

ロジスティック回帰分析

ウェブ掲載用ハンドアウト

増田 弘毅

2023年度公開講座「統計と数学」
11月25日(土)

はじめに: データ解析の汎用的ホワイトボックス



2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

2

内容概観

- イントロ: 回帰分析の概要
 - パラメトリックな確率分布族と説明変数
- ベルヌーイ分布と(2値)ロジスティック回帰分析
 - モデルの構造, 推定方法, 判別・予測
- 多項分布と多項ロジスティック回帰分析
 - カテゴリカルな応答変数への拡張

2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

3

回帰分析 (Regression analysis)

- 「回帰」= 「元の状態へ戻ること」
- 統計では応答変数と説明変数の関係の統計分析全般をあらわす

説明変数 X → 応答変数 Y

観測データ $(X_1, Y_1), \dots, (X_n, Y_n)$ から確率構造を推測

2023/11/25


『ロジスティック回帰分析』増田弘毅 (東大数理)

4

フランシス・ゴルトン (1822-1911)

- 同別親子間の身長関係の傾向を調査
- 人類の身長の平均**回帰**傾向を示唆
- **相関係数** (線形関係) の概念を提唱

$$Y = aX + b + (\text{誤差})$$



応答変数が2値の場合?

© https://en.wikipedia.org/wiki/Regression_toward_the_mean

要因のある2値反応データ

- 生活習慣病の**発症**確率の予測
- 疾患のリンパ節への**転移**確率の予測
- 化学成分量を要因として**薬効有無**の判断
- 試験をパスするにはどのくらい勉強すれば?

2値の確率分布を想定したい

$$x = (x_1, \dots, x_p) \xrightarrow{\text{要因入力}} \text{変換} \xrightarrow{\text{出力}} y \in \{0, 1\}$$

ベルヌーイ (Bernoulli) 分布

- 表が出る確率が θ のコイン投げの結果の分布 ($0 < \theta < 1$):

$$\text{確率} \begin{cases} P[Y = 1] = \theta \\ P[Y = 0] = 1 - \theta \end{cases} \Rightarrow p(y; \theta) = \theta^y (1 - \theta)^{1-y}, \quad y \in \{0, 1\}$$

- P は Probability の頭文字.

- θ はさまざまな**要因** (説明変数) に依存して変わるはず

要因入力: (x_1, x_2, \dots, x_p)


結果出力: $y = 0$ or $y = 1$ ← $p(y; \theta(x)) = \theta(x)^y (1 - \theta(x))^{1-y}$

確率のロジット変換

$$p = \frac{1}{1 + e^{-z}} \quad 0 < p < 1, z \in \mathbb{R} \quad z = \log \left(\frac{p}{1-p} \right)$$

- 各 $a \in \mathbb{R}$ に対し, $(-\infty, \infty)$ から $(0, 1)$ への関数

$$z \mapsto \frac{1}{1 + e^{-az}}$$



- 統計的パラメータ $\beta = (\beta_1, \dots, \beta_p) \in \mathbb{R}^p$ の導入と変換:

$$\begin{aligned} \log \left(\frac{P[Y_i = 1]}{1 - P[Y_i = 1]} \right) &= \beta^\top x_i := \langle \beta, x_i \rangle = \sum_{j=1}^p x_{ij} \beta_j \\ \Leftrightarrow P[Y_i = 1] &= (1 + \exp(-\beta^\top x_i))^{-1} \end{aligned}$$

ロジスティック回帰モデル

- データセット $(x_1, y_1), \dots, (x_n, y_n)$:
 - 説明変数 $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})^T \in \mathbb{R}^p$
 - 目的変数 $y_i \in \{0, 1\}$
- 未知パラメータ $\beta = (\beta_1, \dots, \beta_p)$
- 目的変数 y_i の統計モデル:

$$p(y_i|x_i; \beta) = \pi(x_i; \beta)^{y_i} \{1 - \pi(x_i; \beta)\}^{1-y_i},$$

$$\pi(x_i; \beta) = \frac{1}{1 + \exp\left(-\sum_{j=1}^p \beta_j x_{ij}\right)}$$

要因入力: (x_1, x_2, \dots, x_p)

結果出力: $y = 0$ or $y = 1$

- ベルヌーイ分布の**パラメータ変動版**

Cox, D.R. (1958) The regression analysis of binary sequences (with discussion). *J Roy Stat Soc B* 20: 215–242.

