

事例研究(ミクロ経済政策・問題分析 III)

- 規制産業と料金・価格制度 -

(第7回 - 手法(3) 応用データ解析/基礎的手法)

2010年 6月 2日

戒能一成

0. 本講の目的

(手法面)

- **応用データ解析の手順や基本的な作業の流れ (Strategy) を理解する**
- 特にグラフ化や統計検定などの手法を用いた、データ解析手法の選択と検定・確認について理解する

(内容面)

- 計量経済学・統計学を実戦で応用する際の基礎的留意点を理解する (1)

1. 制度の効果を測るには

1-1. 政策分析の基本手順

– 料金・価格制度やその変更が及ぼす効果を推計するためには、以下の2つの作業が必要

- 1) **制度変更による経済データへの影響経路と、因果関係・寄与度の推定** (「モデル構築」)
→ 制度変更がどのような変化をもたらすか？
- 2) 制度の創設・変更と同時に生じた**経済データの「有意な変化」**の計測 (「モデル実証」)
→ 数量・価格や費用は本当に変化したか？
(→ 変化していれば余剰分析が応用可能)

1. 制度の効果を測るには

1-2. 政策分析の条件(1)

– 制度(変更)の効果推計に際し充足すべき条件

1) **他の条件一定** “Ceteris Paribus”

→ 制度変更以外の外的要因変化の影響が、可能な限り十分除去されていること

2) **政策影響の独立性** “Unconfoundness”

→ 制度(変更)の影響が、制度の実施/非実施と独立と見なせること (影響の均質性)

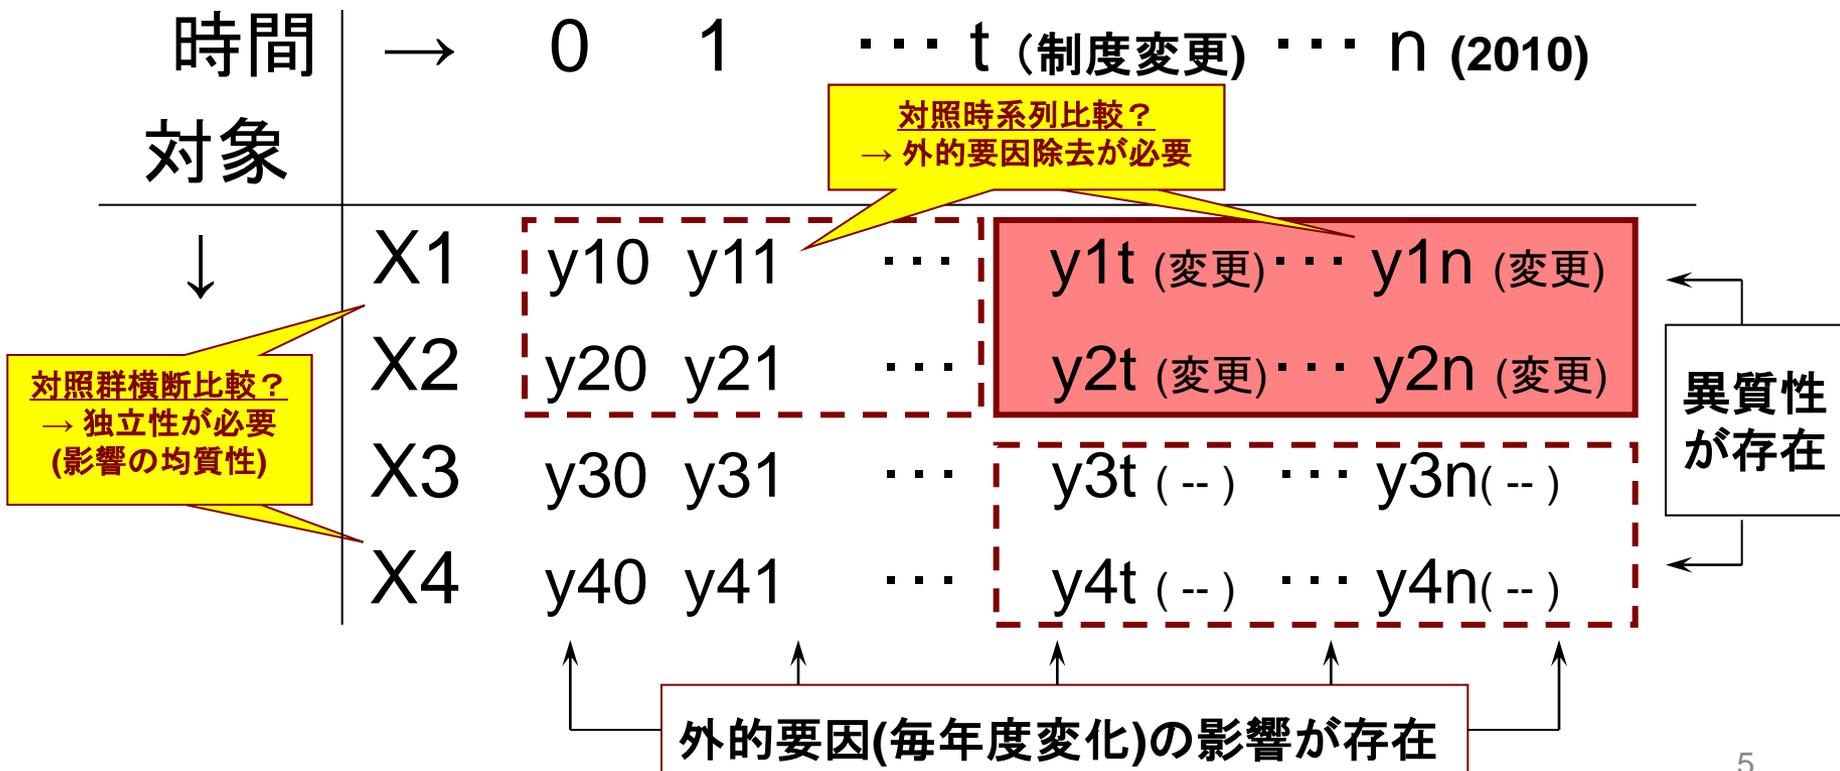
3) **対照群・時間**の存在 “Overlap”

