

2019/5/9 北大SPH・統計解析の基礎⑦⑧

## 回帰分析



北海道大学 医学統計学  
横田 勲

## 今回の内容

- ▶ 一般線形モデル
  - ▶ デザイン行列
  - ▶ 最小二乗法
  - ▶ 回帰診断
  - ▶ カテゴリカル変数のコーディング
- ▶ 一般線形混合効果モデル
- ▶ 一般化線形モデル
  - ▶ リンク関数と分布
- ▶ 関連、因果、予測
  - ▶ 決定係数、予測性能指標、ROC曲線

## 分散分析ではできないこと

- ▶ 因子は離散的なもののみ
  - ▶ 治療群、性別、・・・
- ▶ 年齢や血清マーカーのような連続量の影響も検討したい
  - ▶ 構造モデルを基にした  
一般線形モデル general linear model

## 一元配置の構造モデル

- ▶  $y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$ 
  - ▶  $y_{ij}$  : 第*i*水準の*j*番目の対象者の反応
  - ▶  $\alpha_i$ を全体平均( $\mu$ )と第*i*水準の効果( $\alpha_i$ )に分解
    - ▶  $\sum_{i=1}^a \alpha_i = 0$ という制約
  - ▶  $\varepsilon_{ij}$ は互いに独立に  
平均0、分散 $\sigma^2$ の正規分布に従うと仮定
- ▶ 第*i*水準の平均値は $\mu + \alpha_i$ として表現

## 回帰モデルで書き直し

- ▶  $y_{ij} = \mu + \alpha_1 x_1 + \dots + \alpha_a x_a + \varepsilon_{ij}$ 
  - ▶  $x_1$  : 第1水準の場合に1, それ以外は0をとる
  - ▶  $\vdots$
  - ▶  $x_a$  : 第*a*水準の場合に1, それ以外は0をとる
- ▶ やっぱり第*i*水準の平均値は $\mu + \alpha_i$

## 各対象者の反応に対する回帰モデル

$$\begin{aligned}
 y_{11} &= \mu + \alpha_1 \times 1 + \alpha_2 \times 0 + \dots + \alpha_a \times 0 + \varepsilon_{11} \\
 &\vdots \\
 y_{1n} &= \mu + \alpha_1 \times 1 + \alpha_2 \times 0 + \dots + \alpha_a \times 0 + \varepsilon_{1n} \\
 y_{21} &= \mu + \alpha_1 \times 0 + \alpha_2 \times 1 + \dots + \alpha_a \times 0 + \varepsilon_{21} \\
 &\vdots \\
 y_{2n} &= \mu + \alpha_1 \times 0 + \alpha_2 \times 1 + \dots + \alpha_a \times 0 + \varepsilon_{2n} \\
 &\vdots \\
 &\vdots \\
 y_{a1} &= \mu + \alpha_1 \times 0 + \alpha_2 \times 0 + \dots + \alpha_a \times 1 + \varepsilon_{a1} \\
 &\vdots \\
 y_{an} &= \mu + \alpha_1 \times 0 + \alpha_2 \times 0 + \dots + \alpha_a \times 1 + \varepsilon_{an}
 \end{aligned}$$

## 行列表現

7

$$\begin{pmatrix} y_{11} \\ \vdots \\ y_{1n} \\ y_{21} \\ \vdots \\ y_{2n} \\ \vdots \\ y_{a1} \\ \vdots \\ y_{an} \end{pmatrix} = \begin{pmatrix} 1 & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots \\ \ddots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 1 \\ \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_a \end{pmatrix} + \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{1n} \\ \varepsilon_{21} \\ \vdots \\ \varepsilon_{2n} \\ \vdots \\ \varepsilon_{a1} \\ \vdots \\ \varepsilon_{an} \end{pmatrix}$$

次元  $an \times 1$        $an \times (a+1)$        $(a+1) \times 1$        $an \times 1$

$Y$                    $X$                    $\beta$                    $\varepsilon$

