テキスト マクロを使用します。

## CFI

比較適合指標 (CFI, Bentler, 1990) は次の式で表されます。

$$\text{CFI} = 1 - \frac{\max(\hat{C} - d, 0)}{\max(\hat{C}_b - d_b, 0)} = 1 - \frac{\text{NCP}}{\text{NCP}_b}$$

ここで  $\hat{C}$ 、 $d$  および NCP は評価されるモデルの乖離度、自由度および非心度パラメータ推定値であり、 $\hat{C}_b$ 、 $d_b$  および  $\text{NCP}_b$  は、ベースラインモデルの乖離度と自由度、および非心度パラメータ推定値です。

CFI は 0 ~ 1 の範囲に収まるように切り捨てられる点以外、CFI は McDonald と Marsh (1990) の相対非心度指標 (RNI) と同じです。

$$\text{RNI} = 1 - \frac{\hat{C} - d}{\hat{C}_b - d_b}$$

1 に近い CFI 値は、適合度が非常に高いことを示しています。

注: 出力パス図に相対適合指標の値を表示するには、 $\forall$ cfi テキスト マクロを使用します。

## 儉約性修正済み測度

James 他 (1982) は、評価対象のモデルとベースライン モデルの両方の検定において自由度の数が考慮されるように、NFI に儉約性指標 をかけることを提唱しました。Mulaik 他 (1989) は、GFI にも同じ修正を適用することを提案しました。Amos でも、CFI に儉約性修正を適用しています。

578 ページの「PGFI」も参照してください。

### PNFI

PNFI は、James 他 (1982) の儉約性修正を NFI に適用した結果です。

$$\text{PNFI} = (\text{NFI})(\text{PRATIO}) = \text{NFI} \frac{d}{d_b}$$

ここで  $d$  は評価されるモデルの自由度です。  $d_b$  はベースライン モデルの自由度です。

注: 出力パス図に儉約性標準適合指標の値を表示するには、 $\forall$ pnfi テキスト マクロを使用します。

### PCFI

PCFI は、James 他 (1982) の儉約性修正を CFI に適用した結果です。

$$\text{PCFI} = (\text{CFI})(\text{PRATIO}) = \text{CFI} \frac{d}{d_b}$$

ここで  $d$  は評価されるモデルの自由度です。  $d_b$  はベースライン モデルの自由度です。

注: 出力パス図に儉約性比較適合指標の値を表示するには、 $\forall$ pcfi テキスト マクロを使用します。



## GFI および関連測度

ここでは、GFI と関連測度について説明します。

### GFI

**GFI** (適合度指標) は、ML および ULS 推定のために Jöreskog と Sörbom (1984) によって考案され、Tanaka and Huba (1985) によって他の推定基準に一般化されました。

GFI は次の式で表されます。

$$\text{GFI} = 1 - \frac{\hat{F}}{\hat{F}_b}$$

ここで  $\hat{F}$  は、付録 B に定義されている最小乖離度であり、 $\hat{F}_b$  は  $\Sigma^{(g)} = \mathbf{0}$ ,  $g=1, 2, \dots, G$  で F を評価すると得られます。(D2) は付録 B では  $\Sigma^{(g)} = \mathbf{0}$  について定義されていないため、最尤法推定値について例外を設ける必要があります。最尤法推定値の場合の GFI を計算するため、付録 B の  $f(\Sigma^{(g)}; \mathbf{S}^{(g)})$  は  $\mathbf{K}^{(g)} = \Sigma^{(g)}(\hat{\gamma}_{ML})$  で次のように計算されます。

$$f(\Sigma^{(g)}; \mathbf{S}^{(g)}) = \frac{1}{2} \text{tr} \left[ \mathbf{K}^{(g)-1} (\mathbf{S}^{(g)} - \Sigma^{(g)}) \right]^2$$

ここで、 $\hat{\gamma}_{ML}$  は  $\gamma$  の最尤法推定値です。GFI は常に 1 未満です。GFI = 1 は完全な適合を示します。

注: 出力パス図に適合度指標の値を表示するには、`%gfi` テキスト マクロを使用します。

### AGFI

**AGFI** (修正済み適合度指標) は、モデルの検定で使用可能な自由度を考慮します。次の式で表されます。

$$\text{AGFI} = 1 - (1 - \text{GFI}) \frac{d_b}{d}$$

ここで

$$d_b = \sum_{g=1}^G p^{*(g)}$$

AGFI の上限値は 1 で、この場合完全な適合を示します。ただし、GFI のように下限値は 0 ではありません。

注: 出力パス図に修正済み GFI の値を表示するには、`%agfi` テキスト マクロを使用します。

## PGFI

Mulaik 他 (1989) によって提唱された **PGFI** (倏約性適合度指標) は、モデルの検定で使用可能な自由度を考慮して **GFI** を修正したものです。

$$\text{PGFI} = \text{GFI} \frac{d}{d_b}$$

$d$  は評価されるモデルの自由度であり、

$$d_b = \sum_{g=1}^G p^{*(g)}$$

はベースライン ゼロ モデルの自由度です。

注: 出力パス図に倏約性 **GFI** の値を表示するには、`¥pgfi` テキスト マクロを使用します。

## その他の測度

その他の適合測度について説明します。

## HI 90

Amos は、複数の統計量の母集団の値に対して **90%** 信頼区間を報告します。上限値と下限値は、**HI 90** および **LO 90** というラベルの列で表されます。

## HOELTER

Hoelter (1983) のクリティカル  $N$  は、モデルが正しいという仮説を受け入れるための最大標本サイズです。Hoelter は、クリティカル  $N$  を決定するために使用する有意水準を指定していませんが、彼の例では **0.05** を使用しています。Amos は、**0.05** および **0.01** の有意水準に対してクリティカル  $N$  を報告します。

例 6 の各モデルについて Amos によって表示されるクリティカル  $N$  を示します。

モデル	HOELTER 0.05	HOELTER 0.01
モデル A: 自己相関なし	164	219
モデル B: 最も一般的	1615	2201
モデル C: 時間不変	1925	2494
モデル D: A と C の合成	216	277
独立モデル	11	14

たとえば、モデル A は、標本の積率が Wheaton の研究で検出されたのとまったく同じで標本サイズが 164 であれば、0.05 レベルで使用されたはずですが、標本サイズが 165 の場合、モデル A は棄却されたこととなります。Hoelter は、200 以上のクリティカル N は十分な適合度を示すと主張しています。複数のグループの分析において、Hoelter はグループ数の 200 倍のしきい値を提唱しています。おそらく、このしきい値は 0.05 の有意水準と共に使用される値です。この標準では、例 6 のモデル A と独立モデルは除外されます。Hoelter の基準によれば、モデル B は満足のいくものです。私自身は、Hoelter による 200 の標準の主張の正当性は確信していません。残念ながら、クリティカル N をモデルの選択に実際に役立つには、このような標準が必要です。Bollen と Liang (1988) は、クリティカル N の統計量に関する研究を報告しています。

注：出力パス図に Hoelter のクリティカル N を表示するには、 $\alpha = 0.05$  については `¥five` テキスト マクロを使用し、 $\alpha = 0.01$  については `¥hone` を使用します。

## LO 90

Amos は、複数の統計量の母集団の値に対して 90% 信頼区間を報告します。上限値と下限値は、HI 90 および LO 90 というラベルの列で表されます。

## RMR

**RMR** (残差平均平方根) は、平均平方量の平方根であり、この値だけ、標本分散および共分散は、モデルが正しいという仮定の下に得られた推定値から相違しています。

$$\text{RMR} = \sqrt{\frac{\sum_{g=1}^G \left\{ \sum_{i=1}^{p_g} \sum_{j=1}^{j \leq i} \left( \hat{s}_{ij}^{(g)} - \sigma_{ij}^{(g)} \right)^2 \right\}}{\sum_{g=1}^G p_g^*}}}$$

RMR が小さければ小さいほど、適合度は高くなります。RMR が 0 の場合は、完全な適合度を示します。

例 6 からの以下の出力は、RMR によると、飽和モデルを除けばモデル A が検討対象のモデルの中で最適であることを示しています。

モデル	RMR	GFI	AGFI	PGFI
モデル A: 自己相関なし	0.284	0.975	0.913	0.279
モデル B: 最も一般的	0.757	0.998	0.990	0.238
モデル C: 時間不変	0.749	0.997	0.993	0.380
モデル D: A と C の合成	0.263	0.975	0.941	0.418
飽和モデル	0.000	1.000		
独立モデル	12.342	0.494	0.292	0.353

注：出力パス図に残差平均平方根の値を表示するには、`¥rmr` テキスト マクロを使用します。

## 選択された適合度のリスト

少数の適合度に集中する場合、以下の適合度のみを選出して報告した Browne と Mels (1992) の暗黙の推奨を検討してみてください。

565 ページの「CMIN」

565 ページの「P」

567 ページの「FMIN」

568 ページの「F0」、90% 信頼区間

570 ページの「PCLOSE」

569 ページの「RMSEA」、90% 信頼区間

572 ページの「ECVI」、90% 信頼区間 (570 ページの「AIC」) も参照)

