

Regresszió a mintában: következtetés

Ferenci Tamás
tamas.ferenci@medstat.hu

2018. február 7.

Tartalom

- 1 Az OLS elv és használata a lineáris regresszió becslésére
 - Az OLS-elv
 - A lineáris regresszió becslése tisztán deskriptíve
 - Modellminősítés tisztán deskriptíve
- 2 Az OLS mintavételi tulajdonságai
 - Mintavételi helyzet
 - A mintavétel tulajdonságok szemléltetése szimulációval
 - A mintavétel tulajdonságok matematikai levezetése
- 3 Becslés és hipotézisvizsgálat a lineáris modellben
 - Alkalmazási feltételek
 - Egy paraméter
 - Modell egésze
 - Lineáris megkötés(ek)

Előkészületek az OLS-becsléshez

- Nem kell hozzá semmilyen regresszió, a legközönségesebb következtető statisztikai példán is elmondható
- Például: sokasági várható érték becslése normalitás esetén (legyen a szórás is ismert)
- Ami fontos: bár egy alap következtető statisztika kurzuson nem szokták mondani, de lényegében itt is az a helyzet, hogy egy *modellt* feltételezünk a sokaságra
- Jelesül $Y \sim \mathcal{N}(\mu, \sigma_0^2)$, amit nem melleleg úgy is írhatnánk, hogy $Y = \mu + \varepsilon$, ahol $\varepsilon \sim \mathcal{N}(0, \sigma_0^2)$
- A másik ami fontos: a modelltől következik egy *becsült érték* minden mintabeli elemhez
- Jelen esetben, ha m egy feltételezett érték az ismeretlen sokasági várható értékre:

$$\hat{y}_i = m$$

Az OLS-elv

- OLS-elvű becslés: az ismeretlen sokasági paraméterre az a becült érték, amely mellett a tényleges mintabeli értékek, és az adott paraméter melletti, modellből származó becült értékek közti eltérések négyzetének összege a legkisebb:

$$\hat{\mu} = \arg \min_m \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \arg \min_m \sum_{i=1}^n (y_i - m)^2$$

- (Aminek a megoldása természetesen $\hat{\mu} = \bar{y}$)

A mintavétel a lineáris regressziós feladatban

- Tételezzük fel, hogy az $(Y, X_1, X_2, \dots, X_k)$ változóinkra veszünk egy n elemű mintát
- Az i -edik mintaelem: $(y_i, x_{i1}, x_{i2}, \dots, x_{ik})$
- Feltételezzük azt is, hogy a mintavétel fae (független, azonos eloszlású)

Lineáris regresszió becslése OLS-elven

- *Hajszálpontosan ugyanaz* történik, mint az előbb, csak a sokaságra feltételezett modellünk kicsit bonyolultabb, jelesül:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon$$

- A becsült értékek adott b_0, b_1, \dots, b_k sokasági paraméterek mellett:

$$\hat{y}_i = b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_k x_{ik}$$

- A feladat tehát ugyanaz:

$$\begin{aligned} (\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k) &= \arg \min_{b_0, b_1, b_2, \dots, b_k} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \\ &= \arg \min_{b_0, b_1, b_2, \dots, b_k} \sum_{i=1}^n [y_i - (b_0 + b_1 x_{i1} + b_2 x_{i2} + \dots + b_k x_{ik})]^2 \end{aligned}$$

- Annyi bonyolódottság van, hogy itt most *több* paramétert kell becsülni, de ez csak a kivitelezést nehezíti, elvileg teljesen ugyanaz a feladat

Az OLS-becslési feladat vektoros-mátrixos jelölésekkel

- A jelölések egyszerűsítése érdekében fogjuk össze mindent vektorokba és mátrixokba; egyedül a magyarázó változók nem triviálisak, mert kiegészítjük őket egy csupa 1 oszloppal (ún. design mátrix):

$$\mathbf{X}_{n \times (k+1)} = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{pmatrix}$$

- Így ugyanis a feladat:

$$\arg \min_{\mathbf{b}} (\mathbf{y} - \mathbf{Xb})^T (\mathbf{y} - \mathbf{Xb})$$

- Az $(\mathbf{y} - \mathbf{Xb})^T (\mathbf{y} - \mathbf{Xb})$ hibanégyzetösszeget *ESS*-sel (error sum of squares) is fogjuk jelölni

Az OLS-becslési feladat megoldása

A megoldás:

$$\arg \min_{\mathbf{b}} (\mathbf{y} - \mathbf{X}\mathbf{b})^T (\mathbf{y} - \mathbf{X}\mathbf{b}) = \arg \min_{\mathbf{b}} \left[\mathbf{y}^T \mathbf{y} - 2\mathbf{b}^T \mathbf{X}^T \mathbf{y} + \mathbf{b}^T \mathbf{X}^T \mathbf{X} \mathbf{b} \right]$$

