

マルチレベルモデル

教育学研究科M1 西村優美子

1


マルチレベルモデル

さまざまな名前ではばれている

- マルチレベルモデル
- 潜在曲線モデル
- 階層線形モデル
- 成長曲線モデル
- 混合効果モデル ...

階層性のあるサンプルの分析に使用

- 例えば...市町村→学校→生徒
学校→生徒→**時点**



2

潜在曲線モデル

各個体から経時的に反復測定したデータの解析に用いる。

✓ 全体のデータを一つにすることで全体の傾向がわかる

⇒ 個体差の情報は失われる

✓ 各個体ごとのデータを直線や曲線で表現

個体ごとにその推移を追うことですべての個体の変化のパターンがわかる

⇒ まとまりがなくなってしまう

① 個人内変化: 個人が時間の経過とともにどう変化するか

② 変化の個人差: 変化の個人差を予測するものは何か

経時変化の個体差を何らかの説明変数で記述

→ 男女、年齢、国籍、環境要因、etc...

この2つを同時に検討する。



これが**潜在曲線モデル**である。

2つのモデル

レベル1 サブモデル_個人成長モデル

- 母集団のメンバーそれぞれが研究期間中に経験する変化を示す

レベル2 サブモデル

- 変化の個人間差を表す曲線と時不変な個人の特徴との関係を記述

例 狩野 裕先生の潜在曲線モデルの解説から引用

[青少年のアルコール消費回数の変化]

図7.1では時間が経過するにつれて増加していることがわかる
 ⇒同時に標準偏差も大きくなっていることがわかる。
 →個人差が顕著に

内4名の個人プロフィールを取りだしてみる(図7.6)
 →人により、傾きも切片も多様であることがわかる。




図 7.1: アルコール消費回数の経時変化 (回答者全体)

図7.1ではこの**個人の違い**を捉え切れていない。

そこで、**潜在曲線モデル**を取り入れる。
 さらに個人差をもたらず説明変数として**性別**を想定してみる。




図 7.6: アルコール消費回数と時間経過 (男女別プロフィール)

5

レベル1 サブモデル 個人成長モデル

まずはじめに、個人のモデルを立てる
 1次式で表せるとすると...

$$Y_{ij} = \beta_{0j} + \beta_{1j}A_{ij} + R_{ij}$$

個人のアルコール消費回数値 個人特有の切片 個人特有の傾き 計測時点 t-1 個人特有の誤差

※もちろん二次式のモデルを立てることも可能。




図 7.6: アルコール消費回数と時間経過 (男女別プロフィール)

6

レベル1 サブモデル


個人成長モデル

$$Y_{ij} = \beta_{0j} + \beta_{1j}A_{ij} + R_{ij}$$

T2における消費回数(Y2)は
 $1.36 + 0.88 \times 1 = 2.24$
 と予測できる。

個人差において、例えば傾きは
 $0.88 \pm 2 \times \sqrt{3.27} \div 0.88 \pm 3.62$
 ぐらいばらついていることがわかる。

※Eは分散(直線の当てはまりの悪さ)を示す。



共分散

7

レベル1 サブモデル

個人成長モデル

$$Y_{ij} = \beta_{0j} + \beta_{1j}A_{ij} + R_{ij}$$

共分散から、切片と傾きの相関が
 算出できる
 (計算過程は省きますが...)

◦ $r = -0.10 \rightarrow$ 有意でない

観測開始時点でアルコール消費
 回数が多い人
 → その後の消費回数の増加率
 も高い

or

観測開始時点でのアルコール消費
 回数が多い人
 → 既にその時点で消費の臨界点
 に達しているから、その後の消費
 回数はあまりのびない

というような関係は見られなかったということになる。




図 7.4: 1 次のモデルの推定結果

共分散

8

レベル2_サブモデル

$$Y_{ij} = \beta_{0j} + \beta_{1j}A_{ij} + R_{ij}$$

$$\begin{cases} \beta_0 = \alpha_0 + \gamma_0 X_4 + d_1 \\ \beta_1 = \alpha_1 + \gamma_1 X_4 + d_2 \end{cases}$$

個人特有の切片 (切片の)切片 (切片の)傾き×(性別)+誤差

個人特有の傾き (傾きの)切片 (傾きの)傾き×(性別)+誤差

測定時点の影響を排除した上で、なんらかの指標が切片や傾きに与える影響を調べることが可能

レベル2_サブモデル

$$\begin{cases} \beta_0 = \alpha_0 + \gamma_0 X_4 + d_1 \\ \beta_1 = \alpha_1 + \gamma_1 X_4 + d_2 \end{cases}$$