最尤法推定の場合、Browne と Cudeck (1989, 1993) が ECVI に代えて MECVI (572 ページ) を提唱しています。

## 非識別可能性の数値診断

パラメータを識別するのか、あるいはモデル全体を識別するのかを判定するために、Amos では近似二次導関数の行列および関連する行列の順位を調べます。使用される手法は、McDonald & Krane (1977) の手法に似ています。この方法には原理的な難点もあります (Bentler & Weeks, 1980; McDonald, 1982)。また、境界線上にある行列の順位の判定には実務的な問題もあります。こうした困難のため、可能であれば、事前にモデルの識別可能性を判定しておく必要があります。複雑なモデルでは、事前判定が不可能であるため、Amos の数値判定に依存する必要があります。幸いなことに、Amos は現実の識別可能性の評価に大変優れています。



## 適合度を使用したモデルの順位付け

一般的に、選択肢が多過ぎるため、1つの適合度を選択することは困難です。適合度の目的が、絶対的な標準によってモデルの長所を判定するのではなく、モデルを相互に比較することである場合には、選択が容易になります。たとえば、モデルの集合のランク順を決める場合は、RMSEA、RFI、またはTLIのどれを使用しても問題はないことが分かります。これらの各測度は、 $\hat{C}$  および  $\hat{C}/d$  のみによる  $d$  に依存しており、それぞれ単調に  $\hat{C}/d$  に依存しています。したがって、各測度によるモデルのランク順は同じになります。このため、探索的モデル特定化手順では、RMSEAのみが報告されます。

$$\text{RMSEA} = \sqrt{\frac{\hat{C}-d}{nd}} = \sqrt{\frac{1}{n}\left(\frac{\hat{C}}{d}-1\right)}$$

$$\text{RFI} = \rho_1 = 1 - \frac{\hat{C}/d}{\hat{C}_b/d_b}$$

$$\text{TLI} = \rho_2 = \frac{\frac{\hat{C}_b}{d_b} - \frac{\hat{C}}{d}}{\frac{\hat{C}_b}{d_b} - 1}$$

次の適合度は、 $\hat{C}$  および  $\hat{C}-d$  のみによる  $d$  に依存しており、単調に  $\hat{C}-d$  に依存しています。探索的モデル特定化手順では、すべての代表としてCFIのみが報告されます。

$$\text{NCP} = \max(\hat{C} - d, 0)$$

$$\text{FO} = \hat{F}_0 = \max\left(\frac{\hat{C} - d}{n}, 0\right)$$

$$\text{CFI} = 1 - \frac{\max(\hat{C} - d, 0)}{\max(\hat{C}_b - d_b, \hat{C} - d, 0)}$$

$$\text{RNI} = 1 - \frac{\hat{C} - d}{\hat{C}_b - d_b} \quad (\text{Amos では報告されない})$$

次の適合度は、単調に  $\hat{C}$  に依存しており、 $d$  には全く依存していません。探索的モデル特定化手順では、すべての代表として  $\hat{C}$  が報告されます。

$$\text{CMIN} = \hat{C}$$

$$\text{FMIN} = \frac{\hat{C}}{n}$$

$$\text{NFI} = 1 - \frac{\hat{C}}{\hat{C}_b}$$

次の各適合度は  $\hat{C}$  と  $d$  の重み付け合計であり、モデルのランク順を生成できます。探索的モデル特定化手順では、CAIC 以外の各適合度が報告されます。

BCC

AIC

BIC

CAIC



次の各適合度は、独自のモデルのランク順を提供します。ランク順はベースライン モデルの選択にも依存しています。探索的モデル特定化手順では、これらの測度は報告されません。

IFI =  $\Delta_2$

PNFI

PCFI

次の適合度は、最尤法の推定の場合に Amos によって報告される、 $\hat{C}$  および  $d$  の関数ではない速度です。探索的モデル特定化手順では、これらの測度は報告されません。

GFI

AGFI

PGFI



## 記述適合度のベースライン モデル

7つの適合度 (NFI、RFI、IFI、TLI、CFI、PNFI、およびPCFI) では、他のモデルと比較するための、帰無 または ベースライン 不良モデルが必要です。探索的モデル特定化手順では、4つの帰無モデルまたはベースライン モデルから選択できます。

**帰無モデル 1:** 観測変数間に相関がないことが必要です。観測変数の平均値と分散は制約されません。これは、探索的モデル特定化を実行しない、通常の Amos 分析における独立モデルです。


**帰無モデル 2:** 観測変数間の相関度が等しいことが必要です。観測変数の平均値と分散は制約されません。

**帰無モデル 3:** 観測変数間に相関がなく、平均値が 0 であることが必要です。観測変数の分散は制約されません。これは、平均値と定数項が明示的なモデル パラメータである、Amos 4.0.1 以前で使用されるベースライン独立モデルです。

**帰無モデル 4:** 観測変数間の相関度が等しいことが必要です。観測変数の分散は制約されません。平均値は 0 であることが必要です。

各帰無モデルは、NFI、RFI、IFI、TLI、CFI、PNFI、PCFI に対して異なる値を生成します。帰無モデル 3 と帰無モデル 4 は、平均値と定数項が指定したモデルで明示的に推定されない場合にのみ、探索的モデル特定化で当てはめられます。帰無モデル 3 と帰無モデル 4 は、平均値と定数項が制約されるモデルの評価に適していると言えます。平均値と定数項は制約されないが、欠損データによる最尤法を許可するためだけに推定されるような一般的な状況で、帰無モデル 3 と帰無モデル 4 を当てはめる理由はほとんどありません。

探索的モデル特定化で当てはめるベースライン モデルを指定するには

- ▶ メニューから [分析] → [探索的モデル特定化] の順に選択します。
  - ▶ [探索的モデル特定化] ツールバーの [オプション] ボタン  をクリックします。
  - ▶ [オプション] ダイアログ ボックスで、[次を検索] タブをクリックします。
- 4 つの帰無モデルと飽和モデルが、[ベンチマーク モデル] グループに表示されます。

# AIC、BCC、および BIC の再調整

適合度 AIC、BCC、および BIC は、付録 C に定義されています。各測度の形式は  $\hat{C} + kq$  で、 $k$  はすべてのモデルで同じ値になります。小さい値の方が優れており、データへの高い適合度 (小さい  $\hat{C}$ ) と儉約性 (小さい  $q$ ) の組み合わせを示しています。測度は単一のモデルの長所を判定するためではなく、モデルの相互比較のために使用されます。

Amos の探索的モデル特定化手順では、これらの測度の 3 通りの再調整方法が用意されており、例 22 および 例 23 に示されています。この付録では、再調整された適合度の公式を示します。

以下では、 $AIC^{(i)}$ 、 $BCC^{(i)}$ 、および  $BIC^{(i)}$  をモデル  $i$  の適合度とします。

## ゼロ ベースの再調整

AIC、BCC、および BIC は、モデルの相互比較のみに使用され、小さい値の方が大きい値よりも優れているため、以下のように定数を追加しても弊害はありません。

$$AIC_0^{(i)} = AIC^{(i)} - \min_j [AIC^{(j)}]$$

$$BCC_0^{(i)} = BCC^{(i)} - \min_j [BCC^{(j)}]$$

$$BIC_0^{(i)} = BIC^{(i)} - \min_j [BIC^{(j)}]$$

再調整された値は 0 または正の値です。たとえば、AIC に従った場合の最適なモデルでは  $AIC_0 = 0$  となり、これより劣るモデルでは、最適なモデルよりどれだけ劣るかを示す、正の  $AIC_0$  値が生成されます。

- ▶ 探索的モデル特定化後に  $AIC_0$ 、 $BCC_0$ 、および  $BIC_0$  を表示するには、[探索的モデル特定化] バーで  をクリックします。
- ▶ [オプション] ダイアログボックスの [結果] タブで、[ゼロベース (min=0)] をクリックします。

## 赤池ウェイト / Bayes 因子 (合計 = 1)

- ▶ 以下の再調整を得るには、[オプション] ダイアログボックスの [結果] タブで、[赤池ウェイト / Bayes 因子 (合計 = 1)] をクリックします。

$$AIC_p^{(i)} = \frac{e^{-AIC^{(i)}/2}}{\sum_m e^{-AIC^{(m)}/2}}$$

$$BCC_p^{(i)} = \frac{e^{-BCC^{(i)}/2}}{\sum_m e^{-BCC^{(m)}/2}}$$

$$BIC_p^{(i)} = \frac{e^{-BIC^{(i)}/2}}{\sum_m e^{-BIC^{(m)}/2}}$$

各再調整された測度の合計は、モデル全体で 1 になります。再調整は、包括的な探索的モデル特定化の後にのみ実行されます。発見的探索を実行するか、[最善の\_\_モデルのみを保存] に正の値を指定した場合、分母での総和は計算されず、再調整も実行されません。 $AIC_p^{(i)}$  は、Burnham & Anderson (1998) によって赤池ウェイトと名付けられました。 $BCC_p^{(i)}$  は  $AIC_p^{(i)}$  と同じに解釈されます。ベイジアン法フレームワーク内およびモデルに対して同記事前確率を指定した適切な仮定の下では、 $BIC_p^{(i)}$  は事後確率の近似値となります。

