

# 医学統計勉強会

東北大学病院循環器内科・東北大学臨床研究推進センター 共催

東北大学大学院医学系研究科EBM開発学寄附講座

宮田 敏


## 比率と分割表

疾患の発症率など，物事の**頻度 (frequency)** を議論する際，以下の三つの概念を使い分ける。

- **比 (ratio)** : A, B ( $\neq 0$ ) が存在するとき、 $A/B$  を**比**という。  
AとBは互いを含まない。  
– 例：性比。BMI=体重/身長<sup>2</sup>
- **割合 (proportion)** : A, B ( $\neq 0$ ) が存在し，分子Aが分母Bに含まれるとき， $A/B$  を**割合**という。  $0 \leq \text{割合} \leq 1$ 。
- **率 (rate)** : 単位時間あたりのイベントの発生割合。  
– **率** = イベント発生件数/延べ観察時間

割合と率：

例：4匹のマウスの生存時間を観察した。



死亡割合：イベント数/標本数 =  $2/4 = 0.5$

死亡率（人日法）：イベント数/延べ観察時間  
 $= 2/(12+3+9+12) = 0.0556$

「率」は、時間単位によって値が変わることに注意。

## 母比率の推定と検定

$X_1, \dots, X_n$ ：イベントの有無

$$X_i = \begin{cases} 1: \text{イベント有り} \\ 0: \text{イベントなし} \end{cases}, P(X_i = 1) = p \quad \text{母比率}$$

推定量：  $\hat{p} = X/n$

期待値：  $E(\hat{p}) = p$

分散：  $V(\hat{p}) = p(1-p)/n$

標準誤差：  $s.e.(\hat{p}) = (p(1-p)/n)^{1/2}$

母比率の信頼区間 (信頼水準  $100(1-\alpha)\%$ )

$$\left( \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right)$$

ただし、 $z_{\alpha/2}$ : 標準正規分布の上側  $100(\alpha/2)\%$  点

母比率の仮説検定 (有意水準  $\alpha$ )

$$H_0: p = p_0$$

$$H_1: p \neq p_0$$

棄却域:

$$Z = \frac{|\hat{p} - p_0| - 1/2n}{\sqrt{\frac{p_0(1-p_0)}{n}}} > z_{\alpha/2}$$

## Clopper-Pearson 正確信頼区間

前ページの信頼区間と仮説検定はよく用いられるが、標本数が十分大きいときに適用される近似を用いている。(通常  $np > 5$  程度) また、 $\hat{p} = 0$  あるいは  $1$  となったとき、信頼区間が構成出来ない。

Clopper-Pearson 正確信頼区間 (テキスト P.4)

$$\left( \frac{x}{(n-x+1)F_1 + x}, \frac{(x+1)F_2}{(x+1)F_2 + n-x} \right)$$

ただし、 $F_1 = F(\alpha/2, 2(n-x+1), 2x)$  :  $df1=2(n-x+1)$ ,  $df2=2x$  の F 分布の上側  $100(\alpha/2)\%$  点.  $F_2 = F(\alpha/2, 2(x+1), 2(n-x))$  :  $df1=2(x+1)$ ,  $df2=2(n-x)$  F 分布の上側  $100(\alpha/2)\%$  点.

# カテゴリデータの要約

度数分布：**水準** カテゴリの種類  
**度数** 各水準のデータ数  
**割合 (相対度数)** 度数/サンプル数 (%)

**分割表 (Contingency table)**：2種類のカテゴリデータの水準の組み合わせごとに、度数を求めた表。

(例)

