

Efekty losowe

Bogumiła Koprowska Elżbieta Kukla

1 Wstęp

- Czym są efekty losowe?
- Przykłady
- Model mieszany

2 Estymacja

- Jednokierunkowa klasyfikacja (ANOVA)
- Metoda największej wiarygodności (ML)
- Metoda największej wiarygodności z restrykcjami (REML)

3 Testowanie

- Test ilorazu wiarygodności
- Testowanie efektów stałych
- Testowanie efektów losowych

Jednokierunkowa ANOVA

Było: $Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$

$i = 1, 2, \dots, k,$

$j = 1, 2, \dots, n$

Y_{ij} - j -ta obserwacja na i -tym poziomie czynnika

μ - ogólna wartość średnia

α_i - efekt i -tego poziomu czynnika

ε_{ij} - niezależne zmienne losowe $\sim N(0, \sigma^2)$

Obserwacje Y_{ij} , $j = 1, 2, \dots, n$ dla każdej ustalonej wartości wskaźnika i tworzą **grupę**.

Dane zgrupowane

- każda obserwacja należy do jednej grupy i jest tylko jeden czynnik grupujący
- hierarchiczne, zagnieżdżone zbiory danych - bardziej skomplikowane przypadki
- nie możemy zakładać niezależności obserwacji, obserwacje są skorelowane w ramach grup
- efekty losowe - wygodne do modelowania tego typu danych

Efekt losowy a efekt stały

1 Efekt stały

nieznana liczba, którą estymujemy z danych

2 Efekt losowy

zmienna losowa, estymujemy parametry opisujące rozkład efektu losowego

Przykłady

1 Z astronomii:

1861 r. - astronom Airy sformułował model $Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$ z losowymi efektami α_i do opisu obserwowanych przez teleskop obiektów astronomicznych

2 Z medycyny:

traktowanie pacjentów poddanych leczeniu, jako wybranych losowo z większego zbioru pacjentów, których cechy chcemy estymować

Kiedy używać efektów losowych?

- gdy efektom danego czynnika nie można przypisać charakteru stałego, należy uznać je za losowe
- gdy chcemy uzyskać informacje o całej populacji, nasze obserwacje traktujemy jako próbkę z całej populacji
- niektórzy statystycy polecają zawsze używanie efektów losowych

Model mieszany

- w modelu mieszanym pojawiają się efekty stałe i efekty losowe
- najprostszy przykład - **model dwukierunkowej klasyfikacji**:

$$y_{ijk} = \mu + \tau_i + \nu_j + \varepsilon_{ijk}$$

gdzie

$$i = 1, 2, \dots, m, j = 1, 2, \dots, l, k = 1, \dots, n_{ij}$$

efekty stałe:

$$\mu, \tau_i$$

efekty losowe, i.i.d.:

$$\nu_j \sim N(0, \sigma_\nu^2)$$

$$\varepsilon_{ijk} \sim N(0, \sigma^2)$$

Estymacja efektów, przykład

1 Hipoteza zerowa przy estymacji efektów:

- stałych - $H_0 : \tau_i = 0 \forall i$
- losowych - $H_0 : \sigma_v^2 = 0$

2 Przykład - badania biologiczne:

badanie cechy potomków zadanej populacji / matek, np.
efekt czynnika płci - efekt stały,
efekt j -tej matki - efekt losowy

Estymacja

Estymacja efektów

Estymacja efektów w modelu losowym jest możliwa przy użyciu:

- klasyfikacji jednokierunkowej (ANOVY)
- metody największej wiarygodności (ML)
- metody największej wiarygodności z restrykcjami (REML)

Najprostszy model losowy

Model jednokierunkowej klasyfikacji (ANOVA):

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$$

$$i = 1, \dots, a$$

$$j = 1, \dots, n$$

$$\alpha_i \sim N(0, \sigma_\alpha^2)$$

$$\varepsilon_{ij} \sim N(0, \sigma_\varepsilon^2)$$

- **Komponenty wariancyjne:** $\sigma_\alpha^2, \sigma_\varepsilon^2$
- **Wewnątrzgrupowy współczynnik korelacji:** $\rho = \frac{\sigma_\alpha^2}{\sigma_\alpha^2 + \sigma_\varepsilon^2}$

Estymatory

- **Dekompozycja wariancji:**

$$\sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{..})^2 = \sum_{i=1}^a \sum_{j=1}^n (y_{ij} - \bar{y}_{i.})^2 + \sum_{i=1}^a \sum_{j=1}^n (\bar{y}_{i.} - \bar{y}_{..})^2$$

$$SST = SSE + SSA$$

- $E(SSE) = a(n-1)\sigma_{\varepsilon}^2$
 $E(SSA) = (a-1)(n\sigma_{\alpha}^2 + \sigma_{\varepsilon}^2)$

- **Estymatory:**

$$\hat{\sigma}_{\varepsilon}^2 = SSE / (a(n-1)) = MSE$$

$$\hat{\sigma}_{\alpha}^2 = \frac{SSA / (a-1) - \hat{\sigma}_{\varepsilon}^2}{n} = \frac{MSA - MSE}{n}$$