→ 制度(変更)が非実施の群・時間があること⁴

1. 制度の効果を測るには

1-3. 政策分析の条件(2)

- 制度(変更)の効果推計に際し充足すべき条件
→ **分析手法・手順の選択や精度を規定**



1. 制度の効果を測るには

1-4. 制度影響モデルの仮構築(1)

- 問題とする財サービスの費用、価格・料金、数量などについて、**制度が及ぼす影響経路・内容を、経済理論に基づく簡単な影響モデルで記述**
 - 費用、料金・価格、数量の変化
- 当該変化において、**外的要因**が存在する場合、(後で取除くことを目的に)外的要因の影響経路と内容を加味したモデルを構築
 - 需要変化(率)、一般物価・金利、他の制度

1. 制度の効果を測るには

1-5. 制度影響モデルの仮構築(2)

- 制度影響モデル(例: 投資影響による費用変化)

$$- C(t) = C_{\text{fix}}(t,H) + c_{\text{val}}(t) * Q(t) + \varepsilon(t)$$

$$\rightarrow Y(t) = \alpha_1(\text{or } \alpha_0) + \beta * X(t) + \varepsilon(t)$$

$$- C_{\text{fix}}(H) = \Delta C_{\text{fixpo}}(H(1\text{or}0)) + C_{\text{fixtr}}$$

$$- c_{\text{val}}(t) = c_{\text{fuel}}(t) + c_{\text{waste}}(t)$$

$C(t)$: t期実質総費用, $Q(t)$: t期供給量, $\varepsilon(t)$: 誤差項

$C_{\text{fix}}(t,H)$: t期固定費

$\Delta C_{\text{fixpo}}(H(1\text{or}0))$ 政策実施(H(1))以降の実質減価償却費 +
同利払費変化(政策影響部分)

C_{fixtr} 過去10年平均実質固定費(不変)

$c_{\text{val}}(t)$: t期可変費原単位

$c_{\text{fuel}}(t), c_{\text{waste}}(t)$ 実質単位燃料費・ゴミ処理費(外部要因)

1. 制度の効果を測るには

1-6. 制度影響モデルの実測・修正

- 1-4. で構築した制度影響モデルを、実際の統計データを用いて実測する
- 実際の統計処理はパッケージ・ソフトで実施する (STATA, EViews, ...)
 - 重要なのは、**必要とされる前提条件に応じた適切な手法の選択と、検定結果などの解釈**
- 明らかに理論と矛盾する結果が出た場合には、1-4. に戻って制度影響モデルを再考する (ex. 正の価格弾力性, 負の所得効果...)

2. 応用データ解析の基礎(1): 線形回帰モデル

2-1. 線形回帰モデルとは

- 最も簡単な線形回帰モデルは、被説明変数(例: 費用)を説明変数(前期固定資産、燃料費...)で **最小二乗法により回帰分析したモデル**

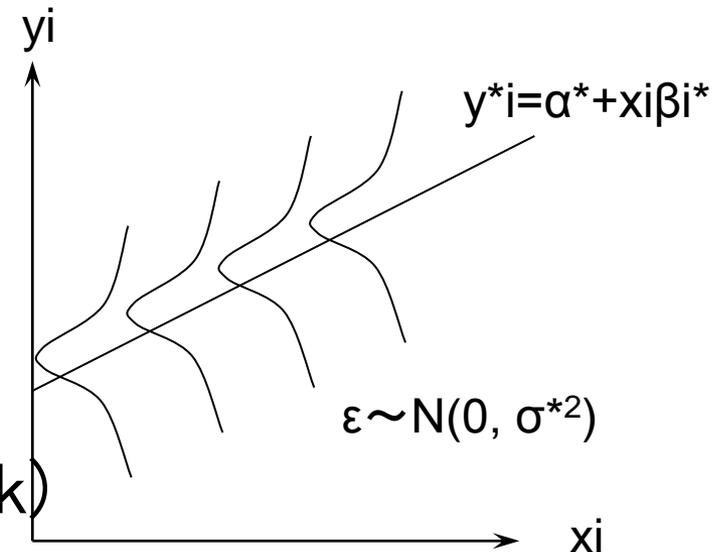
$$y = \alpha + x' \beta + \varepsilon$$

$$\rightarrow y^* = \alpha^* + x' \beta^*$$

$$\alpha^* = y - x' \beta^*$$

$$\beta^* = (x' x)^{-1} x' y$$

$$\sigma^{*2} = (y - y^*)' (y - y^*) / (n - k)$$



- 最も簡単で扱いやすい手法だが...

2. 応用データ解析の基礎(1): 線形回帰モデル

2-2. 線形回帰モデルと前提条件(1)

– 線形回帰モデルが適用できる前提条件は 4つ

#1: **線形性** Linearity

– 適切な変換で $y = \alpha + x' \beta + \varepsilon$ 型になること

→ 適用困難例と対処

– y が **離散値** (0, 1), **切断値** ($y_i \mid y_i > 0$)

→ ダミー変数・切断変数モデル回帰

→ 平均措置効果(ATE; matching 他)

– y がCES型(= $(K^\delta + L^\delta)^\gamma$) 等**連続非線形**

→ 非線形回帰 (数値解析法)

2. 応用データ解析の基礎(1): 線形回帰モデル

2-3. 線形回帰モデルと前提条件(2)

#2: **説明変数の外生性** Strict Exogeneity

– 説明変数 X が誤差項 ε と独立であること

$$\Leftrightarrow E(\varepsilon_i | X) = 0 \quad (i = 1 \text{ to } n)$$

→ 適用困難例と対処

– 説明変数 X が**誤差項 ε と相関**あり

(X と Y が需給均衡・同時決定の場合など)

→ 操作変数法 Instrumental Variable

X とは相関があるが ε とは相関が

ない変数 Z を探して併用回帰

2. 応用データ解析の基礎(1): 線形回帰モデル

2-4. 線形回帰モデルと前提条件(3)

#3: **説明変数の非多重共線性** No Multicollinearity

– 説明変数 x_i が他の x_j ($i \neq j$) の組合わせで表現できないこと $\Leftrightarrow \text{rank } X_{k \times n}' X_{n \times k} = k$

→ 適用困難例と対処

– 説明変数 X の間での**相関高**

→ 主成分回帰

→ 一部変数除去 (= モデルの見直し)

