

Postavitev hipotez

NUJNO!

Milena Kovač

10. januar 2013

Postavitev in preizkušanje hipotez

Hipoteze zastavimo najprej ob načrtovanju preizkusa

Ob obdelavi jih morda malo popravimo

Preizkus hipotez opravimo v treh korakih

1. Preizkusimo, ali je **model** značilen.
2. Preizkusimo, kateri **vplivi** v modelu so značilni
3. Preizkusimo, kateri **nivoji** pri značilnih vplivih se med seboj razlikujejo

Zapis hipoteze

- Hipoteza je vedno sestavljena iz:
 - ničelne hipoteze in
 - alternativne hipoteze

$H_0 : P_1 - P_2 = 0$ ■ = med pasmama P_1 in P_2 ni razlike

$H_1 : P_1 - P_2 \neq 0$ = med pasmama je razlika

- Ničelno in alternativno hipotezo vedno v paru in v tej obliki!

Ničelna hipoteza - skalarna oblika

Primeri:

$$H_0 : P_1 - P_2 = 0 \blacksquare$$

= med pasmama P_1 in P_2 ni razlike

$$H_0 : M_i - M_{i'} = 0 \blacksquare$$

= med mesecema M_i in $M_{i'}$ ni razlik

$$H_0 : b = 0 \blacksquare$$

= regresijski koeficient b ni različen od nič

$$H_0 : b = 9.7 \blacksquare$$

= regresijski koeficient b se ne razlikuje od 9.7

$$H_0 : P_1 - P_2 = 0 \wedge P_1 - P_3 = 0 \blacksquare$$

= pasmi P_2 in P_3 se ne razlikujeta od pasme P_1

Linearne kombinacije parametrov za sistematske vplive:

- seštevamo in odštevamo parametre

$$\begin{array}{l} P_1 - P_2 \\ b \end{array}$$

- množimo in/ali delimo parametre s konstantami

Hipoteze

- **Ničelna hipoteza: H_0**
 - model ni primeren, vpliv nima učinka, ni razlik med posameznimi nivoji
- **Alterativna hipoteza: H_1 ali H_2 ali H_a**
 - vse ostale možnosti
 - ★ model je značilen, vpliv ima učinek, med nivoji so razlike
 - samo del ostalih možnosti (večje ali manjše), drugi del je povsem nepomemben
 - ★ nova zdravila morajo biti bolj učinkovita od starih

Ničelna hipoteza - matrična oblika

Primeri:

$$H_0 : \mathbf{K}\boldsymbol{\beta} = \mathbf{0}$$

$$H_0 : \mathbf{K}\boldsymbol{\beta} = \mathbf{m}$$

K - matrika linearnih kombinacij (lokacijskih) parametrov
za matriko uporabimo tudi črko **H**

pri eni sami kombinaciji uporabljamo vektor **k'** ali **h'**

β - parametri za sistematske vplive (lokacijski parametri)

0 - vektor pričakovanih vrednosti za linearne kombinacije

m - vektor pričakovanih vrednosti za linearne kombinacije
(tudi od nič različne vrednosti)

Matrika hipotez

$$\mathbf{K} = \begin{bmatrix} \mathbf{k}'_1 \\ \mathbf{k}'_2 \\ \vdots \\ \mathbf{k}'_p \end{bmatrix}$$

- vsaka vrstica je lahko samostojna hipoteza
- lahko opravimo tudi skupni preizkus

Alternativna hipoteza - skalarna oblika

- $H_1 : P_1 - P_2 \neq 0$ med pasmama P_1 in P_2 je razlika
- $H_1 : M_i - M_{i'} \neq 0$ med mesecema M_i in $M_{i'}$ so razlike
- $H_1 : b \neq 0$ regresijski koeficient b je različen od 0
- $H_1 : b \neq 9.7$ regr. koef. b se razlikuje od 9.7
- $H_1 : P_1 - P_2 > 0$ razlika med pasmama P_1 in P_2 je večja od 0
- $H_1 : M_i - M_{i'} < 0$ razlika med M_i in $M_{i'}$ je manjša od 0
- $H_1 : b > 0$ regresijski koeficient b je večji od 0
- $H_1 : b < 9.7$ regr. koef. b je manjši od 9.7

Alternativna hipoteza - matrična oblika

Primeri:

$H_1 : \mathbf{K}\boldsymbol{\beta} \neq \mathbf{0}$ linearne kombinacije so različne od 0

$H_a : \mathbf{K}\boldsymbol{\beta} \neq \mathbf{m}$ linearne kombinacije so različne od konstant v vektorju \mathbf{m}

$H_1 : \mathbf{K}\boldsymbol{\beta} > \mathbf{0}$ linearne kombinacije so večje od 0

