

## L05 ロジスティック回帰

樋口さぶろお <https://hig3.net>

龍谷大学 先端理工学部 数理・情報科学課程

多変量解析☆演習 L05(2021-10-28 Thu)

最終更新: Time-stamp: "2021-10-27 Wed 14:45 JST hig"

### 今日の目標

- 回帰と分類の違いを説明できる
- ロジスティック回帰の統計モデルを説明できる
- np.\* で関数値を, matplotlib で式からグラフを得られる
- statsmodels.glm でロジスティック回帰を実行できる



## ここまで来たよ

### 3 線形回帰モデル - 単回帰

### 5 ロジスティック回帰

- 分類問題
- ロジスティック回帰の統計モデル
- Python で関数値を求める・グラフを描く
- ロジスティック回帰の実行

## 予測問題の回帰タイプと分類タイプ

### 線形回帰の学習データ

	説明変数 $x$	目的変数 $Y$
1	10.3	21.1
2	12.1	22.9
⋮		
$n$	19.8	41.2

機械学習の言葉では  
教師あり, **回帰**=目的変数が連続値

$Y$  には小さい(?) 誤差を含む。

### ロジスティック回帰の学習データ

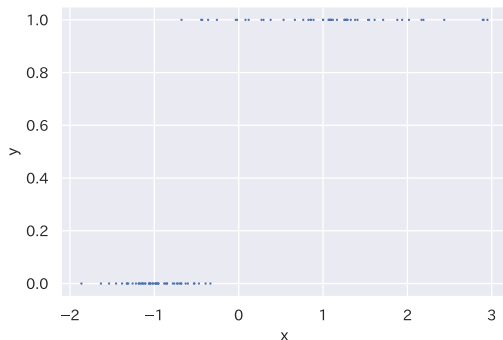
	説明変数 $x$	目的変数 $Y$	ダミー 変数
1	10.3	A	0
2	12.1	B	1
⋮			
$n$	19.8	A	0

機械学習の言葉では  
教師あり, **分類**=目的変数がカテゴリ変数  $\simeq$  離散

# ロジスティック回帰の学習データ

$X$  連続値

$Y$  間隔に意味のない有限個  $\simeq$  離散型, 今日は  $A \rightarrow 0, B \rightarrow 1$  に限定)



- 予測

- ▶ 回帰 連続値変数
  - ★ 線形回帰 単回帰
  - ★ 線形回帰 重回帰
- ▶ 分類 カテゴリ変数
  - ★ **ロジスティック回帰 単回帰**
  - ★ **ロジスティック回帰 重回帰**

## ここまで来たよ

### 3 線形回帰モデル - 単回帰

### 5 ロジスティック回帰

- 分類問題
- **ロジスティック回帰の統計モデル**
- Python で関数値を求める・グラフを描く
- ロジスティック回帰の実行

# ロジスティック回帰

## ロジスティック回帰

データ  $(x_i, y_i)$  ( $i = 1, \dots, n$ )  $x$  は連続値,  $y = A \text{ xor } B$  から

$$P(Y = B) = \frac{e^{\beta \cdot x}}{1 + e^{\beta \cdot x}}, \quad P(Y = A) = 1 - P(Y = B),$$

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}, \quad x = \begin{bmatrix} 1 \\ x_1 \end{bmatrix}, \quad \beta \cdot x = \beta_0 + \beta_1 \cdot x_1$$

という説明がもっともになるように,  $\beta_0, \beta_1$  を推定すること. それを使って,  $x$  が与えられたときの  $P(Y = B)$  や  $Y$  を推定すること.

回帰っていうけど分類じゃん? by 機械学習の人

$\beta_0 + \beta_1 \cdot x_1$  ってあたりが回帰? 0 と 1 の間の連続値 (確率) だから回帰?

by 統計学の人

$\beta_0 + \beta_1 \cdot x_1 + \epsilon$ ,  $\epsilon \sim N(0, \sigma^2)$  ではない. 推定するもの (左辺) がすでに確率

# ロジスティック回帰はもっとも 1:1 次関数 対 ロジスティック関数

$$p = P(Y = 1) = \beta_0 + \beta_1 \cdot x_1$$

じゃだめなの？


↪  $p = \beta_0 + \beta_1 x$  は、  
 $-\infty < x < +\infty$  のとき  $-\infty < y < +\infty$ .

確率のとり範囲  $0 \leq p \leq 1$  に収まらない…

$x \in (-\infty, \infty)$  を  $y \in (0, 1)$  に写す写像ある？

一例 (標準) シグモイド関数. sigmoid function  $y = \frac{e^x}{1+e^x} = \frac{1}{1+e^{-x}}$

$x$	$-\infty$		0		$+\infty$
$y'$	+	+	$\frac{1}{4}$	+	+
$y$	0	↗	$\frac{1}{2}$	↗	+1





# 標準シグモイド関数を移動拡大縮小したもの ロジスティック関数 (logistic function)


$\beta_1 > 0$  とする.

