

縦断データをどのように扱ったらよいのか ～統計分析の温故知新～

中京大学 スポーツ科学部
中野 貴博




本日の構成

本日の構成

1. 縦断データとは？
2. 縦断データにおける欠損値の扱い
3. 縦断データにおける分析視点
4. 測定間隔の問題
5. 分析の実際
 - 潜在成長モデル
 - マルチレベル分析

参考文献

- 1) JUDITH D.SINGER & JOHN B.WILLETT 著, 松本聡子 訳 (2012) 縦断データの分析 (1). 朝倉書店.
- 2) 宇佐美慧, 荘島宏二郎 (2015) 発達心理学のための統計学7: 縦断データの分析. 誠信書店.
- 3) 安藤正人 (2011) マルチレベルモデル入門: 実習: 継時データ分析. ナカニシヤ出版.
- 4) いちばんやさしい、医療統計: SPSSで多重代入法を実施するには.
<https://best-biostatistics.com/spss/spss-mi.html>
- 5) 小塩真司 (2020) 研究事例で学ぶSPSSとAmosによる心理・調査データ解析 第3版



縦断データとは？

縦断データ

複数の対象者に対して複数回の時点にわたって集めたデータ

⇒ 2時点から縦断データとも言えるが、
変化の軌跡を描くという観点から、3時点以上が適切

※. 対比として

横断データ：

複数の対象に対して1時点のみのデータ収集

⇒ 一般的に相関や差、構造などが主な分析視点

時系列データ：

限られた特定の対象に対して多数回のデータ収集

20以上から、時には何万点という時点でのデータ収集


⇒ 多くの場合、予測が分析の中心視点になる

縦断データでは、変化が主な分析視点

縦断データとは？

縦断データでは、この図のようにデータ収集が等間隔であることは、理想的であるが、現代の分析手法では必須ではなくなっている

横断データ



縦断データとは？

縦断データの長所

- 交絡要因の影響を排除し易い
 - ⇒ 同一対象者のデータのため、各時点における背景（交絡要因）は原則、同じとみなせる
 - ⇒ 横断データやその繰り返しによる反復横断データでは交絡要因の統制は極めて難しい
- 発達の軌跡（変化）を観察、評価できる
 - ⇒ 特に、変化の個人差を評価できるのが最大の長所
 - ⇒ 対象者を平均化すれば集団としての変化の平均的傾向は示せるしかし、これは縦断データの主目的ではないし、他のデータ形式でも可能な部分がある
- 変化の違い（個人差）の要因を検討できる
 - ⇒ データ収集をしているどこかの時点で、他の変数のデータがあれば、この変数を軌跡（変化）の個人差を与えた要因として検討することができる（cf. 媒介分析など）

縦断データとは？

縦断データの短所

- 時間的，人的，経済的コストがかかる
 - ⇒ データ収集に時間がかかる。また，一般的に人的，経済的コストの負担も横断データに比べると大きくなる
- 統計分析やその解釈が少々，複雑
 - ⇒ 分析は頑張るしかない！（以前に比べれば，ソフトの発展あり）
 - ⇒ 解釈は，丁寧に冷静に見ないと，複雑になる傾向はある
- データの欠損（欠測）が生じやすい
 - ⇒ 長期のデータ収集に伴い，データの欠損割合が高まる
 - ⇒ 変数が多かったり，期間が長かったりすれば，尚更，完全な形の縦断データを得るのは難しく，欠損が多くなる。
 - ⇒ 欠損があってもある程度の分析は可能だが，精度は当然落ちる5年や10年といった水準のデータになれば，半数残れば良い，ぐらゐの発想でのデータ収集計画が必要。 変数が増えれば尚更

縦断データにおける欠損値の扱い

欠損を回避するために

- ① 調査などでは「わからない」の選択肢はやめる
- ② 一定年齢にならないと該当しないような項目は使わない
- ③ 飽きや回答に若干でも抵抗のありそうな項目は避ける
- ④ IDや名前（特に漢字）の入力はミス無くしておく
生年月日のデータが得られるとマッチングの確立は格段にアップする