## 赤池ウェイト / Bayes 因子 (max = 1)

- ▶ 以下の再調整を得るには、[オプション] ダイアログ ボックスの [結果] タブで、[赤池ウェイト / Bayes 因子 (max = 1)] をクリックします。

$$AIC_L^{(i)} = \frac{e^{-AIC^{(i)}/2}}{\max_m [e^{-AIC^{(m)}/2}]}$$

$$BCC_L^{(i)} = \frac{e^{-BCC^{(i)}/2}}{\max_m [e^{-BCC^{(m)}/2}]}$$

$$BIC_L^{(i)} = \frac{e^{-BIC^{(i)}/2}}{\max_m [e^{-BIC^{(m)}/2}]}$$

たとえば、AIC に従った場合の最適なモデルでは  $AIC_L = 1$  となり、これより劣るモデルでは、0 ~ 1 の  $AIC_L$  値が生成されます。 $AIC_L$  の詳細については、Burnham & Anderson (1998) を、また、 $BIC_L$  の詳細については、Raftery (1993, 1995) および Madigan & Raftery (1994) を参照してください。





本書は米国 IBM が提供する製品およびサービスについて作成したものです。この資料の他の言語版を IBM から入手できる場合があります。ただし、これを入手するには、本製品または当該言語版製品を所有している必要がある場合があります。

本書に記載された製品、サービス、または機能は、他の国で提供されていない場合があります。お客様のお住まいの地域で現在提供されている製品およびサービスに関する情報は、現地の IBM カスタマーサービスにお問い合わせください。IBM 製品、プログラム、またはサービスを言及している場合、それらの IBM 製品、プログラムまたはサービスのみが使用されていることを陳述または暗示してはなりません。IBM の知的財産権を侵害しない、機能的に同等の製品、プログラム、またはサービスが代わりに使用されている場合があります。ただし、IBM 以外の製品、プログラム、またはサービスの機能の評価や検証は、ユーザーの責任にゆだねられます。

IBM は、本書に記述された内容について、特許を有しているか、申請中である場合があります。本書を提供することによって、これらの特許の使用権が認められるわけではありません。使用権については、以下にお問い合わせください。

IBM Director of Licensing  
IBM Corporation  
North Castle Drive, MD-NC119  
Armonk, NY 10504-1785  
US

2バイト文字（DBCS）で記載されている事項のライセンスに関するお問い合わせは、お客様が所在する国の IBM 知的財産部門、または下記宛先に書面でお送りください。

知的財産権ライセンス係

法務および知的財産法

〒103-8510

日本国東京都中央区日本橋箱崎町19番21号

日本アイ・ビー・エム株式会社

INTERNATIONAL BUSINESS MACHINES CORPORATION は、本書を、第三者の権利を侵害していないこと、市販性、または特定目的との適合性を含む(ただしこれらに限定されない)明示または暗示の保証をすることなく、「現状のまま」提供するとします。一部の国は、特定の取引における明示的または暗示的な保証の放棄を認めていないため、上述の文言がお客様に適用されない場合があります。

この情報には、技術的に不正確な情報または誤字や誤植が含まれることがあります。ここに示される情報は定期的に変更されていますが、これらの変更は本書の改訂版で適用されます。IBM は、予告なくいつでも、本書に記載の製品やプログラムに機能改善や機能変更を提供する場合があります。

本書中の IBM 以外の Web サイトに対する参照は、便宜上の目的でのみ参照されており、いかなる意味でもこれらの Web サイトを推奨するものではありません。これらの Web サイトで提供されている資料は本 IBM 製品のための資料ではなく、お客様の自己責任の下、これらの Web サイトをご利用ください。

IBM は、お客様への義務を発することなく、IBM が適切であると判断した方法で、お客様からの情報を使用または配布する場合があります。

本プログラムの使用許諾ライセンス取得者のうち、(i) 独立して作成されたプログラムと他のプログラム(本プログラムを含む)の間の情報の交換、および(ii) 交換された情報の相互使用を行う目的で、使用許諾ライセンスに関する情報を必要とするお客様は、以下にお問い合わせください。

IBM Director of Licensing

IBM Corporation

North Castle Drive, MD-NC119

Armonk, NY 10504-1785

US

そのような情報は、該当する諸条件の下、一部のケースでは有償によって、提供できる場合があります。

本書に記載された使用許諾ライセンス取得のプログラム、およびそれに提供されるすべての使用許諾ライセンス取得の資料は、IBM Customer Agreement、IBM International Program License Agreement、またはお客様と当社の間で締結する同等のすべての契約によって提供されます。

IBM 以外の製品に関する情報は、それらの製品の提供者、提供者の公開告示、または他の一般提供情報より取得されています。IBM は、それらの製品を検証してないため、IBM 以外の製品に関するパフォーマンス、互換性、または他の主張を裏付けることはできません。IBM 以外の製品の機能に関するご質問は、それらの製品の提供者にお問い合わせください。

IBMの将来の方向性または意向に関する記述は、単に目標や目的を示しているものであり、予告なしに変更または撤回される場合があります。

この情報には、日常の取引で使用されるデータやレポートの例が含まれます。これらを可能な限り完全に説明するために、例には個人、会社、ブランド、および製品の名前が含まれます。これらの名前はすべて架空のものであり、名前や名称が類似する個人や企業が実在しているとしても、それは偶然にすぎません。

著作権使用許諾：

本書には、様々なオペレーティング・プラットフォームでのプログラミング手法を例示するサンプル・アプリケーション・プログラムがソース言語で掲載されています。お客様は、サンプル・プログラムが書かれているオペレーティング・プラットフォームのアプリケーション・プログラミング・インターフェースに準拠したアプリケーション・プログラムの開発、使用、販売、配布を目的として、いかなる形式においても、IBMに対価を支払うことなくこれらのサンプル・プログラムを複製し、改変し、配布することができます。これらのサンプル・プログラムは、あらゆる条件下における完全なテストを経ていません。従ってIBMは、これらのサンプル・プログラムについて信頼性、利便性または機能性があることをほのめかしたり、保証したりすることはできません。これらのサンプル・プログラムは「現状有姿」の状態を提供されるものであり、いかなる保証も提供されません。IBMは、お客様の当該サンプル・プログラムの使用から生ずるいかなる損害に対しても一切の責任を負いません。

これらのサンプル・プログラムの各複製物もしくはすべての部分または二次的著作物にも、次のように著作権表示を入れていただく必要があります。

© Copyright IBM Corp. 2021. このコードの一部は、IBM Corp.のサンプル・プログラムから取られています。

© Copyright IBM Corp. 1989 - 2021. All rights reserved.



---

# 参考文献

- Akaike, H. 1973. Information theory and an extension of the maximum likelihood principle. Proceedings of the 2nd International Symposium on Information Theory, B. N. Petrov and F. Csaki, eds. Budapest: Akademiai Kiado. 267–281 より。
- \_\_\_\_\_. 1978. A Bayesian analysis of the minimum AIC procedure. *Annals of the Institute of Statistical Mathematics*, 30: 9–14.
- \_\_\_\_\_. 1987. Factor analysis and AIC. *Psychometrika*, 52: 317–332.
- Allison, P. D. 2002. *Missing data*. Thousand Oaks, CA: Sage Publications.
- Anderson, E. 1935. The irises of the Gaspe Peninsula. *Bulletin of the American Iris Society*, 59: 2–5.
- Anderson, T. W. 1957. Maximum likelihood estimates for a multivariate normal distribution when some observations are missing. *Journal of the American Statistical Association*, 52: 200–203.
- \_\_\_\_\_. 1984. *An introduction to multivariate statistical analysis*. New York: John Wiley and Sons.
- Arbuckle, J. L. Unpublished, 1991. Bootstrapping and model selection for analysis of moment structures.
- \_\_\_\_\_. 1994a. Advantages of model-based analysis of missing data over pairwise deletion. RMD Conference on Causal Modeling (West Lafayette, IN) において発表。
- \_\_\_\_\_. 1994b. A permutation test for analysis of covariance structures. Psychometric Society, University of Illinois, Champaign, IL の年次総会において発表。
- \_\_\_\_\_. 1996. Full information estimation in the presence of incomplete data. *Advanced structural equation modeling*, G. A. Marcoulides and R. E. Schumacker, eds. Mahwah, New Jersey: Lawrence Erlbaum Associates. より。
- Arminger, G., P. Stein, and J. Wittenberg. 1999. Mixtures of conditional mean- and covariance-structure models. *Psychometrika*, 64:4, 475–494.
- Attig, M. S. 1983. The processing of spatial information by adults. The Gerontological Society, San Francisco の年次総会において発表。
- Beale, E. M. L., and R. J. A. Little. 1975. Missing values in multivariate analysis. *Journal of the Royal Statistical Society Series B*, 37: 129–145.

