




# 日本行動計量学会セミナー

## 線形モデルの理論とRを用いた分析事例

以下に、資料を配置する予定です。

<https://logics-of-blue.com/bms-seminar-2025/>



# 自己紹介・セミナー概要

# 自己紹介

名前

馬場真哉

学生の頃の専門

水産学 


前職

システムエンジニア

現職

フリーランス  
東京科学大学非常勤講師  
北海道大学非常勤講師  
帝京大学特任講師

# 本も書いています



# セミナーのテーマ

## (前半)線形回帰モデルから一般化線形モデルへ

ロジスティック回帰モデルの特徴を学び  
分析結果を理解できるようになる

## (後半)切片と傾きが時間に応じて変化する回帰モデル

線形ガウス状態空間モデルの初歩を学び  
簡単な分析ができるようになる

# 単純なモデルを発展させる 分析モデルの特徴を理解し、実装する



# 回帰分析の初歩

# 内容

1. 回帰分析とは？ 回帰モデルとは？

2. 回帰モデルと正規分布

# 回帰分析の目的

## 回帰分析の目的

2つ以上の変数の関係性を、定量的に表す式を求める

→回帰モデル

変数が2つの場合は「単回帰モデル」と呼ばれる


## 単回帰モデルによって得られた数式の例

$$\text{ビールの売り上げ} = 22.79 + \text{気温} \times 0.69$$




# 線形回帰モデル

ビールの売り上げと気温の散布図




# 線形回帰モデル

売り上げ =  $22.79 + \text{気温} \times 0.69$ の直線を追加  
(回帰直線と呼ぶ)



# 線形回帰モデル

売り上げ =  $22.79 + \text{気温} \times 0.69$ の直線を追加  
(回帰直線と呼ぶ)



# 回帰分析の目的

## 単回帰モデルによって得られた数式の例

$$\text{ビールの売り上げ} = 22.79 + \text{気温} \times 0.69 + \text{誤差}$$

誤差を入れるのを忘れない

# 回帰分析のメリット

**解釈**      売上と気温の関係性が分かる  
→ 気温が上がると、売り上げも上がる

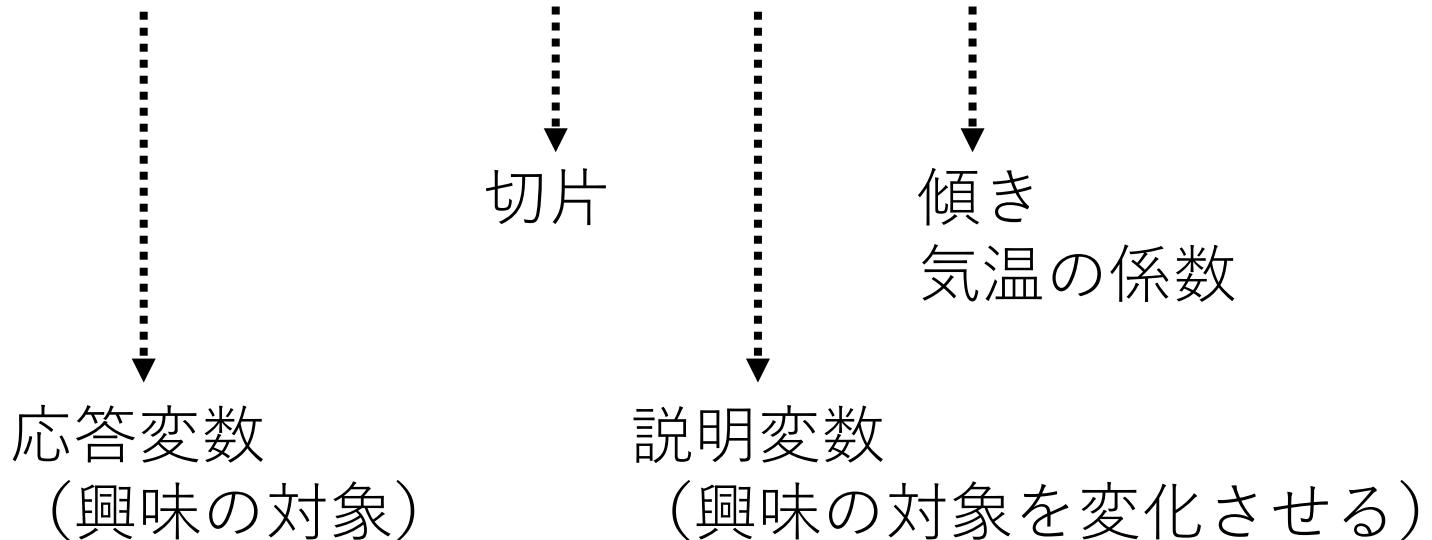
**予測**      気温をもとにして、売り上げを予測できる  
→ 気温が10度の時の売り上げを予測する  
     $\text{売り上げ} = 22.79 + 10 \times 0.69 \approx 30$   
    およそ、30万円の売り上げになると予測

**現象を数式で表現し、  
現象の解釈や予測に役立たせる**

# 線形回帰モデル

## 回帰分析によって得られた数式の例

$$\text{ビールの売り上げ} = 22.79 + \text{気温} \times 0.69 + \text{誤差}$$



一般的な記号

切片  $\beta_0$ 、傾き  $\beta_1$ 、  
応答変数  $Y_i$ 、説明変数  $x_i$ 、誤差  $\varepsilon_i$

$$Y_i = \beta_0 + x_i \cdot \beta_1 + \varepsilon_i$$

# 内容

1. 回帰分析とは？ 回帰モデルとは？

2. 回帰モデルと正規分布

# 線形回帰モデル

## 回帰分析によって得られた数式の例

① ビールの売り上げ =  $22.79 + \text{気温} \times 0.69 + \text{誤差}$

$Y_i$   $x_i$

平均が0である  
正規分布に従うと仮定

- ※ 独立などの条件を満たせば、正規分布以外の分布の誤差でも、最小二乗法を用いたパラメータ推定には支障ない  
→これから説明する一般化線形モデルを理解するために、今回の講義では最初から正規分布を仮定する