欠損のタイプ

- ① 完全ランダム欠測（欠損）
⇒ 得られているデータとの関係はなく，無作為かつ等確率で生じる
- ② ランダム欠測（欠損）
⇒ 得られているデータに依存して発生する欠損
- ③ 非ランダム欠測（欠損）
⇒ 欠損したデータに依存して発生する… …正直，扱いづらい


縦断データにおける欠損値の扱い

① 完全データ

	幼児知能			言語理解		
	4歳	5歳	6歳	4歳	5歳	6歳
A児	88	94	91	10	60	80
B児	105	113	108	20	50	50
C児	102	100	103	30	40	90

② 完全ランダム欠測

	幼児知能			言語理解		
	4歳	5歳	6歳	4歳	5歳	6歳
A児	88	94	91	10	60	80
B児	105	113	108	20	50	50
C児	102	100	103	30	40	90



どのデータが欠測するかサイコロを振って決めるようなもの

③ ランダム欠測

	幼児知能			言語理解		
	4歳	5歳	6歳	4歳	5歳	6歳
A児	88	94	91	10	60	80
B児	105	113	108	20	50	50
C児	102	100	103	30	40	90



観測されたデータから欠測の有無を推測できる (A児の4, 5歳時の知能の測定値の低さにより欠測)

④ 非ランダム欠測

	幼児知能			言語理解		
	4歳	5歳	6歳	4歳	5歳	6歳
A児	88	94	91	10	60	80
B児	105	113	108	20	50	50
C児	102	100	103	30	40	90



欠測したデータから欠測の有無を推測できる (言語理解検査ができないことを嫌っての回答拒否)

欠測メカニズムの例 (濃い網掛け部分は欠測)

縦断データにおける欠損値の扱い

欠損値処理の方法


- ① 削除法
- ② 単一代入法
- ③ 多重代入法
- ④ 完全情報最尤推定法

} ちょっと古典的な方法

} 近年では、推奨されている方法

☆ ちょっと模擬データで試してみます

シャトルラン	20m 完全データ	
	8歳	10歳
Aくん	36	47
Bくん	39	52
Cくん	30	38
Dくん	30	33
Eくん	49	68
Fくん	36	40
Gくん	37	45
Hくん	39	46
平均	37.0	46.1
標準偏差	6.0	10.6



上の4つの方法で
復元すると

シャトル	20m 欠損ありデータ	
	8歳	10歳
Aくん	36	47
Bくん	39	
Cくん	30	
Dくん	30	
Eくん	49	68
Fくん	36	40
Gくん	37	
Hくん	39	46

縦断データにおける欠損値の扱い

削除法


欠損のある対象者ごと削除するという、もったいない方法

完全データ

10歳平均：46.1

10歳SD：10.6

20m シャトル	欠損ありデータ	
	8歳	10歳
Aくん	36	47
Bくん	39	
Cくん	30	
Dくん	30	
Eくん	49	68
Fくん	36	40
Gくん	37	
Hくん	39	46




20m シャトル	欠損ありデータ	
	8歳	10歳
Aくん	36	47
Eくん	49	68
Fくん	36	40
Hくん	39	46
平均	40.0	50.3
標準偏差	6.2	12.2

単一代入法+ α

何らかの代表値を代入する方法。


もしくは、得られているデータから作成した回帰式を用いて代入する方法。

20m シャトル	欠損ありデータ	
	8歳	10歳
Aくん	36	47
Bくん	39	
Cくん	30	
Dくん	30	
Eくん	49	68
Fくん	36	40
Gくん	37	
Hくん	39	46



平均値を代入

20m シャトル	欠損ありデータ	
	8歳	10歳
Aくん	36	47
Bくん	39	50.25
Cくん	30	50.25
Dくん	30	50.25
Eくん	49	68
Fくん	36	40
Gくん	37	50.25
Hくん	39	46
平均	37.0	50.3



回帰式で代入
10歳 =
 $1.912 \times 8歳 - 26.241$

20m シャトル	欠損ありデータ	
	8歳	10歳
Aくん	36	
Bくん	39	
Cくん	30	
Dくん	30	
Eくん	49	
Fくん	36	
Gくん	37	
Hくん	39	
平均	37.0	