- Beck, A. T. 1967. *Depression: causes and treatment*. Philadelphia, PA: University of Pennsylvania Press.
- Bentler, P. M. 1980. Multivariate analysis with latent variables: Causal modeling. *Annual Review of Psychology*, 31: 419–456.
- \_\_\_\_\_. 1985. *Theory and Implementation of EQS: A Structural Equations Program*. Los Angeles, CA: BMDP Statistical Software.
- \_\_\_\_\_. 1989. *EQS structural equations program manual*. Los Angeles, CA: BMDP Statistical Software.
- \_\_\_\_\_. 1990. Comparative fit indexes in structural models. *Psychological Bulletin*, 107: 238–246.
- Bentler, P. M., and D. G. Bonett. 1980. Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88: 588–606.
- Bentler, P. M., and C. Chou. 1987. Practical issues in structural modeling. *Sociological Methods and Research*, 16: 78–117.
- Bentler, P. M., and E. H. Freeman. 1983. Tests for stability in linear structural equation systems. *Psychometrika*, 48: 143–145.
- Bentler, P. M., and D. G. Weeks. 1980. Linear structural equations with latent variables. *Psychometrika*, 45: 289–308.
- Bentler, P. M., and J. A. Woodward. 1979. Nonexperimental evaluation research: Contributions of causal modeling. *Improving Evaluations*, L. Datta and R. Perloff, eds. Beverly Hills: Sage Publications より。
- Bollen, K. A. 1986. Sample size and Bentler and Bonett's non-normed fit index. *Psychometrika*, 51: 375–377.
- \_\_\_\_\_. 1987. Outliers and improper solutions: A confirmatory factor analysis example. *Sociological Methods and Research*, 15: 375–384.
- \_\_\_\_\_. 1989a. *Structural equations with latent variables*. New York: John Wiley and Sons.
- \_\_\_\_\_. 1989b. A new incremental fit index for general structural equation models. *Sociological Methods and Research*, 17: 303–316.
- Bollen, K. A., and K. G. Jöreskog. 1985. Uniqueness does not imply identification: A note on confirmatory factor analysis. *Sociological Methods and Research*, 14: 155–163.
- Bollen, K. A., and J. Liang. 1988. Some properties of Hoelter's CN. *Sociological Methods and Research*, 16: 492–503.
- Bollen, K. A., and J. S. Long, eds. 1993. *Testing structural equation models*. Newbury Park, CA: Sage Publications.
- Bollen, K. A., and R. A. Stine. 1992. Bootstrapping goodness-of-fit measures in structural equation models. *Sociological Methods and Research*, 21: 205–229.
- Bolstad, W. M., and J. M. Curran. 2017. *Introduction to Bayesian statistics*. Hoboken, NJ: John Wiley and Sons.
- Boomsma, A. 1987. The robustness of maximum likelihood estimation in structural equation models. *Structural Modeling by Example: Applications in Educational, Sociological, and Behavioral Research*, P. Cuttance and R. Ecob, eds. Cambridge University Press, 160–188. より。

- Botha, J. D., A. Shapiro, and J. H. Steiger. 1988. Uniform indices-of-fit for factor analysis models. *Multivariate Behavioral Research*, 23: 443–450.
- Bozdogan, H. 1987. Model selection and Akaike's information criterion (AIC): The general theory and its analytical extensions. *Psychometrika*, 52: 345–370.
- Brown, C. H. 1983. Asymptotic comparison of missing data procedures for estimating factor loadings. *Psychometrika*, 48:2, 269–291.
- Brown, R. L. 1994. Efficacy of the indirect approach for estimating structural equation models with missing data: A comparison of five methods. *Structural Equation Modeling: A Multidisciplinary Journal*, 1: 287–316.
- Browne, M. W. 1982. Covariance structures. *Topics in applied multivariate analysis*, D. M. Hawkins, ed. Cambridge: Cambridge University Press, 72–141 より。
- \_\_\_\_\_. 1984. Asymptotically distribution-free methods for the analysis of covariance structures. *British Journal of Mathematical and Statistical Psychology*, 37: 62–83.
- Browne, M. W., and R. Cudeck. 1989. Single sample cross-validation indices for covariance structures. *Multivariate Behavioral Research*, 24: 445–455.
- \_\_\_\_\_. 1993. Alternative ways of assessing model fit. *Testing structural equation models*, K. A. Bollen and J. S. Long, eds. Newbury Park, CA: Sage Publications, 136–162 より。
- Browne, M. W., and G. Mels. 1992. RAMONA user's guide. The Ohio State University, Columbus, OH.
- Burnham, K. P., and D. R. Anderson. 1998. *Model selection and inference: A practical information-theoretic approach*. New York: Springer-Verlag.
- Burnham, K. P., and D. R. Anderson. 2002. *Model selection and multimodel inference: A practical information-theoretic approach*. 2nd ed. New York: Springer-Verlag.
- Burns, D. D. 1999. *Feeling good: the new mood therapy*. New York: Avon Books.
- \_\_\_\_\_. 2020. *Feeling great: the revolutionary new treatment for depression and anxiety*. Eau Claire, WI: PESI.
- Byrne, B. M. 1989. *A primer of LISREL: Basic applications and programming for confirmatory factor analytic models*. New York: Springer-Verlag.
- \_\_\_\_\_. 2001. *Structural equation modeling with Amos: Basic concepts, applications, and programming*. Mahwah, New Jersey: Erlbaum.
- Carmines, E. G., and J. P. McIver. 1981. Analyzing models with unobserved variables. *Social measurement: Current issues*, G. W. Bohrnstedt and E. F. Borgatta, eds. より。 Beverly Hills: Sage Publications.
- Cattell, R. B. 1966. The scree test for the number of factors. *Multivariate Behavioral Research*, 1: 245–276.
- Celeux, G., M. Hurn, and C. P. Robert. 2000. Computational and inferential difficulties with mixture posterior distributions. *Journal of the American Statistical Association*, 95:451, 957–970.
- Chen, F., K. A. Bollen, P. Paxton, P. J. Curran, and J. B. Kirby. 2001. Improper solutions in structural equation models: Causes, consequences, and strategies. *Sociological Methods and Research*, 29:4, 468–508.

- Chung, H., E. Loken, and J. L. Schafer. 2004. Difficulties in drawing inferences with finite-mixture models: A simple example with a simple solution. *American Statistician*, 58:2, 152–158.
- Cliff, N. 1973. Scaling. *Annual Review of Psychology*, 24: 473–506.
- \_\_\_\_\_. 1983. Some cautions concerning the application of causal modeling methods. *Multivariate Behavioral Research*, 18: 115–126.
- Cochran, W. G. 1952. The  $\chi^2$  test of goodness of fit. *Annals of Mathematical Statistics*, 23: 315–345.
- Cook, T. D., and D. T. Campbell. 1979. *Quasi-experimentation: Design and analysis issues for field settings*. Chicago: Rand McNally.
- Croon, M. 2002. Ordering the classes. *Applied Latent Class Analysis*: 137–162, J. A. Hagenaars and A. L. McCutcheon, eds. より。Cambridge, UK: Cambridge University Press.
- Crowley, J., and M. Hu. 1977. Covariance analysis of heart transplant data. *Journal of the American Statistical Association*, 72: 27–36.
- Cudeck, R., and M. W. Browne. 1983. Cross-validation of covariance structures. *Multivariate Behavioral Research*, 18: 147–167.
- Davis, W. R. 1993. The FC1 rule of identification for confirmatory factor analysis: A general sufficient condition. *Sociological Methods and Research*, 21: 403–437.
- Diaconis, P., and B. Efron. 1983. Computer-intensive methods in statistics. *Scientific American*, 248:5, 116–130.
- Ding, C. 2006. Using regression mixture analysis in educational research. *Practical Assessment Research and Evaluation*, 11:11. <http://pareonline.net/getvn.asp?v=11&n=11> で入手可能。
- Dolker, M., S. Halperin, and D. R. Divgi. 1982. Problems with bootstrapping Pearson correlations in very small samples. *Psychometrika*, 47: 529–530.
- Draper, N. R., and H. Smith. 1981. *Applied regression analysis*. 2nd ed. New York: John Wiley and Sons.
- Edgington, E. S. 1987. *Randomization tests*. 2nd ed. New York: Marcel Dekker.
- Efron, B. 1979. Bootstrap methods: Another look at the jackknife. *Annals of Statistics*, 7: 1–26.
- \_\_\_\_\_. 1982. *The jackknife, the bootstrap, and other resampling plans*. (SIAM Monograph #38) Philadelphia: Society for Industrial and Applied Mathematics.
- \_\_\_\_\_. 1987. Better bootstrap confidence intervals. *Journal of the American Statistical Association*, 82: 171–185.
- Efron, B., and G. Gong. 1983. A leisurely look at the bootstrap, the jackknife, and cross-validation. *American Statistician*, 37: 36–48.
- Efron, B., and D. V. Hinkley. 1978. Assessing the accuracy of the maximum likelihood estimator: Observed versus expected Fisher information. *Biometrika*, 65: 457–87.
- Efron, B., and R. J. Tibshirani. 1993. *An introduction to the bootstrap*. New York: Chapman and Hall.
- European Values Study Group and World Values Survey Association. *European and world values surveys four-wave integrated data file, 1981–2004*. Vol. 20060423. 2006.