正規分布を使ってモデルを作る



# 線形回帰モデル

## 回帰分析によって得られた数式の例

①  $Y_i = 22.79 + x_i \times 0.69 -$  平均0、分散 $\sigma^2$ の正規分布に従う誤差

②  $Y_i \sim \text{Normal}(22.79 + x_i \cdot 0.69, \sigma^2)$

誤差が正規分布に従う

→  $Y$ も正規分布に従う(正規分布の特徴)

# 線形回帰モデル


## 回帰分析によって得られた数式の例

- ①  $Y_i = 22.79 + x_i \times 0.69 + \text{平均}0、\text{分散}\sigma^2\text{の正規分布に従う誤差}$
- ②  $Y_i \sim \text{Normal}(22.79 + x_i \cdot 0.69, \sigma^2)$
- ③  $\mu_i = 22.79 + x_i \cdot 0.69$   
 $Y_i \sim \text{Normal}(\mu_i, \sigma^2)$

**正規分布の期待値や分散を見やすくする  
→ 式を2行に分けた。意味は全く同じ**


# 線形回帰モデル

売り上げの分布は、平均が「 $22.79 + 10 \times 0.69$ 」の正規分布




# 線形回帰モデル

売り上げの分布は、平均が「 $22.79 + 25 \times 0.69$ 」の正規分布




# 回帰モデルのイメージをデータを変えて確認



気温が「0，10，20，30」の4種類のみ存在。  
売り上げを応答変数として、回帰直線を描いた

# 気温別に、売り上げデータのヒストグラムを描く

## → 正規分布の釣り鐘型の分布になる





# 統計モデルと確率分布 再考


# モデルとは

## モデル

現象を単純化した「模型」のこと  
プラモデルのモデル

## モデルの例

飛行機のモデル（模型）を考える



ぼくの考えた「さいきょう」の  
飛行機だよ！！

（馬場が描きました）

**プロペラが無いので飛ばない**



# モデルとは


## モデルの使い道

モデルを使えば、  
実際に行動する前に、結果について議論できる  
何億円ものお金をかけて本物を作る前に、  
空気抵抗や推進力などいろいろなことを検討できる

**データに基づいてモデルを作ること、  
将来の予測等ができるかもしれない**


# モデルの利用

## モデルと現実の対応に要注意




モデルの飛行機には、エンジンもプロペラもあってちゃんと飛ぶことがわかりました

でもなんか、本物の飛行機は飛ばんのだが




本物の飛行機には、エンジンついてないからね～

ダメじゃん




# モデルの利用

## モデルと現実の対応に要注意



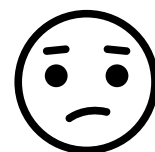
回帰分析の結果、こういう感じになったよ！

データは線形回帰モデルが適合しそうなの？



全然違います

その分析結果を本当に使うの……？



# 統計学におけるモデル

## モデル

模型。現実世界の模型を作る

## 統計学におけるモデル

観測したデータを生み出す確率的な過程を  
簡潔に記述したもの。

Graham Upton, Ian Cook. (白幡慎吾 監訳). (2010). 統計学辞典. 共立出版

**「データを生み出す確率的な過程」や  
「データが得られる過程」に着目**

# 統計学におけるモデル

## 今回の事例

湖からの標本抽出

→5尾の魚だけがいる湖から1尾抽出する

1cm




2cm




3cm



4cm



5cm



とても小さな湖から無作為に1尾を取得  
このモデル(データが得られる過程)は？

# 統計学におけるモデル

1cm



2cm



3cm



4cm



5cm



どの体長も、0.2の  
確率で得られる

体長	確率
1cm	0.2
2cm	0.2
3cm	0.2
4cm	0.2
5cm	0.2

## 確率分布


確率変数(この場合の体長)と確率の対応関係のこと  
今回は右上の数表が確率分布となる

このモデルはちょっと単純すぎ？  
もう少し現実味のあるモデルにしたい

# 正規分布を利用したモデル

## 正規分布の特徴

平均値(期待値)に近い値が出やすい  
平均値に対して左右対称の確率分布



体長	確率
1cm	0.1
2cm	0.2
3cm	0.4
4cm	0.2
5cm	0.1

正規分布を使う方がよさそうな気がする？

# 正規分布を利用したモデル

## ビールの売り上げは正規分布に従うか？

平均的な売り上げになりやすく、  
上振れ・下振れは同等の確率で発生するとみなせそう？  
→このように想定できるなら、正規分布がよさそう

## どんなデータでも正規分布を使えるか？

0か1しかとらないデータは、正規分布を使えない気がする  
整数の値しかとらないデータも、正規分布は不適合

**正規分布以外の確率分布を使う方が  
現実にあうモデルになる可能性がある**





# ロジスティック回帰の初歩

# 一般化線形モデルの基本

## 線形回帰モデル

$$\mu_i = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Normal}(\mu_i, \sigma^2)$$



正規分布しか扱えない

## 一般化線形モデル(Generalized Linear Models :GLM)

正規分布以外の分布を扱うことができる

**正規分布しか使えない線形回帰モデルから  
様々な分布が使える一般化線形モデルへ**

# 一般化線形モデルの基本

## 一般化線形モデルの構造(イメージ)

$$g(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$

⋮  
→ 線形の構造(線形予測子)でパラメータが変化  
リンク関数 $g()$ を使い、モデルの表現力を上げる(後述)

$Y_i \sim$  何らかの分布( $\theta_i$ )