(ex. ダミー変数は全ての分類に設定できない

∴ 少なくとも分類の 1つは他の補集合)

2. 応用データ解析の基礎(1): 線形回帰モデル

2-5. 線形回帰モデルと前提条件(4)

#4: **誤差項の均一分散性** Homoskedasticity

- 誤差項 ε の分散は全て σ^2 で共分散なし

$$\Leftrightarrow E(\varepsilon' \varepsilon | X) = \sigma^2 I$$

- 通常さらに 誤差項 ε は正規分布 $N(0, \sigma^2 I)$ と仮定する

→ 適用困難例と対処

- **分散が不均一**

→ 不均一分散回帰 Heterosked. robust

- **系列相関あり [重要]**

→ 時系列分析法 Time Series Analysis⁴³

2. 応用データ解析の基礎(1): 線形回帰モデル

2-6. 線形回帰モデルと実用上の問題

- 現実の料金・価格制度の分析という視点からは、**線形回帰モデルの前提条件が成立しない場合多**

#1 線形性: **成立しない場合有**

(→ “凸/凹型” Convex/Concave, 離散型など)

#2 説明変数の外生性: (回避可能)

#3 説明変数の非多重共線性: (回避可能)

#4 誤差項の均一分散性: **ほぼ確実に成立せず**

(→ 殆どの場合「時系列相関」あり, 粘着性など)

→ 分析手法として**時系列分析・パネルデータ分析**
が有効 (後述)

3. 応用データ解析の基礎(2): 線形回帰と検定

3-1. 決定係数・自由度修正済決定係数

- **決定係数 R^2** ; 最も一般的な精度指標
- 推計式 $y^* = \alpha^* + x' \beta^*$ が、実際の y の変動のどの程度を説明しているかを表す係数
 - $0 \leq R^2 \leq 1$, $R^2 = 1 - (y - y^*)' (I - X(X'X)^{-1}X') y$
- 但し、説明変数 X をたくさん使うと R^2 は実際の精度と無関係に大きくなるので、**自由度修正済決定係数 R^2 (Adjusted R^2)** が用いられる
 - $\text{Adj. } R^2 = 1 - (n-1)/(n-k)(1 - R^2)$
 - n: 試料数 k: 説明変数数 $\text{Adj. } R^2 \leq 1$

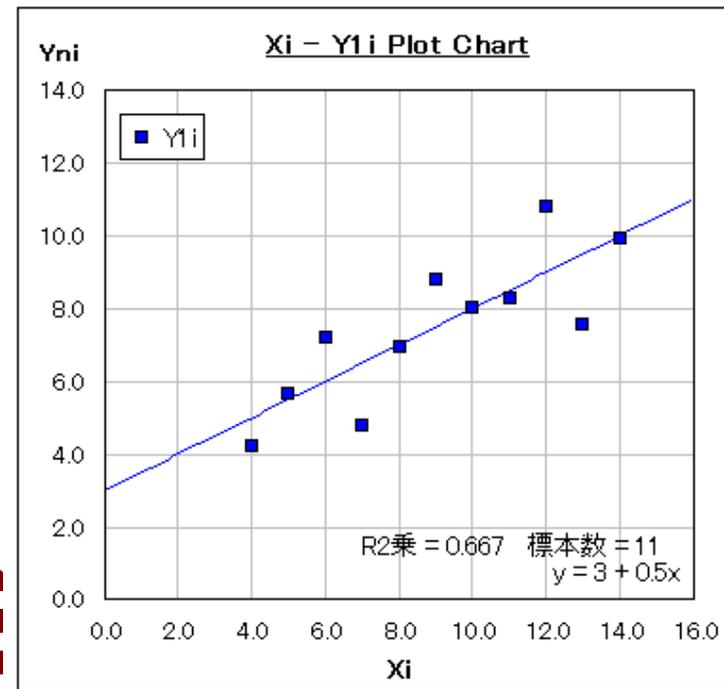
3. 応用データ解析の基礎(2): 線形回帰と検定

3-2. グラフ化(=可視化)による考察の重要性(1)

– 記述統計量(=X,Yの平均・分散等)と決定係数のみに頼ると危険、必ず**グラフ化(=可視化)**すべき

– Anscombe ('73) $Y_{ni} = 3.0 + 0.5X_i$ **Adj.R²=0.666**

i	Xi	Y1i	Y2i	Y3i
1	10.0	8.04	9.14	7.46
2	8.0	6.95	8.14	6.77
3	13.0	7.58	8.74	12.74
4	9.0	8.81	8.77	7.11
5	11.0	8.33	9.26	7.81
6	14.0	9.96	8.10	8.84
7	6.0	7.24	6.13	6.08
8	4.0	4.26	3.10	5.39
9	12.0	10.84	9.13	8.15
10	7.0	4.82	7.26	6.42
11	5.0	5.68	4.74	5.73
平均	9.00	7.50	7.50	7.50
分散	3.32	2.03	2.03	2.03