Wady ANOVY

Wady korzystania z ANOVY:

- estymator wariancji może przyjmować ujemne wartości
- skomplikowane obliczenia w przypadku gdy dane są niezbalansowane

Metoda największej wiarygodności (ML)

- nie ma takich wad jak ANOVA
- musimy założyć, jaki rozkład mają błędy i efekty losowe (zwykle rozkład normalny)
- dla modelu wyłącznie z efektami stałymi mamy:

$$y = X\beta + \varepsilon, y \sim N(X\beta, \sigma^2 I)$$

gdzie

X - macierz planu doświadczenia $n \times p$

β - wektor p stałych parametrów

ε - wektor błędów losowych

Model mieszany

- dla modelu mieszanego:

$$y = X\beta + Z\gamma + \varepsilon, y|\gamma \sim N(X\beta + Z\gamma, \sigma^2 I)$$

gdzie

Z - macierz $n \times q$ opisująca wpływ efektów losowych na obserwacje y

γ - wektor q efektów losowych

ε - wektor błędów losowych

- dalej zakładamy, że $\gamma \sim N(0, \sigma^2 D)$, wówczas:

$$\begin{aligned} \text{var}y &= \text{var}Z\gamma + \text{var}\varepsilon = \sigma^2 ZDZ^T + \sigma^2 I \\ y &\sim N(X\beta, \sigma^2(I + ZDZ^T)) \end{aligned}$$

- przyjmuje się, że wektory losowe γ i ε są niezależne

Estymacja przy użyciu metody największej wiarygodności (ML)

- jeśli przyjmiemy, że $V = I + ZDZ^T$, wówczas łączna gęstość y wynosi:

$$\frac{1}{(2\pi)^{n/2}|\sigma^2 V|^{1/2}} e^{-\frac{1}{2\sigma^2}(y-X\beta)^T V^{-1}(y-X\beta)}$$

- logarytm wiarygodności:

$$l(\beta, \sigma, D|y) = -\frac{n}{2}\log 2\pi - \frac{1}{2}\log|\sigma^2 V| - \frac{1}{2\sigma^2}(y-X\beta)^T V^{-1}(y-X\beta)$$

- estymacji podlega nieznaną wektor stałych parametrów modelu β , wariancja σ^2 i macierz komponentów wariancyjnych D

Wady ML

Wady korzystania z metody największej wiarygodności (ML):

- trudności w przypadku bardziej złożonych modeli, wymagających estymacji większej liczby parametrów efektów losowych
- problem z estymatorem wariancji, gdy maksimum wiarygodności jest przyjmowane dla ujemnych wartości
- estymatory są często dość silnie obciążone

Metoda największej wiarygodności z restrykcjami (REML)

- nie ma wielu wad, które dotyczyły ANOVY i ML
- dla danych zbalansowanych, estymatory obliczone przy użyciu REML są zwykle takie same jak obliczone przy użyciu ANOVY
- dostajemy estymatory nieobciążone lub o zredukowanym obciążeniu
- idea: bierzemy K - dopełnienie ortogonalne X (tzn. $K^T X = 0$).

Wówczas: $K^T y \sim N(0, \sigma^2 K^T V K)$,

następnie możemy korzystać z metody ML (nie mamy już efektów stałych)

Testowanie

Test ilorazu wiarygodności

Do porównywania hipotez H_0 i H_1 używamy testu **ilorazu wiarygodności**:

$$2(l(\hat{\beta}_1, \hat{\sigma}_1, \hat{D}_1|y) - l(\hat{\beta}_0, \hat{\sigma}_0, \hat{D}_0|y))$$

gdzie

$\hat{\beta}_1, \hat{\sigma}_1, \hat{D}_1$ - estymatory największej wiarygodności (MLE) parametrów przy hipotezie alternatywnej

$\hat{\beta}_0, \hat{\sigma}_0, \hat{D}_0$ - MLE przy hipotezie zerowej

Wady testu ilorazu wiarygodności

Wady testu ilorazu wiarygodności:

- test jest przybliżony i często przybliżenie to jest nienajlepsze
- wymaga wielu dodatkowych założeń, np. parametry przy hipotezie zerowej nie mogą być na brzegu przestrzeni parametrów

Testowanie efektów stałych

- nie możemy użyć metody REML do porównania dwóch modeli, które różnią się tylko efektami stałymi
- do testowania efektów stałych używamy ML (jeśli chcemy korzystać z testu ilorazu wiarygodności)
- p-wartości generowane przez test ilorazu wiarygodności dla efektów stałych są przybliżone i często zbyt małe - wyolbrzymiają wagę niektórych efektów
- do znalezienia dokładniejszej p-wartości możemy użyć metody **parametrycznego bootstrapu**

Testowanie efektów losowych

- hipoteza zerowa zwykle ma postać $H_0 : \sigma^2 = 0$
problem - to nie jest wewnątrz przestrzeni parametrów
- jeśli jednak przyjmiemy, że otrzymujemy rozkład χ^2 , wówczas otrzymana p -wartość będzie zwykle większa niż powinna
- metody numeryczne (bootstrap)

Dziękujemy!