- Felson, R.B., and G. W. Bohrnstedt 1979. "Are the good beautiful or the beautiful good?" The relationship between children's perceptions of ability and perceptions of physical attractiveness. *Social Psychology Quarterly*, 42: 386–392.
- Fisher, R. A. 1936. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7: 179–188.
- Fox, J. 1980. Effect analysis in structural equation models. *Sociological Methods and Research*, 9: 3–28.
- Fraley, C., and A. E. Raftery. 2002. Model-based clustering, discriminant analysis, and density estimation. *Journal of the American Statistical Association*, 97:458, 611–631.
- Frühwirth-Schnatter, S. 2004. Estimating marginal likelihoods for mixture and Markov switching models using bridge sampling techniques. *The Econometrics Journal*, 7: 143–167.
- Furnival, G. M., and R. W. Wilson. 1974. Regression by leaps and bounds. *Technometrics*, 16: 499–511.
- Gelman, A., J. B. Carlin, H. S. Stern, D. B. Dunson, A. Vehtari, and D. B. Rubin. 2013. *Bayesian data analysis*. 3rd ed. Boca Raton: Chapman and Hall/CRC.
- Gill, J. 2004. Introduction to the special issue. *Political Analysis*, 12:4, 323–337.
- Graham, J. W., S. M. Hofer, S. I. Donaldson, D. P. MacKinnon, and J. L. Schafer. 1997. Analysis with missing data in prevention research. *The science of prevention: Methodological advances from alcohol and substance abuse research*, K. Bryant, M. Windle, and S. West, eds. より。
- Graham, J. W., S. M. Hofer, and D. P. MacKinnon. 1996. Maximizing the usefulness of data obtained with planned missing value patterns: An application of maximum likelihood procedures. *Multivariate Behavioral Research*, 31: 197–218.
- Gulliksen, H., and J. W. Tukey. 1958. Reliability for the law of comparative judgment. *Psychometrika*, 23: 95–110.
- Hamilton, L. C. 1990. *Statistics with Stata*. Pacific Grove, CA: Brooks/Cole.
- Hamilton, M. 1960. A rating scale for depression. *Journal of Neurology, Neurosurgery, and Psychiatry*, 23: 56–62.
- Hayduk, L. A. 1987. *Structural equation modeling with LISREL*. Baltimore: Johns Hopkins University Press.
- Hoelter, J. W. 1983. The analysis of covariance structures: Goodness-of-fit indices. *Sociological Methods and Research*, 11: 325–344.
- Hoeting, J. A., D. Madigan, A. E. Raftery, and C. T. Volinsky. 1999. Bayesian model averaging: a tutorial. *Statistical Science*, 14: 382–417.
- Holzinger, K. J., and F. A. Swineford. 1939. A study in factor analysis: The stability of a bi-factor solution. *Supplementary Educational Monographs*, No. 48. Chicago: University of Chicago, Dept. of Education.
- Hoshino, T. 2001. Bayesian inference for finite mixtures in confirmatory factor analysis. *Behaviormetrika*, 28:1, 37–63.
- Hu, L., and P. M. Bentler. 1999. Cutoff criteria for fit indices in covariance structure analysis: conventional criteria versus new alternatives. *Structural Equation Modeling*, 6: 1–55.

- Hubert, L. J., and R. G. Golledge. 1981. A heuristic method for the comparison of related structures. *Journal of Mathematical Psychology*, 23: 214–226.
- Huitema, B. E. 1980. *The analysis of covariance and alternatives*. New York: John Wiley and Sons.
- Ibrahim, J. G., M-H Chen, S. R. Lipsitz, and A. H. Herring. 2005. Missing data methods for generalized linear models: A review. *Journal of the American Statistical Association*, 100:469, 332–346.
- Jackman, S. 2000. Estimation and inference via Bayesian simulation: An introduction to Markov chain Monte Carlo. *American Journal of Political Science*, 44:2, 375–404.
- James, L. R., S. A. Mulaik, and J. M. Brett. 1982. *Causal analysis: Assumptions, models, and data*. Beverly Hills: Sage Publications.
- Jamison, C., and F. Scogin. 1995. The outcome of cognitive bibliotherapy with depressed adults. *Journal of Consulting and Clinical Psychology*, 63: 644–650.
- Jasra, A., C. C. Holmes, and D. A. Stephens. 2005. Markov chain Monte Carlo methods and the label switching problem in Bayesian mixture modeling. *Statistical Science*, 20:1, 50–67.
- Jöreskog, K. G. 1967. Some contributions to maximum likelihood factor analysis. *Psychometrika*, 32: 443–482.
- \_\_\_\_\_. 1969. A general approach to confirmatory maximum likelihood factor analysis. *Psychometrika*, 34: 183–202.
- \_\_\_\_\_. 1971. Simultaneous factor analysis in several populations. *Psychometrika*, 36: 409–426.
- \_\_\_\_\_. 1979. A general approach to confirmatory maximum likelihood factor analysis with addendum. *Advances in factor analysis and structural equation models*, K. G. Jöreskog and D. Sörbom, eds. Cambridge, MA: Abt Books, 21–43 より。
- Jöreskog, K. G., and D. Sörbom. 1984. *LISREL-VI user's guide*. 3rd ed. Mooresville, IN: Scientific Software.
- \_\_\_\_\_. 1989. *LISREL-7 user's reference guide*. Mooresville, IN: Scientific Software.
- \_\_\_\_\_. 1996. *LISREL-8 user's reference guide*. Chicago: Scientific Software.
- Judd, C. M., and M. A. Milburn. 1980. The structure of attitude systems in the general public: Comparisons of a structural equation model. *American Sociological Review*, 45: 627–643.
- Kalbfleisch, J. D., and R. L. Prentice. 2002. *The statistical analysis of failure time data*. Hoboken, NJ: John Wiley and Sons.
- Kaplan, D. 1989. Model modification in covariance structure analysis: Application of the expected parameter change statistic. *Multivariate Behavioral Research*, 24: 285–305.
- Kendall, M. G., and A. Stuart. 1973. *The advanced theory of statistics*. Vol. 2, 3rd ed. New York: Hafner.
- Kline, R. B. 2016. *Principles and practice of structural equation modeling*. 4th ed. New York: The Guilford Press.
- Kullback, S., and R. A. Leibler. 1951. On information and sufficiency. *Annals of Mathematical Statistics*, 22: 79–86.
- Lazarsfeld, P. F., and N. W. Henry. 1968. *Latent structure analysis*. Boston: Houghton Mifflin.

- Lee, S., and S. Hershberger. 1990. A simple rule for generating equivalent models in covariance structure modeling. *Multivariate Behavioral Research*, 25: 313–334.
- Lee, S. Y. 2007. *Structural equation modeling: A Bayesian approach*. Chichester, UK: John Wiley and Sons.
- Lee, S. Y., and X. Y. Song. 2004. Evaluation of the Bayesian and maximum likelihood approaches in analyzing structural equation models with small sample sizes. *Multivariate Behavioral Research*, 39:4, 653–686.
- Lee, S. Y., and X. Y. Song. 2003. Bayesian analysis of structural equation models with dichotomous variables. *Statistics in Medicine*, 22: 3073–3088.
- Linhart, H., and W. Zucchini. 1986. *Model selection*. New York: John Wiley and Sons.
- Little, R. J. A., and D. B. Rubin. 1989. The analysis of social science data with missing values. *Sociological Methods and Research*, 18: 292–326.
- \_\_\_\_\_. 2020. *Statistical analysis with missing data*. 3rd ed. Hoboken, NJ: John Wiley and Sons.
- Little, R. J. A., and N. Schenker. 1995. Missing data. In: *Handbook of statistical modeling for the social and behavioral sciences*, G. Arminger, C. C. Clogg, and M. E. Sobel, eds. New York: Plenum.
- Loehlin, J. C., and A. A. Beaujean. 2017. *Latent variable models: An introduction to factor, path, and structural equation analysis*. 5th ed. New York: Routledge.
- Loken, E. 2004. Using latent class analysis to model temperament types. *Multivariate Behavioral Research*, 39:4, 625–652.
- Lord, F. M. 1955. Estimation of parameters from incomplete data. *Journal of the American Statistical Association*, 50: 870–876.
- Lubke, G. H., and B. Muthén. 2005. Investigating population heterogeneity with factor mixture models. *Psychological Methods*, 10:1, 21–39.
- MacCallum, R. C. 1986. Specification searches in covariance structure modeling. *Psychological Bulletin*, 100: 107–120.
- \_\_\_\_\_. 1990. The need for alternative measures of fit in covariance structure modeling. *Multivariate Behavioral Research*, 25: 157–162.
- MacCallum, R. C., M. Roznowski, and L. B. Necowitz. 1992. Model modifications in covariance structure analysis: The problem of capitalization on chance. *Psychological Bulletin*, 111: 490–504.
- MacCallum, R. C., D. T. Wegener, B. N. Uchino, and L. R. Fabrigar. 1993. The problem of equivalent models in applications of covariance structure analysis. *Psychological Bulletin*, 114: 185–199.
- MacKay, D. J. C. 2003. *Information theory, inference and learning algorithms*. Cambridge, UK: Cambridge University Press.
- MacKinnon, D. P., C. M. Lockwood, and J. Williams. 2004. Confidence limits for the indirect effect: distribution of the product and resampling methods. *Multivariate Behavioral Research*, 39:1, 99–128.