⋮  
→ 正規分布以外の様々な分布に対応

# 一般化線形モデルの基本

## 正規線形モデル(線形回帰モデル)

リンク関数が恒等関数であり、  
正規分布を確率分布として用いる一般化線形モデル

## 恒等関数

$f(x) = x$ となる関数のこと

## 線形回帰モデル(復習)

$$\mu_i = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Normal}(\mu_i, \sigma^2)$$

# 一般化線形モデルの基本

## ロジスティック回帰モデル

一般化線形モデルにはいろいろな種類がある

- ・ポアソン回帰モデル
- ・ガンマ回帰モデル

→用いる確率分布によって名前が変わる

今回は「ロジスティック回帰モデル」に焦点を当てる

# 内容

1. 二項分布を使ったモデル化
2. ロジスティック関数・ロジット関数
3. ロジスティック回帰の構造

# 二項分布

## 二項分布の確率質量関数

$$\text{Bin}(X|n, \theta) = {}_n C_x \cdot \theta^x \cdot (1 - \theta)^{n-x}$$

確率変数 $X$ は0以上 $n$ 以下の整数を取りうる

パラメータは $n, \theta$ の2つ

$n$ ：試行回数

$\theta$ ：成功確率

# 二項分布

## 二項分布が適合しそうな例

表が出る確率が $\theta$ であるコインを $n$ 回投げた時、 $X$ 回の表が出る確率

$$\text{Bin}(X|n, \theta) = {}_n C_x \cdot \theta^x \cdot (1 - \theta)^{n-x}$$

## 期待値

$$E(X) = n\theta$$

## 分散

$$V(X) = n\theta(1 - \theta)$$



# ロジスティック回帰

## 線形回帰モデルとロジスティック回帰モデルの比較

モデルの構造は似ているが違いもある

### 確率分布の違い

線形回帰 : 正規分布

ロジスティック回帰 : 二項分布

→これが大事。ここが変わると連鎖的に色々変わる

### 変化するパラメータの違い

線形回帰 : 期待値 $\mu$ が変化する

ロジスティック回帰 : 成功確率 $\theta$ が変化する

→確率分布が違うので、パラメータも変わる

→期待値は「試行回数 $n$ 」×「成功確率 $\theta$ 」なので注意

# ロジスティック回帰

## 線形回帰モデルの場合

①  $Y_i = \beta_0 + \beta_1 \cdot x_i + \text{正規分布に従う誤差}$

## ロジスティック回帰モデルの場合

②  $Y_i = \beta_0 + \beta_1 \cdot x_i + \text{二項分布に従う誤差} \cdots ?$



これは間違い！

**誤差が加わる構造ではないので注意！**

# ロジスティック回帰

## 線形回帰モデルの場合

①  $Y_i = \beta_0 + \beta_1 \cdot x_i + \text{正規分布に従う誤差}$

③  $\mu_i = \beta_0 + \beta_1 \cdot x_i$   
 $Y_i \sim \text{Normal}(\mu_i, \sigma^2)$



確率分布のパラメータが変わる！

**③の構造で確率分布を変更するイメージ！  
ロジスティック回帰は成功確率 $\theta$ が変化する**

# ロジスティック回帰

## データの例

10人ずつの班を用意しテストを受験、 $Y$ 人が合格  
班ごとに勉強時間 $x$ を変化

→試行回数 $n$ は10回（1つの班に10人いる）

→成功確率 $\theta$ は、勉強時間によって変化する

## データが得られる確率的な過程(仮)

$$\theta_i = \beta_0 + \beta_1 \cdot x_i$$

$$Y_i \sim \text{Bin}(10, \theta_i)$$




NormalをBinに変更した。実は、まだ修正が必要

# ロジスティック回帰モデル

二項分布に従うデータに対して、線形構造を指定する問題点

$$\theta_i = \beta_0 + \beta_1 \cdot x_i$$

⋮  
→  $\theta_i$ が0未満や1以上の値をとることがありうる



# 内容


1. 二項分布を使ったモデル化
2. ロジスティック関数・ロジット関数
3. ロジスティック回帰の構造

# ロジスティック回帰モデル

## ロジスティック関数

$$\text{logistic}(x) = \frac{1}{1 + \text{EXP}(-x)}$$

0から1の範囲しかとらない



# ロジスティック回帰モデル

ロジスティック関数は、なぜ0以上1以下しかとらないか

$$\text{logistic}(x) = \frac{1}{1 + \text{EXP}(-x)}$$

以下は指数関数と呼ぶ。  $e$  はネイピア数 (2.7くらいの値)

$$e^x$$

以下のように表記することもある (意味は同じ)