A szélsőérték-keresést oldjuk meg többváltozós deriválással (kvadratikus felület konvex, a stacionárius pont egyértelmű globális szélsőértékhely):

$$\begin{aligned} \frac{\partial}{\partial \mathbf{b}} \left[\mathbf{y}^T \mathbf{y} - 2\mathbf{b}^T \mathbf{X}^T \mathbf{y} + \mathbf{b}^T \mathbf{X}^T \mathbf{X} \mathbf{b} \right] &= \\ = -2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X} \mathbf{b} = 0 &\Rightarrow \widehat{\beta}_{\text{OLS}} = \left(\mathbf{X}^T \mathbf{X} \right)^{-1} \mathbf{X}^T \mathbf{y}, \end{aligned}$$

ha $\mathbf{X}^T \mathbf{X}$ nem szinguláris

Pár további gondolat

- Az ún. reziduumok:

$$\hat{\mathbf{e}} = \mathbf{y} - \hat{\mathbf{y}}$$

- Az előrejelzések a mintánkra:

$$\hat{\mathbf{y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X} \left(\mathbf{X}^T \mathbf{X} \right)^{-1} \mathbf{X}^T \mathbf{y}$$

- Ez alapján vezessük be a

$$\mathbf{P} = \mathbf{X} \left(\mathbf{X}^T \mathbf{X} \right)^{-1} \mathbf{X}^T$$

mátrixot, ezzel $\hat{\mathbf{y}} = \mathbf{P}\mathbf{y}$

- Emiatt szokták „hat” mátrixnak is nevezni

Az OLS geometriai interpretációja

P projektormátrix lesz ($\mathbf{P}^2 = \mathbf{P}$, azaz idempotens) \rightarrow út az OLS geometriai interpretációjához

Modell jóságának viszonyítási pontjai

- A modell minősítése az ESS alapján? → kézenfekvő, de nem önmagában: viszonyítani kell! Két kézenfekvő alap:
 - Tökéletes (v. szaturált, perfekt modell): minden mintaelemre a pontos értéket becsüli → $\hat{e}_i = 0 \Rightarrow ESS = 0$
 - Nullmodell: semmilyen külső (magyarázó)információt nem használ fel → minden mintaelemet az átlaggal becsül
- Egy adott regressziós modell teljes négyzetösszegének nevezzük, és TSS -sel jelöljük a hozzá tartozó (tehát ugyanazon eredményváltozóra vonatkozó) nullmodell hibanégyzetösszegét:

$$TSS = ESS_{\text{null}} = \sum_{i=1}^n (y_i - \bar{y})^2.$$

Hogyan jellemezzük modellünk jóságát?

- A minősítést képezzük a „hol járunk az úton?” elven: a tökéletesen rossz modelltől a tökéletesen jó modellig vezető út mekkora részét tettük meg
- Az út „hossza” TSS ($= TSS - 0$), amennyit „megtettünk”:
 $TSS - ESS$
- Egy adott regressziós modell regressziós négyzetösszegének nevezzük, és RSS -sel jelöljük a teljes négyzetösszegének és a hibanégyzetösszegének különbségét:

$$RSS = TSS - ESS.$$

Az új mutató bevezetése

Ezzel az alkalmas modelljellemező mutató: a többszörös determinációs együttható (jele R^2):

$$R^2 = \frac{TSS - ESS}{TSS} = \frac{RSS}{TSS}.$$

Az R^2 -ről bővebben

- Ha van konstans a modellben, akkor nyilván $ESS < TSS$, így minden regressziós modellre, amiben van konstans: $0 \leq R^2 \leq 1$.
- Az R^2 egy modell jóságának legszéleskörűbben használt mutatója
- Értelmezhető %-ként: a magyarázó változók ismerete mennyiben csökkentette az eredményváltozó tippelésekor a bizonytalanságunkat (ahhoz képest, mintha nem ismertünk volna egyetlen magyarázó változót sem)
- De vigyázat: nagyságának megítélése, változók száma stb.
- A belőle vont négyzetgyököt többszörös korrelációs együtthatónak szokás nevezni
- Mondani sem kell, ez az R^2 a korábban bevezetett (sokasági) R^2 mintabeli analógja

Az R^2 -ről bővebben

- Ha van konstans a modellben, akkor érvényes a következő felbontás:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

- (Négyzetek nélkül nyilvánvaló, de négyzetekkel is!)
- Röviden tehát:

$$TSS = ESS + RSS$$

- Összevetve az előző definícióval, kapjuk, hogy

$$RSS = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

Egy megjegyzés a konstans szerepéről

- Az előzőek is motiválják, hogy megállapítsuk: konstans *mindenképp* szerepeltetünk a regresszióban, ha inszignifikáns, ha nem látszik különösebb értelme stb. *akkor is!* – csak és kizárólag akkor hagyhatjuk el, ha az a modell tartalmából adódóan elméleti követelmény (erre látni fogunk nemsokára egy példát is, a standardizált regressziót)
- Ellenkező esetben (ún. konstans nélküli regresszió), a fenti felbontás nem teljesül, így a „hol járunk az úton” elven konstruált R^2 akár negatív is lehet!