多重

基本
差分
それを
できた
SPSS

完

10

欠損データ値を代入 *無題4 [missing] - IBM SPSS Statistics データ エディタ

変数 方法 制約条件

代入法 Imputation_ 0

自動(A)
このオプションは、

ユーザー指定(C)
 完全条件指定
この方法は、
最大反復回数

単調
この方法は、
数の順序が、

カテゴリ予測変数に

スケール変数のモデル

線型回帰(L)
 予測平均照合 (PI)
完全なケースを

特異性許容度(S): 1

	Imputation_	シャトラン_8歳	シャトラン_10歳	var	var
1	0 A	36.00	47.00		
2	0 B	39.00			
3	0 C	30.00			
4	0 D	30.00			
5	0 E	49.00	68.00		
6	0 F	36.00	40.00		
7	0 G	37.00			
8	0 H	39.00	46.00		
9	1 A	36.00	47.00		
10	1 B	39.00	40.00		
11	1 C	30.00	46.00		
12	1 D	30.00	46.00		
13	1 E	49.00	68.00		
14	1 F	36.00	40.00		
15	1 G	37.00	46.00		
16	1 H	39.00	46.00		
17	2 A	36.00	47.00		
18	2 B	39.00	40.00		
19	2 C	30.00	46.00		
20	2 D	30.00	46.00		
21	2 E	49.00	68.00		
22	2 F	36.00	40.00		
23	2 G	37.00	46.00		
24	2 H	39.00	46.00		
25	3 A	36.00	47.00		
26	3 B	39.00	40.00		
27	3 C	30.00	46.00		
28	3 D	30.00	46.00		
29	3 E	49.00	68.00		

数]タブで指定した変

だと
させ
それ
い。

概要

概要

データビュー

変数ビュー

ビュー

プ

縦断データにおける分析視点

分析視点

縦断データにおける主な分析視点は、**変化!**

- ① 時間的経過による個人の変化パターンを明らかにしようとする（記述的）
⇒ 線形，非線形，不規則，周期的などなど（個人内）
- ② 予測変数（影響変数）が変化パターンに及ぼす影響
⇒ 予測変数の違いが個々のパターンの違いをうむ？（個人差）

これを階層的にとらえると・・・


レベル1は，個人内の時間的变化・・・傾き

個々の成長の軌跡（上昇，下降など）を描写することがねらい
これを行うことで，軌跡の違いがありそう？何が影響している？
などの疑問点が見えてくる

レベル2は，時間的变化の個人差

個々の変化パターンは，何かしらの要因で変わっている？
レベル1で疑われた変化パターンの不均一性について，予測変数
（影響変数）で説明できる？ ⇒⇒ 個々の変化パターンと予測変数の関

縦断データにおける分析視点



赤線と青線の変化パターンのはなぜ生じる？

予測変数による違いを考える
⇒ レベル

測定間隔の問題

ちょっと気になる点 ⇒ データ収集の間隔の問題はどう??

理想は・・・

等間隔で収集されたデータが魅力的であることは事実。
反復測定分散分析などでは、必須になるが・・・

現実的には・・・

すべてを等間隔で考えると、データ収集のハードルは上がる
ある期間、変化が想定されない場合は、間隔をあける
逆に大きな変化が想定される場合は、データ収集回数を増やす
⇒ 結果的には、描画すれば軌跡は見える！
⇒ 軌跡が見えれば、個人差を与えた要因を考えるには
十分（いわゆる、リサーチクエスチョンにつながる？）

あとは、影響変数との関係を見る際の統計モデルの問題かな？

結果に最も影響をあたえるであろうリズムや間隔を
保持したデータ収集をする

ここからは、ちょっとデータを
増やして実際の分析手続きを
やってみようと思います

模擬データの概要

20人の児童の20mシャトルランのデータ

- 縦断データ：小学校1年から6年の毎年のデータ（年一回同時期）
- 予測変数1：1年生時点での運動実施時間（3件法：長・並・短）
- 予測変数2：4年生時点での成熟年齢（暦年齢以上／暦年齢以下）

データセットの形式

個人一時点のデータセットを使う！

⇒ 各個人が複数のレコードを持っている形式

ID	1年	2年	3年	4年	5年	6年
ID 1	15	19	26	42	55	69
ID 2	14	22	30	44	55	68
ID 3	25	35	45	49	54	59





















