

## Mantel-Haenszel の方法

長島 健悟

城西大学 薬学部

2008 年 6 月 12 日

1/39

2/39

## 本発表での取り扱い


- ① 前向き・後ろ向き研究 (データの特徴, 相対リスク (リスク比とオッズ比), 交絡因子のバランス (データの収集方法, マッチング, コントロールの選択など)
  - 論文全体に渡っているが, 特に前半 pp.719-730
  - カバーできる範囲で
- ②  $2 \times 2$  表の検定と推定
- ③ 各層で共通なオッズ比が 1 か否かの検定
- ④ 各層で共通なオッズ比の推定
  - 後半 pp.730-746
  - $2 \times 2 \times k$  表,  $i \times j \times k$  表の話

## Mantel &amp; Haenszel (1959) について

- Mantel N, Haenszel W. Statistical aspects of the analysis of data from retrospective studies of disease. *J. Nat. Cancer Inst.* 1959; **22**(4): 719-748.
- ① 前向き・後ろ向き研究 (データの特徴), 相対リスク (リスク比とオッズ比), 交絡因子のバランス (データの収集方法, マッチング, コントロールの選択など)
  - ②  $2 \times 2$  表の検定と推定
  - ③ 各層で共通なオッズ比が 1 かどうかの検定
    - $2 \times 2 \times k$  表の場合の Mantel-Haenszel 検定
    - 1:1 マッチングの場合の検定
    - $2 \times j \times k$  表の場合 (多水準の曝露因子に対する拡張)
  - ④ 各層で共通なオッズ比の推定
    - $2 \times 2 \times k$  表における, Mantel-Haenszel 推定量  $R$  の提案と, その他の推定量  $R_1, R_2, R_3, R_4$  の比較
    - 1:1 マッチングの場合の推定

## 前向き研究

- 利点
  - 原因 → 結果, リスク比, リスク差が計算できる, 結果の解釈が容易
  - 複数の結果因子を調べることができる
  - 曝露因子の測定バイアスが少ない場合が多い
- 欠点
  - 追跡する時間が長い, コストが高い, 後ろ向き研究より時間がかかる
  - 結果因子の発生確率が小さい場合に過ぎない




3/39

4/39

後向き研究

- 利点
  - コストが低い, 研究期間が比較的短い, 個人レベルでの研究が可能なこと
  - 結果因子の発生確率が小さい場合に適している
- 欠点
  - 原因 ← 結果, リスク比, リスク差が計算できない
  - 曝露因子の測定バイアスが問題



Mantel & Haenzel (1959)

- 事例: John Snow のコレラの研究, 喫煙と肺がんの関連についての研究
  - 役割と限界について議論する
  - 仮説を生み出す過程で後向き研究は使える
  - 結果因子の比較が可能な状況を作る必要がある
  - 交絡因子は曝露因子間で均一であることが必要
- 後向き研究と前向き研究のどちらかしか実施できないときは, 同じ結論を得たい
- 発症確率が非常に小さいとき, 倫理的にランダム化試験が行えない場合など

2 × 2 表

表: コホート研究

セル確率	発症あり	発症なし	合計
曝露あり	$q_1$	$1 - q_1$	1
曝露なし	$q_2$	$1 - q_2$	1
確率変数	発症あり	発症なし	合計
曝露あり	$Y_{11}$		$m_{1+}$
曝露なし	$Y_{21}$		$m_{2+}$
合計			$m_{++}$

$$\begin{cases} Y_{11} \sim B(m_{1+}, q_1) \\ Y_{21} \sim B(m_{2+}, q_2) \end{cases} \quad (1)$$

2 × 2 表

表: ケース・コントロール研究

セル確率	曝露あり	曝露なし	合計
発症あり	$p_1$	$1 - p_1$	1
発症なし	$p_2$	$1 - p_2$	1
確率変数	曝露あり	曝露なし	合計
発症あり	$X_{11}$		$n_{1+}$
発症なし	$X_{21}$		$n_{2+}$
合計			$n_{++}$

$$\begin{cases} X_{11} \sim B(n_{1+}, p_1) \\ X_{21} \sim B(n_{2+}, p_2) \end{cases} \quad (2)$$

## リスク比とオッズ比

- 発症リスク比  $\phi$  (risk ratio)
- ケース・コントロール研究では曝露リスク比しか計算できない

$$\phi = \frac{q_1}{q_2} \tag{3}$$

- 発症オッズ比  $\psi$  (odds ratio)
- 発症確率が小さいとき, リスク比に近似

$$\psi = \frac{q_1/(1-q_1)}{q_2/(1-q_2)} \left( = \frac{p_1/(1-p_1)}{p_2/(1-p_2)} \right) \tag{4}$$

