

第 14 章: 発展的なパネルデータ法

Jeffrey Wooldridge (2016).

Introductory Econometrics: A Modern Approach
Seventh Edition. Cengage Learning.

2026-03-06

準備

必要なパッケージの読み込み

- ▶ `wooldridge` パッケージの読み込み

```
library(wooldridge)
```

- ▶ `plm` パッケージの読み込み (パネルデータ分析に使用)

```
library(plm)
```

14-1 固定効果推定

固定効果変換 (Fixed Effects Transformation)

- ▶ モデル: $y_{it} = \beta_1 x_{it} + a_i + u_{it}, \quad t = 1, 2, \dots, T$ [14.1]
- ▶ 個体 i に関して時間平均をとると:

$$\bar{y}_i = \beta_1 \bar{x}_i + a_i + \bar{u}_i [14.2]$$

- ▶ [14.1] から [14.2] を引く (固定効果変換 / within 変換):

$$\ddot{y}_{it} = \beta_1 \ddot{x}_{it} + \ddot{u}_{it}, \quad t = 1, 2, \dots, T [14.3]$$

- ▶ $\ddot{y}_{it} = y_{it} - \bar{y}_i$: 時間平均除去データ (time-demeaned data)
- ▶ a_i が消去される \Rightarrow OLS で β_1 を一致推定できる

固定効果推定量の特性

- ▶ [14.3] を Pooled OLS で推定したものが**固定効果推定量 (within 推定量)**
- ▶ **時間不変の変数** (出生地、性別など) は時間平均除去によって消去され、推定不可能
- ▶ 厳密外生性仮定 ($E(u_{it} | \mathbf{X}_i, a_i) = 0$) のもとで不偏・一致
- ▶ a_i と x_{it} が任意に相関していても構わない (第 13 章の FD と同じ強み)
- ▶ 自由度: $df = NT - N - k = N(T - 1) - k$ (時間平均除去により個体ごとに自由度を 1 失う)

複数の説明変数への拡張

- ▶ 一般的な観測不能効果モデル [14.4]:

$$y_{it} = \beta_1 x_{it1} + \beta_2 x_{it2} + \cdots + \beta_k x_{itk} + a_i + u_{it}$$

- ▶ 各変数を時間平均除去 \Rightarrow [14.5]:

$$\ddot{y}_{it} = \beta_1 \ddot{x}_{it1} + \beta_2 \ddot{x}_{it2} + \cdots + \beta_k \ddot{x}_{itk} + \ddot{u}_{it}$$

- ▶ これを Pooled OLS で推定する

例 14.1: 職業訓練が不良品率に与える影響 (JTRAIN)

- ▶ データ: 54 社 × 3 年 (1987~1989 年)
- ▶ 従属変数: $\log(\text{scrap}_{it})$ (不良品率の対数)
- ▶ 説明変数: 年ダミー $d88, d89$, 補助金 grant , ラグ補助金 grant_{-1}
- ▶ $df = 54(3 - 1) - 4 = 104$

```
data(jtrain)
pdata_jt <- pdata.frame(jtrain, index = c("fcode", "year"))
res_fe141 <- plm(lscrap ~ d88 + d89 + grant + grant_1,
                 data = pdata_jt, model = "within",
                 na.action = na.omit)
summary(res_fe141)$coefficients
```

```
##           Estimate Std. Error   t-value   Pr(>|t|)
## d88      -0.08021567  0.1094751 -0.7327297 0.46537158
## d89      -0.24720279  0.1332183 -1.8556220 0.06633916
## grant    -0.25231487  0.1506290 -1.6750751 0.09692392
## grant_1  -0.42158951  0.2102000 -2.0056593 0.04748974
```

例 14.1: 結果の解釈

- ▶ $\hat{\beta}_{grant_{-1}} \approx -0.422$: 前年に補助金を受けると不良品率が約 34%低下 [$\exp(-0.422) - 1 \approx -0.344$]、5%水準で有意
- ▶ $\hat{\beta}_{grant} \approx -0.252$: 当年補助金は 10%水準で有意 (即時効果は小さい)
- ▶ d_{89} の係数が負 \Rightarrow 補助金とは無関係に 1989 年の生産性は上昇 \Rightarrow 年ダミーを含めることの重要性

例 14.2: 教育収益率の時間変化 (WAGEPAN)