こっちはあまり推奨できない！
AMOSではこれでもできる























こちらの形式が基本

ID	学年	記録	予測変数
ID 1	1	15	1
ID 1	2	19	1
ID 1	3	26	1
ID 1	4	42	1
ID 1	5	55	1
ID 1	6	69	1
ID 2	1	14	2
ID 2	2	22	2
ID 2	3	30	2
ID 2	4	44	2
ID 2	5	55	2
ID 2	6	68	2
ID 3	1	25	3
ID 3	2	35	3
ID 3	3	45	3
ID 3	4	49	3
ID 3	5	54	3
ID 3	6	59	3



個人内の変化をプロット&軌跡



近似直線を当てはめてみる



平均的な変化と比較して…



分析の実際（視点の整理）

ここまで来たら、次は時間的变化の個人差（レベル2）の段階

- ⇒ 1. 变化の個人差をパラメータで検討する。
- 2. 予測変数（影響変数）との関係を検討する。
 - ※. 軌跡を示すパラメータを使ってクラスターなどを適用も。

検討に用いるパラメータ

- ⇒ 切片：初期値に差があるかどうか
 - ⇒ 傾き：変化率に差があるかどうか
- } 両者の相関も検討可

※. 非線形などでは、軌跡を示す関数の係数を用いることができる
次数を上げた当てはめでは、何次の係数に差があるかで、時点
や期間の定義が一定程度可能になるかも

推定された切片と傾きの標本平均値や標本分散

⇒ 全体の把握や比較につながる

予測変数の群ごとの切片と傾きの標本平均値や標本分散

⇒ 予測変数による变化の個人差が見られる

縦断データにおける分析視点

ID 切片 傾き 運動実施時間

ID 1	9.524	11.257	1
ID 2	11.476	10.943	2
ID 3	28.000	6.600	3
ID 4	7.762	9.629	1
ID 5	3.905	9.571	1
ID 6	14.857	7.657	2
ID 7	12.286	7.486	2
ID 8	15.750	7.650	2
ID 9	8.400	11.400	1
ID 10	29.762	7.229	3
ID 11	5.952	7.286	1
ID 12	32.048	6.314	3
ID 13	11.286	6.486	2
ID 14	15.571	7.771	2
ID 15	30.714	6.714	3
ID 16	24.762	8.029	3
ID 17	6.524	7.857	1
ID 18	19.190	6.657	3
ID 19	13.381	7.514	2
ID 20	6.857	5.657	1



切片 (初期値) 傾き (変化率)

平均値	15.40	7.99
標準偏差	9.00	1.68
相関係数	-0.449	
運動実施時間 (短)	平均値 6.99	8.95
	標準偏差 1.82	2.12
	相関係数 0.302	
運動実施時間 (並)	平均値 13.52	7.93
	標準偏差 1.90	1.40
	相関係数 -0.229	
運動実施時間 (長)	平均値 27.41	6.92
	標準偏差 4.75	0.62
	相関係数 -0.254	

分析の実際

反復測定分散分析ではだめ？

データが整っていれば十分に有効だと思う。ただし、後述する分析における利点を考慮し、分析モデルの適用も要検討。ただし、難しいモデルが良いということではなく、データや仮説にあっていれば従来の分析でも大きな問題はないと個人的には思う

潜在成長（曲線）モデル

共分散構造分析の枠組みの中で縦断データに合ったモデルを構築して検証できる強力な分析モデル。切片や傾きの意味合いをしっかりと理解して用いれば解釈も比較的容易

⇒ とても有効なツールだが、しっかりした仮説が重要と思う

マルチレベル分析

近年、適用が増えてきている分析モデル。階層線型モデルとか線型混合モデルは同じ意味で呼ばれる。従来型の分散分析（交互作用の検定含む）の混合モデルと手続き的にはほぼ同じだが、マルチレベルモデルに比べいくつかの利点がある。