$H_1 : \mathbf{K}\boldsymbol{\beta} > \mathbf{m}$ linearne kombinacije so večje od konstant v vektorju \mathbf{m}

$H_1 : \mathbf{K}\boldsymbol{\beta} < \mathbf{0}$ linearne kombinacije so manjše od 0

$H_1 : \mathbf{K}\boldsymbol{\beta} < \mathbf{m}$ linearne kombinacije so manjše od konstant v vektorju \mathbf{m}

Potrditev ali zavrnitev hipoteze

- ničelna in alternativna hipoteza vedno v paru

Primer I	Primer II
$H_0 : P_1 - P_2 = 0$	$H_0 : P_1 - P_2 = 0$
$H_1 : P_1 - P_2 \neq 0$	$H_1 : P_1 - P_2 > 0$

- lahko so bolj sestavljene, a dajemo prednost enostavnim
- se izključujeta:
 - nikoli ne držita obe hkrati
 - lahko je še tretja možnost, ki pa za nas nikakor ni zanimiva

Potrditev ali zavrnitev hipoteze

- **sprejmemo ničelno hipotezo, alternativno zavrnamo**
 - potem nobena linearna kombinacija (npr. razlika) ni značilna,
 - razlik med nivoji ni,
 - ne izvedemo naslednjega koraka pri preizkušanju hipotez ...
- **zavrnamo ničelno hipotezo, sprejmemo alternativno**
 - iščemo pomembne razlike,
 - med primerjavami je najmanj ena značilna (pomembna)
- **ni tretje možnosti**

Regresijski koeficienti in hipoteze

- če so različni od nič ali od konstante (npr. 9.7)

Primer I	Primer II
$H_0 : b = 0$	$H_0 : b = 9.7$
$H_1 : b \neq 0$	$H_1 : b > 9.7$

- če lahko bolj ugnezdene nadomestimo z manj ugnezdenimi ali glavnimi (želimo poenostaviti model)

Primer I

$$H_0 : b_1 = b_2 = \dots = b_p$$

$$H_1 : b_i \neq 0$$

Če drži ta hipoteza, potem

razlik med regresijskimi koeficienti ni lahko jih zamenjamo s skupnim b ne moremo poenostaviti

Nikoli ne preizkušamo

- razlik med nivojema dveh različnih vplivov
 - med pasmo P_1 in mesecem M_2 ni razlik
 $H_0 : P_1 - M_2 = 0$ ■
 - regresijski koeficient b se ne razlikuje od vpliva pasme P_1
 $H_0 : b - P_1 = 0$ (različne enote!)■
 - regresijskih koeficientov pri različnih stopnjah polinoma
 $H_0 : b_I - b_{II} = 0$ (različne enote!)

Kombinirane razlike

- Kombiniranih razlik se izogibamo:

npr: npr. vsota razlike med pasmama P_1 in P_2 in polovici razlike med mesecema M_1 in M_2

$$H_0 : P_1 - P_2 + 0.5 * (M_1 - M_2) = 0$$

$$H_1 : P_1 - P_2 + 0.5 * (M_1 - M_2) \neq 0$$

- zaradi interpretacije
- hipoteze naj imajo vsebinski pomen, smisel

Postavitev matrike **K**

- matrična oblika nazoren prikaz hipoteze in uporabljena v statističnih paketih
- vsaka vrstica predstavlja eno linearno kombinacijo
- sestavljene hipoteze pri zapletenih strukturah podatkov in kompleksnem modelu (manjkajoči podatki, interakcije...)
- možnosti:
 - napišemo linearno kombinacijo direktno
 - napišemo najprej kombinacijo za parametra, ki jih primerjamo potem pa sestavimo kombinacijo za preizkus

Preizkus razlik med pasmami - možnost I

Primer: mladice treh pasem (P_i) na treh farmah (F_j)

$$y_{ijk} = \mu + P_i + F_j + e_{ijk}$$

Vektor ocen za lokacijske parametre

$$\hat{\beta}' = [\hat{\mu} \quad \hat{P}_1 \quad \hat{P}_2 \quad \hat{P}_3 \quad \hat{F}_1 \quad \hat{F}_2 \quad \hat{F}_3]$$

Preizkus razlik med pasmami - možnost I

Možne razlike med pasmami:

$P_1 - P_2$ razlika med prvo in drugo pasmo ■

$P_1 - P_3$ razlika med prvo in tretjo pasmo ■

$P_2 - P_3$ je linearna kombinacija prvih dveh razlik ■

upoštevamo samo linearno neodvisne kombinacije

Matrični zapis prvih dveh linearnih kombinacij:

$$\mathbf{K} = \begin{bmatrix} \hat{\mu} & \hat{P}_1 & \hat{P}_2 & \hat{P}_3 & \hat{F}_1 & \hat{F}_2 & \hat{F}_3 \\ 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 & 0 & 0 \end{bmatrix}$$