- ▶ データ: 545 人 × 8 年 (1980~1987 年)、WAGEPAN
- ▶ 固定効果では educ (時間不変) は推定不可 ⇒ educ × 年ダミーの交差項を使用

```
data(wagepan)
pdata_wp <- pdata.frame(wagepan, index = c("nr", "year"))
res_fe142 <- plm(lwage ~ married + union + exper + expersq +
                d81 + d82 + d83 + d84 + d85 + d86 + d87 +
                I(educ * d81) + I(educ * d82) + I(educ * d83) +
                I(educ * d84) + I(educ * d85) + I(educ * d86) +
                I(educ * d87),
                data = pdata_wp, model = "within")
# 交差項の係数のみ表示
coef(res_fe142)[grep("educ", names(coef(res_fe142)))]
```

```
## I(educ * d81) I(educ * d82) I(educ * d83) I(educ * d84) I(educ * d85)
## 0.004990619 0.001650951 -0.002662147 -0.009825689 -
0.009214474
## I(educ * d86) I(educ * d87)10
```

例 14.2: 解釈

- ▶ $d87 \cdot educ$ の係数 ≈ 0.030 ($t \approx 2.48$): 最大
- ▶ 1987 年の教育収益率は基準年 (1980 年) より約 3%ポイント高い
- ▶ 交差項 7 本の結合有意性検定: p 値 ≈ 0.28 (まとめて有意でない)
- ▶ 教育収益率は 1980~1987 年を通じてほぼ一定という結論

14-1a ダミー変数回帰

ダミー変数回帰 (Dummy Variable Regression)

- ▶ a_i を各個体のパラメータとして推定する伝統的な方法
- ▶ N 個の切片ダミー変数を説明変数に含めて OLS 推定 \Rightarrow **ダミー変数回帰**
- ▶ **重要な性質:** ダミー変数回帰は固定効果推定量と全く同じ $\hat{\beta}_j$ を与える
- ▶ 固定効果推定後、各個体の固定効果の推定値 [14.6]:

$$\hat{a}_i = \bar{y}_i - \hat{\beta}_1 \bar{x}_{i1} - \dots - \hat{\beta}_k \bar{x}_{ik}$$

- ▶ N が大きい場合、ダミー変数回帰は非実用的 (変数が多すぎる)

14-1b 固定効果 vs 1 階差分

固定効果法 (FE) と 1 階差分法 (FD) の比較

特徴	FE (固定効果)	FD (1 階差分)
$T = 2$ のとき	同一	同一
$T \geq 3$ のとき	異なる推定量	異なる推定量
u_{it} が系列無相関	効率的	非効率
u_{it} がランダムウォーク	非効率	効率的
測定誤差に対する感度	高い	高い

- ▶ $T = 2$: FE と FD は同一 \Rightarrow どちらでも良い
- ▶ $T \geq 3$: u_{it} の系列相関構造で選択
 - ▶ 系列無相関 \Rightarrow FE が優れる
 - ▶ ランダムウォーク的の正の系列相関 \Rightarrow FD が優れる

14-1c 不均衡パネル

不均衡パネルの固定効果推定

- ▶ **不均衡パネル (unbalanced panel):** 一部の個体で欠損期間がある
- ▶ 個体 i の観測期間数を T_i とすると、総観測数
 $= T_1 + T_2 + \dots + T_N$
- ▶ 時間平均除去は個体ごとに T_i 期間の平均を使う
- ▶ 固定効果推定は不均衡パネルでも同様に適用可能
- ▶ 注意: 欠損が**自己選択的** (離脱が誤差項と相関) な場合はバイアスが生じる
 - ▶ ただし FE は a_i と選択指標の相関を許容するため、FD より頑健な場合がある

例 14.3: 不均衡パネルでの職業訓練効果 (JTRAIN)

- ▶ sales (売上の対数) と employ (従業員数の対数) を追加
- ▶ 3 社が完全に脱落、5 観測が追加欠損 $\Rightarrow n = 148$

```
res_fe143 <- plm(lscrap ~ d88 + d89 + grant + grant_1 +
                lsales + lemploy,
                data = pdata_jt, model = "within",
                na.action = na.omit)
summary(res_fe143)$coefficients[c("grant", "grant_1"), ]
```

```
##           Estimate Std. Error  t-value  Pr(>|t|)
## grant    -0.2967542  0.1570861 -1.889119 0.06206040
## grant_1  -0.5355783  0.2242060 -2.388778 0.01896951
```

- ▶ $\hat{\beta}_{grant} \approx -0.297$ 、 $\hat{\beta}_{grant_1} \approx -0.536$: 基本結果と整合的