$$\text{EXP}(x)$$

$x = 0$  なら、指数関数の結果は1になる

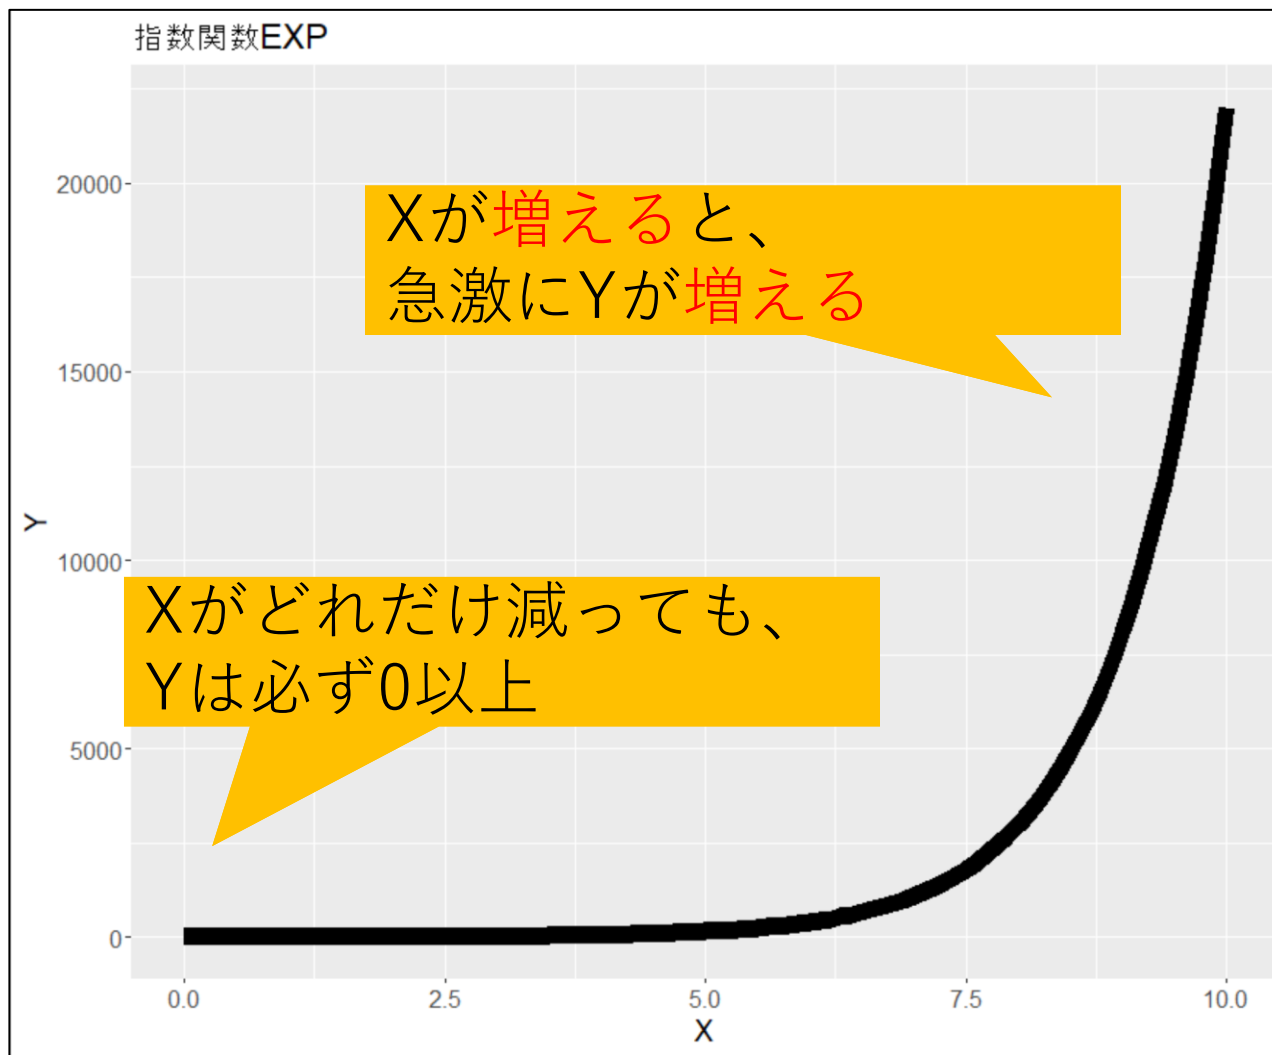
$$e^0 = \text{EXP}(0) = 1$$



# ロジスティック回帰モデル

## 指数関数のグラフ①

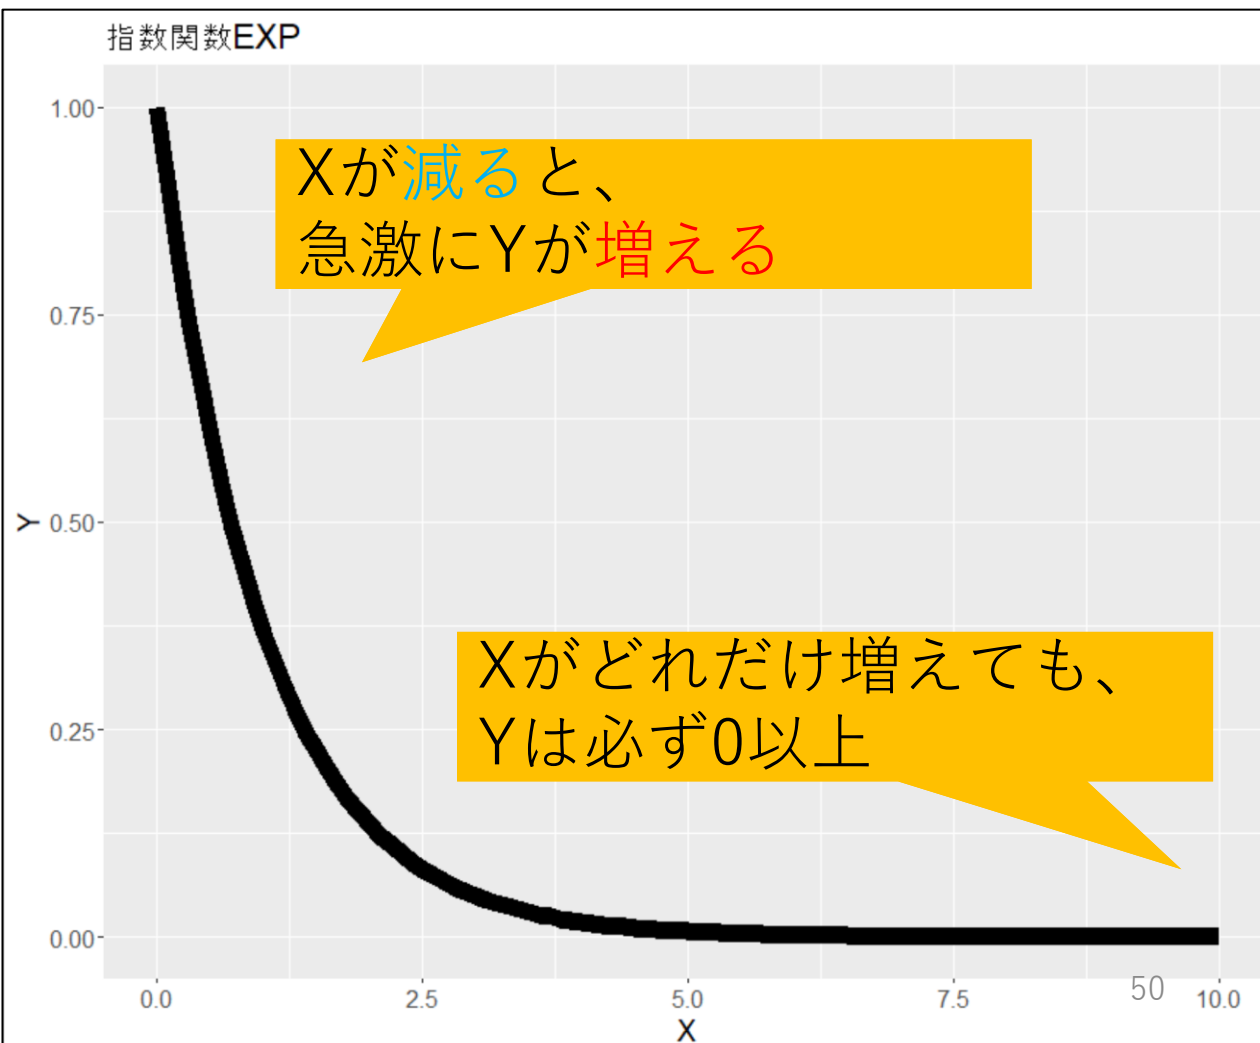
$$e^x = \text{EXP}(x)$$



# ロジスティック回帰モデル

## 指数関数のグラフ②

$$e^{-x} = \text{EXP}(-x)$$



# ロジスティック関数

## ロジスティック関数

$x$ が増えると、

急激に $\text{EXP}(-x)$ が0に近づく

→分母の値が「1」に近づく

→ロジスティック関数の結果は1に近づく

$$\text{logistic}(x) = \frac{1}{1 + \text{EXP}(-x)}$$

$x$ が減ると、

急激に $\text{EXP}(-x)$ が増える

→分母の値が増える

→ロジスティック関数の結果は0に近づく

0.25  
0.00

-10

-5

0

5

10

x

# ロジスティック回帰モデル

## ロジット関数

$$\text{logit}(x) = \log \frac{x}{1-x}$$

ロジット関数はロジスティック関数の逆関数

$$\text{logit}(\text{logistic}(x)) = x$$

# 内容

1. 二項分布を使ったモデル化
2. ロジスティック関数・ロジット関数
3. ロジスティック回帰の構造

# ロジスティック回帰モデル

データが得られる確率的な過程(修正版)

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

# ロジスティック回帰モデル

## データが得られる確率的な過程(修正版)

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

リンク関数として  
ロジット関数を使う

## 1つ目の式の左右両辺にロジスティック関数を適用

$$\theta_i = \text{logistic}(\beta_0 + \beta_1 \cdot x_i)$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$


線形予測子にロジスティック関数を  
適用したと解釈できる

# ロジスティック回帰モデル

## データが得られる確率的な過程(修正版)

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Bin}(10, \theta_i)$$

$$\theta_i = \text{logistic}(\beta_0 + \beta_1 \cdot x_i)$$
$$Y_i \sim \text{Bin}(10, \theta_i)$$





# まとめ

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

$$\theta_i = \text{logistic}(\beta_0 + \beta_1 \cdot x_i)$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