## 一般線形モデル

8

- ▶  $Y = X\beta + \varepsilon$ 
  - ▶ アウトカム  $y$  をモデルで説明する分  $X\beta$  と誤差  $\varepsilon$  の和で表現
  - ▶  $X$ : デザイン行列 design matrix
  - ▶  $\beta$ : 回帰係数(ベクトル) coefficient (vector)

## デザイン行列

9

- ▶ 作り方次第で、以下の解析を表現可能
  - ▶ 線形回帰分析 (単回帰、重回帰)
  - ▶ t検定
  - ▶ 一元配置分散分析
  - ▶ 多元配置分散分析 (ブロック因子を含む)
  - ▶ 繰り返し測定分散分析
  - ▶ 共分散分析 analysis of covariance
  - ▶ . . .

## 例: t検定を表現①

10

- ▶ 群1と群2の平均値を比較したい
- ▶  $y_{ij} = \beta_0 + x_{1j}\beta_1 + \varepsilon_{ij}$ 
  - ▶  $x_1$ : 群1なら1, 群2なら0
- ▶ 群1の平均値
 
$$\begin{aligned}
 & \frac{y_{11} + y_{12} + \dots + y_{1n}}{n} \\
 &= \frac{(\beta_0 + 1 \times \beta_1 + \varepsilon_{11}) + (\beta_0 + 1 \times \beta_1 + \varepsilon_{12}) + \dots + (\beta_0 + 1 \times \beta_1 + \varepsilon_{1n})}{n} \\
 &= \beta_0 + \beta_1 \quad (\because \text{ランダム誤差は期待値が0})
 \end{aligned}$$

## 例: t検定を表現②

11

- ▶ 群2の平均値
 
$$\begin{aligned}
 & \frac{y_{21} + y_{22} + \dots + y_{2n}}{n} \\
 &= \frac{(\beta_0 + 0 \times \beta_1 + \varepsilon_{21}) + (\beta_0 + 0 \times \beta_1 + \varepsilon_{22}) + \dots + (\beta_0 + 0 \times \beta_1 + \varepsilon_{2n})}{n} \\
 &= \beta_0
 \end{aligned}$$
- ▶ 群間差(群1の平均値 - 群2の平均値)は  $\beta_1$
- ▶  $\beta_1 = 0$  であるかの検定が t検定

## 記法

12

- ▶ 分散分析とは記法をやや変更
- ▶  $Y = (y_1, y_2, \dots, y_n)^T$ 
  - ▶  $y_i$ : 対象者  $i (= 1, \dots, n)$  のアウトカム
- ▶  $\beta = (\beta_0, \beta_1, \dots)^T$ 
  - ▶  $\beta_0$ : 切片項 intercept の回帰係数

## 例：単回帰分析

13


## ▶ 水疱性角膜症の術前中心角膜厚

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.

## 散布図

14




## 角膜厚と年齢の関連

15

- ▶ 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
  - ▶  $y_i = \beta_0 + x_i\beta_1 + \varepsilon_i$ 
    - ▶  $\beta_0$  : 切片
    - ▶  $\beta_1$  : 傾き

## 残差平方和を最小に

16



## 最小二乗法


17

- ▶  $\sum_i^n (y_i - \hat{y}_i)^2 = \sum_i^n \{y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i)\}^2$  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

## 単回帰の場合

18

- ▶ ①  $y$  と  $x$  の平均をみつける
- ▶ 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みつける



## 誤差の4条件

19

- ▶ 独立性
  - ▶ 各対象者の誤差が互いに独立
- ▶ 不偏性
  - ▶ 誤差の期待値は0
- ▶ 等分散性
  - ▶ 誤差分散は等しい
- ▶ 正規性
  - ▶ 誤差は正規分布にしたがう
- ▶  $\varepsilon_i \stackrel{i.i.d.}{\sim} N(0, \sigma^2)$

## 推定量の特徴

20

- ▶ 誤差について、正規性を除く3条件を仮定した下で、最小二乗法による回帰係数の推定量は
  - ▶ 不偏
    - ▶ 十分にnが大きい下で、バイアスがない
  - ▶ 最小分散（有効推定量）を満たす（最良線形不偏推定量;BLUE）