- $q_1 = 0.06, q_2 = 0.03$  のときは

$$\phi = \frac{0.06}{0.03} = 2, \psi = \frac{0.06/0.94}{0.03/0.97} = 2.06 \tag{5}$$

## 曝露オッズ比と発症オッズ比<sup>[8]</sup>

- 発症オッズ比  $\psi_D$ , Case-Control 研究の曝露オッズ比  $\psi_E$
- 疾患  $D$ , 非疾患  $\bar{D}$ , 曝露  $E$ , 非曝露  $\bar{E}$
- ベイズの定理より (7) 式

$$\psi_D = \frac{\Pr(D|E)[1-\Pr(D|\bar{E})]}{\Pr(D|\bar{E})[1-\Pr(D|E)]}, \psi_E = \frac{\Pr(E|D)[1-\Pr(E|\bar{D})]}{\Pr(E|\bar{D})[1-\Pr(E|D)]} \tag{6}$$

$$\begin{aligned} \psi_D &= \frac{\frac{\Pr(E|D)\Pr(D)}{\Pr(E|D)\Pr(D)+\Pr(E|\bar{D})\Pr(\bar{D})} \frac{\Pr(\bar{E}|\bar{D})\Pr(\bar{D})}{\Pr(\bar{E}|\bar{D})\Pr(\bar{D})+\Pr(\bar{E}|D)\Pr(D)}}{\frac{\Pr(\bar{E}|\bar{D})\Pr(\bar{D})}{\Pr(\bar{E}|\bar{D})\Pr(\bar{D})+\Pr(\bar{E}|D)\Pr(D)} \frac{\Pr(E|D)\Pr(D)}{\Pr(E|D)\Pr(D)+\Pr(E|\bar{D})\Pr(\bar{D})}} \\ &= \frac{\Pr(E|D)[1-\Pr(E|\bar{D})]}{\Pr(E|\bar{D})[1-\Pr(E|D)]} = \psi_E \end{aligned} \tag{7}$$

- 発症オッズ比  $\psi_D$  と曝露オッズ比  $\psi_E$  は等しい
- 以降ケース・コントロール研究の話に集中します

## 二項分布モデル

- 二項分布の確率関数の積を,  $\psi$  と  $p_2$  で表わして変形する
- 後半は指数型分布属の形,  $X_{+1} = X_{11} + X_{21}$  が  $p_2/(1-p_2)$  の十分統計量

$$\begin{aligned} \Pr(X_{11} = x_{11}, X_{21} = x_{21}) &= \binom{n_{1+}}{x_{11}} \left( \frac{\psi p_2}{1-p_2(1-\psi)} \right)^{x_{11}} \left( \frac{1-p_2}{1-p_2(1-\psi)} \right)^{n_{1+}-x_{11}} \times \\ &\quad \binom{n_{2+}}{x_{21}} p_2^{x_{21}} (1-p_2)^{n_{2+}-x_{21}} \\ &= \left[ 1 + \exp \left\{ \log \psi + \log \left( \frac{p_2}{1-p_2} \right) \right\} \right]^{-n_{1+}} \times \\ &\quad \left[ 1 + \exp \left\{ \log \left( \frac{p_2}{1-p_2} \right) \right\} \right]^{-n_{2+}} \times \\ &\quad \binom{n_{1+}}{x_{11}} \binom{n_{2+}}{x_{21}} \exp \left\{ x_{11} \log \psi + x_{+1} \log \left( \frac{p_2}{1-p_2} \right) \right\} \end{aligned} \tag{8}$$

## 二項分布モデルの最尤推定量と独立性の検定

- オッズ比の最尤推定量  $\hat{\psi}$

$$\hat{\psi} = \frac{X_{11}/(n_{1+} - X_{11})}{X_{21}/(n_{2+} - X_{21})} \tag{9}$$

- 独立性の検定
- 連続修正なし:  $c = 0$ , あり:  $c = 1/2$  (以降同様の記号を使います)

$$\begin{cases} H_0: \psi = 1 \\ H_1: \psi \neq 1 \end{cases} \tag{10}$$

$$\chi^2 = \frac{(|X_{11}(n_{2+} - X_{21}) - X_{21}(n_{1+} - X_{11})| - c)^2}{n_{1+}n_{2+}X_{+1}(n_{++} - X_{+1})} \sim \chi^2(1) \tag{11}$$