Deskriptív és következtető statisztika

- Az előbbi tárgyalás pusztán deskriptív volt: egy darab mintát tekintett, amire meghatározott egy darab regressziós függvényt és kész
- Mintha a feladat csak annyi lenne, hogy pontokra húzzunk egy rájuk jól illeszkedő görbét
- Ez a „görbeillesztési” szemlélet első ránézésre könnyen megérthető, és látszólag egyszerűsíti a helyzetet, valójában azonban rendkívül mérgező a valódi megértésre nézve
- Nem teszi lehetővé ugyanis annak megértését, hogy a háttérben van egy sokaság, és a görbe nem univerzálisan jellemzi azt, hanem csak az adott, konkrét mintára illeszkedik legjobban, és *másik mintából másik görbét kaptunk volna*
- Azaz: figyelmen kívül hagyja a mintavételi helyzetet

A mintavételi helyzet hatásai

- Van egy elméleti regresszió a **sokaságban** (β)
- Az adatbázisunk alapján megkaptuk a regressziós egyenest ($\hat{\beta}$)
- Az adatbázis azonban csak egy **minta** a sokaságából, így a $\hat{\beta}_i$ paraméterek annak hatását *is* tükrözik, hogy konkrétan milyen mintát választottunk
- *Mintavételi ingadozás* lép fel (még akkor is, ha tökéletesen véletlen a mintavétel, ennek tehát semmi köze pl. a reprezentativitáshoz)
- Tehát: az egyes $\hat{\beta}_i$ paraméterek „mintáról-mintára ingadoznak”: minden mintából más paramétereket kapnánk
- (Természetesen reméljük, hogy az ingadozás „kellemes” tulajdonságokkal bír, például a valós érték körül történik, szorosan körülötte stb., erről később)
- Ez tehát egy becslési feladat; az OLS-nek, mint becslőfüggvénynek vizsgálhatóak a tulajdonságai

Még egy fontos megjegyzés

- Nem elég annyit mondani, hogy „jó, hát akkor a háttérben van egy sokaság is”, mintha ezzel el lenne intézve ez a kérdés
- Azt is világosan látni kell, hogy az egész tárgyalás *kiindulópontja*, hogy erre *feltételezünk* egy modellt (pl. azt, hogy
$$Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \varepsilon$$
)
- Ez egy feltételezés, mivel a sokaságot nem ismerjük, így biztosan nem tudhatjuk, hogy igaz-e (csak következtethetünk rá)
- De minden további levezetés mögött ott lesz, hogy mi mit gondoltunk, hogyan viselkedik a sokaság, mi a *sokasági modell*

Előkészület a mintavétel vizsgálatához

- Ahhoz, hogy a mintavétel hatását matematikailag tudjuk vizsgálni, az OLS-becslőt val. változókra kell ráereszteni (szemben az eddigi képlettel – $\widehat{\beta}_{OLS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ – ahol konkrét számokra futtattuk)
- Pontosan ugyanúgy, ahogy az $\frac{1}{n} \sum_{i=1}^n x_i$ -t sem tudjuk következtető statisztikailag vizsgálni (az egy szám), hanem az $\frac{1}{n} \sum_{i=1}^n X_i$ -t nézzük
- Minket tehát $\widehat{\beta}_{OLS} = \left(\underline{\underline{\mathbf{X}^T \mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}^T \mathbf{Y}}}$ fog érdekelni!
- Ahogy az előbbi átlagos példában, így itt is igaz lesz, hogy ekkor a $\widehat{\beta}_{OLS}$ már nem egy konkrét érték (vektor), hanem egy – vektor értékű – val. változó, tehát eloszlása van!
- Ez a mintavételi eloszlás, mi erre, ennek tulajdonságaira, a jó tulajdonságok feltételeire stb. leszünk kíváncsiak
- Előbb szimulációval nyerünk képet, aztán matematikailag is levezetjük

Monte Carlo szimuláció használata

- Számos konkrét véletlen mintát veszünk egy előre specifikált populációból (véletlenszám-generátort használunk)
- Lényegében: empirikusan vizsgálunk egy elméleti kérdést
- Valszámos embert játszunk: ugye azt mondtuk, hogy a valszámosok úgy dolgoznak mintha valahonnan ismernék a sokasági eloszlást – hát most tényleg ismerjük!
- Példának okáért, legyen a valódi sokasági eloszlás


$$(X, Y) \sim \mathcal{N} \left(\begin{pmatrix} 77 \\ 26 \end{pmatrix}, \begin{pmatrix} 42^2 & 0,6 \cdot 20 \cdot 42 \\ 0,6 \cdot 20 \cdot 42 & 20^2 \end{pmatrix} \right)$$

- Ezért a *valódi* regressziós egyenes, a már látottak szerint:


$$\mathbb{E}(Y | X) = 4 + \frac{12}{42}X \approx 4 + 0,2857X$$

- Szimulációs paraméterek: $n = 100$ elemű minta a fenti sokaságból, 1000 ismétlés


A szimuláció eredményei: 1. futtatás




A szimuláció eredményei: 2. futtatás




A szimuláció eredményei: 3. futtatás




A szimuláció eredményei: 4. futtatás




A szimuláció eredményei: 5. futtatás




A szimuláció eredményei: konstans



A szimuláció eredményei: meredekség



A szimuláció eredményei: mindkét paraméter együtt



Az OLS-becslő mintavételi eloszlása

- Tudjuk, hogy $\widehat{\underline{\beta}}_{\text{OLS}} = \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\underline{Y}}$
- Valamint elfogadtuk feltételezésként, hogy a sokasági modell $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \varepsilon = \underline{\underline{X}}^T \underline{\beta} + \varepsilon$
 - És ez van mindegyik megfigyelési egység mögött is, tehát a mintavétel elemzéséhez ezt is írhatjuk:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i$$