3. 応用データ解析の基礎(2): 線形回帰と検定

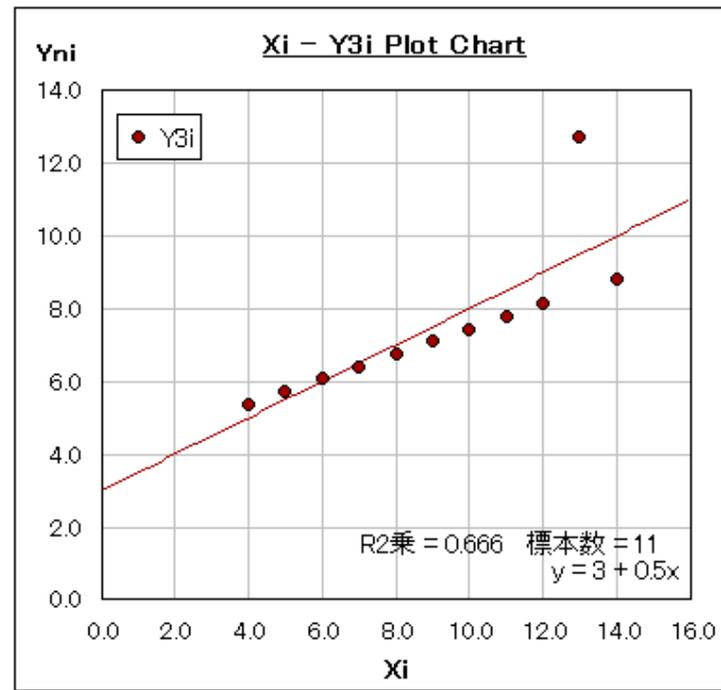
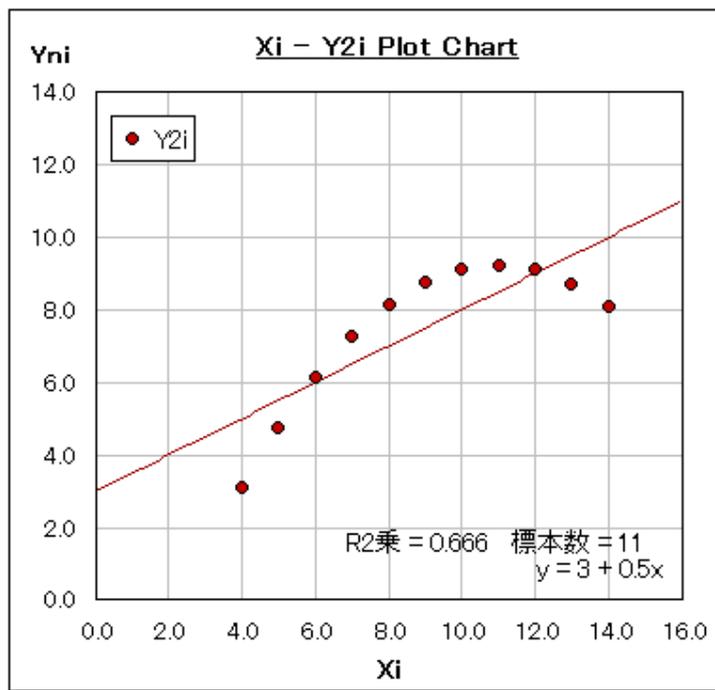
3-3. グラフ化(=可視化)による考察の重要性(2)

- Y2: 前提 #1 (線形) に問題有 (要変数変換)

$$Y2i = -6.00 + 2.78 X_i - 0.13 X_i^2 + \varepsilon_i \quad \text{Adj.}R^2 = 0.999$$

- Y3: 前提 #1, #4(均一分散) に問題有 (特異値)

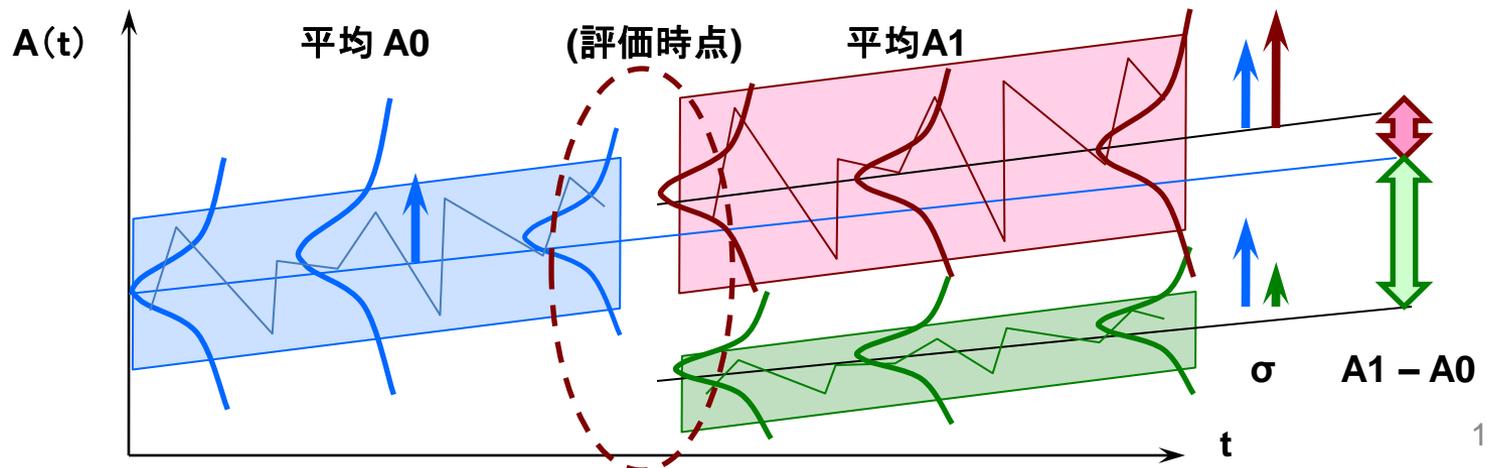
$$Y3i = +4.01 + 0.35 X_i + 4.24 DM\#10 + \varepsilon_i \quad \text{Adj.}R^2 = 0.999$$



3. 応用データ解析の基礎(2): 線形回帰と検定

3-4. 統計検定の基礎(1)

- ある 2つの値の間に差があるかを判定するには条件を揃えた上で**当該試料の「ばらつき」と比べ「差」が十分大きい(=「 $A1 \neq A0$ 」)**かを判定する
- 仮に試料の「ばらつき(標準偏差などの指標)」と比べ「 $A1 - A0$ 」が小さければ差があるとは言えず



