

統計学01

早稲田大学政治経済学部

第22回

西郷 浩

本日の目標

■ 質的な被説明変数

- 例:タイタニック号乗客の生存・死亡
- 説明変数の影響の程度をロジット回帰分析(質的被説明変数のための回帰モデル)で分析する。

■ 参考文献

- 小暮厚之(2009)『Rによる統計データ分析入門』朝倉書店

データ

- タイタニック号の乗客の生存・死亡(1313人分)
 - 氏名
 - 客室の等級(1, 2, 3)
 - 性別(male, female)
 - 年齢(数量)
 - 生存・死亡(1, 0)
 - 参考文献に入手方法が記載されています。

データ

表1: 基本統計

PClass	Age	Sex	Survived
1st:322	Min. : 0.17	female:462	Min. : 0.0000
2nd:280	1st Qu.: 21.00	male :851	1st Qu.: 0.0000
3rd:711	Median : 28.00		Median :0.0000
	Mean : 30.40		Mean : 0.3427
	3rd Qu.: 39.00		3rd Qu.: 1.0000
	Max. : 71.00		Max. : 1.0000
	NA's : 557.00		

データ




図1: 性・客室等級別死亡・生存者数

データ




図2: 年齢別生存率

生存率推定のモデル

■ 被説明変数

- Y: 死亡・生存 (0, 1)

■ 説明変数

- X_2 : 客室の等級 (1, 2, 3)
- X_3 : 性別 (male, female)
- X_4 : 年齢 (数量)

■ 回帰モデル?

- $$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + \varepsilon_i$$

- 不適切。理由: Y_i の取りうる値が 0-1 に限られているから。

生存率推定のモデル

■ 生存率

- $p_i = \Pr(Y_i = 1)$

- 回帰モデル？

- $p_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} (+ \varepsilon_i)$

- 不適切。理由: $0 < p_i < 1$ に限定されているから。

■ オッズ

- $p_i / (1 - p_i)$

- 回帰モデル？

- $p_i / (1 - p_i) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} (+ \varepsilon_i)$

- 不適切。理由: $p_i / (1 - p_i) > 0$ に限定されているから。

生存率推定のモデル

■ 対数オッズ (logit)

□ $\log p_i / (1 - p_i) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} (+ \varepsilon_i)$

- 適切。理由: $-\infty < \log p_i / (1 - p_i) < \infty$

□ 書き換えると

- $p_i = \frac{\exp(\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i})}{1 + \exp(\beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i})}$

□ 回帰係数の推定は？

- 最尤法

- 尤度関数の最大化

生存率モデルの推定

同時確率

$$\begin{aligned} & \Pr(Y_1 = y_1, Y_2 = y_2, \dots, Y_n = y_n) \quad (y_i = 0 \text{ or } 1) \\ &= \Pr(Y_1 = y_1) \Pr(Y_2 = y_2) \cdots \Pr(Y_n = y_n) \quad (\text{independence}) \end{aligned}$$

$$\begin{aligned} & \text{Note: } \Pr(Y_i = y_i) = p_i^{y_i} (1 - p_i)^{1-y_i} \\ &= p_1^{y_1} (1 - p_1)^{1-y_1} p_2^{y_2} (1 - p_2)^{1-y_2} \cdots p_n^{y_n} (1 - p_n)^{1-y_n} \end{aligned}$$

$$\begin{aligned} & \text{Note: } p_i = \frac{\exp(\beta_1 + \beta_2 X_{i2} + \cdots + \beta_p X_{ip})}{1 + \exp(\beta_1 + \beta_2 X_{i2} + \cdots + \beta_p X_{ip})} \\ &= L(\beta_1, \beta_2, \dots, \beta_p; y_1, y_2, \dots, y_n) \quad (\text{尤度関数}) \end{aligned}$$

生存率モデルの推定

最尤法

$$\max L(\beta_1, \beta_2, \dots, \beta_p; y_1, y_2, \dots, y_n)$$

最尤推定量

最尤法によってえられた

$\beta_1, \beta_2, \dots, \beta_p$ の値

(よい性質をもつことが知られている)

ソフトウェアRでは、回帰分析と同じ手間で実行できる。

生存率モデルの推定

表2: ロジスティック回帰の出力

```
> titanic.glm <- glm(Survived~PClass*Sex+Age, family=binomial,  
data=titanic.df)  
> summary(titanic.log.glm)
```

Call:

```
glm(formula = Survived ~ PClass * Sex + Age, family = binomial,  
data = titanic.df)
```

Deviance Residuals:

Min	1Q	Median	3Q	Max
-3.0869	-0.6453	-0.4643	0.4599	2.3346

生存率モデルの推定

表2: ロジスティック回帰の出力(つづき)

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	4.845505	0.598061	8.102	5.41e-16 ***
PClass2nd	-1.486038	0.587018	-2.532	0.011357 *
PClass3rd	-4.038030	0.544289	-7.419	1.18e-13 ***
Sexmale	-3.702774	0.507177	-7.301	2.86e-13 ***
Age	-0.044854	0.008179	-5.484	4.16e-08 ***
PClass2nd:Sexmale	-0.089869	0.656052	-0.137	0.891043
PClass3rd:Sexmale	2.256406	0.581805	3.878	0.000105 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

生存率モデルの推定(おまけ)

- 年齢の効果は直線的か？
 - 変数変換の可能性
 - 先験的に関数形を決めにくい。
 - 一般化加法モデルの利用
 - スプライン関数を利用して柔軟な当てはめを実行する。

生存率モデルの推定(おまけ)

表3: 一般化加法モデルの出力

```
> titanic.gam <- gam(Survived~PClass*Sex+s(Age),  
family=binomial,data=titanic.df)  
> summary(titanic.gam)
```

Family: binomial

Link function: logit

Formula:

Survived ~ PClass * Sex + s(Age)

生存率モデルの推定(おまけ)

表3: 一般化加法モデルの出力(つづき)

Parametric coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	3.3929	0.4865	6.974	3.09e-12 ***
PClass2nd	-1.4112	0.5966	-2.366	0.018005 *
PClass3rd	-3.9049	0.5473	-7.134	9.72e-13 ***
Sexmale	-3.6979	0.5115	-7.229	4.87e-13 ***
PClass2nd:Sexmale	-0.1029	0.6646	-0.155	0.876905
PClass3rd:Sexmale	2.2687	0.5858	3.873	0.000108 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Approximate significance of smooth terms:

	edf	Ref.df	Chi.sq	p-value
s(Age)	3.385	4.211	38.23	1.32e-07 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

生存率モデルの推定(おまけ)




図3: 一般化加法モデルにおける年齢の効果

まとめ

- 多変量解析(回帰分析系)
 - 単回帰分析:説明変数ひとつ
 - 重回帰分析:説明変数2つ以上
 - ダミー変数による回帰式のシフト
 - 分散分析:質的(離散的)な要因
 - 一元配置
 - 二元配置
 - 交互作用の導入
 - ロジスティック回帰:質的被説明変数

まとめ

- Rなどのソフトウェアでは
 - どの手法もほとんど同じコマンドで実行できる。
 - どんどん使ってみることが大事。