- Röviden, értelemszerű vektorokba/mátrixokba fogással:
 $Y_i = \underline{X}_i^T \underline{\beta} + \varepsilon$ avagy az egész adatbázisra: $\underline{\underline{Y}} = \underline{\underline{X}} \underline{\beta} + \underline{\varepsilon}$
- Na de rakjuk csak össze a kettőt:

$$\begin{aligned}\widehat{\underline{\beta}}_{\text{OLS}} &= \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\underline{Y}} = \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \left(\underline{\underline{X}} \underline{\beta} + \underline{\varepsilon}\right) = \\ &= \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\underline{X}} \underline{\beta} + \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\varepsilon} = \underline{\beta} + \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\varepsilon}\end{aligned}$$

Az OLS standard modellfeltevései

Ahhoz, hogy az OLS-nek fennálljanak bizonyos előnyös tulajdonságai, meghatározott feltevéseknek teljesülniük kell. Az ún. standard lineáris modell feltevései:

- 1 Linearitás
- 2 Nincs egzakt multikollinearitás
- 3 Erős (vagy szigorú) exogenitás
- 4 Homoszkedaszticitás
- 5 Autokorrelálatlanság

Linearitás

A sokaságot *valójában* leíró modell tényleg a feltételezett, azaz fennáll, hogy

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon$$

és ez igaz mindegyik megfigyelési egységre, és így az egész mintára is:

$$\underline{Y} = \underline{X}\beta + \underline{\varepsilon}$$

Nincs egzakt multikollinearitás

- Egzakt multikollinearitásnak nevezzük, ha az adatmátrix nem teljes oszloprangú
- Tehát: az oszlopok között lineáris kapcsolat van
- Azaz valamelyik változó előállítható a többi lineáris kombinációjaként
- Érezhető, hogy nem túl szerencsés: minek használjuk egyáltalán azt a változót...? (Úgyis lineáris kombinációt képezünk a többiből is!)
→ a hatások nem lesznek szétválaszthatóak
- Sőt: az OLS becslőfüggvényéből az is látszik, hogy ilyenkor teljesen elakadunk: $\mathbf{X}^T \mathbf{X}$ szinguláris ($\underline{\underline{\mathbf{X}^T \mathbf{X}}}$ 1 valószínűséggel szinguláris)
- Ennek feltétele: \mathbf{X} ($\underline{\underline{\mathbf{X}}}$) nem teljes oszloprangú

Nincs egzakt multikollinearitás

- A feltétel tehát: az adatmátrix 1 valószínűséggel legyen teljes oszloprangú:

$$\mathbb{P}(\text{rank } \underline{\underline{X}} = k) = 1$$

- Ez implikálja, hogy $n \geq k$ (kevesebb mint k -dimenziós vektorból nincs k független)

Erős exogenitás

- Minden $i = 1, 2, \dots, n$ -re

$$\mathbb{E}(\varepsilon_i | \underline{X}_i) = 0$$

- Tartalma: a hibák – az ún. várható érték függetlenség értelemben – függetlenek a magyarázó változóktól

Az erős exogenitás következményei

- Toronyszabály miatt a feltétel *nélküli* várható érték is nulla:

$$\mathbb{E} \left[\mathbb{E} (\varepsilon_i \mid \underline{X}_i) \right] = \mathbb{E} \varepsilon_i = \mathbb{E} (0) = 0$$

- A várható érték függetlenség implikálja a korrelálatlanságot:
 $\text{cov} (X_{ik}, \varepsilon_j) = 0$ avagy – ezzel egyenértékűen, hiszen $\mathbb{E} \varepsilon_i = 0$ –
 $\mathbb{E} (X_{ik} \varepsilon_j) = 0$
- Szokás a korrelálatlanság helyett azt is mondani, hogy a hibák ortogonálisak a magyarázóváltozókra

Az erős exogenitás sérülésének tipikus esetei

- Van olyan változó, ami lényeges magyarázó változó lenne (tehát valódi – sokasági – β -ja nem nulla), de mégsem szerepel a modellben, miközben legalább egy magyarázó változóval korrelál (kihagyott változó esete, „omitted variable bias”) – ez épp a confounding!
- Mérési hiba magyarázó változónál (tehát a mérési változók valódi értékét nem, csak valamilyen zajjal terhelve tudjuk mérni)
- Szimultaneitás (többegyenletes modelleknél)

Az erős exogenitás sérülésének kezelése

- A problémát orvosolhatjuk a megfelelő(bb) modellspecifikációval, függően attól, hogy pontosan mi a baj oka...
- ... illetve bizonyos statisztikai eszközök is a rendelkezésünkre állnak, ilyen az instrumentális változós (IV) becslés, a kétfázisú legkisebb négyzetek módszere (TSLS) stb.