- Madigan, D., and A. E. Raftery. 1994. Model selection and accounting for model uncertainty in graphical models using Occam's window. *Journal of the American Statistical Association*, 89: 1535–1546.
- Manly, B. F. J. 1991. *Randomization and Monte Carlo Methods in Biology*. London: Chapman and Hall.
- Mantel, N. 1967. The detection of disease clustering and a generalized regression approach. *Cancer Research*, 27: 209–220.
- Mantel, N., and R. S. Valand. 1970. A technique of nonparametric multivariate analysis. *Biometrics*, 26: 47–558.
- Mardia, K. V. 1970. Measures of multivariate skewness and kurtosis with applications. *Biometrika*, 57: 519–530.
- \_\_\_\_\_. 1974. Applications of some measures of multivariate skewness and kurtosis in testing normality and robustness studies. *Sankhya, Series B*, 36: 115–128.
- Marsh, H. W., and D. Hocevar. 1985. Application of confirmatory factor analysis to the study of self-concept: First- and higher-order factor models and their invariance across groups. *Psychological Bulletin*, 97: 562–582.
- Martin, J. K., and R. P. McDonald. 1975. Bayesian estimation in unrestricted factor analysis: A treatment for Heywood cases. *Psychometrika*, 40: 505–517.
- Matsumoto, M., and T. Nishimura. 1998. Mersenne twister: A 623-dimensionally equidistributed uniform pseudo-random number generator. *ACM Transactions on Modeling and Computer Simulation*, 8: 3–30.
- Matthai, A. 1951. Estimation of parameters from incomplete data with application to design of sample surveys. *Sankhya*, 11: 145–152.
- McArdle, J. J., and M. S. Aber. 1990. Patterns of change within latent variable structural equation models. *Statistical methods in longitudinal research, Volume I: Principles and structuring change*, A. von Eye, ed. New York: Academic Press, 151–224 より。
- McDonald, R. P. 1978. A simple comprehensive model for the analysis of covariance structures. *British Journal of Mathematical and Statistical Psychology*, 31: 59–72.
- \_\_\_\_\_. 1982. A note on the investigation of local and global identifiability. *Psychometrika*, 47: 101–103.
- \_\_\_\_\_. 1989. An index of goodness-of-fit based on noncentrality. *Journal of Classification*, 6: 97–103.
- McDonald, R. P., and W. R. Krane. 1977. A note on local identifiability and degrees of freedom in the asymptotic likelihood ratio test. *British Journal of Mathematical and Statistical Psychology*, 30: 198–203.
- \_\_\_\_\_. 1979. A Monte-Carlo study of local identifiability and degrees of freedom in the asymptotic likelihood ratio test. *British Journal of Mathematical and Statistical Psychology*, 32: 121–132.
- McDonald, R. P., and H. W. Marsh. 1990. Choosing a multivariate model: Noncentrality and goodness of fit. *Psychological Bulletin*, 107: 247–255.

- Mulaik, S. A. 1990. An analysis of the conditions under which the estimation of parameters inflates goodness of fit indices as measures of model validity. *Psychometric Society の年次総会* (Princeton, New Jersey, June 28–30, 1990) で論文発表。
- Mulaik, S. A., L. R. James, J. Van Alstine, N. Bennett, S. Lind, and C. D. Stilwell. 1989. Evaluation of goodness-of-fit indices for structural equation models. *Psychological Bulletin*, 105: 430–445.
- Muth 始, B., D. Kaplan, and M. Hollis. 1987. On structural equation modeling with data that are not missing completely at random. *Psychometrika*, 52: 431–462.
- Olinsky, A., S. Chen, and L. Harlow. 2003. The comparative efficacy of imputation methods for missing data in structural equation modeling. *European Journal of Operational Research*, 151: 53–79.
- Olsson, S. 1973. An experimental study of the effects of training on test scores and factor structure. Uppsala, Sweden: University of Uppsala, Department of Education.
- Raftery, A. E. 1993. Bayesian model selection in structural equation models. In: *Testing structural equation models*, K. A. Bollen and J. S. Long, eds. Newbury Park, CA: Sage Publications, 163–180.
- \_\_\_\_\_. 1995. Bayesian model selection in social research. *Sociological Methodology*, P. V. Marsden, ed. San Francisco: Jossey-Bass, 111–163 より。
- Rigdon, E. E. 1994a. Calculating degrees of freedom for a structural equation model. *Structural Equation Modeling*, 1: 274–278.
- \_\_\_\_\_. 1994b. Demonstrating the effects of unmodeled random measurement error. *Structural Equation Modeling*, 1: 375–380.
- Rock, D. A., C. E. Werts, R. L. Linn, and K. G. Jöreskog. 1977. A maximum likelihood solution to the errors in variables and errors in equations model. *Journal of Multivariate Behavioral Research*, 12: 187–197.
- Rubin, D. B. 1976. Inference and missing data. *Biometrika*, 63: 581–592.
- \_\_\_\_\_. 1987. *Multiple imputation for nonresponse in surveys*. New York: John Wiley and Sons.
- Runyon, R. P., and A. Haber. 1980. *Fundamentals of behavioral statistics*, 4th ed. Reading, Mass.: Addison-Wesley.
- Salhi, S. 1998. Heuristic search methods. *Modern methods for business research*, G. A. Marcoulides, ed. Mahwah, NJ: Erlbaum, 147–175 より。
- Saris, W. E., A. Satorra, and D. Sörbom. 1987. The detection and correction of specification errors in structural equation models. *Sociological methodology*, C. C. Clogg, ed. San Francisco: Jossey-Bass より。
- Schafer, J. L. 1997. *Analysis of incomplete multivariate data*. London, UK: Chapman and Hall.
- Schafer, J. L., and J. W. Graham. 2002. Missing data: Our view of the state of the art. *Psychological Methods*, 7:2, 147–177.
- Schafer, J. L., and M. K. Olsen. 1998. Multiple imputation for multivariate missing-data problems: A data analyst's perspective. *Multivariate Behavioral Research*, 33:4, 545–571.
- Schwarz, G. 1978. Estimating the dimension of a model. *The Annals of Statistics*, 6: 461–464.

- Scheines, R., H. Hoijtink, and A. Boomsma. 1999. Bayesian estimation and testing of structural equation models. *Psychometrika*, 64: 37–52.
- Shrout, P. E., and N. Bolger. 2002. Mediation in experimental and nonexperimental studies: New procedures and recommendations. *Psychological Methods*, 7:4, 422–445.
- Sobel, M. E. 1982. Asymptotic confidence intervals for indirect effects in structural equation models. *Sociological methodology*, S. Leinhardt, ed. San Francisco: Jossey-Bass, 290–312 より。
- \_\_\_\_\_. 1986. Some new results on indirect effects and their standard errors in covariance structure models. *Sociological methodology*, S. Leinhardt, ed. San Francisco: Jossey-Bass, 159–186 より。
- Sobel, M. E., and G. W. Bohrnstedt. 1985. Use of null models in evaluating the fit of covariance structure models. *Sociological methodology*, N. B. Tuma, ed. San Francisco: Jossey-Bass, 152–178 より。
- Sörbom, D. 1974. A general method for studying differences in factor means and factor structure between groups. *British Journal of Mathematical and Statistical Psychology*, 27: 229–239.
- \_\_\_\_\_. 1978. An alternative to the methodology for analysis of covariance. *Psychometrika*, 43: 381–396.
- Spirtes, P., R. Scheines, and C. Glymour. 1990. Simulation studies of the reliability of computer-aided model specification using the TETRAD II, EQS, and LISREL programs. *Sociological Methods and Research*, 19: 3–66.
- Steiger, J. H. 1989. *EzPATH: Causal modeling*. Evanston, IL: Systat.
- \_\_\_\_\_. 1990. Structural model evaluation and modification: An interval estimation approach. *Multivariate Behavioral Research*, 25: 173–180.
- Steiger, J. H., and J. C. Lind. 1980, May 30. Statistically-based tests for the number of common factors. *Psychometric Society の Annual Spring Meeting (Iowa City) で論文発表*。
- Steiger, J. H., A. Shapiro, and M. W. Browne. 1985. On the multivariate asymptotic distribution of sequential chi-square statistics. *Psychometrika*, 50: 253–263.
- Stelzl, I. 1986. Changing a causal hypothesis without changing the fit: Some rules for generating equivalent path models. *Multivariate Behavioral Research*, 21: 309–331.
- Stephens, M. 2000. Dealing with label switching in mixture models. *Journal of the Royal Statistical Society, Series B*, 62:4, 795–809.
- Stine, R. A. 1989. An introduction to bootstrap methods: Examples and ideas. *Sociological Methods and Research*, 18: 243–291.
- Swain, A. J. 1975. Analysis of parametric structures for variance matrices. Unpublished Ph.D. thesis, University of Adelaide.
- Tanaka, J. S., and G. J. Huba. 1985. A fit index for covariance structure models under arbitrary GLS estimation. *British Journal of Mathematical and Statistical Psychology*, 38: 197–201.
- \_\_\_\_\_. 1989. A general coefficient of determination for covariance structure models under arbitrary GLS estimation. *British Journal of Mathematical and Statistical Psychology*, 42: 233–239.
- Tucker, L. R., and C. Lewis. 1973. A reliability coefficient for maximum likelihood factor analysis. *Psychometrika*, 38: 1–10.