⇒ データ収集のタイミングに柔軟対応。つまり欠損による無駄も少ない


⇒ 個人差をモデルに組み込める。

⇒ 時間を定義する変数を連続尺度とすることでトレンドを議論

分析の実際（反復測定分散分析）

反復測定分散分析

まずは反復測定分散分析で学年間の差を検定してみました。



反復測定分散分析を行った所、学年間で有意な差が確認された。また、多重比較検定の結果、全ての学年間で有意な差が確認された。

恐らく、これに予測変数の要因を加えて、交互作用の検定などを用いれば、一定程度のことは十分に言える。

分析の実際（相互相関）

変数間の相関

さらに、学年間の相関係数も確認してみました。

	運動実施時間	1年	2年	3年	4年	5年	6年
運動実施時間	1.00	0.84	0.88	0.87	0.75	0.57	0.35
1年	-	1.00	0.97	0.94	0.89	0.81	0.66
2年	-	-	1.00	0.98	0.91	0.79	0.60
3年	-	-	-	1.00	0.94	0.83	0.62
4年	-	-	-	-	1.00	0.91	0.76
5年	-	-	-	-	-	1.00	0.94
6年	-	-	-	-	-	-	1.00

相関係数を確認したところ、学年間ではいずれも有意な相関が確認された。また、予測変数である運動実施時間との間にもいずれも有意な相関が確認されたが、学年が進むにつれて相関が弱くなる傾向が確認された。

分析の実際（潜在成長モデル）

潜在成長（曲線）モデル

共分散構造分析における潜在成長モデルをあてはめてみました。

切片と傾きの推定値平均は


切片：15.593

傾き：7.933

シャトラン = $7.933 \times \text{学年} + 15.593$

ただ、ちょっと適合度が悪い？

- ① データ数の問題（模擬データなので…）
- ② 縦断データの系列相関の設定
- ③ 推定モデルが非線形？
- ④ 潜在クラスが存在（予測変数なども考慮）



分析の実際（潜在成長モデル）


潜在成長（曲線）モデル（誤差間/

ということで、
誤差間に相関を設定してみました。

切片と傾きの推定値平均は
切片：15.829
傾き：7.814

シャトラン = $7.814 \times \text{学年} + 15.829$

だいぶ適合度も改善しました。
ちょっと他の方法も試してみます。




CFI=.821

分析の実際（潜在成長モデル）

潜在成長（曲線）モデル（2次）

モデルを二次関数（非線形）
にしてみました。



これは、全く適合度が上がらず、
むしろ下がっている。

⇒ モデルは線形で良さそう！

分析の実際（条件付き潜在成長モデル）

条件（予測変数）付き潜在成長モデル

続いて、潜在クラスを想定して、
予測変数を導入してみました。

ここでは、2つ用意してみました。


- ① 1年生時点での運動実施時間
- ② 4年生時点での成熟年齢

さらに適合度があがりました。

CFI : 0.821 \Rightarrow 0.832

RMSEA : 0.382 \Rightarrow 0.350

運動実施時間で、特に切片（初期値）
に強い影響がありそう



CFI=0.832

分析の実際（条件付き潜在成長モデル）

条件（予測変数）付き潜在成長モデル

次に、4年生時点での成熟年齢を予測変数として、設定してみました。


- ① 1年生時点での運動実施時間
- ② 4年生時点での成熟年齢

適合度は、改善しませんでした。

CFI : 0.821 \Rightarrow 0.809

RMSEA : 0.382 \Rightarrow 0.361

適合度はあがりませんでした。が、成熟年齢から傾きへのパス係数は高くなっていたことから、4年生時点での成熟年齢は、その後の記録の伸びに影響がありそう。



CFI=.809

分析の実際（条件付き潜在成長モデル）

条件（予測変数）付き潜在成長モデル

最後に、両方の予測変数を設定してみました。


- ① 1年生時点での運動実施時間
- ② 4年生時点での成熟年齢

適合度が一部であがりました。

CFI : 0.821 \Rightarrow 0.832 \Rightarrow 0.828

RMSEA : 0.382 \Rightarrow 0.350 \Rightarrow 0.331



運動実施時間は切片（初期値）に、
4年生時点での成熟年齢はその後の記録の伸びに影響がある。



分析の実際（条件付き潜在成長モデル）

条件（予測変数）付き潜在成長モデル

ということで、条件に合わせてグラフ化すると



分析の実際（マルチレベル分析）

マルチレベル分析

階層構造を有するデータに適用できる分析手法

- ⇒ 例えば，階層1：児童，階層2：学級：階層3：学校
- ⇒ 各階層をレベルとして表現することからマルチレベル分析
 - ⇒ 階層線形モデルとか線形混合モデルは同義

