

Kevert modellek: szelekció, diagnosztika



Miért válogatunk a modellek között?

- ▶ Egy módja a kérdéses faktor hatásának ellenőrzésére. Van, aki a faktorokhoz nem is nyer ki további p -értéket
- ▶ Az adatainkat legjobban leíró modellre vágyunk. (Bár van olyan szemlélet is, hogy minek vennék fel olyan változót, aminek a hatása nem érdekel, deeee ha nincs hatása a szelekció alapján, akkor az is egy válasz!!!!)

Hasznos csomagok (van még pár, válogatás)

- ▶ lme4 - modellek létrehozása
- ▶ lmerTest - az egyikféle lehetőség hez kell a p -érték kinyeréséhez
- ▶ car - p -érték kinyerés egy módjához
- ▶ MuMIn - hatásnagyságok kinyerése
- ▶ emmeans - post hoc teszt végzéséhez
- ▶ lattice, visreg és ggplot2 (lehetséges ábrázolási módok: az első kettő modelldiagnosztikához, a ggplot2 pedig ha gondoljátok (Kati basic R csomagban ábrázol, én ggplot2-ben))

Random hatások I



- ▶ intercept (metszéspont): az összes fix hatásra az első (ábécében vagy beállított sorrend alapján) szintek becsült értéke. Ha van random slope, elhagyható ($0 + \dots | \text{subject}$), de ennek akkor van értelme, ha a faktorunk szám, de nem értelmes a 0 értékre becsülni. A random metszéspont azt teszi, hogy feltételezem, hogy az "alap" érték változhat az adott hatás mentén (beszélők közötti különbség - pl.

Random hatások II

mindentől függetlenül is eltérő átlagos alapfrekvenciákat használunk).

- ▶ slope (meredekség): A kérdéses faktor hatását beszélőnként is elemzi, azaz megengedi, hogy a mostani példánkban az egyik beszélő esetében nagyobb, a másikéban kisebb hatással bírjon az udvariasság az f_0 -ra.

A random hatások is tesztelhetők, betehetőek, kivehetőek, vagyis a modellek összevethetőek ezek mentén is. Pl.:

$\text{lmer}(\text{frequency} \sim \text{attitude} + \text{gender} + (1 \mid \text{subject}), \text{pol})$

vs.

$\text{lmer}(\text{frequency} \sim \text{attitude} + \text{gender} + (1 + \text{attitude} \mid \text{subject}), \text{pol})$

vs.

$\text{lmer}(\text{frequency} \sim \text{attitude} + \text{gender} + (0 + \text{attitude} \mid \text{subject}), \text{pol})$ # Ez az, ahol csak akkor van értelme, ha random hatásunk

Random hatások III

faktora szám, és a 0-nak nincs értelme - tehát subjectre pl. nem annyira van, de technikailag opció.

Kevert modellben mindig kell min. 1 random hatás. Az alábbi modell tehát csak egy "sima" lm:

$\text{lmer}(\text{frequency} \sim \text{attitude} + \text{gender}, \text{pol})$

És ilyen sincs:

~~$\text{lmer}(\text{frequency} \sim \text{attitude} + \text{gender} + (0 | \text{subject}), \text{pol})$~~

Modellszelekció I

Fentről lefele vagy lentől felfele is lehet haladni. A cél azonban a lehető legkomplexebb modell megtartása.

A kérdéses fix és random hatásokat illeszttem a modellbe, majd elhagyom, amelyik hatása érdekel.

```
mod.1 <- lmer(frequency ~ attitude * gender + (1 + attitude | subject) + (1 + attitude | scenario), pol, REML = F)
```

```
mod.2 <- lmer(frequency ~ attitude + gender + (1 + attitude | subject) + (1 + attitude | scenario), pol, REML = F)
```

Összevetem a két modellt: `anova(mod.1, mod.2)`

```
Data: pol
Models:
mod.2: frequency ~ attitude + gender + (1 + attitude | subject) + (1 + attitude | scenario)
mod.1: frequency ~ attitude * gender + (1 + attitude | subject) + (1 + attitude | scenario)
      npar    AIC    BIC logLik deviance Chisq Df Pr(>Chisq)
mod.2   10 814.90 839.09 -397.45   794.90
mod.1   11 814.89 841.50 -396.45   792.89 2.0023  1    0.1571
```

Modellszelekció II

Mivel nincs szignifikáns eltérés, a **szűkebb** modellt tartom meg.