## 非心超幾何分布モデル (条件付き推測)

表: 非心超幾何分布モデル

確率変数	発症あり	発症なし	合計
曝露あり	$X_{11}$		$n_{1+}$
曝露なし			$n_{2+}$
合計	$X_{+1} = n_{+1}$		$n_{++}$

- 局外パラメータ  $p_2/(1-p_2)$  の十分統計量  $X_{+1} = X_{11} + X_{21}$  の条件付き分布に基づいて推測する
- この場合, 条件付き分布は興味のあるパラメータ  $\psi$  にしか依存しない
- 指数型分布属の重要な性質

## 条件付き分布と標本空間

$$\Pr(X_{11} = x_{11} \mid X_{+1} = n_{+1}) = \frac{\Pr(X_{11} = x_{11}, X_{+1} = n_{+1})}{\Pr(X_{+1} = n_{+1})} = \frac{\binom{n_{1+}}{x_{11}} \binom{n_{2+}}{n_{+1} - x_{11}} \psi^{x_{11}}}{\sum_{u \in \Omega_X} \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u} \psi^u} \quad (12)$$

- 集合  $\Omega_X$  は十分統計量  $X_{+1} = n_{+1}$  を与えたもとの標本空間

$$\Omega_X = \{u \in \mathbb{Z}_+ \mid \max(0, n_{+1} - n_{2+}) \leq u \leq \min(n_{1+}, n_{+1})\} \quad (13)$$

- 無条件分布の場合の標本空間は  $\Omega_S$

$$\Omega_S = \{(u, v) \in \mathbb{Z}_+^2 \mid 0 \leq u \leq n_{1+}, 0 \leq v \leq n_{2+}\} \quad (14)$$

13/39

## 非心超幾何分布モデルの条件付き最尤推定量

- オッズ比の条件付き最尤推定量  $\hat{\psi}_C$  は (15) 式を満たす解
- (15) 式はスコア関数=0 とおいたもの

$$x_{11} = E[X_{11} \mid X_{+1} = n_{+1}, \hat{\psi}_C] \quad (15)$$

$$E[X_{11} \mid X_{+1} = n_{+1}, \hat{\psi}_C] = \frac{\sum_{u \in \Omega_X} u \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u} \hat{\psi}_C^u}{\sum_{u \in \Omega_X} \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u} \hat{\psi}_C^u} \quad (16)$$

## 非心超幾何分布モデルの独立性の検定

- 独立性の検定 (Fisher's exact test), 仮説は (10) 式と同じ
- 帰無仮説のもとで,  $X_{11}$  は (12) 式の超幾何分布に従う
- 両側  $P$  値の計算には流儀がある, 何の統計量に基づいているかによって異なる

$$\Pr(X_{11} = x_{11} \mid X_{+1} = n_{+1}, \psi = 1) = \frac{\binom{n_{1+}}{x_{11}} \binom{n_{2+}}{n_{+1} - x_{11}}}{\binom{n_{++}}{n_{+1}}} \quad (17)$$

- $P$ -Value =  $2 \Pr(X_{11} \geq x_{11})$
- $P$ -Value =  $\Pr(Z_F \leq z_F)$ ,  $Z_F = \Pr(X_{11})$ ,  $z_F = \Pr(x_{11})$
- $P$ -Value =  $\Pr(|X_{11} - E_0[X_{11}]| \geq |x_{11} - E_0[X_{11}]|)$

15/39

16/39

## 層別解析 (Stratified analysis)

- 後向き試験データにおける  $2 \times 2$  表の解析
  - すばらしいデータ?
  - $2 \times 2$  表では明らかに交絡が存在する場合は, 層別解析やマッチング
- 層別解析 (Stratified analysis)
  - 層には分けるが最終的には全体の効果以外は見えない
- サブグループ解析 (Subgroup analysis)
  - グループそれぞれの効果を見たい
- 多変量解析 (Multivariate analysis)
  - さらに仮定をおいた数理モデルを使って, 他の因子の効果も見る

 $2 \times 2 \times k$  表

- $k$  個の  $2 \times 2$  表
- 結果因子や曝露因子以外の因子で, さらに分けられた分割表

表:  $2 \times 2 \times k$  表

セル確率	曝露あり	曝露なし	合計
発症あり	$p_{1k}$	$1 - p_{1k}$	1
発症なし	$p_{2k}$	$1 - p_{2k}$	1

確率変数	曝露あり	曝露なし	合計
発症あり	$X_{11k}$		$n_{1+k}$
発症なし	$X_{21k}$		$n_{2+k}$
合計			$n_{++k}$