縦断データでは，どう考えるか？

- ⇒ レベル1：時期，レベル2：個人

基本的な手続きは，潜在成長モデルに類似

- ⇒ 全体での回帰直線の推定 → 切片・傾き：固定効果
潜在成長モデルに類似
- ⇒ ランダム切片モデル → 切片分散：変量効果，傾き：固定効果
- ⇒ ランダム傾きモデル → 切片：固定効果，傾き分散：変量効果
- ⇒ ランダム係数モデル → 切片分散：変量効果，傾き分散：変量効果

条件付き潜在成長モデルに類似

分析の実際（マルチレベル分析）

マルチレベル分析の縦断データへの応用

縦断データでは、どう考えるか？

⇒ レベル1：時期, レベル2：個人

模擬データに当てはめて考えると・・・

学年（Grade）＝ 時期

ID＝ 個人

20mシャトルランの記録＝ 従属変数

運動実施時間＝ 予測変数（個の特性）

- ① 全体の切片＋運動時間 i 群の学生 j の偏差＋誤差（ヌルモデル）
- ② ①のモデルに時期（傾き）を説明変数として追加したモデル
- ③ ②のモデルに傾きと切片の無相関を仮定
- ④ ②のモデルに傾きと切片の相関を仮定（無構造）
- ⑤ 運動実施時間という個の特性によって切片と傾きが変化するモデル

分析の実際（マルチレベル分析）

マルチレベル分析（切片と傾き（時期）を説明変数）

全体での切片と傾きを推定し，個人間の偏差を組み込んだモデル
パラメータ推定値

	推定値	標準誤差	自由度	t値	p値
切片（全体）	15.593	1.983	19	7.863	<0.001
傾き（全体）	7.933	0.347	19	22.876	<0.001

固定効果の検定

要因	F値	p値
傾き	523.32	<0.001

学年がシャトルランの結果に
有意に影響している

※. 各グループごとのバラつき（変量効果）を考慮し
ても、全体として見たときに右上がりのトレンド

切片と傾きの共分散は， -4.652 ($p=0.174$)

統計的に有意ではないが負の値なので切片が大きくなると傾きが小さくなる傾向を示している。

適合度：AIC = 696.658 BIC = 707.741

分析の実際（マルチレベル分析）

マルチレベル分析（切片と傾き（時期）を説明変数）

SPSSはMIXEDモデル（Syntax）

```
MIXED shuttle_run BY ID WITH Grade_1  
  /METHOD = REML  
  /FIXED = Grade_1  
  /RANDOM = INTERCEPT Grade_1 |  
SUBJECT(ID) COVTYPE(UN)  
  /PRINT = SOLUTION TESTCOV.
```

Rのパッケージはlmer4, lmerTest

```
m001 <- lmer (shuttle_run ~ Grade_1 + (1 + Grade_1 | ID), data=MLdata)  
summary (m001)  
anova (m001)
```

出力はSPSSの方が丁寧でわかりやすい

分析の実際（マルチレベル分析）

マルチレベル分析（運動時間によって切片と傾きが変化）

個人の運動実施時間（予測変数）によって切片と傾きが変化するモデル
パラメータ推定値

	推定値	標準誤差	自由度	t値	p値
切片（全体）	16.156	0.752	17	21.478	<0.001
切片（運動：短）	7.783	1.268	17	6.137	<0.001
切片（運動：並）	13.272	1.268	17	10.466	<0.001
切片（運動：長）	27.413	1.37	17	20.014	<0.001
傾き（全体）	7.885	0.322	17	24.490	<0.001
傾き（運動：短）	8.735	0.543	17	16.093	<0.001
傾き（運動：並）	7.996	0.543	17	14.732	<0.001
傾き（運動：長）	6.924	0.586	17	11.810	<0.001

固定効果の検定

要因	F値	p値
運動時間	57.877	<0.001
傾き	599.768	<0.001
運動時間×学年	2.58	0.105

学年および運動時間がシャトルランの結果に有意に影響
交互作用は有意ではない

分析の実際（マルチレベル分析）

マルチレベル分析（運動時間によって切片と傾きが変化）

多重比較（切片/傾き）

水準	切片の差	p値	傾きの差	p値
運動：短－並	-5.49	0.007	0.74	0.349
運動：短－長	-19.63	<0.001	1.81	0.037
運動：並－長	-14.14	<0.001	1.07	0.197