## ロジスティック回帰モデル

リンク関数がロジット関数であり、  
二項分布を確率分布として用いる一般化線形モデル

モデルの構造は、  
ロジスティック関数を使って覚えるとわかりやすい

$$\theta_i = \frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot x_i))}$$


$$Y_i \sim \text{Bin}(n, \theta_i)$$

$$\text{logistic}(x) = \frac{1}{1 + \text{EXP}(-x)}$$

「ある」「ない」などの二値分類や  
「○個中、×個が成功」といったデータに対して適用する



# 尤度と最尤法



切片と傾きの計算方法

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Bin}(n, \theta_i)$$

# 内容

1. 尤度と最尤法の基本
2. 対数と対数尤度
3. ロジスティック回帰の尤度

# 尤度と最尤法

## 尤度

パラメータを指定したときに  
手持ちのデータが得られる確率を計算することによって得る

## 尤度関数


標本 $y$ は固定。パラメータ $\theta$ を入力すると尤度を出力する関数  
 $f(y|\theta)$ と表記される

(尤度関数の合計値や積分値は1にならないので注意)

(尤度関数は確率質量関数や確率密度関数とはみなせない)

# 尤度と最尤法

例) コインを10枚投げた。そのうちの2枚が表だった



データ： 表2枚

パラメータ： $\theta$  = コインを投げて表が出る確率

尤度関数： $f(y|\theta) = \text{Bin}(2|10, \theta)$

$$= {}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2}$$

$$f(y|0.1) = {}_{10}C_2 \cdot 0.1^2 \cdot (1 - 0.1)^{10-2} \approx 0.19$$


$$f(y|0.2) = {}_{10}C_2 \cdot 0.2^2 \cdot (1 - 0.2)^{10-2} \approx 0.30$$

$$f(y|0.3) = {}_{10}C_2 \cdot 0.3^2 \cdot (1 - 0.3)^{10-2} \approx 0.23$$

# 尤度と最尤法

例) コインを10枚投げる作業を2回行った。

1回目：2枚表      2回目：4枚表



データ：      表2枚・表4枚

パラメータ： $\theta$  = コインを投げて表が出る確率

尤度関数： $f(y|\theta) = \text{Bin}(2|10, \theta)$   
 $\times \text{Bin}(4|10, \theta)$


$$= {}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2} \\ \times {}_{10}C_4 \cdot \theta^4 \cdot (1 - \theta)^{10-4}$$