2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

9

最尤 (さいゆう) 法によるモデルの推定

$$p(y_i|x_i, \beta) = \pi(x_i; \beta)^{y_i} \{1 - \pi(x_i; \beta)\}^{1-y_i}$$

$$\pi(x_i; \beta) = \frac{1}{1 + \exp\left(-\sum_{j=1}^p \beta_j x_{ij}\right)}$$

- データの実現値 $\{(x_i, y_i)\}_{i=1}^n$ が生じた**対数確率 (対数尤度)**

$$\ell_n(\beta) = \log \left(\prod_{i=1}^n p(y_i|x_i, \beta) \right) = \sum_{i=1}^n \beta^T x_i y_i - \sum_{i=1}^n \log \{1 + \exp(\beta^T x_i)\}$$

- 数値最適化で ℓ_n を最大にする最尤推定量 $\hat{\beta}$ を求める: $\ell_n(\beta) \leq \ell_n(\hat{\beta})$

最尤推定量の分布を近似できる → 推定誤差の定量的評価

2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

10

データが多いときの最尤推定量の基本性質


- $\hat{\beta}$ の分布 $\underset{n \rightarrow \infty}{\approx}$ 真値 β_0 を平均とする正規分布

- 2次元の場合 (対称 $A = \begin{pmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{pmatrix}$, $a_{11} > 0$, $\det(A) = a_{11}a_{22} - a_{12}^2 > 0$)

$$z = z(x, y)$$

$$\mapsto \frac{1}{2\pi\sqrt{\det(A)}} \exp\left(-\frac{1}{2}z^T A^{-1}z\right)$$

$$= \frac{1}{2\pi\sqrt{\det(A)}} \exp\left\{-\frac{1}{2}\begin{pmatrix} x & y \end{pmatrix} A^{-1} \begin{pmatrix} x \\ y \end{pmatrix}\right\}$$



2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)




11

推定精度の評価法: 信頼集合の構成

- 例. データ $\{(x_i, y_i)\}_{i=1}^n \Rightarrow \beta_0 := (\beta_1, \beta_2)$ の 95% 近似信頼領域

$$\left| (\hat{\beta} - \beta_0)^T \left(-\frac{1}{n} \frac{\partial^2}{\partial \beta^2} \ell_n(\hat{\beta}) \right) (\hat{\beta} - \beta_0) \right| \leq "p \text{ と } 95\% \text{ で決まる定数}"$$

$\underset{n \rightarrow \infty}{\approx} \chi^2(p)$ (自由度 p のカイ二乗分布)



2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)


12

推定されたモデルに基づく判別法

- 入力 $x_0 = (x_{01}, \dots, x_{0p})$ に対する**反応確率の予測**

$$\pi(x_0; \hat{\beta}) = \frac{1}{1 + \exp\left(-\sum_{j=1}^p \hat{\beta}_j x_{0j}\right)}$$

$$\begin{cases} \geq 0.5 & \Rightarrow \hat{Y}_0 = 1 \\ < 0.5 & \Rightarrow \hat{Y}_0 = 0 \end{cases}$$





説明変数に関する非線形化

- 脊柱後弯症 (Kyphosis)
 - 発症頻度は生後月齢について**単調性がない**
- いつ施術すれば発症確率を抑制できる？


$$p(y_i|x_i, \beta') = \pi(x_i; \beta')^{y_i} \{1 - \pi(x_i; \beta')\}^{1-y_i}$$

$$\pi(x_i; \beta') = \frac{1}{1 + \exp\left\{-\left(\beta_0 + \sum_{j=1}^p \beta_j b_j(x_i)\right)\right\}}$$



Hastie, T. and Tibshirani, R. (1990), Generalized Additive Models, *Chapman and Hall*.