14-2 変量効果モデル

変量効果モデルの設定

- ▶ 同じ不観測効果モデルから出発 [14.7]:

$$y_{it} = \beta_0 + \beta_1 x_{it1} + \cdots + \beta_k x_{itk} + a_i + u_{it}$$

- ▶ 変量効果 (RE) の仮定 [14.8]:

$$\text{Cov}(x_{itj}, a_i) = 0, \quad t = 1, \dots, T; \quad j = 1, \dots, k$$

- ▶ a_i がすべての説明変数と無相関と仮定 $\Rightarrow a_i$ を誤差項に含める
- ▶ 合成誤差項: $v_{it} = a_i + u_{it}$
- ▶ a_i が各期間の誤差に入るため、 v_{it} は時間を通じて正の系列相関を持つ

GLS 変換 (準時間平均除去)

- ▶ 合成誤差の系列相関を除去するため一般化最小二乗法 (GLS) を適用
- ▶ 変換パラメータ [14.10]:

$$\theta = 1 - [\sigma_u^2 / (\sigma_u^2 + T\sigma_a^2)]^{1/2}$$

- ▶ 変換後の方程式 [14.11]:

$$y_{it} - \theta \bar{y}_i = \beta_0(1 - \theta) + \beta_1(x_{it1} - \theta \bar{x}_{i1}) + \dots + (v_{it} - \theta \bar{v}_i)$$

- ▶ **quasi-demeaned (準時間平均除去)** データに基づく Pooled OLS \Rightarrow **変量効果推定量**
- ▶ $\theta = 0$: Pooled OLS と同一
- ▶ $\theta = 1$: 固定効果推定量と同一

例 14.4: 賃金方程式 (WAGEPAN)

▶ 3 手法 (Pooled OLS, RE, FE) の比較

Pooled OLS (参考)

```
res_pols <- plm(lwage ~ educ + black + hisp + exper + expersq +  
               married + union +  
               d81 + d82 + d83 + d84 + d85 + d86 + d87,  
               data = pdata_wp, model = "pooling")
```

変量効果 (RE)

```
res_re <- plm(lwage ~ educ + black + hisp + exper + expersq +  
             married + union +  
             d81 + d82 + d83 + d84 + d85 + d86 + d87,  
             data = pdata_wp, model = "random")
```

固定効果 (FE)

```
res_fe <- plm(lwage ~ expersq + married + union +  
             d81 + d82 + d83 + d84 + d85 + d86 + d87,  
             data = pdata_wp, model = "within")
```

例 14.4: 結果の比較

```
# 時間変動変数の係数比較
vars <- c("expersq", "married", "union")
rbind(
  POLS = coef(res_pols)[vars],
  RE    = coef(res_re)[vars],
  FE    = coef(res_fe)[vars]
)
```

```
##           expersq    married      union
## POLS -0.002411703  0.10825295  0.18246128
## RE   -0.004723943  0.06398602  0.10613443
## FE   -0.005185498  0.04668036  0.08000186
```

例 14.4: 解釈

- ▶ $\hat{\theta} \approx 0.643$: RE は Pooled OLS と FE の中間
- ▶ married の係数: POLS(0.108) > RE(0.064) > FE(0.047)
 - ▶ 能力の高い人が結婚しやすい \Rightarrow POLS/RE は上方バイアス
- ▶ union の係数: POLS(0.182) > RE(0.106) > FE(0.080)
 - ▶ 組合効果の一部は個人固有特性に起因
- ▶ FE では educ, black, hispan は時間不変のため推定不可

14-2a 変量効果 vs Pooled OLS

変量効果と Pooled OLS の選択

- ▶ Breusch-Pagan (1980) 検定: $H_0 : \sigma_a^2 = 0$ (個体効果が存在しない)
- ▶ $\sigma_a^2 = 0$ なら観測不能効果なし \Rightarrow Pooled OLS が適切
- ▶ ただし、この検定はあくまで $\sigma_a^2 > 0$ を確認するもの
 - ▶ $\sigma_a^2 > 0$ でも a_i が x_{it} と相関していれば RE/POLS ともに不一致
- ▶ **実務上の含意:** RE は Pooled OLS より好まれることが多い (特に誤差構造が RE 仮定に近い場合)
 - ▶ 系列相関の除去により効率的
 - ▶ a_i の一部を誤差項から除去 \Rightarrow バイアスを軽減