Preizkus razlik med pasmami - možnost II

Možne razlike med pasmami:

$P_1 - P_2$ razlika med prvo in drugo pasmo

$P_1 - P_3$ razlika med prvo in tretjo pasmo

$P_2 - P_3$ je linearna kombinacija prvih dveh razlik

**upoštevamo samo linearno neodvisne kombinacije
izbor je lahko različen**

Matrični zapis prve in tretje linearne kombinacije:■

$$\mathbf{K} = \begin{bmatrix} \hat{\mu} & \hat{P}_1 & \hat{P}_2 & \hat{P}_3 & \hat{F}_1 & \hat{F}_2 & \hat{F}_3 \\ 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & -1 & 0 & 0 & 0 \end{bmatrix}$$

Preberimo naslednje linearne kombinacije

$$\mathbf{H} = \begin{bmatrix} \hat{\mu} & \hat{P}_1 & \hat{P}_2 & \hat{P}_3 & \hat{F}_1 & \hat{F}_2 & \hat{F}_3 \\ 0 & 0 & 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & 0 & 2 & 0 & -2 \\ 0 & 0 & 0 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}$$

Obrazložitev:

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 1 & -1 & 0 \end{bmatrix} \quad \blacksquare \quad \text{razlika med prvo in drugo farmo}$$

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 2 & 0 & -2 \end{bmatrix} \quad \blacksquare \quad \text{dvakratna razlika med 1. in 3. farmo}$$

$$\begin{bmatrix} 0 & 0 & 0 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix} \quad \blacksquare \quad \text{povprečje treh farm}$$

Odvisne linearne kombinacije

$$\mathbf{H} = \begin{bmatrix} \hat{\mu} & \hat{P}_1 & \hat{P}_2 & \hat{P}_3 & \hat{F}_1 & \hat{F}_2 & \hat{F}_3 \\ 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 & 0 & 0 \\ 0 & 0 & 2 & -2 & 0 & 0 & 0 \end{bmatrix}$$

Obrazložitev: ■

$$\begin{array}{r} -2 * \\ +2 * \end{array} \begin{bmatrix} 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 & 0 & 0 \end{bmatrix} \\ \hline \begin{bmatrix} 0 & 0 & 2 & -2 & 0 & 0 & 0 \end{bmatrix}$$

tretja vrstica je linearna kombinacija prve in druge;

neprimerna matrika za preizkus hipotez

Ocenljivost linearnih kombinacij

- **Sistemi enačb z nepolnim rangom**
 - nimajo rešitve (nezanimivi!) ali
 - imajo neskončno mnogo rešitev (izbiramo mi ali program sam)
- **Poročamo in preverjamo samo ocenljive funkcije**
 - rešitve ocenljivih funkcij so vedno enake!
- **Poročamo in preverjamo samo najnujnejše**
 - samo linearno neodvisne kombinacije
(matrika K ali H morata imeti polni rang v vrstici)
 - samo en set linearno neodvisnih kombinacij
 - brez pomena si ne izmišljujemo kompliciranih kombinacij

Sistem enačb

$$\begin{bmatrix}
 n & n_1 & n_2 & n_3 & \Sigma x_{ij} \\
 n_1 & n_1 & & & \Sigma x_{1j} \\
 n_2 & & n_2 & & \Sigma x_{2j} \\
 n_3 & & & n_3 & \Sigma x_{3j} \\
 \Sigma x_{ij} & \Sigma x_{1j} & \Sigma x_{2j} & \Sigma x_{3j} & \Sigma x_{ij}^2
 \end{bmatrix}
 \begin{bmatrix}
 \hat{\mu} \\
 \hat{A}_1 \\
 \hat{A}_2 \\
 \hat{A}_3 \\
 \hat{b}
 \end{bmatrix}
 =
 \begin{bmatrix}
 \Sigma y_{ij} \\
 \Sigma y_{1j} \\
 \Sigma y_{2j} \\
 \Sigma y_{3j} \\
 \Sigma x_{ij}y_{ij}
 \end{bmatrix}$$

$$C\hat{\beta} = \omega$$

Ocenljivost linearnih kombinacij (nadalj.)

- Linearna kombinacija je ocenljiva, če velja:

za vektor

$$\mathbf{k}'\mathbf{C}^{-1}\mathbf{C} = \mathbf{k}'$$

za matriko

$$\mathbf{K}\mathbf{C}^{-1}\mathbf{C} = \mathbf{K}$$

statistični paketi preverijo ocenljivost linearnih kombinacij

Ocenljivost linearnih kombinacij (nadalj.)