## 積二項分布モデル

- 各層が独立であることを仮定して, 二項分布の積で表現したモデル
- $X_{+1k} = X_{11k} + X_{21k}$  が  $p_{2k}/(1 - p_{2k})$  の十分統計量

$$\Pr(X_{11k} = x_{11k}, X_{21k} = x_{21k}) =$$

$$\prod_k \left[ 1 + \exp \left\{ \log \psi_k + \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \right]^{-n_{1+k}} \times$$

$$\left[ 1 + \exp \left\{ \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \right]^{-n_{2+k}} \times$$

$$\binom{n_{1+k}}{x_{11k}} \binom{n_{2+k}}{x_{21k}} \exp \left\{ \sum_k x_{11k} \log \psi_k + \sum_k x_{+1k} \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \quad (19)$$

## 共通オッズ比 (summary relative risk/common odds ratio)

- 各層のオッズ比が等しいと仮定する
- 曝露因子と交絡因子の間に交互作用が存在しない状況

$$\psi_1 = \psi_2 = \dots = \psi_k = \psi \quad (20)$$

- オッズ比共通の仮定をおいた積二項分布モデル

$$\Pr(X_{11k} = x_{11k}, X_{21k} = x_{21k}) =$$

$$\prod_k \left[ 1 + \exp \left\{ \log \psi + \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \right]^{-n_{1+k}} \times$$

$$\left[ 1 + \exp \left\{ \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \right]^{-n_{2+k}} \times$$

$$\binom{n_{1+k}}{x_{11k}} \binom{n_{2+k}}{x_{21k}} \exp \left\{ \left( \sum_k x_{11k} \right) \log \psi + \sum_k x_{+1k} \log \left( \frac{p_{2k}}{1 - p_{2k}} \right) \right\} \quad (21)$$

積非心超幾何分布モデル

確率変数	発症あり	発症なし	合計
曝露あり	$X_{11k}$		$n_{1+k}$
曝露なし			$n_{2+k}$
合計	$X_{+1k} = n_{+1k}$		$n_{+k}$

- オッズ比共通の仮定において, 局外パラメータ  $p_{2k}/(1-p_{2k})$  の十分統計量  $X_{+1k} = X_{11k} + X_{21k}$  の条件付き分布に基づいて推測する
- $\Omega_{X_k}$  は層  $k$  の十分統計量を与えたもとの標本空間

$$\Pr(X_{11k} = x_{11k} | X_{+1k} = n_{+1k}) = \prod_k \frac{\binom{n_{1+k}}{x_{11k}} \binom{n_{2+k}}{n_{+1k} - x_{11k}} \psi^{x_{11k}}}{\sum_{u_k \in \Omega_{X_k}} \binom{n_{1+k}}{x_{11k}} \binom{n_{2+k}}{n_{+1k} - x_{11k}} \psi^{u_k}} \quad (22)$$

$$\Omega_{X_k} = \{u_k \in \mathbb{Z}_+ \mid \max(0, n_{+1k} - n_{2+k}) \leq u_k \leq \min(n_{1+k}, n_{+1k})\} \quad (23)$$

積非心超幾何分布モデルの条件付き最尤推定量

- 共通オッズ比の条件付き最尤推定量  $\hat{\psi}_C$  は (24) 式を満たす解
- (24) 式はスコア関数=0 とおいたもの

$$\sum_k x_{11k} = \sum_k E[X_{11k} | X_{+1k} = n_{+1k}, \hat{\psi}_C] \quad (24)$$

$$E[X_{11k} | X_{+1k} = n_{+1k}, \hat{\psi}_C] = \frac{\sum_{u_k \in \Omega_{X_k}} u_k \binom{n_{1+k}}{u_k} \binom{n_{2+k}}{n_{+1k} - u_k} \hat{\psi}_C^{u_k}}{\sum_{u_k \in \Omega_{X_k}} \binom{n_{1+k}}{u_k} \binom{n_{2+k}}{n_{+1k} - u_k} \hat{\psi}_C^{u_k}} \quad (25)$$

5つの共通オッズ比の推定量 I

- Mantel-Haenszel (1959) の提案のうちの一つ
- 提案する共通オッズ比  $R$  と, Haenszel, et al. (1954) の  $R_1$ , Wynder, et al. (1954) の  $R_2$  のほかに,  $R_3$  と  $R_4$  を示している

$$\begin{aligned} A_k &= X_{11k} & B_k &= n_{1+k} - X_{11k} \\ C_k &= n_{+1k} - X_{11k} & D_k &= n_{2+k} - n_{+1k} - X_{11k} \end{aligned} \quad (26)$$

$$\begin{aligned} R &= \frac{\sum_k A_k D_k / n_{+1k}}{\sum_k B_k C_k / n_{+2k}} \\ R_1 &= \frac{\sum_k A_k \sum_k D_k}{\sum_k B_k \sum_k C_k} \left/ \frac{\sum_k E[A_k] \sum_k E[D_k]}{\sum_k E[B_k] \sum_k E[C_k]} \right. \\ R_2 &= \frac{\sum_k A_k \sum_k \frac{D_k}{n_{2+k}}}{\sum_k B_k \sum_k \frac{C_k}{n_{2+k}}} \end{aligned} \quad (27)$$