Homoszkedaszticitás

- A feltétel azt köti ki, hogy $\sigma_i^2 := \mathbb{D}^2 \left(\varepsilon_i \mid \underline{X} \right) = \sigma^2$ i -től függetlenül minden $i = 1, 2, \dots, n$ -re
- Tartalma: a hibák különböző megfigyelésekhez tartozó szórása állandó (nem függ attól, hogy melyik megfigyelésről van szó) avagy – másként megfogalmazva ugyanez – a becsült értékek szóródása a tényleges körül állandó
- Jellemzően keresztmetszeti adatoknál felmerülő kérdés (hamarosan foglalkozunk is vele bővebben)

Autokorrelálatlanság

- Tartalma: a különböző megfigyelésekhez tartozó hibák korrelálatlanok egymással
- Fae mintavételezésnél ez tehát *automatikusan* teljesül!
- Nem fae esetben a feltétel azt köti ki, hogy $\text{cov}(\varepsilon_i, \varepsilon_j \mid \underline{X}) = 0$ minden $i, j = 1, 2, \dots, n, i \neq j$ -re
- Ezzel egyenértékű $\mathbb{E}(\varepsilon_i \varepsilon_j \mid \underline{X}) = 0$ (hiszen $\mathbb{E}\varepsilon_i = 0$, így a kovariancia a két változó szorzatának várható értéke)
- Elsősorban idősoros adatok kérdésköre, most nem is foglalkozunk vele bővebben

A homoszkedaszticitás és az autokorrelálatlanság együtt

- Mindkettő felfogható úgy, mint az ε_i hibák (feltételes) kovarianciamátrixára vonatkozó megkötés
 - Homoszkedaszticitás: a kovarianciamátrix főátlójában ugyanazok az elemek (σ^2) vannak (ugye itt vannak a szórásnégyzetek)
 - Autokorrelálatlanság: a kovarianciamátrix főátlóján kívüli elemek nullák (a mátrix diagonális)
- A kettő *együtt*: a kovarianciamátrix $\sigma^2 \mathbf{I}$ alakú (szokás az illet skalármátrixnak is nevezni)

σ^2 becslése

Nem részletezzük, de belátható, hogy ez esetben a σ^2 -re adható OLS-becslés:

$$\widehat{\sigma^2} = \frac{ESS}{n - (k + 1)} = \frac{\widehat{\mathbf{e}}^T \widehat{\mathbf{e}}}{n - (k + 1)}$$

Mintavételileg rögzített magyarázó változók

- Egyszerűbb tárgyalások azt feltételezik, hogy a magyarázó változók mintavételileg rögzítettek (mintha determinisztikusan megszabhatnánk az értéküket: \underline{X}_i igazából \mathbf{x}_i)
- Ennek sok baja van:
 - 1 Nem annyira szép és elegáns (nyilván ez speciális esete a mi tárgyalásunknak!)
 - 2 Nem teszi lehetővé egy sor kérdés mélyebb tárgyalását
 - 3 Alapjában megkérdőjelezhető az alkalmazása nem-experimentális tudományokban (mint a közgazdaságtan...)
- Az előnye, hogy egyszerűsít: ekkor a hiba feltételes és feltétel nélküli eloszlása ugyanaz lesz, a ' \underline{X}_i ' jellegű feltételek elhagyhatóak...
- ...emiatt a modellfeltevések a következőkre egyszerűsödnek:
 - Erős exogenitás: $\mathbb{E}\varepsilon_i = 0$ minden $i = 1, 2, \dots, n$ -re
 - Homoszkedaszticitás: $\mathbb{D}^2\varepsilon_i = \sigma^2$ minden $i = 1, 2, \dots, n$ -re
 - Autokorrelálatlanság: $\mathbb{E}(\varepsilon_i\varepsilon_j) = 0$ minden $i \neq j = 1, 2, \dots, n$

A mintavételi tulajdonságok

- Ezek lesznek a standard modellfeltevések. . .
- . . . most nekiállunk megvizsgálni, hogy a teljesülésük esetén milyen tulajdonságokkal bír az OLS-becslő

Várható érték

- Tudjuk, hogy

$$\widehat{\beta}_{\text{OLS}} = \beta + \left(\underline{\underline{X}}^T \underline{\underline{X}} \right)^{-1} \underline{\underline{X}}^T \underline{\underline{\varepsilon}}$$

- Ez alapján mi $\widehat{\beta}_{\text{OLS}}$ várható értéke (várható érték-vektora)?

$$\begin{aligned} \mathbb{E} \widehat{\beta}_{\text{OLS}} &= \beta + \mathbb{E} \left[\left(\underline{\underline{X}}^T \underline{\underline{X}} \right)^{-1} \underline{\underline{X}}^T \underline{\underline{\varepsilon}} \right] = \\ &= \beta + \mathbb{E} \left\{ \mathbb{E} \left[\left(\underline{\underline{X}}^T \underline{\underline{X}} \right)^{-1} \underline{\underline{X}}^T \underline{\underline{\varepsilon}} \mid \underline{\underline{X}} \right] \right\} = \\ &= \beta + \mathbb{E} \left\{ \left(\underline{\underline{X}}^T \underline{\underline{X}} \right)^{-1} \underline{\underline{X}}^T \mathbb{E} \left[\underline{\underline{\varepsilon}} \mid \underline{\underline{X}} \right] \right\} = \beta \end{aligned}$$