# 尤度と最尤法

例) コインを10枚投げる作業を2回行った。

1回目：2枚表      2回目：4枚表

データ：      表2枚・表4枚



パラメータ： $\theta$  = コインを投げて表が出る確率

尤度関数： 
$$f(y|\theta) = {}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2} \\ \times {}_{10}C_4 \cdot \theta^4 \cdot (1 - \theta)^{10-4}$$

式の書き換え

データ：  $y_1 = 2, y_2 = 4$

尤度関数： 
$$f(y|\theta) = \prod_{i=1}^2 {}_{10}C_{y_i} \cdot \theta^{y_i} \cdot (1 - \theta)^{10-y_i}$$

# 尤度と最尤法

## 対数尤度

尤度の対数をとったもの。計算が楽になる(後述)

## 最尤法

(対数) 尤度を最大にするパラメータを選ぶという、  
パラメータ推定の原理のこと



# 尤度と最尤法

例) コインを10枚投げた。そのうちの2枚が表だった

データ： 表2枚

## 最尤法

尤度が最も大きくなる  
パラメータを採用

パラメータ： $\theta$  = コインを投げて表が出る確率

関数：  $f(y|\theta) = {}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2}$

$$f(y|0.1) = {}_{10}C_2 \cdot 0.1^2 \cdot (1 - 0.1)^{10-2} \approx 0.19$$

$$f(y|0.2) = {}_{10}C_2 \cdot 0.2^2 \cdot (1 - 0.2)^{10-2} \approx 0.30$$

$$f(y|0.3) = {}_{10}C_2 \cdot 0.3^2 \cdot (1 - 0.3)^{10-2} \approx 0.23$$

# 内容

1. 尤度と最尤法の基本
2. 対数と対数尤度
3. ロジスティック回帰の尤度

# 対数と対数尤度

## 対数と対数尤度

尤度が最大になるパラメータを採用するのが最尤法

尤度の代わりに、尤度の対数をとった「対数尤度」を使う  
→なぜわざわざ対数をとるのか？

# 対数と対数尤度

## 対数

指数の計算の逆だと思えばOK

### 指数

$$2^1 = 2$$

$$2^2 = 4$$

$$2^3 = 8$$

### 対数

$$\log_2 2 = 1$$

$$\log_2 4 = 2$$

$$\log_2 8 = 3$$

# 対数と対数尤度

## 対数

指数の計算の逆だと思えばOK

指数
$2^1 = 2$
$2^2 = 4$
$2^3 = 8$

対数
$\log_2 2 = 1$
$\log_2 4 = 2$
$\log_2 8 = 3$

$\log_2 8$ の「 $2$ 」の部分に対数の底（テイ）と呼ぶ

# 対数と対数尤度

$$\log_2 2 = 1$$

$$\log_2 4 = 2$$

$$\log_2 8 = 3$$

## 対数の特徴

掛け算を足し算に変えることができる

素朴な掛け算

$$2 \times 4 = 8$$

両辺に対数をとる

$$\log_2(2 \times 4) = \log_2(8)$$

対数の中の掛け算は、対数の外の足し算になる

$$\log_2(2) + \log_2(4) = \log_2(8)$$

# 対数と対数尤度

$$\log_2 2 = 1$$

$$\log_2 4 = 2$$

$$\log_2 8 = 3$$

## 対数の特徴

掛け算を足し算に変えることができる

素朴な掛け算

$$2 \times 4 = 8$$

両辺に対数をとる

$$\log_2(2 \times 4) = \log_2(8)$$

1 2 3

対数の中の掛け算は、対数の外の足し算になる

$$\log_2(2) + \log_2(4) = \log_2(8)$$

# 対数と対数尤度

## 自然対数

EXP（ネイピア数の指数関数）の逆は、対数の底を略する  
これを自然対数と呼ぶ

対数の底は何でもよいが、  
自然対数を使うことが多い

### 自然対数

$$\log e = 1$$

$$\log e^2 = 2$$


$$\log e^3 = 3$$



# 尤度と最尤法

例) コインを10枚投げる作業を2回行った。

1回目：2枚表      2回目：4枚表



データ：      表2枚・表4枚

パラメータ： $\theta$  = コインを投げて表が出る確率

尤度関数：

$$f(y|\theta) = {}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2} \\ \times {}_{10}C_4 \cdot \theta^4 \cdot (1 - \theta)^{10-4}$$

対数尤度関数：

$$\log(f(y|\theta)) = \\ \log({}_{10}C_2 \cdot \theta^2 \cdot (1 - \theta)^{10-2}) + \log({}_{10}C_4 \cdot \theta^4 \cdot (1 - \theta)^{10-4})$$

# 尤度と最尤法

例) コインを10枚投げる作業を2回行った。

1回目：2枚表      2回目：4枚表

データ：  $y_1 = 2, y_2 = 4$

尤度関数：  $f(y|\theta) = \prod_{i=1}^2 {}_{10}C_{y_i} \cdot \theta^{y_i} \cdot (1 - \theta)^{10-y_i}$

対数尤度関数：

$$\log(f(y|\theta)) = \sum_{i=1}^2 \log({}_{10}C_{y_i} \cdot \theta^{y_i} \cdot (1 - \theta)^{10-y_i})$$

