

2021/1/21 医療統計学 (3年) ⑤

回帰分析



北海道大学 医学統計学
横田 勲

1

今回の内容

- ▶ 一般線形モデル
- ▶ ロジスティック回帰モデル

2

2


例：ラットの反復投与実験

- ▶ ある薬物Aの影響を調べるために、ラット40匹を10匹ずつの4群に分け、薬剤の静脈内投与を35日続けた
 - ▶ A1: 対照群 A2: 薬物Aを5mg/kg
 - ▶ A3: 薬物Aを10mg/kg A4: 薬物Aを20mg/kg
- ▶ 反応：血中ヘモグロビン濃度 (mg/dl)
- ▶ 因子：薬物濃度 (投与群)
- ▶ 水準：A1, A2, A3, A4の4水準

3

3

ヘモグロビン濃度の分布



4

4

線形回帰分析

- ▶ 対象者 $k(= 1, \dots, n)$ に対する単回帰分析
 - ▶ i 番目の対象者の反応 Y_k
 - ▶ 説明変数 X_k
 - ▶ 治療群、性別、年齢、血清マーカー、...
 - ▶ 回帰パラメータ α, β
 - ▶ ランダム誤差 $\varepsilon_k \sim N(0, \sigma^2)$
- ▶ 以下の足し算を用いた方程式を置く

$$Y_k = \alpha + X_k\beta + \varepsilon_k$$

5

5

一般線形モデル general linear model

- ▶ 回帰分析のみならず、 t 検定や分散分析も統一的に扱うことが可能
- ▶ t 検定の場合
 - ▶ 治療群が1のとき $X_k = 1$ 、群が2のとき $X_k = 0$

$$Y_k = \alpha + X_k\beta + \varepsilon_k$$
 - ▶ 誤差 ε_k は期待値がゼロ

6

6

期待値をとってみよう 7

- ▶ 群1であるkさん $Y_k = \alpha + 1 \times \beta + \varepsilon_k$
- ▶ 群1全員の期待値（平均値）は、

$$\frac{(\alpha + \beta + \varepsilon_1) + (\alpha + \beta + \varepsilon_2) + \dots}{n_1} = \alpha + \beta$$
(∵ ランダム誤差は期待値が0)
- ▶ 同様に、群2の期待値は、

$$\frac{(\alpha + \varepsilon_1) + (\alpha + \varepsilon_2) + \dots}{n_2} = \alpha$$

7

t検定の場合 8

- ▶ $Y_k = \alpha + X\beta + \varepsilon_k$
- ▶ α : 群2の平均値
- ▶ β : 群間差
- ▶ $\beta = 0$ であるかの検定がt検定

8

一元配置分散分析の場合 9

- ▶ 治療群が4つ(1,2,3,4)あるならば、
 - ▶ 治療群が1のとき $X_1 = 1$ 、それ以外 $X_1 = 0$
 - ▶ 治療群が2のとき $X_2 = 1$ 、それ以外 $X_2 = 0$
 - ▶ 治療群が3のとき $X_3 = 1$ 、それ以外 $X_3 = 0$
 - ▶ 治療群が4のとき $X_4 = 1$ 、それ以外 $X_4 = 0$
- $$Y_k = X_1\beta_1 + X_2\beta_2 + X_3\beta_3 + X_4\beta_4 + \varepsilon_k$$
- ▶ $\beta_1 = \beta_2 = \beta_3 = \beta_4 = 0$ であるかの検定がF検定