5つの共通オッズ比の推定量 II

$$\begin{aligned} R_3 &= \frac{\sum_k (n_{2+k} \frac{A_k}{n_{1+k}}) \sum_k D_k}{\sum_k (n_{2+k} \frac{B_k}{n_{1+k}}) \sum_k C_k} \\ R_4 &= \frac{\sum_k (n_{+k} \frac{A_k}{n_{1+k}}) \sum_k (n_{+k} \frac{D_k}{n_{2+k}})}{\sum_k (n_{+k} \frac{B_k}{n_{1+k}}) \sum_k (n_{+k} \frac{C_k}{n_{2+k}})} \end{aligned} \quad (28)$$

- $R, R_1$  は  $\sum X_{11k} = \sum E[X_{11k} | n_{+1k}, \psi = 1]$  の時 1 になる共通オッズ比の推定量
- $R_1$  の分子は, 層を無視して 1 つの  $2 \times 2$  分割表にしたときのオッズ比の推定量. 分母は, 各層の  $H_0$  のもとの期待値の和から計算するの で 1 に近い値.  $R_1$  は  $\psi = 1$  の方向にバイアスがある
- $R_4$  は, 標準化リスクを用いたもの.  $R_2, R_3$  は, 標準化に近い補正をしたもの. 共通オッズ比というよりは標準化に近い?  $R_2$  は  $n_{2+k}$  が,  $R_3$  は  $n_{1+k}$  が,  $R_4$  はどちらかが 0 の場合定義できない.

### 共通オッズ比に対する独立性の検定

- Mantel-Haenszel (1959) の提案のうちの一つ
- 積非心超幾何分布モデルの  $\psi_C = 1$  のもとでの条件付きスコア検定にも一致

$$\begin{cases} H_0: \psi_1 = \psi_2 = \dots = \psi_k = \psi = 1 \\ H_1: \psi_1 = \psi_2 = \dots = \psi_k = \psi \end{cases} \quad (29)$$

$$\chi^2_{MH} = \frac{(|\sum_k X_{11k} - \sum_k E[X_{11k}]| - c)^2}{\sum_k V[X_{11k}]} \sim \chi^2(1) \quad (30)$$

$$E[X_{11k}] = \frac{n_{1+k}n_{+1k}}{n_{++k}} \quad (31)$$

$$V[X_{11k}] = \frac{n_{1+k}n_{2+k}n_{+1k}n_{+2k}}{n_{++k}^2(n_{++k} - 1)}$$

### Cochran-Mantel-Haenszel 検定

- Cochran (1954; pp.443-446)<sup>[4]</sup> も似たような検定だから?
- 積二項分布モデルを仮定し, 各層のリスク差の重み付き平均にもとづく統計量
- Mantel-Haenszel オッズ比  $R$  とは関係ない
- 分散の推定量が少し違う (二項分布ベースなので  $np(1-p)$  の形)

$$V^C[X_{11k}] = \frac{n_{1+k}n_{2+k}n_{+1k}n_{+2k}}{n_{++k}^3} \quad (32)$$

- Cochran (1954) では他にも
  - カテゴリの併合について
  - 分割表の  $\chi^2$  検定の使い分けの基準 (正確検定, 連続性の補正, 通常の検定)
  - Cochran-Armitage trend test を提案

### 1:1 マッチング

- Case と Control が 2 人 1 組という条件が付く
- 多項分布モデル,  $M(z_{++}, \pi_{11}, \pi_{12}, \pi_{21})$

表: 1:1 マッチング

セル確率	Control		合計
	曝露	非曝露	
Case 曝露	$\pi_{11}$	$\pi_{12}$	$p_1$
Case 非曝露	$\pi_{21}$	$\pi_{22}$	$1 - p_1$
合計	$p_2$	$1 - p_2$	1

確率変数	Control		合計
	曝露	非曝露	
Case 曝露	$Z_{11}$	$Z_{12}$	
Case 非曝露	$Z_{21}$	$Z_{22}$	
合計			$z_{++}$