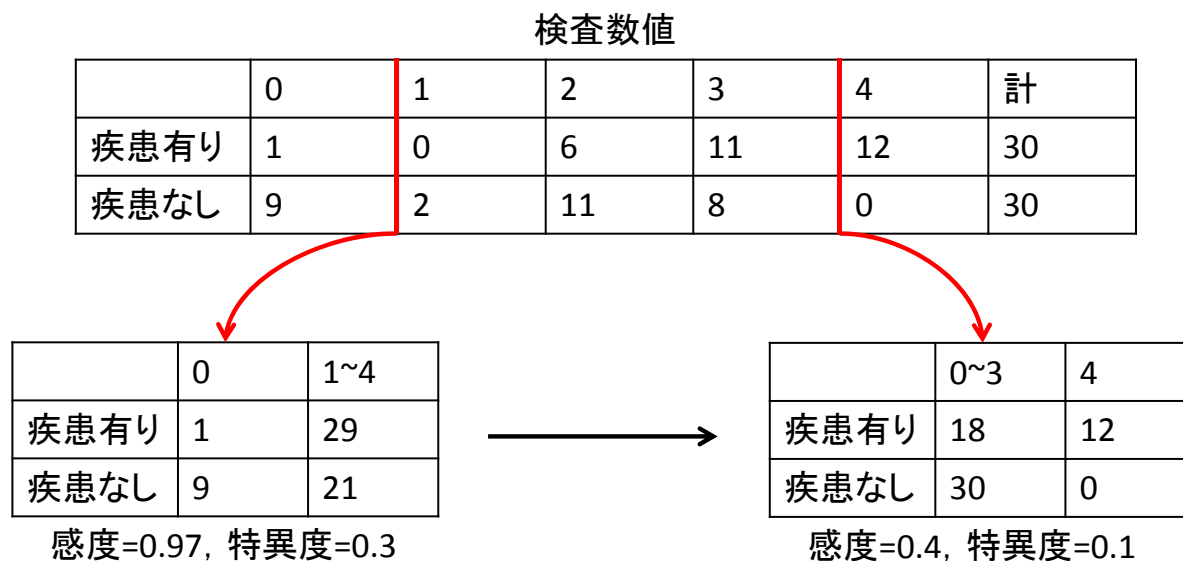
2×2分割表

	疾患有り	疾患なし
要因陽性	a	c
要因陰性	b	d

要因の有無により疾患を予測するとき、その精度を測るために以下の概念を定義する。


- **正答率 (accuracy rate)**： $(a+d)/(a+b+c+d)$
- **感度 (sensitivity)**：疾患有りのうち、陽性と判断される割合。 $a/(a+c)$  疾患有りなのに陰性と判断される割合を**偽陰性率 (false negative rate)**と呼ぶ。
- **特異度 (specificity)**：疾患なしのうち、陰性と判断される割合。 $d/(b+d)$  疾患なしなのに陽性と判断される割合を**偽陽性率 (false positive rate)**と呼ぶ。
- **陽性的中率 (positive predictive rate)**：陽性のうち疾患有りの割合。 $a/(a+b)$
- **陰性的中率 (negative predictive rate)**：陰性のうち疾患なしの割合。 $d/(c+d)$

検査数値が、三段階以上もしくは実数値をとる場合、カットポイントのとり場所により、複数の2×2分割表にデータをまとめることが出来る。検査数値の順序に従って分割表を作り、感度、特異度が求められる。



柳川 堯, 木 由布子 (著)「バイオ統計の基礎—医薬統計入門」近代科学社 (2010/02)

前項のように、検査数値の可能なカットポイントの順に、一連の分割表を作り感度、特異度が計算出来る。縦軸に感度、横軸に(1-特異度)をとったグラフを**ROC曲線**(Receiver Operating Characteristic curve)と呼び、ROC曲線の下面積を**AUC**(Area Under Curve)と呼ぶ。



# 分割表の検定（独立性の検定）

	6カ月以内死亡	6カ月以上生存
牛乳抗体陽性	29	80
牛乳抗体陰性	10	94

$$\hat{p}_1 = 29/(29 + 80) = 0.266$$

$$\hat{p}_2 = 10/(10 + 94) = 0.0962$$

帰無仮説  $H_0: p_1 = p_2$  母比率が一定.

対立仮説  $H_1: p_1 \neq p_2$  母比率が異なる.

もし、二つの変数に**関連がなければ**、グループによらず（=陽性でも陰性でも）、母比率（=6カ月以内に死亡する確率）は**一定のはず**  $\Rightarrow$  **帰無仮説  $H_0$**   
関連があれば、母比率が**異なる**  $\Rightarrow$  **対立仮説  $H_1$**

2×2分割表に限り、**片側仮説**が可能。  $H_1: p_1 > (<) p_2$

## 分割表の検定（独立性の検定） 続き

**$\chi^2$ 検定 (chi-squared test)**：サンプル数が多いとき、検定統計量の分布が $\chi^2$ 分布で近似されることを利用した検定。分割表の度数は、最低**5**は必要とされる。必ず**Yatesの連続補正 (Yates's continuity correction)**を行う。

**Fisherの直接法 (Fisher's exact test)**：サンプル数によらず、正確な**p**値を計算できる検定。

**Fisherの直接法が第一選択**。分割表が大きすぎてFisher検定が実行できない場合に限り、Yatesの連続補正をした $\chi^2$ 検定を選択する。

## 分割表とオッズ比

	疾患有り	疾患なし
要因陽性	a	b
要因陰性	c	d

帰無仮説  $H_0: p_1 = p_2$  母比率が一定.

対立仮説  $H_1: p_1 \neq p_2$  母比率が異なる.

この検定を、オッズ比から考える。  $H_0$ : オッズ比=1

$$\text{陽性オッズ} = \frac{p_1}{1-p_1}, \quad \text{陰性オッズ} = \frac{p_2}{1-p_2}$$

$$\text{オッズ比} = \frac{p_1}{1-p_1} \bigg/ \frac{p_2}{1-p_2} = \frac{p_1(1-p_2)}{p_2(1-p_1)}$$

## シンプソンのパラドックス

分割表で考える2つの要因の双方に影響を与える因子を、**交絡因子 (confounding factor)** と呼ぶ。交絡因子を無視して検定を行うと、本来存在した関連が見えなくなったり、その逆が起こることがある。

いま、A, B 2つの要因の間の分割表を考えているとする。第3の要因Zの値によって、標本が二つの層に分けられたとする。それぞれの分割表は以下の通りとする。

	Z1	
	B	Not B
A	80	16
Not A	160	160

Odds ratio=5

	Z2	
	B	Not B
A	50	452
Not A	10	452

Odds ratio=5

交絡因子zを無視して、二つの分割表を統合してしまうと、

	B	Not B
A	130	468
Not A	170	612

この分割表のオッズ比を計算すると、オッズ比=1となる。交絡因子zで層別しておけばオッズ比=5、すなわち要因A有りのほうが5倍オッズが高かったことが分かるが、交絡因子を無視したためにリスクが全く見えなくなっている。

⇒ Mantel-Haenszel検定

## Take Home Message

1. 比と割合と率
2. 母比率の推定と検定
  - Clopper-Pearsonの正確信頼区間
3. 分割表の推定
  - 感度、特異度、その他
  - ROC曲線
4. 分割表の検定
5. シンプソンのパラドックス
  - 交絡因子
6. Mantel-Haenszel検定

以上