傾きや切片に男女差があるとき、説明変数として性別を入れる。

$\gamma_0 \neq 0, \gamma_1 \neq 0$ であれば、男女差があるということになる。
今回女性を $X_4=0$ 、男性を $X_4=1$ としているので、表7.2のようになる。

※誤差 d_1 と d_2 に相関が設定されているのは、切片と傾きの関係が性別だけでは完全に説明できない可能性を考慮。




図 7.7: 説明変数のあるモデル

表 7.2: 切片と傾きの期待値

	$X_4 = 0$ (女性)	$X_4 = 1$ (男性)
$E(\beta_0)$	α_0	$\alpha_0 + \gamma_0$
$E(\beta_1)$	α_1	$\alpha_1 + \gamma_1$

3つの説明変数

説明変数はいくつでも投入可能。

- 年齢
- 親のアルコール依存度...

わかること

- 年齢**
傾きへの影響は認められない。T1の時点では、年齢が1つ上だと0,6消費量は増加。
- 性別**
切片に影響しないが、経年によって増加させる。男性で0.53傾きが上がる。
- 親のアルコール依存度**
経年による増加に影響。切片には影響しない。

この図でのEは分散(直線の当てはまりの悪さ)、Dは誤差(説明変数によって説明しきれなかった程度)を表す。




図 7.8: 3つの説明変数を導入した潜在曲線モデル (推定結果)

2次のモデル

1次だけでなく、2次にも対応

$$x_t = \beta_0 + (t-1)\beta_1 + (t-1)^2\beta_2 + e_t \quad (t = 1, 2, 3)$$

詳しく時点ごとの式に表すと

$$x_1 = \beta_0 + 0 \times \beta_1 + 0 \times \beta_2 + e_1$$

$$x_2 = \beta_0 + 1 \times \beta_1 + 1 \times \beta_2 + e_2$$

$$x_3 = \beta_0 + 2 \times \beta_1 + 4 \times \beta_2 + e_3$$




図 7.9: 2次の項のあるモデル


2次の式を使った例

(Oppenheimer, Measelle, Laurent, & Ablow, 2013)

違う授業で紹介した論文に使われてました。

母親のRSA(呼吸性洞性不整脈)の時系列的変化(10秒ごとの)をグラフ化

- ✓二次成長曲線が線型モデルよりもデータをよりよく説明することがわかった
- ✓切片の説明変数→RSAのベースライン
- ✓1次の傾き、2次の傾きへの有意なパス係数は認められなかった(説明変数はなし)。
- ✓InfantDistressは共変量(MotherCESDは共変量の予測変数)



Final model predicting mothers' still face RSA.

Predictor	Coefficient	SE	p
Intercept (level at time 6)	.107	.008	<.001
Mean baseline RSA	.434	.211	.04
Linear	2.7×10^{-5}	8.8×10^{-5}	.76
Quadratic	-6×10^{-6}	2×10^{-6}	.005
Infant distress	-.005	.002	.03
Mother CESD	.0004	.0002	.02

Amosを用いて

※心理データ解析 補足
説明(2)(小塩真司先生)
のデータを引用

中学1年生から3年生にかけて、毎年あるテストを実施した。

添付したSPSSのようなデータが得られたとする。
2列目からの数字は得点


	被験者	@1年	@2年	@3年
1	1	8	14	16
2	2	11	17	20
3	3	9	16	20
4	4	7	10	19
5	5	8	22	28
6	6	15	22	30
7	7	8	16	25
8	8	9	12	25
9	9	8	14	24
10	10	15	17	14
11	11	3	15	15
12	12	9	14	21
13	13	11	16	18
14	14	13	21	28
15	15	10	20	25
16	16	13	22	23
17	17	13	16	23
18	18	11	17	23
19	19	8	13	18
20	20	9	12	15

AMOSでやってみよう

- ◆はじめに...事前にお渡ししたSPSSのファイルをどこかに保存
- ◆Amosをたちあげる
- ◆プラグイン(P)
→Growth Curve Modelを選択
- ◆Number of time pointsは
今回は中学1～3年時点の
のデータなので3を選択




右図が出てればOK →



15

観測変数の指定と パス係数の固定

- ◆左の図形の中からを選択
→ファイル名をクリック
→先ほど保存したSPSSのファイルを指定
→開く→OK
- ◆を選択(観測変数の指定)
X1に「@1年 1年」をドラッグアンドドロップ
X2.3も同様
→これで観測変数の名前が表示される
- ◆SLOPEから観測変数へのパス係数を
右から順に0,1,2と変更する↓
赤丸のところをダブルクリック
パラメータのタブをクリック→パス係数変更
1年に伸びている矢印の係数を0
2年に伸びている矢印の係数を1
3年に伸びている矢印の係数を2に変更