## 回帰診断


21

- ▶ 一般線形モデルの前提が正しいか
  - ▶ 説明変数の関数形
    - ▶ 効果の加法性、交互作用の検討
  - ▶ 誤差の4(3)条件
- ▶ 残差分析
- ▶ 影響度分析

## 残差分析

22

- ▶ 残差を予測値や説明変数に対してプロット



## 影響度分析

23

- ▶ ある人のデータを除いたときに、回帰係数の推定値や予測値がどれくらい変化するか
- ▶ Cookの距離
  - ▶ 予測値の変化を基準化した指標

## デザイン行列の作り方

24

- ▶ 3水準、繰り返し数が2回の一元配置

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \\ y_6 \end{pmatrix} = \begin{pmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \varepsilon_4 \\ \varepsilon_5 \\ \varepsilon_6 \end{pmatrix}$$

$Y \qquad X \qquad \beta \qquad \varepsilon$

- ▶ 正規方程式を解いてみよう

$$\mathbf{X}^T \mathbf{X} \boldsymbol{\beta} = \mathbf{X}^T \mathbf{Y}$$

25

▶  $\mathbf{X}^T \mathbf{X}$ 

$$= \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{pmatrix} \begin{pmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{pmatrix}$$

$$= \begin{pmatrix} 6 & 2 & 2 & 2 \\ 2 & 2 & 0 & 0 \\ 2 & 0 & 2 & 0 \\ 2 & 0 & 0 & 2 \end{pmatrix}$$

$$\mathbf{X}^T \mathbf{X} \boldsymbol{\beta} = \mathbf{X}^T \mathbf{Y}$$

26

$$\begin{cases} 6\beta_0 + 2\beta_1 + 2\beta_2 + 2\beta_3 = y_1 + \dots + y_6 \\ 2\beta_0 + 2\beta_1 = y_1 + y_2 \\ 2\beta_0 + 2\beta_2 = y_3 + y_4 \\ 2\beta_0 + 2\beta_3 = y_5 + y_6 \end{cases}$$

▶ 解が不定

▶ 3水準の実験から  
4つの平均値を求めるなんてムリ

## 一意に推定可能な次数に

27

▶ 切片をなくす

▶ GLM coding without intercept

▶ ある水準を参照水準とする

▶ Reference coding

▶ ある水準との対比

▶ Effect coding

## 各コーディング

28

GLM coding

	$x_1$	$x_2$	$x_3$
水準1	1	0	0
水準2	0	1	0
水準3	0	0	1

Reference coding

	$x_1$	$x_2$
水準1	1	0
水準2	0	1
水準3	0	0

Effect coding

	$x_1$	$x_2$
水準1	1	0
水準2	0	1
水準3	-1	-1

## GLM coding without intercept

29

▶  $E(y) = x_1\beta_1 + x_2\beta_2 + x_3\beta_3$ 

▶ 水準1の平均値

$$E(y) = 1 \cdot \beta_1 + 0 \cdot \beta_2 + 0 \cdot \beta_3 = \beta_1$$

▶ 水準2の平均値

$$E(y) = 0 \cdot \beta_1 + 1 \cdot \beta_2 + 0 \cdot \beta_3 = \beta_2$$

▶ 水準3の平均値

$$E(y) = 0 \cdot \beta_1 + 0 \cdot \beta_2 + 1 \cdot \beta_3 = \beta_3$$

## Reference coding

30

▶  $E(y) = \beta_0 + x_1\beta_1 + x_2\beta_2$ 

▶ 水準1の平均値

$$E(y) = 1 \cdot \beta_0 + 1 \cdot \beta_1 + 0 \cdot \beta_2 = \beta_0 + \beta_1$$

▶ 水準2の平均値

$$E(y) = 1 \cdot \beta_0 + 0 \cdot \beta_1 + 1 \cdot \beta_2 = \beta_0 + \beta_2$$

▶ 水準3 (参照水準) の平均値

$$E(y) = 1 \cdot \beta_0 + 0 \cdot \beta_1 + 0 \cdot \beta_2 = \beta_0$$

▶  $\beta_0$ : 水準3の平均値▶  $\beta_1$ : 水準1の平均値 - 水準3の平均値▶  $\beta_2$ : 水準2の平均値 - 水準3の平均値