A két fix hatás vizsgálata:

```
mod.3 ← lmer(frequency ~ attitude + (1 + attitude | subject) +  
(1 + attitude | scenario), pol, REML = F)
```

```
mod.4 ← lmer(frequency ~ gender + (1 | subject) + (1 |  
scenario), pol, REML = F)
```

```
anova(mod.2, mod.3, mod.4)
```

```
Data: pol  
Models:  
mod.4: frequency ~ gender + (1 | subject) + (1 | scenario)  
mod.3: frequency ~ attitude + (1 + attitude | subject) + (1 + attitude | scenario)  
mod.2: frequency ~ attitude + gender + (1 + attitude | subject) + (1 + attitude | scenario)  
-----  
      npar    AIC      BIC    logLik deviance  Chisq Df Pr(>Chisq)  
mod.4      5 816.72 828.81 -403.36   806.72  
mod.3      9 823.32 845.09 -402.66   805.32  1.3964  4  0.844822  
mod.2     10 814.90 839.09 -397.45   794.90 10.4261  1  0.001243 **  
---  
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


Modellszelekció III

Ez alapján mindkét faktorom hatása elég jelentős ahhoz, hogy tartalmazza a modell őket! Azaz a jelenlegi legbővebb, mod.2 nevű modellel megyek tovább.

“We used R (R Core Team, 2012) and lme4 (Bates, Maechler Bolker, 2012) to perform a linear mixed effects analysis of the relationship between pitch and politeness. As fixed effects, we entered politeness and gender (without interaction term) into the model. As random effects, we had intercepts for subjects and items, as well as by-subject and by-item random slopes for the effect of politeness. Visual inspection of residual plots did not reveal any obvious deviations from homoscedasticity or normality. P-values were obtained by likelihood ratio tests of the full model with the effect in question against the model without the effect in question.” (Winter:

https://bodo-winter.net/tutorial/bw_LME_tutorial2.pdf)

A végső modell p -értékeinek kinyerése I

- ▶ `summary(mod.2)` - alapcsomag függvénye. Interceptnek az ábécében (vagy a faktorszintek sorrendjében) elől álló jellemzőt veszi. Ehhez képest mutatja be a többi szint becsült értékét! Újrarendezéssel (`relevel()` és `factor(..., levels = c(...))`) paranccsal átállítva a faktorunk sorrendjét megkaphatjuk a többi becsült eltérést is.

```
> summary(mod.2)
```

```
Linear mixed model fit by maximum likelihood . t-tests use Satterthwaite's method ['lmerModLmerTest']  
Formula: frequency ~ attitude + gender + (1 + attitude | subject) + (1 + attitude | scenario)  
Data: pol
```

AIC	BIC	logLik	deviance	df.resid
814.9	839.1	-397.4	794.9	73

```
Scaled residuals:
```

Min	1Q	Median	3Q	Max
-2.1946	-0.6690	-0.0789	0.5256	3.4251

```
Random effects:
```

Groups	Name	Variance	Std.Dev.	Corr
scenario	(Intercept)	182.083	13.494	
	attitudepol	31.244	5.590	0.22
subject	(Intercept)	392.344	19.808	
	attitudepol	1.714	1.309	1.00
Residual		627.890	25.058	

```
Number of obs: 83, groups: scenario, 7; subject, 6
```

A végső modell p -értékeinek kinyerése II

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t)	
(Intercept)	257.991	13.528	7.600	19.071	1.08e-07	***
attitudepol	-19.747	5.922	7.062	-3.335	0.012354	*
genderM	-110.806	17.510	5.936	-6.328	0.000759	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Correlation of Fixed Effects:

```
(Intr) atttdp
attitudepol -0.105
genderM      -0.647  0.003
optimizer (nloptwrap) convergence code: 0 (OK)
boundary (singular) fit: see help('isSingular')
```

A végső modell p -értékeinek kinyerése III

- ▶ Anova(mod.2) - a car csomag Anova() függvénye, χ^2 -próbát hajt végre (nem kell lmerTest()-csomag)

Analysis of Deviance Table (Type II Wald chisquare tests)

Response: frequency

	Chisq	Df	Pr(>Chisq)	
attitude	11.119	1	0.0008544	***
gender	40.045	1	2.481e-10	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

A végső modell p -értékeinek kinyerése IV

- ▶ `anova(mod.2)` - az alapcsomag `anova()` függvénye (az `lmerTest` csomagot is behívva végzett `lmer()`-függvénnyel áll szóba)

```
Type III Analysis of Variance Table with Satterthwaite's method
              Sum Sq Mean Sq NumDF  DenDF F value    Pr(>F)
attitude    6981.6  6981.6      1  7.0616  11.119 0.0123537 *
gender      25144.0 25144.0      1  5.9360  40.045 0.0007592 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Főhatás: a faktor hatása önmagában (pl. nem hatása az f_0 -ra) VS.
Interakció: több faktor közös hatása (pl. nem * udvariasság). Két módon bánnak a főhatással, ha az interakció szignifikáns: Nem foglalkoznak vele. Azt is megnézik és közlik.

A végső modell p -értékeinek kinyerése V

Aki nem foglalkozik vele: a faktorok interakcióját tartja lényegesnek, mert az egyik hatás a másik hatás feltételében teljesül adott módon.