- Linearna kombinacija ni ocenljiva, če velja:

$$\mathbf{KC}^{-1}\mathbf{C} = \mathbf{H}$$

- toda \mathbf{H} iz zgornje enačbe je ocenljiva, ker velja

$$\mathbf{HC}^{-1}\mathbf{C} = \mathbf{H}$$

pred uporabo presodite, če so hipoteze v \mathbf{H} smiselne

Primer

$$\begin{array}{ccc}
 & \mathbf{C} & \mathbf{C}^{-} \\
 \left[\begin{array}{cccc}
 22 & 6 & 8 & 8 \\
 6 & 6 & & \\
 8 & & 8 & \\
 8 & & & 8
 \end{array} \right] & \cdot & \left[\begin{array}{cccc}
 0 & 0 & 0 & 0 \\
 0 & 1/6 & & \\
 0 & & 1/8 & \\
 0 & & & 1/8
 \end{array} \right]
 \end{array}$$

- Ali lahko napišete model za zgornji primer?
- Dobili smo eno od neskončno mnogo splošnih inverz:
... črtali prvo vrstico in prvi stolpec ...

Primer (nadalj.)

$$\mathbf{C}^{-1}\mathbf{C} = \mathbf{I} \begin{bmatrix} 22 & 6 & 8 & 8 \\ 6 & 6 & & \\ 8 & & 8 & \\ 8 & & & 8 \end{bmatrix}$$

$$\begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 1/6 & & \\ 0 & & 1/8 & \\ 0 & & & 1/8 \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix}$$

- Pazimo na vrstni red matrik!

- Matrika služi kot filter za preverjanje hipotez

Primer

$$\mathbf{KC}^{-}\mathbf{C} = \mathbf{I}$$

$$\begin{bmatrix} 0 & 1 & -1 & 0 \\ 0 & 0.5 & 0 & -0.5 \\ 0 & 0 & 2 & -2 \end{bmatrix} \cdot \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 1 & -1 & 0 \\ 0 & 0.5 & 0 & -0.5 \\ 0 & 0 & 2 & -2 \end{bmatrix}$$

- Pogoju ocenljivosti smo zadostili
- Lahko uporabili katerokoli drugo splošno inverzo

Utrdimo!

Preberimo in opišimo naslednji zapis!

$$\mathbf{K} = \begin{bmatrix} \hat{\mu} & \hat{P}_1 & \hat{P}_2 & \hat{P}_3 & \hat{F}_1 & \hat{F}_2 & \hat{F}_3 \\ 0 & 1 & 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 0 & -1 & 0 & 0 & 1 \end{bmatrix}$$

Obrazložitev:

$$\begin{bmatrix} 0 & 1 & 0 & 0 & -1 & 0 & 0 \end{bmatrix} \quad \blacksquare \text{ razlika med 1. pasmo in 1. farmo}$$

$$\begin{bmatrix} 0 & 0 & 0 & -1 & 0 & 0 & 1 \end{bmatrix} \quad \blacksquare \text{ razlika med 3. farmo in 3. pasmo}$$

kombinacije so nesmiselne

Sestavimo linearno kombinacijo!

Povprečni učinek pasme P_i :

- srednja vrednost
- vpliv izbrane pasme
- povprečni vpliv treh pasem, ker so pasme na vseh treh farmah ■

$$E(y_{i.}) = 1\mu + 1P_i + 1/3(F_1 + F_2 + F_3)$$

Sestavimo linearno kombinacijo (nadalj.)!

$$E(y_i) = 1\mu + 1P_i + 1/3(F_1 + F_2 + F_3)$$

Linearna kombinacija za povprečni učinek pasme P_1

$$\mathbf{k}'_1 = \begin{bmatrix} 1 & 1 & 0 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}$$

Linearna kombinacija za povprečni učinek pasme P_2

$$\mathbf{k}'_2 = \begin{bmatrix} 1 & 0 & 1 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix}$$

Linearna kombinacija za razliko med P_1 in P_2

$$\begin{array}{r} \mathbf{k}'_1 + 1 * \begin{bmatrix} 1 & 1 & 0 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix} \\ -\mathbf{k}'_2 - 1 * \begin{bmatrix} 1 & 0 & 1 & 0 & \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \end{bmatrix} \\ \hline \mathbf{k}'_1 - \mathbf{k}'_2 = \begin{bmatrix} 0 & 1 & -1 & 0 & 0 & 0 & 0 \end{bmatrix} \end{array}$$

Linearne kombinacije za testiranje hipotez

- biti morajo smiselne
- moramo jih znati razložiti
- biti morajo ocenljive
- ocenljivost je odvisna od statističnega modela in strukture podatkov (manjkajoči podatki!)
- po vsakem čiščenju ali preurejanju podatkov moramo preveriti ocenljivost
- istočasno preizkušamo samo hipoteze, ki so med seboj linearno neodvisne