### Effect coding

31

- $E(y) = \beta_0 + x_1\beta_1 + x_2\beta_2$ 
  - 水準1の平均値  
 $E(y) = 1 \cdot \beta_0 + 1 \cdot \beta_1 + 0 \cdot \beta_2 = \beta_0 + \beta_1$
  - 水準2の平均値  
 $E(y) = 1 \cdot \beta_0 + 0 \cdot \beta_1 + 1 \cdot \beta_2 = \beta_0 + \beta_2$
  - 水準3 (参照水準) の平均値  
 $E(y) = 1 \cdot \beta_0 - 1 \cdot \beta_1 - 1 \cdot \beta_2 = \beta_0 - \beta_1 - \beta_2$
- $\beta_0$ : 全体平均
  - (水準1の平均値 + 水準2の平均値 + 水準3の平均値)/3
- $\beta_1$ : 水準1の平均値 - 全体平均
- $\beta_2$ : 水準2の平均値 - 全体平均

### SASでの例

32

GLM coding without intercept

Reference coding

Effect coding

### 説明変数を自分でコーディング

33

- 解釈しやすい回帰係数となるように
- 例: JMPでロジスティック回帰
  - 説明変数(trt)を0,1で入力

説明変数を名義変数      説明変数を連続変数

パラメータ推定値			パラメータ推定値		
項	推定値	標準誤差	項	推定値	標準誤差
切片	-3.7290143	0.1563322	切片	-3.6635616	0.2264554
trt[0]	0.06545268	0.1563322	trt	-0.1309054	0.3126645

推定値は次の対数オッズに対するもの      推定値は次の対数オッズに対するもの

Effectコーディング

### 相関のあるデータ

34

- アウトカムが互いに独立という前提が成立しない
  - 同一対象者、マッチしたペア、施設等
- 相関が生じる単位を「ブロック」とした
  - ブロック因子を含む二元配置分散分析
  - 繰り返し測定分散分析
  - Unbalancedな2因子実験

### 例: 中心角膜厚データ

35

- 水準数3、ブロック数11の乱塊法

ID	術前[μm]	術後24週	術後2年
1	760	511	532
2	964	525	538
3	727	540	546
4	792	640	710
5	637	509	529
6	775	505	525
7	750	626	550
8	657	489	503
9	649	595	543
10	741	539	523
11	725	561	572

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

### 線形回帰モデルで表現

36

$y_i = \beta_0 + x_1\beta_1 + x_2\beta_2 + x_3\beta_3$

時点効果

$+ z_1\gamma_1 + z_2\gamma_2 + \dots + z_{11}\gamma_{11} + \epsilon_i$

ブロック因子

- $x_1$ : 時点が術前なら1、それ以外は0
- $x_2$ : 時点が24週なら1、それ以外は0
- $x_3$ : 時点が2年なら1、それ以外は0
- $z_1$ : IDが1なら1、それ以外は0
- ...
- $z_{11}$ : IDが11なら1、それ以外は0

ブロック因子もすべて推定する必要がある

## 繰り返し測定分散分析の構造モデル

37

- ▶  $y_{ijk} = \mu + \alpha_i + u_{ij} + \beta_k + (\alpha\beta)_{ik} + \varepsilon_{ijk}$
- ▶  $\mu$  : 全体平均
  - ▶  $\alpha_i$  : 治療の主効果 (①) ブロックの代わりに誤差を入れた
  - ▶  $u_{ij}$  : 1次誤差
    - ▶ 治療の割付をした個人における誤差
  - ▶  $\beta_k$  : 時点の主効果 (②)
  - ▶  $(\alpha\beta)_{ik}$  : 治療と時点の交互作用 (③)
  - ▶  $\varepsilon_{ijk}$  : 2次誤差
    - ▶ 個人のうち各時点の測定に関する誤差