初期の運動時間が短いほど切片が有意に低くなっている

初期の運動時間が短い群は長い群に比べて傾きが有意に大きい

⇒ 全体的には初期の運動時間が短い群の方が傾きが大きい

切片と傾きの共分散は、1.527 (p=0.198)

正の値なので切片が大きくなると傾きが大きくなる傾向だが、統計的に有意ではない上に値も小さめ。

適合度：AIC = 647.926 BIC = 658.871

AIC、BICともにこのモデルが最小 ⇒ このモデルで解釈

分析の実際（マルチレベル分析）

マルチレベル分析（運動時間によって切片と傾きが変化）

```
MIXED shuttle_run BY ID PAtime WITH Grade_1
  /METHOD = REML
  /FIXED = PAtime Grade_1 PAtime*Grade_1
  /RANDOM = INTERCEPT Grade_1 | SUBJECT(ID) COVTYPE(UN)
/TEST = 'Intercept(ENT)'
  INTERCEPT 1 PAtime 1/3 1/3 1/3;
  INTERCEPT 1 PAtime 1 0 0;
  INTERCEPT 1 PAtime 0 1 0;
  INTERCEPT 1 PAtime 0 0 1
/TEST = 'Slope(ENT)'
  Grade_1 1 PAtime*Grade_1 1/3 1/3 1/3;
  Grade_1 1 PAtime*Grade_1 1 0 0;
  Grade_1 1 PAtime*Grade_1 0 1 0;
  Grade_1 1 PAtime*Grade_1 0 0 1
/TEST = 'Intercept(diff)'
  PAtime 1 -1 0;
  PAtime 1 0 -1;
  PAtime 0 1 -1
/TEST = 'Slope(diff)'
  PAtime*Grade_1 1 -1 0;
  PAtime*Grade_1 1 0 -1;
  PAtime*Grade_1 0 1 -1
```

分析の実際（マルチレベル分析）

マルチレベル分析（運動時間によって切片と傾きが変化）

Rのパッケージはlmer4, lmerTest

```
m001 <- lmer (shuttle_run ~ PAtime*Grade_1 + (1 + Grade_1 | ID),  
data=MLdata)  
summary (m001)  
anova (m001)
```

分析の実際（最終解釈）

模擬データですが，一応，解釈まとめてみます。

- いずれの分析結果を見ても，学年間での有意な相関（系列相関）が認められる。また，学年間の記録には有意な差がある。
- 学年（時の変数）による20mシャトルランの記録への回帰は有意な切片および傾きが得られる。また，回帰モデルは線形回帰。

ここからは，予測変数を含めたメインの結果です。

- 予測変数としては初期段階での運動時間が有意な効果があり，特に切片に高い効果。傾きにも効果はある。
- 4年生時点の成熟年齢は傾きには効果が見られるが，運動時間のみの予測変数とするモデルが最良。
- 切片と傾きにはわずかに関係が見られ，切片が大きくなると傾きが小さくなる傾向。つまり，初期の運動時間が長い方が上昇率は下がるが，最終的に逆転するほどの差ではない。⇒ 若干の早熟傾向？
- 初期の運動時間が短いほど切片が有意に低い
初期の運動時間が短い群は長い群に比べて傾きが有意に大きい

まとめ

- ① 従来の反復測定分散分析に始まり様々な分析モデルが提案されていますが、データにあった分析の適用が大切。
- ② 分散分析などの従来型の方法が悪いということはない
⇒ 整ったデータであれば、むしろ結果は頑健
- ③ 潜在成長曲線やマルチレベル分析などは、モデルとしては非常に柔軟かつデータの欠損などにも柔軟に対応できるというメリットがある
⇒ しかし、有るデータで回帰を引くことになるので、粗さに目をつぶるべきではないと個人的には思う
- ④ 一番大切なのは良いデータを収集する努力
欠損が少なくしっかり時間構造化されたデータであれば複雑なモデルに頼る必要性はない。むしろ、統計モデルありきの結論導出には疑問あり