3. 応用データ解析の基礎(2): 線形回帰と検定

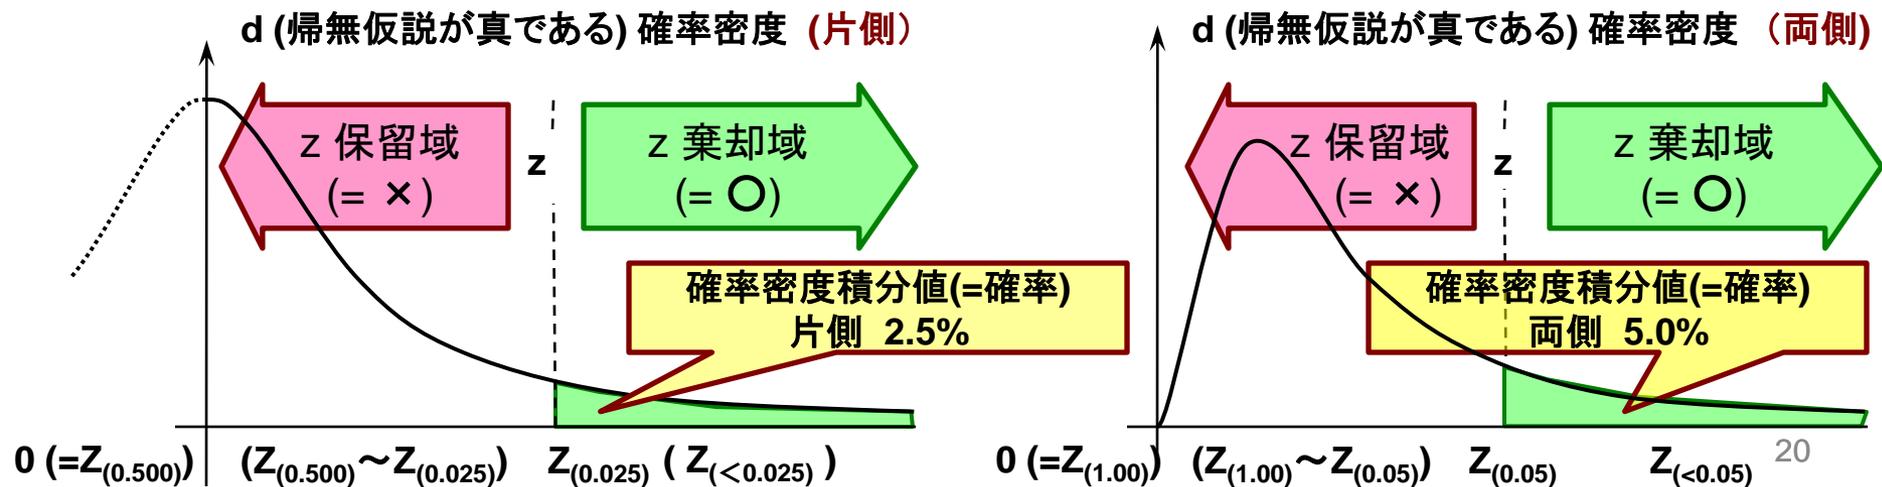
3-5. 統計検定の基礎(2)

- 統計検定の多くは、検定したい内容を否定する仮説(帰無仮説: H_0)を敢えて設けた上で、当該**帰無仮説が統計的に見て「真」である確率が十分に小さいといえるか否か**を判定
 - 帰無仮説が「真」の確率が十分小
 - ⇒ 内容を否定する仮説が「棄却」⇒ ○
- つまり「**背理法**」
- 通常「**95%有意**」(= 確率 5%以下, “*”)が、稀に「**99%有意**」(同 1%以下, “**”)が用いられる

3. 応用データ解析の基礎(2): 線形回帰と検定

3-6. 統計検定の基礎(3)

- 95%・片側検定の場合、確率(= 確率密度積分値)が2.5%となる点 $Z_{(0.025)}$ に対し帰無仮説に対応する検定統計値 Z (= 試料の「ばらつき」に対する検定対象値の比) の大小を判定
- $Z < Z_{(0.025)}$ なら帰無仮説が「真」の確率大 $\Rightarrow \times$



3. 応用データ解析の基礎(2): 線形回帰と検定

3-7. 回帰係数の有意性の検定 ($\Rightarrow \beta \neq 0?$)

- (Student) **t-検定 ; $\beta \neq 0?$ [重要]**

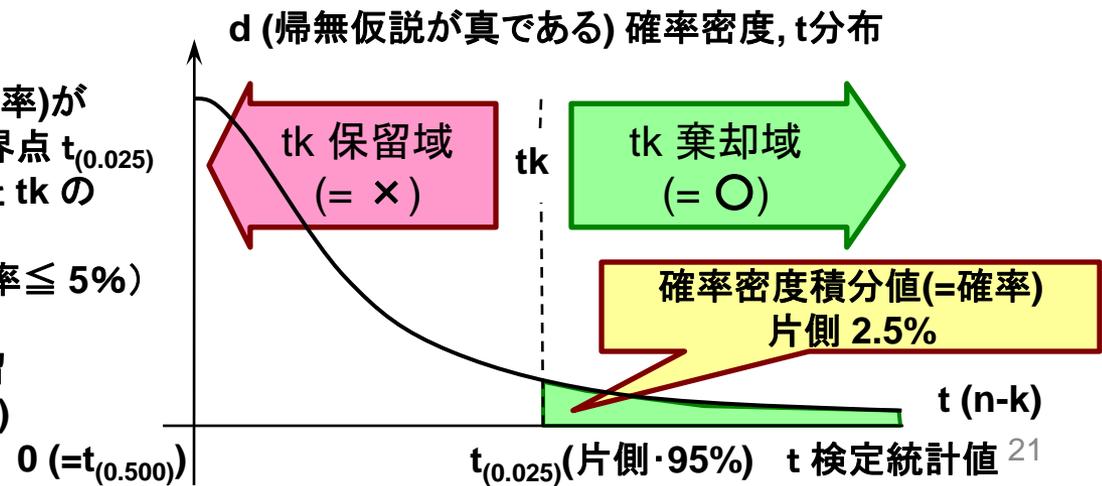
$$t_k = \beta_k / (\sigma^2 \cdot (x'x)^{-1}_{kk})^{0.5} \quad (\text{t値})$$

回帰係数k 回帰係数k に対応する試料のばらつき具合

$t_k \sim t(n-k)$ 自由度 $n-k$ の t分布, 片側

- 結果を **p値 (t_k に対応する確率)** で表すこと多し

- 確率密度の総和(不定積分)は 1
- 確率密度の $+\infty$ からの積分値(=確率)が 2.5%(95%・片側の場合)となる臨界点 $t_{(0.025)}$ に対し、仮説(帰無仮説)に対応した t_k の 大小を判定
- $t_k \geq t_{(0.025)}$ (= 帰無仮説「真」の確率 $\leq 5\%$) の場合帰無仮説を棄却 (= O)
- $t_k < t_{(0.025)}$ の場合帰無仮説を保留 (= 帰無仮説「真」の確率 $> 5\%$, X)