- Az erős exogenitás fennállása esetén tehát az OLS szolgáltatotta becslések *torzítatlanok*
- Nem bizonyítjuk, de az is igaz, hogy *konzisztensek*

Kovarianciamátrix

Az előbbi ismeretében:

$$\begin{aligned}\mathbb{D}^2 \widehat{\boldsymbol{\beta}}_{\text{OLS}} &= \mathbb{E} \left[\left(\widehat{\boldsymbol{\beta}}_{\text{OLS}} - \mathbb{E} \widehat{\boldsymbol{\beta}}_{\text{OLS}} \right) \cdot \left(\widehat{\boldsymbol{\beta}}_{\text{OLS}} - \mathbb{E} \widehat{\boldsymbol{\beta}}_{\text{OLS}} \right)^T \right] = \\ &= \mathbb{E} \left[\left(\widehat{\boldsymbol{\beta}}_{\text{OLS}} - \boldsymbol{\beta} \right) \cdot \left(\widehat{\boldsymbol{\beta}}_{\text{OLS}} - \boldsymbol{\beta} \right)^T \right] = \\ &= \mathbb{E} \left\{ \left[\left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}}}^T \underline{\underline{\boldsymbol{\varepsilon}}} \right] \cdot \left[\left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}}}^T \underline{\underline{\boldsymbol{\varepsilon}}} \right]^T \right\} = \\ &= \mathbb{E} \left[\left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}}}^T \underline{\underline{\boldsymbol{\varepsilon}}} \underline{\underline{\boldsymbol{\varepsilon}}}^T \underline{\underline{\mathbf{X}}} \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \right] = \\ &= \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}}}^T \mathbb{E} \left(\underline{\underline{\boldsymbol{\varepsilon}}} \underline{\underline{\boldsymbol{\varepsilon}}}^T \right) \underline{\underline{\mathbf{X}}} \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} = \\ &= \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} \underline{\underline{\mathbf{X}}}^T \cdot \sigma^2 \mathbf{I} \cdot \underline{\underline{\mathbf{X}}} \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1} = \sigma^2 \left(\underline{\underline{\mathbf{X}}}^T \underline{\underline{\mathbf{X}}} \right)^{-1}\end{aligned}$$

A Gauss–Markov tétel

- Ha mindegyik feltevés teljesül, akkor lineár torzítatlan becslők körében az OLS-becslő minimális varianciájú (azaz hatásos)
- Tehát: $\mathbb{D}^2 \left(\widehat{\beta}_{\text{OLS}} \right) \leq \mathbb{D}^2 \left(\widehat{\beta}' \right)$ bármely más $\widehat{\beta}'$ lineáris becslőre, amire $\mathbb{E} \left(\widehat{\beta}' \right) = \beta$ (azaz torzítatlan)

Összefoglalva

- Amennyiben a standard modellfeltevések közül teljesül a:
 - Linearitás
 - Nincs egzakt multikollinearitás
 - Erős exogenitás

akkor az OLS szolgáltatatta becslések *torzítatlanok és konzisztensek*

- Ha ezen felül teljesül a:
 - Homoszkedaszticitás
 - Autokorrelálatlanság

akkor az OLS szolgáltatatta becslések *hatásosak* (minimális varianciájuk) is

BLUE-tulajdonság

Ezt röviden úgy szokták megfogalmazni, hogy ha valamennyi standard modellfeltétel teljesül, akkor az OLS szolgáltatja a becslések BLUE-k:

- Best (minimális varianciájú)
- Linear (lineáris a mintaelemekben)
- Unbiased (torzítatlan)

A σ^2 és a koefficiensek kovarianciamátrixának becslői

- A σ^2 -nek a $\widehat{\sigma^2} = \frac{ESS}{n-(k+1)}$ becslője torzítatlan, ha mindegyik feltétel fennáll
- A β_i koefficiensek kovarianciamátrixának $\widehat{\sigma^2} \left(\underline{\underline{X^T X}} \right)^{-1}$ becslője szintén
- Tehát vigyázat: itt *már* a torzítatlansághoz *is* kell mindegyik feltétel (a homoszkedaszticitás és az autokorrelálatlanság is)!

A $\widehat{\beta}_i$ koefficiensek eloszlása

- Az eddigi eredmények ugyan nagyon biztatóak, de még mindig nem mondanak semmit arról, hogy konkrétan mi a becsült koefficiensek (mintavételi) eloszlása
- A $\widehat{\beta}_{OLS} = \beta + (\underline{X}^T \underline{X})^{-1} \underline{X}^T \varepsilon$ nem sok jót sejtet: ebből úgy tűnik, hogy ez \underline{X} -től és ε -től is függ, ráadásul egy elég komplexnek kinéző módon...
- Szerencsére nem ennyire rossz a helyzet!
- Van egy nevezetes speciális eset, amikor a becsült koefficiensek eloszlása egyszerű alakú, és *nem is függ* \underline{X} eloszlásától, ez pedig az, ha a hibák feltételes eloszlása normális
- Vigyázat: a hibák normalitása *nem* része a standard modellfeltevéseknek, azaz a BLUE-ság akkor is megvalósul, ha a hibák eloszlása nem normális!
- Ráadásul, még ha nem is tudjuk, hogy a normalitás teljesül, de nagy a mintánk, akkor a centrális határeloszlás-tétel miatt aszimptotikus közelítésként akkor is használhatjuk az így nyert eredményeket