## 2つの誤差

38

- ▶ 個人による誤差
  - ▶ ヒトの違いによって生じる
  - ▶ 同一対象者では同じ値を持つが、対象者間では値が分布する
  - ▶ 変量効果 random effect と呼ぼう
- ▶ 個人内での繰り返し測定による誤差
  - ▶ 同じヒトでも複数回測定したことによって生じる

## 固定効果と変量効果

39

- ▶ 固定効果 fixed effects
  - ▶ 因子の水準に普遍性があり、効果自体の推定に関心がある
    - ▶ 治療、時期、予後因子・・・
- ▶ 変量効果 random effects
  - ▶ 因子の水準はある集団からのサンプルと考え、効果自体の推定ではなく、そのバラツキの大きさに関心がある
    - ▶ 測定単位 (個人、マッチしたペア、施設など) に特有の効果

## 混合効果モデルの別名

40

- ▶ 混合モデル mixed model
  - ▶ mixture modelは全く別の意味!
- ▶ 変量効果モデル random effect model
- ▶ マルチレベルモデル multi-level model
  - ▶ 社会科学の分野で一般的

## ランダム係数モデル

41

- ▶  $y_{ij} = \alpha + Time \times \beta + b_{0i} + Time \times b_{1i} + \varepsilon_{ij}$
- ▶  $y_{ij}$  : 対象者  $i$  の時点  $j$  でのアウトカム
  - ▶ 変量切片  $b_{0i}$  に加え、時点との交互作用変量  $b_{1i}$  を加え、経時変化の傾きについても個人差をゆるす
    - ▶  $b_{0i}$  と  $b_{1i}$  は二変量正規分布に従う

## 混合効果モデルの特徴

42

- ▶ 個人差を適当に調整して、個人全体でのアウトカム評価を行いたい
  - ▶ 繰り返し測定分散分析に比べ、検出力を向上できる場面がある
- ▶ 対象者間での測定回数の違いにもある程度対応可能
  - ▶ 1回しか測定されない人と複数回測定される人が含まれる集団でもOK

## モデルパラメータ推定

43

- ▶ 推奨
  - ▶ 制限付き最尤(REML)法
  - ▶ 分散はサンドウィッチ推定量
    - ▶ JMP14.0では対応していない・・・
- ▶ 要検討
  - ▶ 変量効果の相関構造
  - ▶ 欠測に対する仮定
  - ▶ 自由度の調整
  - ▶ ...

## 効果の指標

44

- ▶ 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

## 2つの治療法を比較する 1800名の観察研究

45

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:  $\frac{22/978}{20/780} = 0.877 \dots \approx 0.88$

## リスク差の回帰モデル①

46

- ▶ 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

## リスク差の回帰モデル②

47

- ▶  $y_i \sim \text{Bin}(n_i, p_i)$ 
  - ▶ 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

## リスク差の回帰モデル③

48

パラメータ	推定値	(95%信頼区間)
$\beta_0$	0.025	(0.014, 0.036)
$\beta_1$	-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

## 一般化線形モデル generalized linear model

49

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

## 分布とリンク関数の組合せ

50

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

## 指数関数・対数関数

51

- ▶  $\log(A \times B) = \log A + \log B$ 
  - ▶ 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
    - ▶  $\exp(a+b) = \exp a \times \exp b$

## 1800名のデータ

52

- ▶ 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

## ロジスティック回帰の例

53

- 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

## ロジスティック回帰分析結果

54

	$\beta$	(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

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

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

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

## 年齢を調整した治療のオッズ比

55

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

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

$$\frac{\exp(\beta_0 + \beta_1)}{\exp(\beta_0)} = \mathbf{\exp(\beta_1)}$$

75歳以上でのオッズ比

$$\frac{\exp(\beta_0 + \beta_1 + \beta_2)}{\exp(\beta_0 + \beta_2)} = \mathbf{\exp(\beta_1)}$$

## 練習問題

56

- ▶ 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？

## 医学研究での目的

57

- ▶ “X” は “疾病Y” と 関連 がある
  - ▶ X：健康状態マーカーや疾病Yを引き起こす疾患など



- ▶ “X” は “疾病Y” の 原因 となる
- ▶ “X” は “疾病Y” を 予測 する

より目的を明確に

## 因果と予測

58

- ▶ 回帰分析から、X-Y間の「関連」を検討
- ▶ Xが原因となり、Yという結果が導かれる
  - ▶ 回帰モデルは因果モデル（‘do’ model）
  - ▶ 交絡因子は制御すべきもの
- ▶ Xの値を与えて、Yという結果を当てる
  - ▶ 回帰モデルは予測モデル（‘see’ model）
  - ▶ 予測精度を高めるためにXを選ぶ

Allison PD. 1998(Book).  
vanHouwelingen JC. The President's speech in ISCB34.