### 1:1 マッチングの Mantel-Haenszel 推定量

- 元々の分割表は ...
- $2 \times 2 \times k (= Z_{11} + Z_{12} + Z_{21} + Z_{22})$  表
- 層の数が無限に増加する極限モデル, 無条件の最尤推定量は  $\psi^2$  に収束<sup>[3, 7]</sup>

	曝露	非曝露	
Case	1	0	$\times Z_{11}$
Control	1	0	

	曝露	非曝露	
Case	1	0	$\times Z_{12}$
Control	0	1	

	曝露	非曝露	
Case	0	1	$\times Z_{21}$
Control	1	0	

	曝露	非曝露	
Case	0	1	$\times Z_{22}$
Control	0	1	

### 1:1 マッチングの Mantel-Haenszel 推定量

- 共通オッズ比の Mantel-Haenszel 推定量  $R$  は

$$R = \frac{\sum X_{11k}(n_{2+k} - n_{+1k} + X_{11k})/n_{+1k}}{\sum (n_{1+k} - X_{11k})(n_{+1k} - X_{11k})/n_{+2k}} = \frac{Z_{12}}{Z_{21}} \quad (33)$$

- 共通オッズ比の条件付き最尤推定量は (34) 式を満たす解
- 1:1 マッチングの時のみ  $R = \hat{\psi}_C$

$$\sum_k X_{11k} = \sum_k \frac{\sum_{u \in \Omega_{2k}} u \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u} \hat{\psi}_C^u}{\sum_{u \in \Omega_{2k}} \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u} \hat{\psi}_C^u} = \sum_k \frac{\sum_{u \in \Omega_{2k}} u \hat{\psi}_C^u}{\sum_{u \in \Omega_{2k}} \hat{\psi}_C^u} \quad (34)$$

$$Z_{11} + Z_{12} + 0 + 0 = Z_{11} + Z_{12} \frac{\hat{\psi}_C}{1 + \hat{\psi}_C} + Z_{21} \frac{\hat{\psi}_C}{1 + \hat{\psi}_C} + 0$$

$$\hat{\psi}_C = \frac{Z_{12}}{Z_{21}} \quad (35)$$

### 1:1 マッチングの Mantel-Haenszel 検定

- Mantel-Haenszel 検定は

$$\chi_{MH}^2 = \frac{\left( \sum_k X_{11k} - \sum_k \frac{n_{1+k} n_{+1k}}{n_{+2k}} \right)^2}{\sum_k \frac{n_{1+k} n_{2+k} n_{+1k} n_{+2k}}{n_{+2k}^2 (n_{+2k} - 1)}} \quad (36)$$

$$= \frac{(Z_{11} + Z_{12} + 0 + 0 - \frac{2Z_{11} + Z_{12} + Z_{21} + 0}{2})^2}{\frac{0 + Z_{12} + Z_{21} + 0}{4}} = \frac{(Z_{12} - Z_{21})^2}{Z_{12} + Z_{21}}$$

### McNemar 検定<sup>[6]</sup>

- 対応のある  $2 \times 2$  分割表に対する周辺同源性 (marginal homogeneity) の検定
- $2 \times 2$  表なので,  $d$  に対する推測に帰着する

$$\begin{cases} H_0: & p_1 = p_2 \quad (d = \pi_{12} - \pi_{21} = 0) \\ H_1: & p_1 \neq p_2 \quad (d \neq 0) \end{cases} \quad (37)$$

$$X_{Mc}^2 = \frac{\hat{d}^2}{\hat{V}[\hat{d} | H_0]} = \frac{(|Z_{12} - Z_{21}| - c)^2}{Z_{12} + Z_{21}} \quad (38)$$

$$\hat{d} = \hat{\pi}_{12} - \hat{\pi}_{21} = \frac{Z_{12} - Z_{21}}{z_{++}}$$

$$V[\hat{d}] = \frac{V[Z_{12}] + V[Z_{21}] - 2Cov[Z_{12}, Z_{21}]}{z_{++}^2} \quad (39)$$

$$\hat{V}[\hat{d} | H_0] = \frac{\hat{\pi}_{12} + \hat{\pi}_{21}}{z_{++}} = \frac{Z_{12} + Z_{21}}{z_{++}^2}$$

### $i \times j \times k$ 表

セル確率 結果因子	曝露因子				合計
	$B_1$	$B_2$	$\dots$	$B_j$	
$A_1$	$\pi_{11k}$	$\pi_{12k}$	$\dots$	$\pi_{1jk}$	1
$A_2$	$\pi_{21k}$	$\pi_{22k}$	$\dots$	$\pi_{2jk}$	1
$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$A_i$	$\pi_{i1k}$	$\pi_{i2k}$	$\dots$	$\pi_{ijk}$	1