**対数を使うと掛け算しなくて済む！**

# 内容

1. 尤度と最尤法の基本
2. 対数と対数尤度
3. ロジスティック回帰の尤度

# 尤度と最尤法

## ロジスティック回帰モデルの場合

ロジスティック回帰モデルでは、成功確率が変わる

### 二項分布の単純なモデル

$$Y \sim \text{Bin}(n, \theta)$$

$\vdots \rightarrow n$  も  $\theta$  も一定

### ロジスティック回帰モデル

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

$\vdots \rightarrow \theta$  が  $x_i$  の影響を受ける

尤度の計算の際、成功確率が変わる  
表が出る確率が違うコインを使うイメージ

# ロジスティック回帰

## データの例

10人ずつの班を用意しテストを受験、 $Y$ 人が合格  
班ごとに勉強時間 $x$ を変化

→試行回数 $n$ は10回（1つの班に10人いる）

→成功確率 $\theta$ は、勉強時間によって変化する

## 対数尤度の計算の対象となるデータの例

モデル(logistic表記)

$$\theta_i = \text{logistic}(\beta_0 + \beta_1 \cdot x_i)$$

$$Y_i \sim \text{Bin}(n, \theta_i)$$

データ

$$y_1 = 2, y_2 = 4$$

$$x_1 = 5, x_2 = 10$$

# 尤度と最尤法

## 尤度の計算例

データ： (10人中)2人・4人合格 / 勉強時間は5時間・10時間

パラメータ： $\beta_0$ 切片、 $\beta_1$ 傾き（勉強時間の係数）

尤度関数：

$$f(y|\theta) = \text{Bin}(2|10, \text{logistic}(\beta_0 + \beta_1 \cdot 5)) \\ \times \text{Bin}(4|10, \text{logistic}(\beta_0 + \beta_1 \cdot 10))$$

# 尤度と最尤法

## 尤度の計算例

データ： (10人中)2人・4人合格 / 勉強時間は5時間・10時間

パラメータ： $\beta_0$ 切片、 $\beta_1$ 傾き（勉強時

成功確率が  
説明変数に応じて変化

尤度関数：

$$f(y|\theta) = \text{Bin}(2|10, \text{logistic}(\beta_0 + \beta_1 \cdot 5)) \\ \times \text{Bin}(4|10, \text{logistic}(\beta_0 + \beta_1 \cdot 10))$$

$$= {}_{10}C_2 \cdot \text{logistic}(\beta_0 + \beta_1 \cdot 5)^2 \cdot (1 - \text{logistic}(\beta_0 + \beta_1 \cdot 5))^{10-2} \\ \times {}_{10}C_4 \cdot \text{logistic}(\beta_0 + \beta_1 \cdot 10)^4 \cdot (1 - \text{logistic}(\beta_0 + \beta_1 \cdot 10))^{10-4}$$



# ロジスティック回帰の係数の解釈



# ロジスティック回帰モデル

データが得られる確率的な過程(修正版)

$$\text{logit}(\theta_i) = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Bin}(10, \theta_i)$$

ロジスティック関数を適用


$$\theta_i = \text{logistic}(\beta_0 + \beta_1 \cdot x_i)$$
$$Y_i \sim \text{Bin}(n, \theta_i)$$