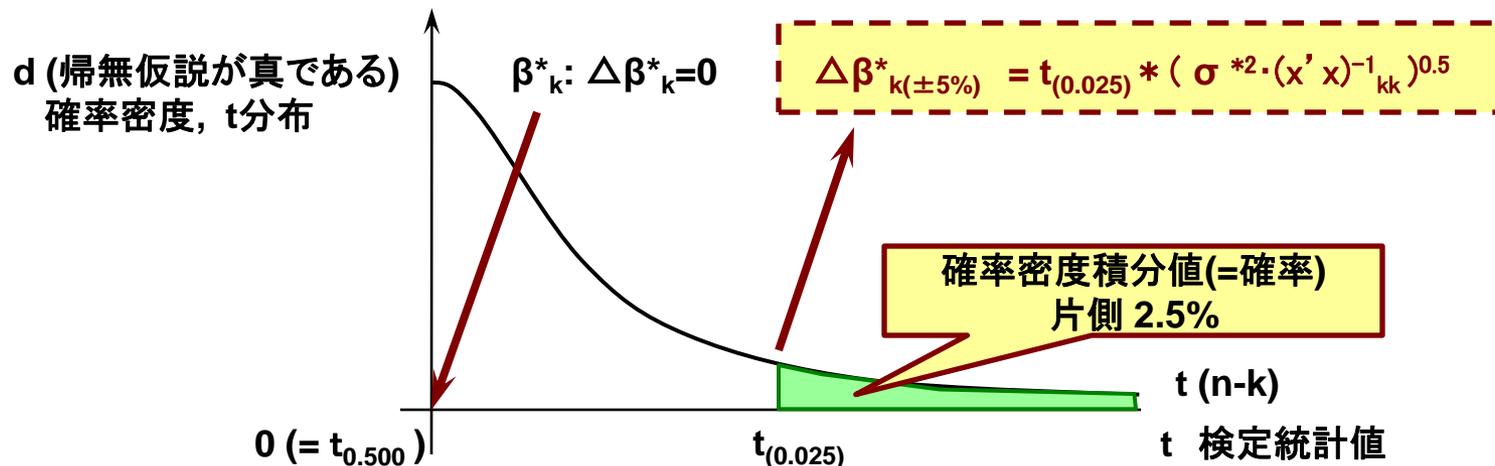


3. 応用データ解析の基礎(2): 線形回帰と検定

3-8. 回帰係数の信頼区間推定

- 95%水準での t検定の考え方を拡張して、逆に回帰係数 β^*_k が信頼できる確率95%の範囲(= β^*_k との差が0と言える確率が片側2.5%以上の範囲、「信頼区間」)を推計できる

$$- \beta^*_{k(\pm 5\%)} = \beta^*_k \pm t_{(0.025)} * (\sigma^{*2} \cdot (x'x)^{-1}_{kk})^{0.5}$$



3. 応用データ解析の基礎(2): 線形回帰と検定

3-9. 平均値の差の検定($\Rightarrow \forall \beta = 0$ の際, $\alpha_1 \neq \alpha_0$?)

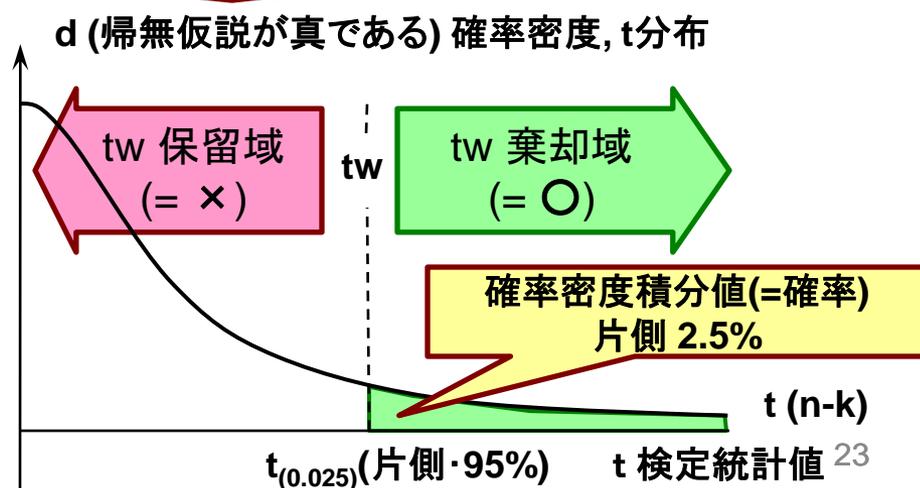
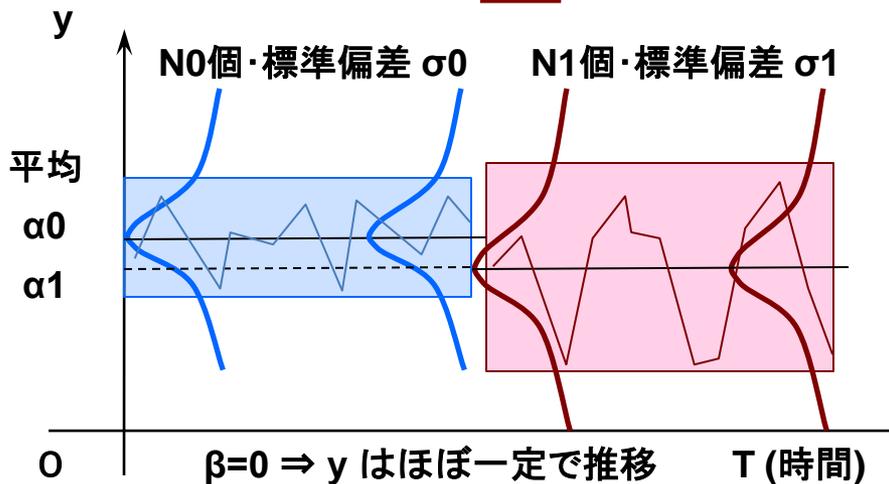
- Welch-t検定; $\alpha_1 \neq \alpha_0$?