- Verleye, G. 1996. Missing at random data problems in attitude measurements using maximum likelihood structural equation modeling. Unpublished dissertation. Frije Universiteit Brussels, Department of Psychology.
- Vermunt, J. K., and J. Magidson. 2005. Structural equation models: Mixture models. *Encyclopedia of statistics in behavioral science*, B. Everitt and D. Howell, eds. Chichester, UK: John Wiley and Sons, 1922–1927 より。
- Warren, R. D., J. K. White, and W. A. Fuller. 1974. An errors-in-variables analysis of managerial role performance. *Journal of the American Statistical Association*, 69: 886–893.
- Wheaton, B. 1987. Assessment of fit in overidentified models with latent variables. *Sociological Methods and Research*, 16: 118–154.
- Wheaton, B., B. Muthén, D. F. Alwin, and G. F. Summers. 1977. Assessing reliability and stability in panel models. *Sociological methodology*, D. R. Heise, ed. San Francisco: Jossey-Bass, 84–136 より。
- Wichman, B. A., and I. D. Hill. 1982. An efficient and portable pseudo-random number generator. Algorithm AS 183. *Applied Statistics*, 31: 188–190.
- Winer, B. J. 1971. *Statistical principles in experimental design*. New York: McGraw-Hill.
- Wothke, W. 1993. Nonpositive definite matrices in structural modeling. In: *Testing structural equation models*, K. A. Bollen and J. S. Long, eds. Newbury Park, CA: Sage Publications, 256–293.
- \_\_\_\_\_. 1999. Longitudinal and multi-group modeling with missing data. *Modeling longitudinal and multiple group data: Practical issues, applied approaches and specific examples*, T. D. Little, K. U. Schnabel, and J. Baumert, eds. より。 Mahwah, New Jersey: Lawrence Erlbaum Associates.
- Zhu, H. T., and S. Y. Lee. 2001. A Bayesian analysis of finite mixtures in the LISREL model. *Psychometrika*, 66:1, 133–152.





# 索引

## A

- ADF, 漸近的分布非依存, 560
- AGFI, 修正済み適合度指標, 577
- AIC
  - Burnham と Anderson によるガイドライン, 300
  - 赤池情報量基準, 283, 570
- Amos Graphics、起動, 9
- AmosEngine メソッド, 52
- Amos による仮定
  - 回帰について, 203
  - 外生変数間の相関について, 71
  - 共分散分析について, 221
  - 欠損データについて, 250
  - 測定モデル内のパラメータについて, 225
  - 分布に関する, 32
- Amos モデルの分布の仮定, 32
- Anderson のアイリスのデータ, 484, 497
- AStructure メソッドの式形式, 72

## B

- Bayes 因子, 590, 591
  - 再調整, 305
- BCC
  - Browne-Cudeck 基準, 283, 571
  - Burnham と Anderson によるガイドライン, 300
  - モデル比較, 299
- BCC を使用したモデル比較, 327
- BIC
  - ベイズ情報量基準, 571
  - モデル比較, 321

## C

- CAIC, 一貫した AIC, 571
- Caption
  - パス図を描画するための pd 方法, 534
- CFI, 比較適合指標 (comparative fit index), 575

## CMIN

- 最小乖離度関数, 109, 565
  - テーブル, 342
- CMIN/DF, 最小乖離度を自由度で割った値, 566
- Cov
  - パス図を描画するための pd 方法, 534
- C における
  - オプション矢印, 313
  - 探索的因子分析, 312
  - 適合度, 314

## D

- DF, 自由度, 564

## E

- ECVI, 期待交差確認指標, 572
- EQS (SEM プログラム), 223
- European Values Study Group, 453

## F

- F0
  - テキスト マクロ, 568
- F0, 母集団の乖離度, 568
- Fisher のアイリスのデータ, 484, 497
- FMIN, 乖離度  $F$  の最小値, 567

## G

- GetCheckBox
  - pd 方法, 539
- GFI, 儉約性適合度指標, 578
- GFI, 適合度指標, 577
- GLS, 一般化した最小 2 乗法, 560
- GroupName メソッド, 157

## H

- HOELTER, クリティカル  $N$ , 578

**L**

LISREL (SEM プログラム), 223

**M**

Mainsub 関数, 531

MCMC 診断, 468

MECVI, 変更された期待交差確認指標, 572

ML, 最尤法推定値, 559

**N**

NCP, 非心度パラメータ, 568

NFI, 相対適合指標 (relative fit index), 574

NFI, 増分適合指標 (incremental fit index), 575

NFI, 標準適合指標 (normed fit index), 573

NNFI, 非標準適合指標 (non-normed fit index), 575

NPAR, パラメータ数, 564

**O**

Observed

パス図を描画するための pd 方法, 532

Occam のウィンドウ、対称, 304

**P**

P, 確率, 565

Path

パス図を描画するための pd 方法, 533

PCFI, 儉約性比較適合指標 (parsimonious comparative fit index), 576

PCLOSE, 母集団 RMSEA の高い適合性, 570

pd 方法

Caption, 534

Cov, 534

GetCheckBox, 539

Observed, 532

Path, 533

Reposition, 534

SetDataFile, 539

UndoResume, 534

UndoToHere, 534

Unobserved, 533

PNFI, 儉約性標準適合指標 (parsimonious normed fit index), 576

PRATIO, 儉約率, 565

**R**

Reposition

パス図を描画するための pd 方法, 534

RFI, 相対非心度指標 (relative noncentrality index), 575

RMR, 残差平均平方根, 579

RMSEA, 近似誤差平均平方根, 569

**S**

Semnet, 4

SetDataFile

pd 方法, 539

SLS, 尺度不変最小 2 乗, 560

**T**

TLI, Tucker-Lewis 指標, 575

**U**

ULS, 重み付けのない最小 2 乗法, 560

UndoResume

pd 方法, 534

UndoToHere

pd 方法, 534

Unobserved

パス図を描画するための pd 方法, 533

**あ**

アイリスのデータ, 484, 497

赤池ウェイト, 590, 591

解釈, 301

表示, 300

新しいグループ, 51, 70, 157

安定指数, 124

安定したモデル, 124

**い**

一貫した AIC(CAIC), 283

入れ子になったモデル, 239

因子得点ウェイト, 111

因子の平均値

制約条件の削除, 344

比較, 343

因子負荷, 339

因子分析, 127  
 構造平均, 209  
 探索的, 323  
 モデル, 209

## う

打ち切りデータ, 439

## お

オブジェクトの移動, 14  
 オブジェクトの形変更, 14  
 オプション出力, 15, 30, 43, 110  
 オプション矢印, 306, 313, 316

## か

カイ2乗確率メソッド, 259  
 カイ2乗統計量, 47  
 図のキャプションへの表示, 48  
 回帰法代入, 427  
 回帰モデル, 9, 13, 442  
 外生変数, 35, 63, 69, 71  
 外生変数間の相関, 71  
 乖離度, 559  
 取得  
 重相関係数の平方, 123  
 パラメータの差に対する検定統計量, 166  
 標準化推定値, 122, 132  
 確率, 28  
 確率的回帰法代入, 427  
 カスタム推定値, 403  
 仮説の検定, 47  
 カテゴリの境界, 459  
 間接効果, 112  
 信頼区間の発見, 397  
 推定, 390  
 表示, 標準化, 393

## き

記述適合度, 587  
 帰無モデル, 587  
 境界。「カテゴリの境界」を参照  
 共通因子, 129  
 共通因子モデル, 128

共分散  
 構造, 339  
 描画, 174  
 不偏推定値, 222  
 ラベル, 174  
 共分散の設定, 25  
 共分散分析, 137  
 代替, 135, 221  
 方法の比較, 235  
 共分散分析の代替分析, 135, 221  
 共分散を描く, 174

## く

グラフィックを使用しないモデルの指定, 529  
 グループ間制約, 212  
 影響されるパラメータ, 340  
 手動設定, 343  
 生成, 351  
 グループ間制約の生成, 351  
 グループの相違の指定  
 規則, 148  
 グループの相違を指定するための規則, 148

## け

計算  
 検定統計量, 100  
 標準化推定値, 30  
 係数, 581  
 結果取得用のメソッド, 52  
 結果の結合、多重代入データ ファイル, 437  
 結果を含むテキスト ファイル, 51  
 欠損データ, 249–270  
 検定統計量, 27  
 計算, 100  
 儉約性, 564  
 儉約性指標, 576

## こ

構造指定, 72  
 パラメータの推定, 72  
 構造方程式モデリング, 2  
 雑誌, 4  
 推定方法, 2  
 構造方程式モデリングに関する雑誌, 4  
 構造モデル, 75  
 構造モデルの共分散, 339  
 固定変数, 32

## 索引

## コピー

テキスト出力の表示, 20  
パス図, 20

固有の変数, 71

混合モデリング, 483

## さ

再帰モデル, 69

再コード化データ, 441, 456, 474

最小乖離度関数, 109

細線化, 381

再調整された測度, 589

作成

2 つ目のグループ, 174  
パス図, 77

散布図

$C-df$ を表す線, 310  
 $C-df$ を表す線の調整, 311  
定数の適合度を表す線, 309  
定数の適合度を表す線の調整, 309  
定数の適合度を表すその他の線, 312  
適合度と複雑度, 307