## 前立腺がんとPSA

60

- ▶ 前立腺がんの発見・病勢と強い関連
  - ▶ スクリーニングにも用いられる
- ▶ がんの細胞壁が壊れやすいため、がんのvolumeに応じてPSAが血液中に漏出

前立腺がん → PSA

## 前立腺がんのリスク因子を検討

61

- ▶ 明らかなリスク因子は、年齢、家族歴
- ▶ 他にもリスク因子はあるに違いない！
  - ▶ 例えば、飲酒の影響を調べてみる
  - ▶ 因果関係を知りたい

飲酒 → 前立腺がん → PSA

## 交絡の影響を解析で除去

62

- ▶ 以下の条件を満たすことで、飲酒と前立腺がんの関係を歪めてしまう
  - ▶ 年齢が高いほど前立腺がんは増える
  - ▶ 年齢と飲酒には関係がある
  - ▶ 飲酒をすれば年齢が増えるわけではない



## たいてい多変量解析で除去

63

Sawada N. et al. *Int J Cancer*. 2014.

## 前立腺がんの予測をしたい

64

- ▶ 前立腺がん発生を精度良く当てたい
  - ▶ どのような因子を用いてもよい
    - ▶ 年齢のようなリスク因子
    - ▶ 前立腺がんの"結果"であるPSA

<http://psacalc.sph.umich.edu>

65

## 変数選択

66

- ▶ 予測モデルを作るため
  - ▶ 少ない変数で当たりのよいモデルを
    - ▶ 特別な測定を要する変数で作ったモデルは使われづらい
- ▶ 因果関係を調べるためには使わない
  - ▶ 交絡調整が目的ゆえ、利用可能なすべての変数を用いる

## モデルのよさ、精度の測り方

67

- ▶ モデルのあてはまり
  - ▶ 決定係数 $R^2$
  - ▶ 尤度とAIC
- ▶ 予測精度、予測結果のよさ
  - ▶ 平均二乗誤差、Brierスコア
  - ▶ ROC曲線、c 統計量

決定係数  $R^2$ 

68

$$R^2 = 1 - \frac{\text{残差平方和}}{\text{全体の平方和}} = \frac{\text{モデルで説明した平方和}}{\text{全体の平方和}}$$

- ▶ データの持つ全ばらつきのうち、モデルで説明した割合
  - ▶ 単回帰の場合、相関係数の2乗に一致

## 確率(密度)関数と尤度

69

- ▶ データは確率変数の実現値
  - ▶ 確率分布 (パラメータ  $\beta$  を持つモデル) を仮定すれば、当該データが得られる確からしさを定義
  - ▶  $f(x_1, \dots, x_n; \beta) = \prod_i^n f(x_i; \beta)$
- ▶ 尤度  $L(\beta; x)$ 
  - ▶  $f(x; \beta)$  を  $\beta$  の関数としてみたもの

## 最尤法 maximum likelihood method

70

- ▶ 尤度が最大になるようなパラメータ  $\theta$  を推定値とみなす手法
  - ▶ 当該データが得られる確からしさが最大ゆえ
- ▶ 例：一般線形モデル
  - ▶ 誤差に正規分布を仮定すれば、最尤推定値と最小二乗法による推定値が一致
- ▶ 例：一般化線形モデル
  - ▶ たいていの場合、最尤推定量は統計的によい性質をもつ