$$tw = (\alpha_1 - \alpha_0) / (\sigma_1^2/N_1 + \sigma_0^2/N_0)^{0.5}$$

平均値の差 / 状態1・0の「ばらつき」の合成値

$tw \sim t(v)$ 自由度 v のt分布, 片側

$$v = (\sigma_1^2/N_1 + \sigma_0^2/N_0)^2 / (\sigma_1^2/(N_1^2 \cdot (N_1 - 1)) + \sigma_0^2/(N_0^2 \cdot (N_0 - 1)))^{0.5}$$



3. 応用データ解析の基礎(2): 線形回帰と検定

3-10. 平均値の差の検定の応用 (簡易定常化法)

- 分析対象 y が複数の説明変数 X から影響を受けている場合でも、 $\beta_i \gg \beta_{\text{others}}$ ならば、
(X_i の y への影響が他の X より卓越する場合)
 y/X_i はほぼ一定となり、Welch t-検定が使える

$$y = \alpha + X_i * \beta_i + X_j * \beta_j + \varepsilon$$

$$y/X_i = \beta_i + \left[X_j/X_i * \beta_j + \alpha / X_i + \varepsilon / X_i \right]$$

$$\rightarrow \ll \beta_i$$

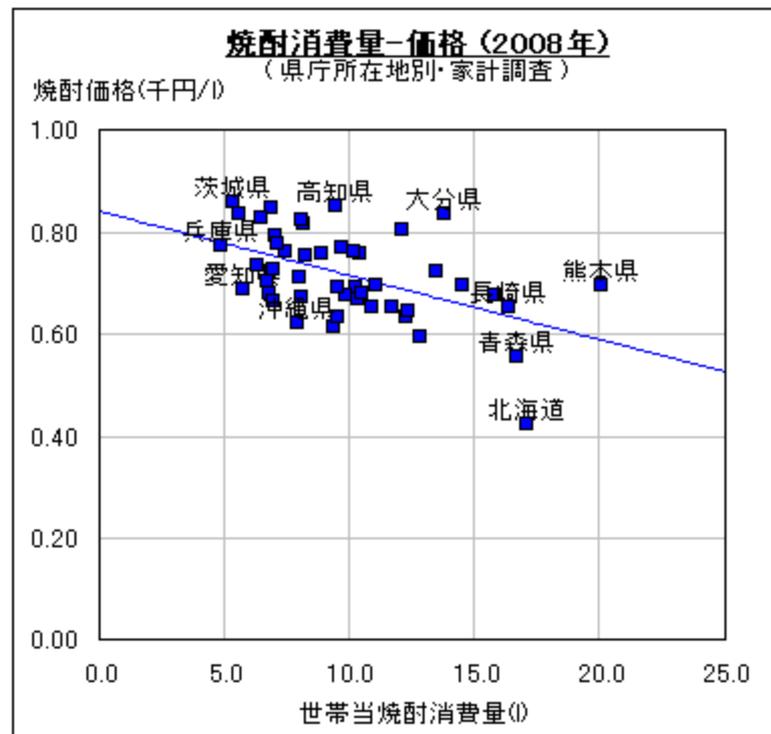
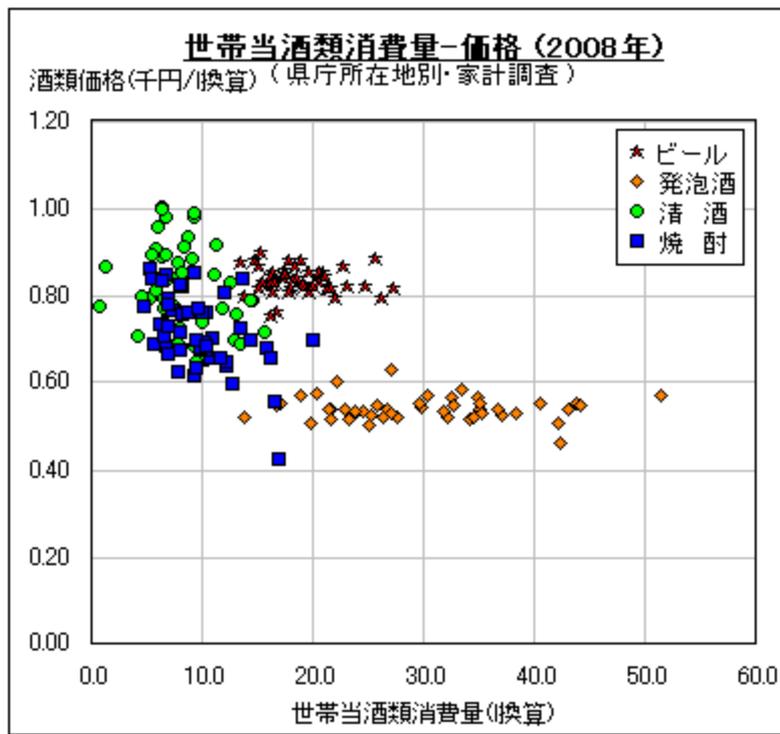
$$y/X_i = \beta_i + \varepsilon' \quad (= X_j/X_i * \beta_j + \alpha / X_i + \varepsilon / X_i)$$

→ ほぼ一定なら Welch t-検定が適用可

4. 応用データ解析の基礎(3): 実戦編

4-1. 回帰分析と結果の解釈(1) STATA

- 例: 酒類消費量(家計調・県庁所在地別・2008)
- まず **P-Qグラフ(価格-数量)**を書いてみる



4. 応用データ解析の基礎(3): 実戦編

4-2. 回帰分析と結果の解釈(2) STATA

- 焼酎購入量(家計調・県庁所在地別・2008)

l_{saq}: 消費量(対数, l) l_{sap}: 価格(対数, ¥/l)

l_{exp}: 消費支出(対数) l_{pdp}: 人口密度(対数)

l_{beep}, l_{sesp}, h_{hpsp}: ビール・清酒・発泡酒価格(対数)

```
. reg lsaq lsap lbeep lsesp lhpsp lexp lpdp
```

↑ 適切な代替財は?