Hibák normalitása

- $\underline{\varepsilon}$ feltételes eloszlása feltéve \underline{X} -et többváltozós normális
- A standard modellfeltevéseket is felhasználva ez azt jelenti, hogy

$$\underline{\varepsilon} \mid \underline{X} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$$

- Ez láthatóan nem függ \underline{X} -től, így persze a hibák feltétel nélküli eloszlása is $\mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

Hibanormalitás és a becsült koefficiensek eloszlása

- Ha $\underline{\varepsilon}$ eloszlása normális, akkor $\left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\varepsilon}$ -é is az
- Ez azért nagyon jó hír, mert a normális eloszláshoz csak két dologra kell tudnunk: várható érték-vektort és kovarianciamátrixot!
- Az viszont könnyen meghatározható (az egyszerűség kedvéért a $|\underline{\underline{X}}|$ feltételt nem írjuk ki a következőkben)

- Várható érték:

$$\mathbb{E} \left[\left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\varepsilon} \right] = \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \mathbb{E} \underline{\varepsilon} = \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \mathbf{0} = \mathbf{0}$$

- Kovarianciamátrix:

$$\begin{aligned} \mathbb{D}^2 \left[\left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \underline{\varepsilon} \right] &= \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \cdot \mathbb{D}^2 \underline{\varepsilon} \cdot \underline{\underline{X}} \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} = \\ &\left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \underline{\underline{X}}^T \cdot \sigma^2 \mathbf{I} \cdot \underline{\underline{X}} \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} = \sigma^2 \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \end{aligned}$$

- Összefoglalva: $\widehat{\underline{\beta}}_{\text{OLS}} \sim \mathcal{N} \left(\underline{\beta}, \sigma^2 \left(\underline{\underline{X}}^T \underline{\underline{X}}\right)^{-1} \right)$

Emlékeztetőül

- A most következő eredmények csak akkor egzaktak, ha a hibanormalitás is fennáll
- Ám aszimptotikusak, így közelítőleg akkor is fennállnak, ha elég nagy a mintanagyság (minél nagyobb, annál inkább)

Becsült regressziós koefficiensek mintavételi eloszlása

- A $\hat{\beta}_i$ becslt regressziós koefficiens mintavételi ingadozását tehát a következő összefüggés írja le:

$$\frac{\hat{\beta}_i - \beta_i}{\text{se}(\hat{\beta}_i)} \sim \mathcal{N}(0, 1),$$

ahol $\text{se}(\hat{\beta}_i) = \sqrt{\sigma^2 \left[(\underline{\underline{X}}^T \underline{\underline{X}})^{-1} \right]_{kk}}$

- Sajnos ezzel a gyakorlatban nem sokra megyünk, mert σ^2 -et általában nem ismerjük
- Helyettesítsük a jó tulajdonságú becslőjével, $\hat{\sigma}^2$ -tel!
- Így persze már más lesz az eloszlás, de szerencsére meghatározható, hogy mi, és nem bonyolult: $n - (k + 1)$ szabadságfokú t -eloszlás

Változó relevanciája

Egy változót relevánsnak nevezünk, ha a sokasági paramétere nem nulla:
 $\beta_i \neq 0$.

Hipotézisvizsgálat változó relevanciájára

Ez alapján már konstruálhatunk próbát változó relevanciájának vizsgálatára:

- 1 $H_0 : \beta_i = 0$
- 2 Ekkor (azaz ha ez fennáll!) a $t_{\text{emp},i} = \frac{\widehat{\beta}_i}{\text{se}(\widehat{\beta}_i)}$ kifejezés $n - (k + 1)$ szabadságfokú t -eloszlást követ (nulleloszlás)
- 3 Számítsuk ki a konkrét $t_{\text{emp},i}$ -t a mintánkból és döntsük el, hogy hihető-e, hogy $t_{n-(k+1)}$ -ből származik

Hipotézisvizsgálat változó relevanciájára

A hipotézisvizsgálat elvégzéséhez szükséges minden tudnivalót – a nullhipotézisen kívül – összefoglal tehát a következő kifejezés (a későbbiekben is ezt a sémát fogjuk használni hipotézisvizsgálatok megadására):

$$t_{\text{emp},i} = \frac{\hat{\beta}_i}{\text{se}(\hat{\beta}_i)} \stackrel{H_0}{\sim} t_{n-(k+1)}.$$

E próba precíz neve: változó relevanciájára irányuló (parciális) t -próba

Konfidenciaintervallum a paraméterekre

Ez alapján könnyen szerkeszthető CI is, $1 - \alpha$ megbízhatósági szinten:

$$\hat{\beta}_i \pm t_{n-(k+1)}^{(1-\alpha/2)} \cdot \text{se}(\hat{\beta}_i)$$

Modell egészének relevanciája

- A korábban látott t -próba azért volt „parciális”, mert egy változó irrelevanciáját vizsgálta
- Felmerül a kérdés, hogy definiálható-e a modell *egészének* irrelevanciája
- Igen, mégpedig úgy, hogy *valamennyi* magyarázó változó *együttesen is* irreleváns:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$$

- Rövid jelölés arra, hogy $\beta_1 = 0$ és $\beta_2 = 0$ stb. és $\beta_k = 0$ (*semmilyen más* eset jelölésére *ne* használjuk az egyenlőségláncot!)
- Figyelem: az „egyszerre nulla mindegyik” *több* mint, hogy „külön-külön nulla mindegyik”!