## し

シード、乱数, 362

閾値。「カテゴリの境界」を参照

識別可能モデル, 66, 252, 255, 280, 563

識別制約, 138

時系列図, 370

事後

標準偏差, 357  
分布, 357  
平均, 357

自己相関図, 371, 469

事後予測分布, 445, 470, 495, 508, 525  
潜在変数, 474

事前分布, 357, 358, 377  
グループ比率, 528

指定

図のキャプションのグループ名, 162  
等しいパラメータ, 39  
等しいパラメータの利点, 39

指標の回転, 78

修正指数, 95, 100, 354

誤用, 100  
要求, 139

修正指数の誤用, 100

修正指数の要求, 139

収束

事後分布の要約の, 367  
分布の, 366  
ベイズ推定における, 366

自由度, 29

従来の線型回帰, 61

順序 - カテゴリカル データ, 453

条件付き検定, 239

情報理論的適合度, 570

診断

MCMC, 468

信頼区間, 578, 579

信頼領域, 375

## す

垂直に配置, 173

推定

間接効果, 390  
分散と共分散, 21  
平均値, 191

数値カスタム推定値, 409

数量, 541

スクリープロット

最善の適合グラフの表示, 314  
探索的モデル特定化, 315

すべてのモデルの適合, 342

単一の分析, 171

## せ

正規分布, 32

生成されたモデル, 341

生存期間, 440

制約

共分散, 39  
追加によるモデルの改良, 100  
パラメータ, 13  
分散, 38  
平均値と切片項, 350

ゼロ ベースの再調整, 589

ゼロ モデル, 563

描画領域

共分散パスの追加, 80  
測定モデルのウェイトの表示, 340  
非観測変数の追加, 80  
方向の変更, 76

漸近, 28

線型従属, 62  
 宣言用のメソッド, 52  
 潜在構造分析, 496, 509  
 潜在変数  
   事後予測分布, 474

## そ

相関がない変数, 54  
 相関がない変数の検定, 54  
 総合効果, 112  
 測定エラー, 62  
 測定モデル, 75, 278  
 測定モデルのウェイト, 339  
   描画領域での表示, 340  
 測定モデルの残差, 340  
 測定モデルの複写, 78

## た

対称的な Occam のウィンドウ, 304  
 代入  
   回帰, 427  
   確率的回帰法, 427  
   多重, 428  
   データ, 427, 448, 478  
   ベイジアン, 427  
   モデルベースの, 428  
 多重代入, 428  
 多重代入データセット, 435  
 多重代入データ ファイルの結果の結合, 437  
 多変量分散分析, 198  
 単一分析での複数モデル, 106  
 探索的因子分析, 318, 323  
   スクリープロット, 312  
   探索的モデル特定化, 315  
   適合度と複雑度についての散布図, 307  
 探索的モデル特定化, 293–322  
   Bayes 因子を使用したモデル比較, 303  
   BCC を使用したモデル比較, 299  
   BIC を使用したモデル比較, 302  
   CAIC, 584  
   CFI, 583  
   RMSEA, 583  
   赤池ウェイト, 300  
   オプション矢印, 306, 319  
   オプション矢印が少数, 294

確証的, 294  
 高速化, 297  
 実行, 297  
 使用するパラメータ数, 306  
 生成されたモデル, 298  
 探索的因子分析, 315, 318, 323  
 適合度の表示, 297  
 デフォルトに戻す, 296, 320  
 発見的, 323, 332  
 パラメータ推定値, 299  
 必須の矢印, 295  
 プログラムのオプション, 296  
 保持するモデルの制限, 296

探索分析, 91  
 単純モデル, 564

## ち

直接効果, 112

## て

データおよびモデル指定用のメソッド, 52  
 データ代入, 250, 427, 448, 478  
 データの再コード化, 441, 456, 474  
 データの入力, 41  
 データ ファイル, 11  
 適合度, 563, 580, 583  
 テキスト出力としての相関推定値, 31  
 テキスト出力の表示  
   コピー, 20  
 テキスト マクロ, 47, 564–579  
 デフォルト、変更, 223

## と

統計仮説の検定, 94  
 同時因子分析, 179  
 同時方程式モデル, 161  
 同等性の制約条件, 129  
 独自因子, 129  
 特定可能性, 61, 129, 581  
   条件, 129  
 特定可能性の条件, 129  
 独立モデル, 252, 255, 280, 563  
 トレース図, 370, 468, 510  
 トレーニング データ, 483

## な

- 内生変数, 66
- 名前を付ける
  - グループ, 180
  - 変数, 24

## は

- バーンイン 標本, 365
- パス図, 2
  - 印刷, 20
  - オブジェクトの移動, 14, 40
  - オブジェクトの形変更, 14
  - オブジェクトの削除, 15
  - オブジェクトの書式設定, 40
  - カイ2乗統計量の表示, 48
  - キャプションのグループ名の指定, 162
  - コピー, 20
  - 作成, 77
  - 指標の回転, 78
  - 新規, 22
  - 測定モデルの複写, 78
  - データ ファイルの添付, 22, 41
  - 動作のやり直し, 15
  - 動作を元に戻す, 15
  - パラメータの制約, 13
  - 表示の変更, 14
  - 矢印の描画, 13
- 発見的な探索的モデル特定化, 323, 332
  - ステップワイズ法, 332, 333
  - 制限, 335
  - 変数減少法, 332
  - 変数増加法, 332
- パラメータ
  - グループ間制約による影響, 340
  - 等しい、指定の利点, 39
  - 等しいパラメータの指定, 39
- パラメータ制約条件, 37
- パラメータの推定
  - 構造指定, 72

## ひ

- 非拡散事前分布, 377
- 非観測変数, 73
- 非再帰モデル, 69, 119, 120

## 表示

- グラフィックス出力, 19, 26
- 生成されたモデル, 341
- テキスト出力の表示, 17, 27
- パラメータ部分集合, 340
- 標準化間接効果, 393
- 標準化推定値, 133
- 標準化推定値, 30, 122
  - 取得, 132
  - 表示, 133

## ふ

- ブートストラップ, 271–276
    - ADF, 287
    - GLS, 287
    - ML, 287
    - ULS, 287
    - 欠点, 271
    - 失敗, 283
    - 進行状況の監視, 273
    - 診断情報のあるテーブル, 274
    - 推定方法の比較, 285–291
    - 標本, 277
    - 標本の数, 273, 281
    - モデル比較における手法, 277–284
  - 不安定なモデル, 124
  - 付加定数 (切片), 203
  - 複雑モデル, 564
  - 複数グループでの因子分析, 337
  - 複数グループの同時分析, 147
  - 複数グループの分析, 349
  - 不適解, 378
  - 不等式制約、データ, 445, 451
  - 負の分散, 142
  - フリー パラメータ, 35
  - [プロパティをドラッグ] オプション, 173
  - 分散
    - 不偏推定値, 222
    - ラベル, 174
  - 分散と共分散の等質性, 503
  - 分散と共分散の不偏推定値, 222
  - 分類エラー, 495
- へ
- ベースライン モデル, 587
    - 指定, 588
    - 比較, 573
  - ペアごとの削除, 249

- 平均値と切片
    - モデル作成, 191
  - 平均値と切片項
    - 制限, 343, 350
  - [ 平均値と切片を推定 ] オプション
    - 選択しない場合, 194
    - 選択する場合, 194
  - 平均値に関する仮説の検定, 191
  - ベイジアン推定, 357
    - 追加推定値の, 395
  - ベイジアン法代入, 427
  - ベイズ推定における安定性テスト, 387
  - ベイズ推定における許容性テスト, 387
  - ベイズの信頼区間, 358
  - ベイズの定理, 357
  - 変更
    - 描画領域の方向, 76
    - デフォルト, 223
    - デフォルトの動作, 223
    - フォント, 25
  - 変数
    - 外生, 63, 69, 71
    - 固有, 71
    - 名前の入力, 80
    - 非観測, 73
  - 変数減少法による発見的な探索的モデル特定化, 332
  - 変数増加法による発見的な探索的モデル特定化, 332
- ## ほ
- 飽和, 66
  - 飽和モデル
    - オプション指定, 325
    - 特定不能な係数, 64
    - モデル, 66
  - 母集団の乖離度
    - モデルの妥当性の測度, 567
- ## も
- 網羅的な探索的モデル特定化, 332
  - モデル
    - 新しい制約の追加による改良, 100
    - 安定, 124
    - 一方に対するもう一方の検定, 86
    - 入れ子, 239
    - 因子分析, 209
    - 回帰, 9
    - 棄却, 94
    - 共通因子, 128
    - 構造, 75
    - 個別、グラフィック出力の表示, 109
    - 再帰, 69
    - 識別可能, 66, 252, 255, 280, 563
    - 指定, 11, 35
    - 修正, 94
    - 新規, 10
    - 生成, 341
    - ゼロ, 563
    - 描画, 130
    - 測定, 75, 278
    - 単一分析での複数, 106
    - 単純, 564
    - 同時方程式, 161
    - 特定, 61, 64, 76, 93, 121, 129, 138, 209
    - 独立, 252, 255, 280, 563
    - 内生, 66
    - 非再帰, 69, 119, 120
    - 不安定, 124
    - 複雑, 564
    - 複数、統計の表示, 109
    - 平均値と切片項を使用しない, 337
    - 変数の描画, 11
    - 変数の命名, 12
    - 矢印の描画, 13
  - モデルの指定、グラフィックを使用しない, 529
  - モデル比較
    - Bayes 因子の使用, 303
    - BCC の使用, 299
    - BIC の使用, 302, 321
  - モデルベースの代入, 428
- ## よ
- 予測分布。「事後予測分布」を参照
  - 予測変数, 32
- ## ら
- ラベル
    - 出力, 46
    - 分散と共分散, 174
  - ラベル スイッチング, 510, 528
  - 乱数のシード, 362
  - 乱数変数, 32
- ## り
- リストごとの削除, 249