Source	SS	df	MS	Number of obs = 47		
Model	2.67358707	6	.445597846	F(6, 40) = 7.15		
Residual	2.49448231	40	.062362058	Prob > F = 0.0000		
Total	5.16806938	46	.112349334	R-squared = 0.5173		
				Adj R-squared = 0.4449		
				Root MSE = .24972		

	l _{saq}	l _{sap}	l _{beep}	l _{sesp}	l _{hpsp}	l _{exp}	l _{pdp}	_cons
β _i (係数)	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]			
	-1.427614	.3314886	-4.31	0.000	-2.097578	-.7576508		
	3.301218	1.130336	2.92	0.006	1.016723	5.585713		
→	.3204504	.3194426	1.00	0.322	-.3251671	.966068		
	-.5590815	.7909589	-0.71	0.484	-2.157669	1.039506		
	-.6802628	.4823904	-1.41	0.166	-1.65521	.2946847		
	-.1579981	.0537782	-2.94	0.005	-.2666878	-.0493084		
	2.657071	10.10848	0.26	0.794	-17.77292	23.08706		

4. 応用データ解析の基礎(3): 実戦編

4-3. 回帰分析と結果の解釈(3) STATA

- 焼酎購入量(家計調・県庁所在地別・2008)

l_{saq}: 消費量(対数, l) l_{sap}: 価格(対数, ¥/l)

l_{exp}: 消費支出(対数) l_{pdp}: 人口密度(対数)

l_{beep}: ビール価格(対数)

```
. reg lsaq lsap lbeep lexp lpdp
```

推計式説明分・残差分

Source	SS	df	MS
Model	2.59129468	4	.647823671
Residual	2.5767747	42	.061351779
Total	5.16806938	46	.112349334

二乗和・ k, n-k ・平均二乗和

Number of obs = 47
 F(4, 42) = 10.56
 Prob > F = 0.0000
 R-squared = 0.5014
 Adj R-squared = 0.4539
 Root MSE = .24769

F検定結果
 R²・ Adj.R²
 残差平方和

t値・p値

	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
l _{saq}						
l _{sap}	-1.452444	.32794	-4.43	0.000	-2.114253	-.7906338
l _{beep}	3.232778	1.085017	2.98	0.005	1.043126	5.42243
l _{exp}	-.7018367	.4758033	-1.48	0.148	-1.662047	.2583733
l _{pdp}	-.1476392	.0525584	-2.81	0.008	-.2537063	-.041572
_cons	.0037443	9.692547	0.00	1.000	-19.55661	19.5641

β_i (係数)

$\sqrt{\sigma^2(xx)^{-1}}$ (標準誤差)

95%信頼区間上限・下限

4. 応用データ解析の基礎(3): 実戦編

4-4. 回帰分析と結果の解釈(4) STATA

- 焼酎購入量(家計調・県庁所在地別・2008)

理論と整合するか？(1)

$$e_{qx,px} + e_{qx,py} + e_{qx,l} = 0 \text{ (需要関数の同次性条件)}$$

Min(-2.11+1.04-1.66) Max(-0.79+5.42+0.26)

. reg lsaq lsap lbeep lexp lpdp

= -2.73 ~ +4.89

Source	SS	df	MS			
Model	2.59129468	4	.647823671	Number of obs = 47		
Residual	2.5767747	42	.061351779	F(4, 42) = 10.56		
Total	5.16806938	46	.112349334	Prob > F = 0.0000		
				R-squared = 0.5014		
				Adj R-squared = 0.4539		
				Root MSE = .24769		

	βi (係数)	Std. Err.	t	P> t	[95% Conf. Interval]	
lsaq	Coef.					
lsap	-1.452444	.32794	-4.43	0.000	-2.114253	-.7906338
lbeep	3.232778	1.085017	2.98	0.005	1.043126	5.42243
lexp	-.7018367	.4758033	-1.48	0.148	-1.662047	.2583733
lpdp	-.1476392	.0525584	-2.81	0.008	-.2537063	-.041572
_cons	.0037443	9.692547	0.00	1.000	-19.55661	19.5641

95%信頼区間上限・下限

4. 応用データ解析の基礎(3): 実戦編

4-5. 回帰分析と結果の解釈(5) STATA

- 焼酎購入量(家計調・県庁所在地別・2008)

理論と整合するか？(2) 人口密度を外すと...

$$e_{qx,px} + e_{qx,py} + e_{qx,l} = 0 \text{ (需要関数の同次性条件)}$$

Min(-2.42+1.05-1.85) Max(-1.07+5.75+0.21)

. reg lsaq lsap lbeep lexp

= -3.22 ~ +4.89

Source	SS	df	MS				
Model	2.10718286	3	.702394287	Number of obs = 47			
Residual	3.06088652	43	.071183408	F(3, 43) = 9.87			
Total	5.16806938	46	.112349334	Prob > F = 0.0000			
				R-squared = 0.4077			
				Adj R-squared = 0.3664			
				Root MSE = .2668			
	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]		
lsaq							
lsap	-1.741788	.3353633	-5.19	0.000	-2.418113	-1.065464	
lbeep	3.405312	1.16685	2.92	0.006	1.052134	5.75849	
lexp	-.8154809	.5106551	-1.60	0.118	-1.845315	.2143532	
_cons	-.4769214	10.43869	-0.05	0.964	-21.52855	20.5747	

βi (係数)

t値・p値

95%信頼区間上限・下限

4. 応用データ解析の基礎(3): 実戦編

4-6. 回帰分析と結果の解釈(6) STATA

- **不均一分散**最小二乗法 (Heterosked. robust)
 - 回帰係数 β_i は同じ、**標準誤差が異なる**

. hettest (←分散均一性検定が棄却: 清酒の例)

Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
Ho: Constant variance
Variables: fitted values of lsesq

chi2(1) = 17.26
Prob > chi2 = 0.0000

. regress lsesq lsesp lexp lpdp, robust

Linear regression

Number of obs = 47
F(3, 43) = 4.26
Prob > F = 0.0101
R-squared = 0.1756
Root MSE = .49607

$$\sqrt{(x'x)^{-1}x'\Omega x(x'x)^{-1}}$$

lsesq	Coef.	Robust Std. Err.	t	P> t	[95% Conf. Interval]	
lsep	-.7272809	.4543773	-1.60	0.117	-1.64362	.1890582
lexp	2.65602	1.511482	1.76	0.086	-.3921736	5.704214
lpdp	-.0517519	.0654726	-0.79	0.434	-.1837901	.0802862
_cons	-30.95186	23.00742	-1.35	0.186	-77.35076	15.44703