- kyphosisデータ (R “gam” パッケージ)
 - 40人分データ
 - Ageの二次多項式でモデルを推定




要因のあるカテゴリカル反応データ

- 例. 企業評価システム
 - 顧客のさまざまなデータを基に貸し倒れ確率を予測

$$x = (x_1, \dots, x_p) \xrightarrow{\text{要因入力}} \text{変換} \xrightarrow{\text{出力}} y \in \{1, 2, \dots, M\}$$

複数値をとる確率分布を想定する



多項 (Multinomial) 分布


- $n, M \in \{1, 2, \dots\}$, $\mathbf{p} = (p_1, \dots, p_M) \in (0, \infty)^M$, $\sum_{j=1}^M p_j = 1$
- 変数 $Y = (Y_1, \dots, Y_M) \sim$ 多項分布 $\text{Mult}(n, \mathbf{p})$

$$\iff P[Y_1 = y_1, \dots, Y_M = y_M] = \frac{n!}{y_1! \dots y_M!} p_1^{y_1} \dots p_M^{y_M},$$

$$y_j \in \{0, 1, \dots, n\}, \quad \sum_{j=1}^M y_j = n$$

- 多項定理: $(x_1 + \dots + x_n)^M = \sum_{k_1 + \dots + k_n = M} \frac{M!}{k_1! \dots k_n!} x_1^{k_1} \dots x_n^{k_n}$

どのカテゴリーに属するかの要因を組み込む



- データ $(x_1, y_1), \dots, (x_n, y_n)$
 - 説明変数 $x_i = (x_{i1}, \dots, x_{ip}) \in \mathbb{R}^p$
 - 目的変数 (ラベル) $y_i = (y_{i1}, \dots, y_{iM}) \in \{0, 1\}^M$, $\sum_{m=1}^M y_{im} = 1$
 - 目的変数 y_i が第 m 群に属する $\iff y_i = (0, \dots, 0, 1, 0, \dots, 0)$

↓

• 多項分布 $\text{Mult}\left(1, \left(\frac{\exp(x_i^\top \beta'_1)}{\sum_{j=1}^M \exp(x_i^\top \beta'_j)}, \dots, \frac{\exp(x_i^\top \beta'_M)}{\sum_{j=1}^M \exp(x_i^\top \beta'_j)}\right)\right)$ で回帰?

↓

• 多項分布 $\text{Mult}\left(\left(\frac{\exp(x_i^\top \beta_1)}{1 + \sum_{j=1}^{M-1} \exp(x_i^\top \beta_j)}, \dots, \frac{\exp(x_i^\top \beta_{M-1})}{1 + \sum_{j=1}^{M-1} \exp(x_i^\top \beta_j)}, \frac{1}{1 + \sum_{j=1}^{M-1} \exp(x_i^\top \beta_j)}\right)\right)$ で回帰

多項ロジスティック回帰モデルの推定

- データ $(x_1, y_1), \dots, (x_n, y_n)$
 - 説明変数 $x_i = (x_{i1}, \dots, x_{ip}) \in \mathbb{R}^p$
 - 目的変数 (ラベル) $y_i = (y_{i1}, \dots, y_{iM}) \in \{0, 1\}^M$, $\sum_{m=1}^M y_{im} = 1$
 - 目的変数 y_i が第 m 群に属する $\iff y_i = (0, \dots, 0, 1, 0, \dots, 0)$

• “ y_i が第 m 群に属する確率” $\pi_{im} = \pi_{im}(\beta) \xleftarrow{\text{モデリング}} \frac{\exp(x_i^\top \beta_m)}{1 + \sum_{j=1}^{M-1} \exp(x_i^\top \beta_j)}$, $m = 1, \dots, M-1$.