$x_1$	$-\infty$		$-\beta_0/\beta_1$		$+\infty$
$\frac{dp}{dx_1}$	+	+	$\frac{\beta_1}{4}$	+	+
$p = \frac{e^{\beta \cdot x}}{1+e^{\beta \cdot x}}$	0	↗	$\frac{1}{2}$	↗	+1

$$\beta_1 \left( x - \left( -\frac{\beta_0}{\beta_1} \right) \right)$$

$\beta_1$  横拡大縮小

$\beta_0$  横移動



## ロジスティック回帰はもっとも 2:母平均値 対 母比率

	説明変数なし	説明変数あり
母平均値	$Y \sim N(\mu, \sigma^2)$ の母平均値 $\mu$ の推定 <small>岩薩林 確率・統計 §7.1</small> $\bar{Y} = \frac{1}{n}(Y_1 + \dots)$	線形回帰 $Y = \beta_0 + \beta_1 x + \epsilon$ $\beta_j$ : 連立 1 次方程式を解いて
カテゴリ変数の確率	$Y \sim B(1, p)$ の母比率 $p$ の推定 <small>岩薩林 確率・統計 §7.3</small> $\hat{p} = \frac{k}{n}$	ロジスティック回帰 $P(Y = 1) = \frac{e^{\beta \cdot x}}{1 + e^{\beta \cdot x}}$ $\beta_j$ : ニュートン法で

## ここまで来たよ

### 3 線形回帰モデル - 単回帰

### 5 ロジスティック回帰

- 分類問題
- ロジスティック回帰の統計モデル
- Python で関数値を求める・グラフを描く
- ロジスティック回帰の実行

## Python で関数値を求める・グラフを描く

- 数学関数 標準以外に, math, numpy, scipy などに含まれる  
`np.exp(x)`
- リスト: `[-0.5,0,0.5]`
  - ▶ <https://paiza.jp/works/python3/primer/beginner-python4>
- 多くの関数は, リストの各要素に適用される: `np.exp([-0.5,0,0.5])`
- ユーザによる関数定義

```
def 関数名(引数 1, 引数 2):
```

```
    x=1+1
```

```
    # 中略
```

```
    return 返り値
```

ブロックは中括弧の代わりにインデントで. 文末に;  
は不要.


- matplotlib の plot: `plot(横軸の値のリスト, 縦軸の値のリスト)`
  - ▶ リストの長さは同じである必要
  - ▶ *i* 番目同士を組にしてデータ点とみなす

## Matplotlibでのグラフ描画

✓  
1  
秒

```
[18] import matplotlib.pyplot as plt #低レベルグラフ描画
      1 fig, ax=plt.subplots(2,3)
      2 ax[0][0].plot(x,y1)
      3 ax[0][1].plot(x,y1)
      4 ax[0][2].plot(x,x)
```

Figure [matplotlib.lines.Line2D at 0x7fe5b2837e10>]



## ここまで来たよ

### 3 線形回帰モデル - 単回帰

### 5 ロジスティック回帰

- 分類問題
- ロジスティック回帰の統計モデル
- Python で関数値を求める・グラフを描く
- ロジスティック回帰の実行

# ロジスティック回帰の回帰係数の推定方法

尤度 (ゆうど) (2 変数関数) 確率統計 I(2021)L12

$$L(\beta_0, \beta_1) = \prod_{i=1}^n p(y_i | x_i)$$

$x_i$  で測定したときに、測定値  $y_i$  が得られる同時確率 (を、回帰係数  $\beta_0, \beta_1$  の関数として見たもの).

$L(\beta_0, \beta_1)$  を変数  $\beta_0, \beta_1$  について最大化.

微積分 II

$$\rightsquigarrow \frac{\partial L}{\partial \beta_0}(\beta_0, \beta_1) = \frac{\partial L}{\partial \beta_1}(\beta_0, \beta_1) = 0$$

$\rightsquigarrow$  **ニュートン法** (反復法 iteration) で数値的に解く

数値計算法



## statsmodels.glm

```
import statsmodels.api.formula as smf
```

- glm in statsmodels

```
[ ] 1 import statsmodels.api as sm
    2 import statsmodels.formula.api as smf
```

```
✓ [121] 1 result_g=smf.glm(formula='y~x',data=dfb, family=sm.families.Binomial(sm.families.links.logit()),fit())
0秒
```

```
✓ [122] 1 result_g.summary()
0秒
```

## Generalized Linear Model Regression Results

モデル

Dep. Variable: y  
 Model: GLM  
 Model Family: Binomial  
 Link Function: logit

No. Observations: 100  
 Df Residuals: 98  
 Df Model: 1  
 Scale: 1.0000

Method: IRLS  
 Date: Fri, 22 Oct 2021  
 Time: 08:45:09

Log-Likelihood: -8.7065  
 Deviance: 17.413  
 Pearson chi2: 22.8

あてはまり

No. Iterations: 10

Covariance Type: nonrobust

	coef	std err	z	P> z	[0.025 0.975]
Intercept	4.0625	1.843	2.204	0.028	0.450 7.675
x	9.9026	3.610	2.743	0.006	2.828 16.977

回帰係数