14-2b 変量効果 vs 固定効果

FE vs RE の選択基準

- ▶ **FE:** a_i と x_{it} が相関していてもよい \Rightarrow より頑健
- ▶ **RE:** a_i と x_{it} が無相関という仮定が必要 \Rightarrow 効率的 (標準誤差が小さい)
- ▶ **RE を選ぶ場合:** 主要な説明変数が時間不変 (例: educ) \Rightarrow FE では推定不可
- ▶ **Hausman (1978) 検定:** RE 仮定 [14.8] が成立しているか検定

$$H_0 : \text{Cov}(x_{itj}, a_i) = 0 \quad \forall j$$

Hausman 検定の実施

```
# Hausman 検定 (同じ変数セットで FE と RE を推定)
```

```
res_re_h <- plm(lwage ~ expersq + married + union +  
               d81 + d82 + d83 + d84 + d85 + d86 + d87,  
               data = pdata_wp, model = "random")  
res_fe_h <- plm(lwage ~ expersq + married + union +  
               d81 + d82 + d83 + d84 + d85 + d86 + d87,  
               data = pdata_wp, model = "within")  
phtest(res_fe_h, res_re_h)
```

```
##
```

```
## Hausman Test
```

```
##
```

```
## data: lwage ~ expersq + married + union + d81 + d82 + d83 + d84 + d
```

```
## chisq = 37.01, df = 10, p-value = 5.637e-05
```

```
## alternative hypothesis: one model is inconsistent
```

▶ p 値が小さい \Rightarrow RE 仮定を棄却 \Rightarrow FE を採用

14-3 相関変量効果アプローチ

CRE アプローチの基本アイデア

- ▶ a_i が観測変数と相関することを明示的にモデル化
- ▶ a_i と $\{x_{it}\}$ の相関を、時間平均 \bar{x}_i との線形関係で表す [14.12]:

$$a_i = \alpha + \gamma \bar{x}_i + r_i, \quad \text{Cov}(\bar{x}_i, r_i) = 0$$

- ▶ これを元のモデルに代入 [14.14]:

$$y_{it} = \alpha + \beta x_{it} + \gamma \bar{x}_i + r_i + u_{it}$$

- ▶ \bar{x}_i を追加して RE 推定 \Rightarrow 相関変量効果 (CRE) 推定量

CRE と FE の等価性

- ▶ **重要な結果 [14.16]: CRE 推定量は FE 推定量と同一**

$$\hat{\beta}_{CRE} = \hat{\beta}_{FE}$$

- ▶ CRE アプローチの利点:
1. **時間不変変数の係数**を推定できる (δ_j として)
 2. **RE vs FE 検定**の形式的な枠組みを提供 ($H_0 : \gamma = 0$)
 3. 不均衡パネルへの拡張が容易

CRE の推定: WAGEPAN

```
# 時間変動変数の個体平均を計算
wagepan$mean_expersq <- ave(wagepan$expersq, wagepan$nr)
wagepan$mean_married <- ave(wagepan$married, wagepan$nr)
wagepan$mean_union   <- ave(wagepan$union, wagepan$nr)

pdata_wp2 <- pdata.frame(wagepan, index = c("nr", "year"))

res_cre <- plm(lwage ~ expersq + married + union +
               mean_expersq + mean_married + mean_union +
               d81 + d82 + d83 + d84 + d85 + d86 + d87,
               data = pdata_wp2, model = "random")
# 時間平均変数の係数 (γ の推定値)
coef(res_cre)[c("mean_expersq", "mean_married", "mean_union")]

## mean_expersq mean_married mean_union
## 0.003212666 0.161764098 0.161241547
```

CRE: RE vs FE の検定

- ▶ $H_0 : \gamma_1 = \gamma_2 = \dots = \gamma_k = 0$ (RE で十分) [14.19]
- ▶ 時間平均変数 $\bar{x}_{i1}, \dots, \bar{x}_{ik}$ が全て統計的に有意でなければ RE を採用

```
# 時間平均変数の結合有意性検定 (Wald 検定)
```

```
library(car)
```

```
linearHypothesis(res_cre,  
                  c("mean_expersq = 0",  
                    "mean_married = 0",  
                    "mean_union = 0"))
```

```
##
```

```
## Linear hypothesis test:
```

```
## mean_expersq = 0
```

```
## mean_married = 0
```

```
## mean_union = 0
```

```
##
```

```
## Model 1: restricted model
```

```
## Model 2: lwage ~ expersq + married + union + mean_expersq + mean_mar
```

14-4 パネルデータを用いた政策分析

一般的な政策分析フレームワーク [14.22]

$$y_{it} = \eta_1 + \alpha_2 d2_t + \dots + \alpha_T dT_t + \beta w_{it} + \mathbf{x}_{it} \psi + a_i + u_{it}$$