確率変数 結果因子	曝露因子 スコア	$B_1$	$B_2$	$\dots$	$B_j$	合計
		$c_{1k}$	$c_{2k}$	$\dots$	$c_{jk}$	
$A_1$	$r_{1k}$	$X_{11k}$	$X_{12k}$	$\dots$	$X_{1jk}$	$n_{1+k}$
$A_2$	$r_{2k}$	$X_{21k}$	$X_{22k}$	$\dots$	$X_{2jk}$	$n_{2+k}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$A_i$	$r_{ik}$	$X_{i1k}$	$X_{i2k}$	$\dots$	$X_{ijk}$	$n_{i+k}$
合計						$n_{++k}$



## 積多項分布モデル

$$\Pr(X_{ijk} = x_{ijk}) = \prod_i \prod_k \frac{n_{i+k}!}{\prod_j x_{ijk}!} \prod_j p_{ijk}^{x_{ijk}} \quad (40)$$

$$\psi_{ijk} = \frac{p_{ijk} p_{11k}}{p_{i1k} p_{1jk}} \quad (41)$$

$$\Pr(X_{ijk} = x_{ijk}) = c(\boldsymbol{\psi}, \boldsymbol{\theta}) h(\mathbf{x}) \exp\left(\sum_{i=2} \sum_{j=2} \sum_k x_{ijk} \log \psi_{ijk} + \sum_{j=2} \sum_k x_{+jk} \theta_{jk}\right) \quad (42)$$

$$\theta_{jk} = \log\left(\frac{p_{1jk}}{p_{11k}}\right), \quad c(\boldsymbol{\psi}, \boldsymbol{\theta}) = \prod_i \prod_k \left(1 + \sum_{j=2} \exp(\log \psi_{ijk}) \exp(\theta_{jk})\right)^{-n_{i+k}}$$

$$h(\mathbf{x}) = \prod_i \prod_k \frac{n_{i+k}!}{\prod_j x_{ijk}!} \quad (43)$$

33 / 39

## カテゴリに順序がある場合のモデル

$$\Pr(X_{ijk} = x_{ijk}) = c(\boldsymbol{\psi}, \boldsymbol{\theta}) h(\mathbf{x}) \exp\left(\sum_{i=2} \sum_{j=2} \sum_k x_{ijk} (c_{jk} - c_{1k}) \beta_i + \sum_{j=2} \sum_k x_{+jk} \theta_{jk}\right) \quad (44)$$

$$c(\boldsymbol{\beta}, \boldsymbol{\theta}) = \prod_i \prod_k \left(1 + \sum_j \exp[\log\{(c_{jk} - c_{1k}) \beta_i\}] \exp(\theta_{jk})\right)^{-n_{i+k}} \quad (45)$$

- 興味のあるパラメータ  $\beta_i$  に対する十分統計量

$$W_i = \sum_j \sum_k x_{ijk} (c_{jk} - c_{1k})$$


- 局外パラメータ  $\theta_{jk}$  に対する十分統計量  $X_{+jk}$  の条件付き分布に基づいて考えると

$$\Pr(X_{ijk} = x_{ijk} \mid X_{+jk} = n_{+jk}) = \frac{h(\mathbf{x}) \exp(\sum_{i=2} W_i \beta_i)}{\sum_{\mathbf{u} \in \Omega_{X_{+jk}}} h(\mathbf{u}) \exp(\sum_{i=2} W_i \beta_i)} \quad (46)$$

35 / 39

カテゴリに順序がある場合<sup>[8]</sup>

- 行のスコアを ( $r_{1k} \leq r_{2k} \leq \dots \leq r_{ik}$ )
- 列のスコアを ( $c_{1k} \leq c_{2k} \leq \dots \leq c_{jk}$ )
- 片方にスコアを割り付けて,  $\log \psi_{ijk} = (c_{jk} - c_{1k}) \beta_i$  の仮定をおいた検定 → 一般化拡張 Mantel 検定
- 両方にスコアを割り付けて,  $\log \psi_{ijk} = (r_{ik} - r_{1k})(c_{jk} - c_{1k}) \beta$  の仮定をおいた検定 → 拡張相関検定
- 行の数が 2 で, スコアが層に無関係  $c_{jk} = c_j$  の時 → 一般化 Mantel 検定<sup>[5]</sup>