ロジスティック関数が適用  
→ 係数 $\beta_0, \beta_1$ の解釈に注意

# ロジスティック回帰モデル

## ロジスティック関数を適用すると何が変わるか

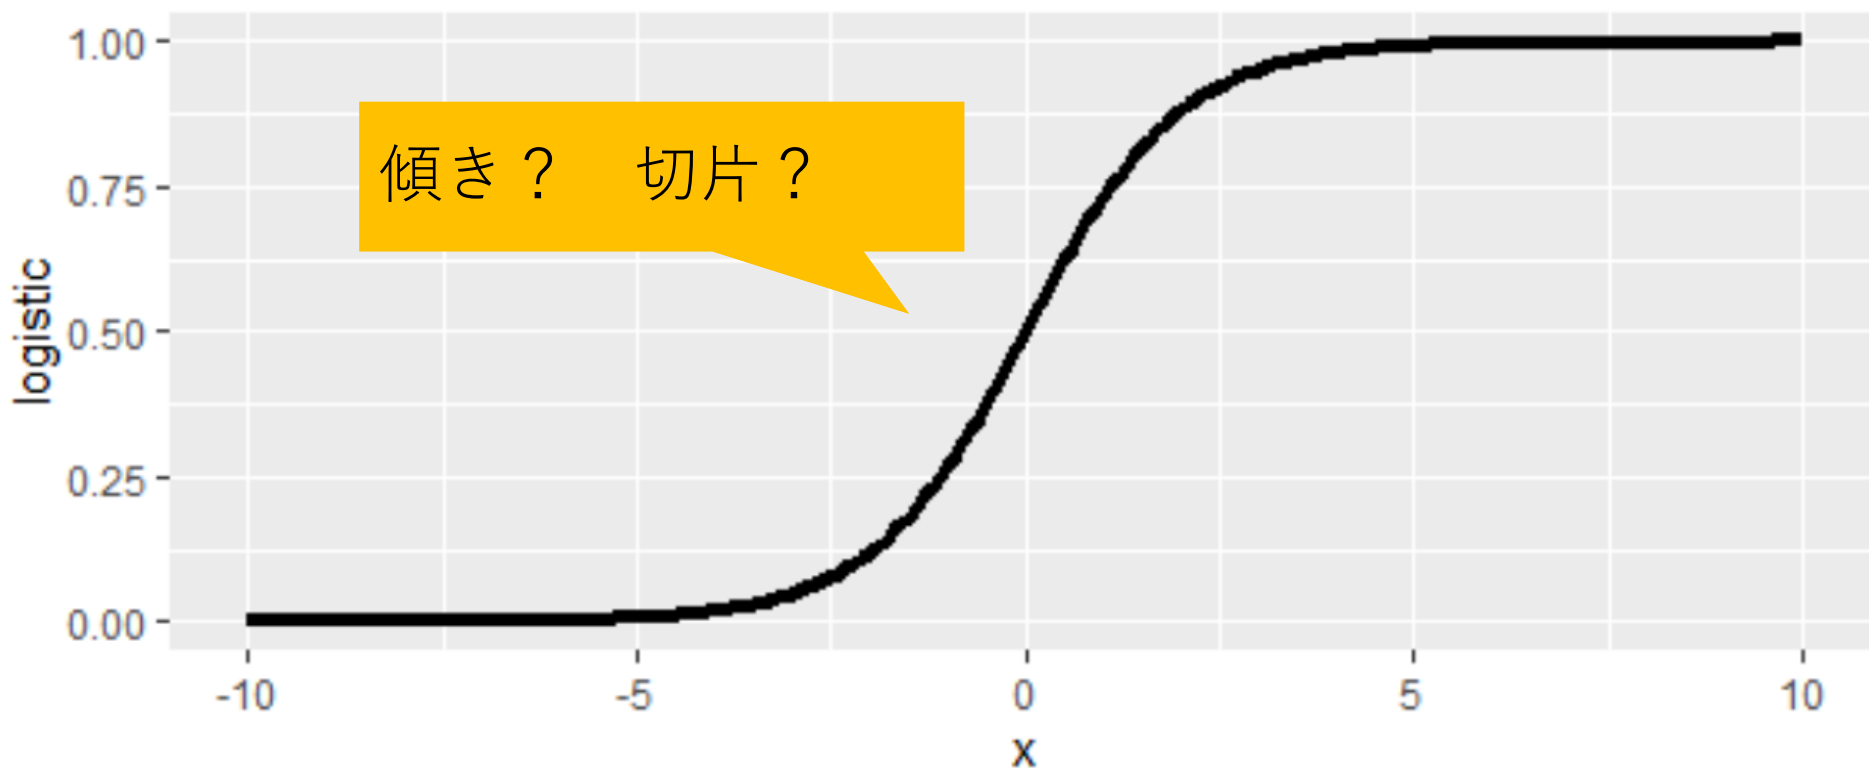
直線の関係性だと、係数の解釈は簡単



# ロジスティック回帰モデル

## ロジスティック回帰

$$\text{logit}(p_i) = \beta_0 + \beta_1 \cdot x_i$$
$$Y_i \sim \text{Bin}(n, p_i)$$



# 内容

1. 切片  $\beta_0$  の解釈

2. 傾き  $\beta_1$  の解釈

# ロジスティック回帰モデル

## オッズ

$$\text{オッズ} = \frac{p}{1-p} \quad p \text{は成功確率}$$

オッズは「成功確率 ÷ 失敗確率」より  
「失敗するよりも何倍成功しやすいか」を表すもの

## 対数オッズ

$$\text{オッズの対数} \quad \text{対数オッズ} = \log \frac{p}{1-p}$$

# ロジスティック回帰モデル

## ロジスティック回帰モデルの解釈

$$\begin{aligned} \text{logit}(p_i) &= \beta_0 + \beta_1 \cdot x_i \\ Y_i &\sim \text{Bin}(10, p_i) \end{aligned}$$

$\beta_0$  は、 $x$  が0の時の  
対数オッズである

# ロジスティック回帰モデル

## ロジット関数(参考)

$$\text{logit}(p) = \log \frac{p}{1-p}$$

ロジット関数は  
対数オッズの定義と同じ！

## 具体例

$x$ が0の時の対数オッズ

$$\text{logit}(p_0) = \beta_0 + \beta_1 \cdot 0$$

$$\log \frac{p_0}{1-p_0} = \beta_0$$

# 内容

1. 切片  $\beta_0$  の解釈

2. 傾き  $\beta_1$  の解釈



# ロジスティック回帰モデル

## オッズ比

オッズの変化率      オッズ比  $= \frac{p_2 \text{のオッズ}}{p_1 \text{のオッズ}} = \frac{p_2 / (1 - p_2)}{p_1 / (1 - p_1)}$

## 対数オッズ比

オッズ比の対数をとったもの

# ロジスティック回帰モデル

## ロジスティック回帰モデルの解釈

$$\text{logit}(p_i) = \beta_0 + \beta_1 \cdot x_i$$

$Y_i \sim \text{Bin}(10, p_i)$

$\beta_1$  は、 $x$  が1単位増えた時の  
対数オッズ比である


# ロジスティック回帰モデル

## 具体例

$x$ が2から3に増えたとする

$$\text{logit}(p_2) = \beta_0 + \beta_1 \cdot 2$$

$$\text{logit}(p_3) = \beta_0 + \beta_1 \cdot 3$$



## ロジスティック関数(参考)

$$\text{logistic}(x) = \frac{1}{1 + \text{EXP}(-x)}$$

両辺にロジスティック関数を適用

$\text{logit}(\text{logistic}(x)) = x$ であることに注意


$$p_2 = \frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot 2))}$$

$$p_3 = \frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot 3))}$$

# ロジスティック回帰モデル

具体例

$$p_2 = \frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot 2))}$$



$p_2$  のオッズをとる

オッズ(参考)

$$\text{オッズ} = \frac{p}{1-p}$$


$$\begin{aligned}\text{オッズ}(p_2) &= \frac{p_2}{1-p_2} = \frac{\frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot 2))}}{1 - \frac{1}{1 + \text{EXP}(-(\beta_0 + \beta_1 \cdot 2))}} \\ &= \underline{\text{EXP}(\beta_0 + \beta_1 \cdot 2)}\end{aligned}$$

# ロジスティック回帰モデル

## 具体例


$$\text{オッズ}(p_2) = \text{EXP}(\beta_0 + \beta_1 \cdot 2)$$

$$\text{オッズ}(p_3) = \text{EXP}(\beta_0 + \beta_1 \cdot 3)$$



オッズ比をとる

$$\frac{\text{オッズ}(p_3)}{\text{オッズ}(p_2)} = \text{EXP}(\beta_1)$$



対数オッズ比 =  $\beta_1$

対数をとる

# Rを用いた実演