16


平均値，切片，因子平均の指定

- ◆  を選択
推定のタブの平均値と切片を推定にチェックが入っているか確認
- ◆ 1年、2年、3年のそれぞれの四角のオブジェクトをダブルクリック
切片が0になっていることを確認
- ◆ E1,2,3のオブジェクトをダブルクリック
分散 のところを書いてある“Var”を消去

17

分析の実行

- ◆  を選択
「出力」タブで「標準化推定値」にチェックを入れる。
- ◆  を選択
適当なファイル名をつけて保存しておいてください。
- ◆ 下の赤丸のところをクリック




18

結果_パス図から

こんなパス図が出てきたら、成功です！

傾きの推定値=5.90、切片の推定値=9.96



19

結果_テキスト出力から

を選択すると、Amos出力というところが開く
【推定値を選択】

	推定値	標準誤差	検定統計量	確率	ラベル
ICEPT	9.965	.650	15.342	***	IMean
SLOPE	5.904	.511	11.544	***	SMean

個人の得点は

1年 = 9.965 + 0×5.904 + 誤差
2年 = 9.965 + 1×5.904 + 誤差
3年 = 9.965 + 2×5.904 + 誤差
と表せる！

→傾きと切片の推定値が有意であることがわかる

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
ICEPT <--> SLOPE	-1.284	2.482	-.518	.605	covariance

相関係数: (グループ番号 1 - モデル番号 1)

	推定値
ICEPT <--> SLOPE	-.276

傾きと切片の共分散は有意ではなかった。
相関係数も-.276

→つまり、はじめに得点が高い生徒はその後の伸び率もいいとか
はじめに得点が高い生徒は、伸びしろがあまりなく伸びが悪い
のような関係は有意でなかったということになる。

20

結果_テキスト出力から

モデル適合を選択

カイ2乗値は1.041、有意ではない

CFIは .997、RMSEAは .047

CMIN

モデル	NPAR	CMIN	自由度	確率	CMIN/DF
モデル番号 1	8	1.041	1	.308	1.041
飽和モデル	9	.000	0		
独立モデル	6	15.210	3	.002	5.070

基準比較

モデル	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
モデル番号 1	.932	.795	.997	.990	.997
飽和モデル	1.000		1.000		1.000
独立モデル	.000	.000	.000	.000	.000

RMSEA

モデル	RMSEA	LO 90	HI 90	PCLOSE
モデル番号 1	.047	.000	.611	.319
独立モデル	.463	.250	.705	.002

①カイ自乗値(検定統計量)はより小さく、p値はより大きなものであることが望ましい

②CFIは0.9(0.95)以上だと説得力のあるモデルであると判断可能。

③RMSEAは0.05よりも小さければ、そのモデルが真のモデルに適合していると判断できる

21

説明変数があるバージョン

説明変数がある分析もAmosで実行することが可能です。よければ一度、やってみてください！

- ◆観測変数「年齢」「性別」「親アルコール」を描き相関を設定
- ◆因子「ICEPT」と「SLOPE」間の相関を外す
- ◆これらの観測変数の各々から二つの因子へパスを引く
- ◆誤差変数d1とd2を描き相関を設定

※この解釈ははじめのほうのスライドでした通りです。




図 7.13: 1 次のモデルの推定結果: 説明変数あり

22

引用文献

- ✓菅原ますみ(2012). 縦断データの分析 I – 変化についてのマルチレベルモデリング– 朝倉書店
- ✓潜在曲線モデルの解説(狩野 裕先生) (www.sigmath.es.osaka-u.ac.jp/~kano/research/application/gasshuku02/LCA.pdf)
- ✓初心者による初心者のための「線形混合モデル」(土屋政雄先生) (<http://researchmap.jp/mub50wc3w-32070/?action...action...1...>)
- ✓マルチレベルモデリング(尾崎幸謙先生) (www010.upp.so-net.ne.jp/koken/multilevel.ppt)
- ✓心理データ解析(小塩真司先生) (http://psy.isc.chubu.ac.jp/~oshiolab/teaching_folder/datakaiseki_folder/top_kaiseki.html)
- ✓Oppenheimer, Measelle, Laurent & Ablow (2013). Mothers' vagal regulation during the Still-Face Paradigm: Normative reactivity and impact of depression symptoms, *Infant Behavior and Development*, 36, 255– 267
- ✓豊田秀樹 (2007). 共分散構造分析 Amos編 東京図書