9

バラツキ variation 10

- ▶ 同じようなものを測定したはずなのに、値が異なってしまうこと
- ▶ 統計で問題にするのはこの「バラツキ」
- ▶ 頻度流統計学では

$$\text{測定値} = \text{真値} + \text{バイアス} + \text{誤差}$$

measurement true value bias error

腎臓手術を受ける患者の真のeGFR 年齢・性別による影響
 前治療による影響
 …

10

バラツキの分解という観点 11

- ▶ 一般線形モデルでも同じ
- ▶ でも真値は分からない
 - ▶ そもそもあまり興味もない
 - ▶ とりあえず基準点を置いて、切片と呼ぼう
 - ▶ 全てモデル因子で分解して、切片を置かなくていい

$$\text{測定値} = \text{切片} + \text{モデル因子} + \text{誤差}$$

measurement intercept model factor error

$$Y_k = \alpha + X_k\beta + \varepsilon_k$$

11

モデルの構築 12

- ▶ 例えば、対照群との比較に興味があれば

$$Y_k = \alpha + X_1\beta_1 + X_2\beta_2 + X_3\beta_3 + \varepsilon_k$$

- ▶ X_1 : 治療群がA2の時だけ1、それ以外は0
- ▶ X_2 : 治療群がA3の時だけ1、それ以外は0
- ▶ X_3 : 治療群がA4の時だけ1、それ以外は0

12

解析結果の見方①

▶ 解析ソフトSASの出力

パラメータ	推定値	標準誤差	t 値	Pr > t	95% 信頼限界	
Intercept	151.4000000	1.92757764	78.54	<.0001	147.4906914	155.3093086
A2	-1.4000000	2.72600644	-0.51	0.6107	-6.9285973	4.1285973
A3	-5.2000000	2.72600644	-1.91	0.0645	-10.7285973	0.3285973
A4	-16.2000000	2.72600644	-5.94	<.0001	-21.7285973	-10.6714027

▶ 整形して

治療群	推定値	95%信頼区間	両側P値
A2 vs A1	-1.4	(-6.9, 4.1)	0.61
A3 vs A1	-5.2	(-10.7, 0.3)	0.06
A4 vs A1	-16.2	(-21.7, -10.7)	<0.01

13

解析結果の見方②

治療群	推定値	95%信頼区間	両側P値
A2 vs A1	-1.4	(-6.9, 4.1)	0.61
A3 vs A1	-5.2	(-10.7, 0.3)	0.06
A4 vs A1	-16.2	(-21.7, -10.7)	<0.01

▶ 治療群A2はA1に比べ、ヘモグロビン濃度の平均の差は-1.4

- ▶ A2のヘモグロビン濃度のほうが低い
- ▶ その信頼区間は(-6.9, 4.1)

14

薬物濃度を連続量として扱う

▶ 薬物Aを与えるごとに、どれだけヘモグロビン濃度は低下するか？

- ▶ A1~A4は0,5,10,20mg/kg投与
- ▶ 薬物増加に従い、ヘモグロビン濃度は直線的に変化すると仮定

▶ Xは薬物Aの濃度として、モデルを構築

$$Y_k = \alpha + X\beta + \varepsilon_k$$

15

回帰直線の推定

パラメータ	推定値	標準誤差	t 値	Pr > t	95% 信頼限界	
Intercept	153.0400000	1.49372220	102.46	<.0001	150.0161175	156.0638825
dose	-0.8388571	0.13038276	-6.43	<.0001	-1.1028032	-0.5749110

▶ 薬物を1mg/kg増やすごとに、ヘモグロビン濃度は-0.84mg/dLだけ変化

16

線形回帰モデル

▶ 反応Yの変化を、説明変数（共変量）X で説明

- ▶ 説明変数が群（カテゴリカル）であれば、群間差が求まる
- ▶ 説明変数が連続量であれば、1単位変化あたりの反応の変化が求まる

17


例：単回帰分析

▶ 水疱性角膜炎の術前中心角膜厚

ID	年齢[歳]	術前中心角膜厚[μm]
1	68	760
2	60	964
3	58	727
4	71	792
5	49	637
6	74	775
7	72	750
8	57	657
9	63	649
10	82	741
11	56	725

Kinoshita S, et al. N Engl J Med. 2018; 995-1003.