Modell egészének relevanciája

- A modell egészének irrelevanciájára magyarul azt jelenti, hogy a modell nem tér el lényegesen a nullmodelltől
- Implikálja, hogy minden magyarázó változó külön-külön is irreleváns (tartalmazza ezeket a hipotéziseket) → előbb teszteljük a modell egészének irrelevanciáját, és csak ennek elvetése utána teszteljük a változókat parciálisan
- A próba konkrét alakja:

$$F_{\text{emp}} = \frac{RSS/k}{ESS/(n-k-1)} \stackrel{H_0}{\sim} F_{k,n-k-1}$$

Modell egészének relevanciája

- A tesztstatisztika átírható mint

$$\frac{RSS/k}{ESS/(n-k-1)} = \frac{R^2/k}{(1-R^2)/(n-k-1)}$$

- Persze: a „nem tér el lényegesen a nullmodelltől” úgy is megfogalmazható, hogy az „ R^2 nem tér el lényegesen a nullától” ($H_0 : R^2 = 0$ is mondható lett volna)

Modell egészének relevanciája

- A próba neve: a modell egészének relevanciájára irányuló (globális) F -próba
- Szokás ANOVA-próbának is nevezni (a $TSS = ESS + RSS$ variancia-felbontáson alapszik; számlálóban és nevezőben a fokkal normált szórásnégyzetek vannak)
- Tipikus eredményközlés az ún. ANOVA-táblában

Lineáris kombináció tesztelése

- A séma:

$$\lambda_{\beta_1}\beta_1 + \lambda_{\beta_2}\beta_2 + \dots + \lambda_{\beta_k}\beta_k = \Lambda$$

- Több koefficiens is érinthet, de csak egy egyenletet tartalmazhat
- Például:
 - Két koefficiens egyezik, $\beta_l = \beta_m$ (ekkor $\lambda_{\beta_l} = +1$, $\lambda_{\beta_m} = -1$, a többi λ nulla és $\Lambda = 0$)
 - Egyik koefficiens c -szerese a másiknak, $\beta_l = c\beta_m$ (ekkor $\lambda_{\beta_l} = +1$, $\lambda_{\beta_m} = -c$, a többi λ nulla és $\Lambda = 0$)
 - Az összes koefficiens összege épp nulla (ekkor mindegyik λ 1 és $\Lambda = 0$)

Lineáris kombináció tesztelése

- A normális lineáris modellben erre teszt szerkeszthető
- Megvalósítás: egyik lehetőség, hogy a t -próbaéhoz hasonló alakra vezetjük vissza
- Legyen $\lambda_{\beta_1}\hat{\beta}_1 + \lambda_{\beta_2}\hat{\beta}_2 + \dots + \lambda_{\beta_k}\hat{\beta}_k = \hat{\Lambda}$, ekkor

$$\frac{\hat{\Lambda} - \Lambda}{\text{se}(\hat{\Lambda})} \stackrel{H_0}{\sim} t_{n-k-1}$$

- Ez az ún. *közvetlen t -próba*
- Vizsgálható Wald-jellegű próbával is (most nem foglalkozunk vele bővebben, de a `gret1` ezt használja)

Több megkötés egyidejű tesztelése

- Az eddigiek kombinálhatóak is: több megkötés (mindegyikük lineáris kombináció), melyeknek egyszerre kell teljesülniük
- Célszerű felírás:

$$H_0 : \mathbf{R}\beta = \mathbf{r},$$

ahol \mathbf{R} $m \times k$ típusú (tehát m a megszorítások száma)

- Az erre adható teszt:

$$F_{\text{emp}} = \frac{(\mathbf{R}\hat{\beta} - \mathbf{r})^T [\mathbf{R}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{R}^T]^{-1} (\mathbf{R}\hat{\beta} - \mathbf{r}) / m}{\text{ESS} / (n - k - 1)} \stackrel{H_0}{\sim} \mathcal{F}(m, n - k - 1)$$

Konkrét példák a fenti sémára

- Ellenőrizhető, hogy ha például...
 - ... $\mathbf{R} = (0 \ 0 \ \dots \ 0 \ 1 \ 0 \dots 0)$ és $r = 0$, akkor a t -tesztet ...
 - ... $\mathbf{R} = \begin{pmatrix} 0 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 1 & 0 \\ 0 & 0 & 0 & \dots & 0 & 1 \end{pmatrix}$ és $\mathbf{r} = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 0 \end{pmatrix}$ akkor az ANOVA-t...
 - ... $\mathbf{R} = (\lambda_{\beta_1} \ \lambda_{\beta_2} \ \dots \ \lambda_{\beta_k})$ és $r = \Lambda$, akkor a lineáris kombináció tesztelését...
 - ... kapjuk vissza.