- ▶ w_{it} : 介入指標 ($w_{it} = 0$ または 1)
- ▶ β : 政策効果 (関心パラメータ)
- ▶ \mathbf{x}_{it} : その他の時変コントロール変数
- ▶ FE または FD で推定 (a_i と w_{it} の相関を許容)
- ▶ DiD (第 13 章) は $T = 2$ の特殊ケース

動的効果の推定 [14.24]

- ▶ $t-1$ 、 $t-2$ 期までのラグ効果を含む動的モデル:

$$y_{it} = \eta_1 + \sum_{t=2}^T \alpha_t dt_t + \beta_0 w_{it} + \beta_1 w_{i,t-1} + \beta_2 w_{i,t-2} + \mathbf{x}_{it} \psi + a_i + u_{it}$$

- ▶ 長期効果: $\beta_0 + \beta_1 + \beta_2$

因果分析の注意点

- ▶ w_{it} が過去の誤差項に反応する場合（フィードバック）⇒ 厳密外生性違反
- ▶ **検定方法:** $w_{i,t+1}$ （次期の政策）を追加し、有意かどうかを確認 [14.25]
 - ▶ 有意 ⇒ フィードバックの存在、FE/FD の結果に注意が必要
- ▶ **偽造検定 (Falsification Test):** 例えば、今年の介入が去年の成果を予測すべきでない

異質トレンドモデル (Heterogeneous Trend Model) [14.26]

- ▶ 個体固有の時間トレンド $g_i t$ が存在する場合:

$$y_{it} = \eta_1 + \sum_{t=2}^T \alpha_t dt_t + \beta w_{it} + \mathbf{x}_{it} \psi + a_i + g_i t + u_{it}$$

- ▶ 1 階差分で a_i を除去 $\Rightarrow g_i$ が残る [14.27]:

$$\Delta y_{it} = \sum_{t=2}^T \alpha_t \Delta dt_t + \beta \Delta w_{it} + \Delta \mathbf{x}_{it} \psi + g_i + \Delta u_{it}$$

- ▶ FE を再度適用して g_i を除去 \Rightarrow 最低 $T \geq 3$ が必要

14-5 他のデータ構造への応用

マッチドペアとクラスターサンプル

- ▶ パネルデータ手法は**時間**以外の構造にも応用可能
- ▶ **マッチドペア** (matched pairs): 例) 兄弟・双子ペアの差分
 - ▶ 家族固有効果 a_f を消去
 - ▶ 例: 十代妊娠が将来所得に与える影響 (姉妹ペア差分)
- ▶ **クラスターサンプル** (cluster sample): 個体がクラスター (学校、企業) から抽出
 - ▶ クラスターが「個体」、クラスター内観測が「時点」に対応
 - ▶ クラスター効果を固定効果または差分で除去

クラスターサンプルにおける注意点

- ▶ 政策変数 w_{it} がクラスター内で変動しない場合 (例: 教師の質の効果) \Rightarrow 固定効果は使えない \Rightarrow 変量効果 (または Pooled OLS + クラスター標準誤差)
- ▶ クラスターを無視して OLS を使う場合 \Rightarrow 標準誤差が過小 (過信) \Rightarrow **クラスター頑健標準誤差 (cluster-robust SE)** を使う
- ▶ Pooled OLS でクラスター頑健標準誤差を使うことで対処可能

クラスター頑健標準誤差の適用場面

- ▶ クラスタリングが正当化されるのは**真のクラスターサンプル**の場合
 - ▶ 無作為サンプルをグループに事後分割しても正当化されない
- ▶ **政策変数がグループレベルで変化する**場合 (例: 最低賃金法)
 - ▶ 処置の割り当て不確実性を考慮するためクラスタリングが適切

ま と め

第 14 章のまとめ

手法	a_i と x_{it} の相関	時間不変変数	効率性
Pooled OLS	不可	推定可	低
固定効果 (FE)	許容	推定不可	中
1 階差分 (FD)	許容	推定不可	中
変量効果 (RE)	不可 (仮定)	推定可	高
相関変量効果 (CRE)	許容	推定可	中

まとめ (続き)

- ▶ **FE vs FD:** u_{it} が系列無相関 \Rightarrow FE 優位 ; ランダムウォーク \Rightarrow FD 優位
- ▶ **RE vs FE:** Hausman 検定または CRE アプローチで選択
- ▶ **CRE:** FE の点推定を維持しつつ、時間不変変数の係数と RE vs FE の検定を提供
- ▶ **政策分析:** 処置指標を適切に定義すれば DiD は FE の特殊ケース ; 動的効果・フィードバック検定も重要
- ▶ **他のデータ構造:** 兄弟ペア、クラスターサンプルにも同様の手法が適用可能