18



角膜厚と年齢の関連

- ▶ 直線的な関係があるか？
 - ▶ 年齢が1歳上がるごとに、角膜厚は平均的にどれだけ変化するか
- ▶ 角膜厚と年齢の関係を表す最も適切な直線を求めたい
 - ▶ $y_i = \beta_0 + x_i\beta_1 + \varepsilon_i$
 - ▶ β_0 : 切片
 - ▶ β_1 : 傾き

20



最小二乗法

- ▶ $\sum_i^n (y_i - \hat{y}_i)^2 = \sum_i^n \{y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i)\}^2$ を最小にする $\hat{\beta}_0, \hat{\beta}_1$
 - ▶ 推定量や推定値について ^ (ハット) を付す
- ▶
$$\begin{cases} \frac{\partial \sum_i^n (y_i - \hat{y}_i)^2}{\partial \hat{\beta}_0} = 0 \\ \frac{\partial \sum_i^n (y_i - \hat{y}_i)^2}{\partial \hat{\beta}_1} = 0 \end{cases}$$
 を解く
- ▶ 一般的には $X^T X \beta = X^T Y$ を解く
 - ▶ 正規方程式

22

単回帰の場合

- ▶ ① y と x の平均を見つける
- ▶ ② 平均値を中心に直線を回転し、残差平方和最小となる場合を見つける

23

連続量の回帰モデル

- ▶ ここまで扱った反応 Y は連続量のみ
 - ▶ 反応あり/なしのような二値データや、人時間データでも行いたい

24

効果の指標

25

- ▶ 治療(曝露)効果の方向や大きさの表現

指標	差の指標	比の指標
リスク、割合	リスク差	リスク比
オッズ		オッズ比
率	率差	率比
ハザード		ハザード比

25

2つの治療法を比較する
1800名の観察研究

26

治療法	イベントあり	イベントなし	合計
試験治療	22 (2.2%)	978	1000
標準治療	20 (2.5%)	780	800
合計	42	1758	1800

- ▶ 標準治療に対する試験治療の
 - ▶ リスク差: $2.2\% - 2.5\% = -0.3\%$
 - ▶ リスク比: $2.2\% / 2.5\% = 0.88$
 - ▶ オッズ比: $\frac{22/978}{20/780} = 0.877 \dots \approx 0.88$

26

リスク差の回帰モデル①

27

- ▶ 一般線形モデルで行ったら?
 - ▶ t検定のように回帰係数を平均値の差となるようモデルを作れたし...
- ▶ アウトカムは連続量ではなく、イベントあり/なしの二値
 - ▶ アウトカムは二項分布に従うと考えたほうが自然

27

リスク差の回帰モデル②

28

- ▶ $y_i \sim \text{Bin}(n_i, p_i)$
 - ▶ アウトカムは二項分布に従う
 - ▶ 今は $n_i = 1$
 - ▶ イベント発生確率が p_i
 - ▶ $E(y_i) = n_i p_i$
 - ▶ 今は y_i の期待値がイベント発生確率 p_i
- ▶ $p_i = \beta_0 + x_i \beta_1$
 - ▶ x_i : 試験治療なら1、標準治療なら0

28

リスク差の回帰モデル③

29

パラメータ	推定値	(95%信頼区間)
β_0	0.025	(0.014, 0.036)
β_1	-0.003	(-0.017, 0.011)

- ▶ 試験治療により、イベント発生が -0.3% (95%CI: $-1.7\%, 1.1\%$) だけ減る
 - ▶ NNTは $\frac{1}{|-0.003|} \approx 333$
- ▶ 割合の差の検定に基づく信頼区間と同じ

29

一般化線形モデル generalized linear model

30

- ▶ アウトカムが指数型分布族に従う
 - ▶ 正規分布、二項分布、Poisson分布など
- ▶ 分布を表現する正準パラメータ θ について

$$g(\theta) = \mathbf{X}\boldsymbol{\beta}$$
 - ▶ $g(\cdot)$ リンク関数
 - ▶ リスク差モデルではそのまま $g(\theta) = \theta$