34 / 39

## 一般化 Mantel 検定

- 列の数が 2 で, スコアが層に無関係 ( $c_{jk} = c_j$ ) で,  $c_1 = 0$  の時,  $W = \sum_j \sum_k X_{2jk} c_j$
- 列が 2 つなのでパラメータが 1 つになる, 以下の仮説に対する検定

$$\begin{cases} H_0: & \beta = 0 \\ H_1: & \beta \neq 0 \end{cases} \quad (47)$$

$$\Pr(X_{ijk} = x_{ijk} \mid X_{+jk} = n_{+jk}; \beta = 0) = \prod_k \frac{\prod_j \binom{n_{+jk}}{x_{2jk}}}{\binom{n_{+jk}}{n_{2+k}}} \quad (48)$$

$$E[W \mid X_{+jk} = n_{+jk}; \beta = 0] = \sum_k n_{2+k} \sum_j \frac{c_j n_{+jk}}{n_{+k}}$$

$$V[W \mid X_{+jk} = n_{+jk}; \beta = 0] = \sum_k \frac{n_{1+k} n_{2+k}}{n_{+k} + (n_{+k} - 1)} [n_{+k} \sum_j c_j^2 n_{+jk} - (\sum_j c_j n_{+jk})^2] \quad (49)$$

$$\chi_{EMH}^2 = \frac{(W - E[W \mid X_{+jk} = n_{+jk}; \beta = 0])^2}{V[W \mid X_{+jk} = n_{+jk}; \beta = 0]} \sim \chi^2(1) \quad (50)$$

36 / 39

## 参考文献

- [1] Agresti A. A survey of exact inference for contingency tables. *Statistical Science* 1992; 7(1): 131–177.
- [2] Agresti A. *Categorical data analysis. 2nd edition*. New York: John Wiley & Sons 2002.
- [3] Breslow N. Odds ratio estimators when the data are sparse. *Biometrika* 1981; 68(1): 73–84.
- [4] Cochran WG. Some methods for strengthening the common  $\chi^2$  tests. *Biometrics* 1954; 10(4): 417–451.
- [5] Mantel N. Chi-square tests with one degree of freedom; extensions of the Mantel-Haenszel procedure. *Journal of the American Statistical Association* 1963; 58(303): 690–700.
- [6] McNemar Q. Note on the sampling error of the difference between correlated proportions or percentages. *Psychometrika* 1947; 12(2): 153–157.
- [7] 佐藤俊哉, 高木廣文, 柳川発, 柳本武美. Mantel-Haenszel の方法による複数の  $2 \times 2$  表の要約. 統計数理 1998; 46(1): 153–177.
- [8] 柳川発. 離散多変量データの解析. 共立出版 1986.

## 超幾何分布の期待値

- $E[X_{11} | n_{+1}, \psi = 1]$  等は省略して  $E[X_{11}]$  と表わす

$$E[X_{11}] = \sum_{u \in \Omega_X} u \Pr[u] = \frac{\sum_{u \in \Omega_X} u \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u}}{\sum_{u \in \Omega_X} \binom{n_{1+}}{u} \binom{n_{2+}}{n_{+1} - u}}$$

$$= \frac{1}{\binom{n_{++}}{n_{+1}}} \sum_{u \in \Omega_X} \frac{n_{1+}(n_{1+} - 1)!}{(u - 1)! (n_{1+} - u)!} \binom{n_{2+}}{n_{+1} - u} = \frac{n_{1+} \binom{n_{++} - 1}{n_{+1} - 1}}{\binom{n_{++}}{n_{+1}}} = \frac{n_{1+} n_{+1}}{n_{++}} \quad (51)$$

---


$$\sum_{u=0}^r \binom{n}{u} \binom{m}{r-u} = \binom{n+m}{r}$$

## 超幾何分布の分散

$$V[X_{11}] = E[X_{11}^2] - \{E[X_{11}]\}^2$$

$$= \sum_{u \in \Omega_X} u(u - 1) \Pr[u] + \sum_{u \in \Omega_X} u \Pr[u] - \{E[X_{11}]\}^2 \quad (52)$$

$$= \frac{n_{1+}(n_{1+} - 1)n_{+1}(n_{+1} - 1)}{n_{++}(n_{++} - 1)} + \frac{n_{1+}n_{+1}}{n_{++}} - \frac{n_{1+}^2 n_{+1}^2}{n_{++}^2}$$

$$= \frac{n_{1+}(n_{++} - n_{1+})n_{+1}(n_{++} - n_{+1})}{n_{++}^2(n_{++} - 1)}$$

- 積非心超幾何分布モデルは, 帰無仮説のもとで  $k$  個の独立な超幾何分布の積になる