Aki foglalkozik vele: egy fő hatás lehet jelentős akkor is, ha a másik csak vele interakcióban hat. Pl. ha az udvariasság más módon befolyásolná az f_0 -t a nők és a férfiak esetében, nem jelentené azt, hogy a nemek közötti f_0 -különbség mindenképp szituációfüggő lenne!

Post hoc teszt I

Ha több szintű (> 2) egy faktor, vagy az interakció hatására vagyunk kíváncsiak: post hoc teszt:

```
emmeans(mod.1, list(pairwise ~ attitude * gender), adjust = "tukey")
```

emmeans csomag, a pairwise-ba a kívánt hatást kell beírni (interakció esetében a modellben írt sorrendben!)

Post hoc teszt II

```
$`emmeans of attitude, gender`  
attitude gender emmean SE df lower.CL upper.CL  
inf F 261 16.0 9.14 224.5 297  
pol F 233 16.8 9.35 195.5 271  
inf M 144 16.0 9.15 108.3 181  
pol M 133 16.9 9.45 94.7 170
```

Degrees-of-freedom method: kenward-roger

Confidence level used: 0.95

```
$`pairwise differences of attitude, gender`  
1 estimate SE df t.ratio p.value  
inf F - pol F 27.4 8.35 4.97 3.283 0.0759  
inf F - inf M 116.2 21.33 7.69 5.448 0.0031  
inf F - pol M 128.1 21.99 9.92 5.824 0.0008  
pol F - inf M 88.8 21.95 9.84 4.046 0.0108  
pol F - pol M 100.7 22.12 7.57 4.550 0.0092  
inf M - pol M 11.9 8.46 5.19 1.404 0.5459
```

Degrees-of-freedom method: kenward-roger

P value adjustment: tukey method for comparing a family of 4 estimates

Diagnosztika I

A modellkészítés során sok hibaüzenet kaphatunk:

- ▶ nem konvergál: újra kell gondolni a modell felépítését, esetleg a további kiírt részletekre rákeresni a megoldásért
- ▶ singular fit: kicsit túltoltuk az illesztést - itt általában az az ok, hogy a random hatásaink minden értéket lefednek, nem hagynak további variabilitást. Ilyenkor egyszerűbb illesztést lehet alkalmazni.

Ha nincs hibaüzenet, akkor is el kell végezni pár elemzést:

A reziduálisok eloszlásának közel normálnak illik lenni, nem szabad értelmezhető trendnek lenni az értékeikben.

- ▶ `plot(mod.2)`
- ▶ `qqnorm(residuals(mod.2)) + qqline(residuals(mod.2))`

Diagnosztika II

Homoescacitást feltételezünk, ellenőrzése:

```
pol$res[!is.na(pol$frequency)] ← abs(residuals(mod.2))^2
```

(A modell reziduálisait beillesztjük egy oszlopba, de itt van egy NA értékünk.) (Normál esetben nem kell az !is.na() parancs!) Az abszolút érték helyett emelünk négyzetre.

```
Levene.Model.pol ← lm(res ~ subject, data=pol) # Modellezzük a rezisuálisokat a beszélők függvényében, van-e eltérés
```

```
anova(Levene.Model.pol) # itt nagyon szorítunk, hogy ne legyen, azaz  $p > 0,05$ -öt kapjunk :oD
```

A becsült értékek kinyerése

Ha `summary()` paranccsal nyertünk ki p -értéket a modellünkből, ezek egy részét már látjuk a táblázatban akkor

```
coef(mod.2)
```

```
summary(mod.2)$coefficients
```

```
ranef(mod.2)
```

```
dotplot(ranef(mod.2, condVar=TRUE)) # a random hatások  
intercepthez képesti ábrázolása
```

Esetleg még a `visreg` csomag `visreg` függvénye:

```
visreg(mod.2, xvar = "frequency", by = "attitude", overlay =  
TRUE, ylab="")
```

```
visreg(mod.2, xvar = "frequency", by = "gender", overlay =  
TRUE, ylab="")
```

Hatásnagyság

A hatásnagyság itt is ellenőrizendő, és nagyon sok mondanivalóval bír:

r.squaredGLMM(mod.2) # MuMIn csomag

Hatásnagyságok Imm-ben:

- ▶ Marginális hatásnagyság (r^2_m): a hány százalékát magyarázzák a modellben foglalt fix hatások az adataimnak
- ▶ Kondicionális hatásnagyság (r^2_c): hány százalékát magyarázzák az adataimnak a teljes modellben foglalt összes hatások, azaz a randomokat is ideértve

Minél nagyobb a marginális hatásnagyság, annál királyabb vagyok. (Bocs: annál jobb a modellem.)

Mi van, ha nagy a különbség a két hatásnagyság között? Mindig a kondicionális lesz nagyobb, hiszen több magyarázó tényezőt tartalmaz. Ha azonban több tizednyi az eltérés, akkor a random hatások túlzottan meghatározóak, és pl. a beszélők közötti variabilitás jelentős, akár megkérdőjelezhetik a fix hatásaim értelmét is.