30

分布とリンク関数の組合せ

分布	リンク関数	効果の指標	別名
二項	恒等	リスク差	
二項	対数	リスク比	
二項 / 多項	ロジット	オッズ比	ロジスティック回帰
Poisson	恒等	率差	
Poisson	対数	率比	Poisson回帰
指数	対数	ハザード比	指数回帰
二項	プロビット		プロビット回帰

- ・ 医学研究ではCox回帰を用いたハザード比推定がほとんど
- ・ イベント割合が極端に低い場合に向かない、効果指標がないといった理由でプロビット回帰はあまり使われない

31

指数関数・対数関数

- ▶ $\log(A \times B) = \log A + \log B$
 - ▶ 対数の底はeであり、通常省略
 - ▶ 比のモデルは掛け算モデル
対数変換すれば足し算モデルになる
 - ▶ 線形モデルで表現できる
- ▶ $e^{\log A} = A$
- ▶ $e^{a+b} = e^a \times e^b$
 - ▶ 以降、 e^a のことを $\exp a$ と表記する
 - ▶ $\exp(a + b) = \exp a \times \exp b$

32

1800名のデータ

- ▶ 年齢でサブグループ化
- ▶ 75歳以上

治療法	イベントあり	イベントなし	合計
試験治療	18 (3.0%)	582	600
標準治療	6 (6.0%)	94	100

- ▶ 75歳未満

治療法	イベントあり	イベントなし	合計
試験治療	4 (1.0%)	396	400
標準治療	14 (2.0%)	686	700

33

ロジスティック回帰の例

↑ オッズ

- ▶ $\text{logit}(p_i) = \log\left(\frac{p_i}{1-p_i}\right) = \beta_0 + x_{1i}\beta_1 + x_{2i}\beta_2$
 - ▶ x_{1i} : 試験治療なら1、標準治療なら0
 - ▶ x_{2i} : 75歳以上なら1、75歳未満なら0
- ▶ 交互作用項は含めていないので、年齢によらず治療効果は同じという仮定

34

ロジスティック回帰分析結果

	β	(95%CI)	オッズ比	(95%CI)
切片	-3.89	(-4.38, -3.40)		
x_1 ; 治療	-0.72	(-1.44, 0.01)	0.49	(0.28-1.01)
x_2 ; 年齢	1.13	(0.40, 1.86)	3.10	(1.50-6.49)

- ▶ 治療のオッズ比とその信頼区間

$$e^{-0.72} = \exp(-0.72) = 0.49$$

$$e^{-1.44} = \exp(-1.44) = 0.28$$

$$e^{0.01} = \exp(0.01) = 1.01$$

35

年齢を調整した治療のオッズ比

オッズ = $\exp\{\beta_0\} \times \exp\{\beta_1\} \times \exp\{\beta_2 \times (75歳以上)\}$
 $\log(\text{オッズ}) = \beta_0 + \beta_1 \times (\text{試験治療}) + \beta_2 \times (75歳以上)$

オッズ	75歳未満	75歳以上
試験治療	$\exp(\beta_0 + \beta_1)$	$\exp(\beta_0 + \beta_1 + \beta_2)$
標準治療	$\exp(\beta_0)$	$\exp(\beta_0 + \beta_2)$

75歳未満でのオッズ比 $\frac{\exp(\beta_0 + \beta_1)}{\exp(\beta_0)} = \exp(\beta_1)$

75歳以上でのオッズ比 $\frac{\exp(\beta_0 + \beta_1 + \beta_2)}{\exp(\beta_0 + \beta_2)} = \exp(\beta_1)$

36

練習問題

37

- ▶ 75歳未満で試験治療を受けた人に対する75歳以上で標準治療を受けた人のイベント発生オッズ比は？

37

まとめ

38

- ▶ 一般線形モデル
- ▶ ロジスティック回帰モデル
 - ▶ 比のモデルでは対数をとって足し算モデルに

38