## 尤度によるあてはまりの評価

71

- ▶ 連続量アウトカム以外では尤度で考える
  - ▶ 大きいほどデータへのあてはまりがよい
  - ▶ 誤差に正規分布を仮定した場合、幸いにも、誤差平方和が小さくなるほど尤度は大きくなる関係

## モデルの複雑さと overfitting

72

- ▶ モデルを複雑にするとより細かな違いまで捉えられる
  - ▶ 関数形を高次にする
  - ▶ 説明変数を増やす
    - ▶ それが無意味な説明変数であっても!
- ▶ 無意味な説明変数をモデル化すると、他のデータへのあてはまりが悪くなる
  - ▶ モデルを活用する際に使いづらい
  - ▶ Overfitting (過適合) という

## Akaike's Information Criterion; AIC

73

- ▶  $-2 \log L(\beta; x) + 2K$ 
  - ▶  $K$  :  $\beta$  のパラメータ数
- ▶ AICが最小となるモデルがよいモデル
  - ▶ パラメータを増やすことへのペナルティを与えた指標
    - ▶ 自由度調整済み決定係数も同様

## 古典的な変数選択法

74

- ▶ 基準に至るまで以下の操作を繰り返す
- ▶ 変数増加法
  - ▶ 変数候補から最もp値の小さなものを加える
- ▶ 変数減少法
  - ▶ 変数候補をすべて含めたモデルから最もp値の大きな変数を除く
- ▶ ステップワイズ法
  - ▶ 変数候補から最もp値の小さなものを加え、モデルから最もp値の大きな変数を除く

## 他の変数選択法

75

- ▶ p値の代わりに用いる基準
  - ▶ AIC
  - ▶ 平均二乗誤差、Brierスコア
  - ▶ c-index
  - ▶ . . .
- ▶ 総当たり法
  - ▶ 変数の組合せ全パターン調べる

## 平均二乗誤差 Mean Squared Error

76

- ▶  $\frac{1}{n}(\hat{y}_i - y_i)^2$ 
  - ▶ 予測値と実測値の差を評価
  - ▶ 平方根をとって、Root MSE; RMSE

## Brier スコア

77

- ▶ イベント有無と生存確率のズレ
  - ▶ 生存時間アウトカムの場合、ある時点 $t$ でのイベント有無と確率のズレ
- ▶ Brierスコア
  - ▶  $\{I(y = 1) - \hat{y}\}^2$
  - ▶  $\{I(T > t) - \hat{S}(t|X)\}^2$ 
    - ▶  $I(\cdot)$ : かつこ内が真のときに1、それ以外は0
    - ▶  $\hat{S}(\cdot)$ : 生存関数の予測値

## 感度と特異度


78







至適基準	評価値	
	陽性	陰性
陽性	a	b
陰性	c	d

- ▶ 感度:  $\frac{a}{a+b}$ 
  - ▶ 本心に陽性であるものを陽性といえたか
- ▶ 特異度:  $\frac{d}{c+d}$ 
  - ▶ 本心に陰性であるものを陰性といえたか

## カットオフ値をもって評価

79





### まとめ①

86

- ▶ 一般線形モデル
  - ▶ デザイン行列をうまく作って、t検定、分散分析、回帰分析等を統一的に表現
  - ▶ 残差平方和を最小にする最小二乗法
  - ▶ カテゴリカル変数のコーディング
    - ▶ GLM / reference / effect coding
    - ▶ コーディングによって推定値の解釈に注意

### まとめ②

87

- ▶ 一般線形混合モデル
  - ▶ 変量効果によって個別の平均に興味はないが、ばらつきを生むものを表現
- ▶ 一般化線形モデル
  - ▶ リスク差・比回帰、ロジスティック回帰、Poisson回帰等を統一的に表現
  - ▶ アウトカムの従う分布を定め、分布のパラメータを線形モデルで表現
    - ▶ リンク関数によって柔軟にモデル化

### まとめ③

88

- ▶ 因果モデルと予測モデル
  - ▶ 変数選択の考え方に違い
  - ▶ 決定係数、AIC
    - ▶ 一般化線形モデルの推定は最尤法
  - ▶ 平均二乗誤差、Brierスコア
  - ▶ ROC-AUC、c-index