• $P[Y_i = (y_1, \dots, y_M)] \leftarrow \pi_{i1}^{y_{i1}} \pi_{i2}^{y_{i2}} \dots \pi_{iM}^{y_{iM}} = “\pi_{i1}, \pi_{i2}, \dots, \pi_{iM}$ のいずれか”

• 対数尤度は $\ell_n(\beta) = \ell_n(\beta_1, \dots, \beta_{M-1}) = \sum_{i=1}^n \sum_{m=1}^M d_{im} \log \pi_{im}(\beta)$


• 統計量 $d_{im} := \begin{cases} 1 & (y_i \text{ の第 } m \text{ 成分が } 1), \\ 0 & (\text{それ以外}). \end{cases} \implies \text{最尤推定量 } \hat{\beta}: \ell_n(\beta) \leq \ell_n(\hat{\beta})$

多項ロジスティック回帰モデルによる多群判別

- 新たな実験点 x_0 に対して, 目的変数 y_0 が m 群に属する確率の予測値が得られる:



$$x_0 \mapsto \begin{cases} \frac{\exp(x_0^\top \hat{\beta}_m)}{1 + \sum_{j=1}^{M-1} \exp(x_0^\top \hat{\beta}_j)}, & 1 \leq m \leq M-1, \\ \frac{1}{1 + \sum_{j=1}^{M-1} \exp(x_0^\top \hat{\beta}_j)}, & m = M. \end{cases}$$

$\implies \hat{\pi}_m(x_0)$ が最大となる m_0 に対して, “ y_0 は m_0 に属する” と判断する (判別問題).



従属性カテゴリカル回帰モデル

- 時間発展現象で説明される多値反応データ系列なども扱えるが、
- 全データの同時分布はだいぶ複雑になる。



2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

21

Coxの部分尤度と統計的漸近理論

- 部分尤度 (Cox, 1975) の考え方に基づいた統一的な枠組みがある。

● イベント A が生じたときの B の条件つき分布: $P[B|A] := \frac{P[A \cap B]}{P[A]}$

... $Y_{t_{j-1}}$ Y_{t_j} $Y_{t_{j+1}}$...

↑ ? ↑ ? ↑

... $X_{t_{j-1}}$ X_{t_j} $X_{t_{j+1}}$...

$$\log f(\mathbf{x}_1^n, \mathbf{y}_1^n) = \log \left(\prod_{j=1}^n f(y_j | \mathbf{x}_1^j, \mathbf{y}_1^{j-1}) \times \prod_{j=1}^n f(x_j | \mathbf{x}_1^{j-1}, \mathbf{y}_1^{j-1}) \right)$$

同時分布

$$= \underbrace{\sum_{j=1}^n \log f(y_j | \mathbf{x}_1^j, \mathbf{y}_1^{j-1})}_{\text{部分尤度}} + \sum_{j=1}^n \log f(x_j | \mathbf{x}_1^{j-1}, \mathbf{y}_1^{j-1})$$

$\mathbf{z}_k := (z_k, z_{k+1}, \dots, z_l)$

Cox, D. R. (1975). Partial likelihood. *Biometrika*, 62(2), 269-276.


2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

22

オルンシュタイン-ウーレンベック過程

- $dX_t = (\mu - \lambda X_t)dt + \sigma dw_t$ (w は標準ブラウン運動)
- $\mathcal{L}(Y_{t_j} | X_{t_j}) = \text{Bernoulli}(\{1 + \exp(-\beta X_{t_j})\}^{-1})$



2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

23

おわりに：回帰モデリングの基本構造

$$f(y; \theta), \theta \in \Theta \subset \mathbb{R}^p \Rightarrow \{f(y; \theta(x, \beta)) : \beta \in \mathbb{R}^{p_\beta}\}$$

$$\Rightarrow y \mapsto f(y; \theta(x_0, \hat{\beta}))$$

- 未知パラメータに依存した確率分布 $f(y; \theta), \theta \in \Theta \subset \mathbb{R}^p$
- θ を説明変数 x と別のパラメータ β の関数 $\theta(x, \beta)$ としてモデリングする。
- x に依存した確率分布族 (統計モデル) $\{f(y; \theta(x, \beta)) : \beta \in \mathbb{R}^{p_\beta}\}$ を作る。
- データ $D := \{(x_1, y_1), \dots, (x_n, y_n)\}$ から β の推定量 $\hat{\beta} = \hat{\beta}(D)$ を構成する。
- 任意の入力 x_0 に対する出力 y の予測分布 $y \mapsto f(y; \theta(x_0, \hat{\beta}))$ を構成できる。

2023/11/25

『ロジスティック回帰分析』増田弘毅 (東大数理)

24