

Анализа података у биологији

Марија Цупарић

Десети час



Тестирање хипотеза у вези са разликом пропорција

хипотезе:

- ★ $H_0(p_1 - p_2 = p_0)$ против $H_1(p_1 - p_2 \neq p_0)$ (двострани тест)
- ★ $H_0(p_1 - p_2 \geq p_0)$ против $H_1(p_1 - p_2 < p_0)$ (једнострани леви)
- ★ $H_0(p_1 - p_2 \leq p_0)$ против $H_1(p_1 - p_2 > p_0)$ (једнострани десни)

тест статистика: $T_{n_1, n_2} = \frac{\bar{X}_{n_1} - \bar{Y}_{n_2} - p_0}{\sqrt{\frac{\bar{X}_{n_1}(1-\bar{X}_{n_1})}{n_1} + \frac{\bar{Y}_{n_2}(1-\bar{Y}_{n_2})}{n_2}}}$ при H_0 има (приближно) $\mathcal{N}(0,1)$

p -вредност теста:

- ★ код једностраног левог теста је површина лево од вредности t_0 коју статистика T_{n_1, n_2} узме у узорку;
- ★ код једностраног десног теста је површина десно од вредности t_0 коју статистика T_{n_1, n_2} узме у узорку;
- ★ код двостраног теста је двострука површина лево од вредности t_0 , ако је $t_0 < 0$ или двострука површина десно од вредности t_0 , ако је $t_0 > 0$.



Пример Произвођач разматра коришћење нове методе узгоја биљака. Прва метода је скупља, али се тврди да је за 10% већи проценат успешно развијених биљака у односу на стандардну методу. Изведен је експеримент и од 1000 биљака узгајаних првом методом 900 је било успешно, а од 900 биљака другим начином 711 је било успешно. Да ли треба користити нову методу узгоја?

Поставимо хипотезе: $H_0(p_1 - p_2 = 0.1)$ $H_1(p_1 - p_2 > 0.1)$.

$$\bar{x}_{n_1} = \frac{900}{1000} = 0.9, \bar{y}_{n_2} = \frac{711}{900} = 0.79$$

Реализована вредност тест статистике:
$$\frac{\bar{x}_{n_1} - \bar{y}_{n_2} - 0.1}{\sqrt{\frac{\bar{x}_{n_1}(1-\bar{x}_{n_1})}{n_1} + \frac{\bar{y}_{n_2}(1-\bar{y}_{n_2})}{n_2}}} = 0.604.$$

p -вредност теста: $P_{H_0}\{T_{n_1, n_2} \geq 0.604\} = 1 - \Phi(0.604) = 0.27$

Закључујемо да немамо основа да подржимо нову методу узгоја.



Пример Директор спортког сектора једног универзитета жели да добије статистичку подршку својој тврдњи да студенти спортисти у мањем проценту падају године него остали студенти. У добијеним узорцима 30 студената спортиста од њих 150 је пало годину, док се то догодило и у случају 43 студента од 200 чланова остатка популације. Да ли ови подаци иду у прилог директорове тврдње?

Поставимо хипотезе: $H_0(p_1 = p_2)$ $H_1(p_1 < p_2)$.

$$\bar{x}_{n_1} = \frac{30}{150} = 0.2, \bar{y}_{n_2} = \frac{43}{200} = 0.215$$

Реализована вредност тест статистике: $\frac{\bar{x}_{n_1} - \bar{y}_{n_2}}{\sqrt{\frac{\bar{x}_{n_1}(1-\bar{x}_{n_1})}{n_1} + \frac{\bar{y}_{n_2}(1-\bar{y}_{n_2})}{n_2}}} = -0.34$.

p -вредност теста: $P_{H_0}\{T_{n_1, n_2} < -0.34\} = 0.37$

Закључујемо да немамо основа да подржимо директорово тврђење да спортисти мање падају годину.



```
prop.test(x=c(30,43),n=c(150,200),alternative="less",
          conf.level=0.95, correct=FALSE)
```

2-sample test for equality of proportions without continuity correction

```
data: c(30, 43) out of c(150, 200)
X-squared = 0.11683, df = 1, p-value = 0.3662
alternative hypothesis: less
95 percent confidence interval:
 -1.00000000 0.05689613
sample estimates:
prop 1 prop 2
 0.200 0.215
```

- ★ Проучавамо како се може моделовати зависност једне променљиве у односу на другу.
- ★ Регресионо моделирање се бави проналажењем адекватног модела којим се описује утицај такозваних независних променљивих (предиктора) X на зависну променљиву (променљиву одговора) Y .
- ★ Регресиони модел: $Y = f(X) + \varepsilon$, где је $f(X)$ регресиона функција, а ε случајна променљива која не зависи од X (и најчешће има $\mathcal{N}(0, \sigma^2)$ расподелу).
- ★ Вредности независне променљиве x (тачке) често можемо сами да бирамо и онда узимамо узорак за Y у тим тачкама.
- ★ Уколико сами бирамо x , то је планирани експеримент, а ако не, онда имамо посматрани експеримент.



- ★ Најчешћа сврха регресионог проучавања је предвиђање.
- ★ Одређујемо једначину уз помоћ које ће вредност од Y бити превиђена довољно добро на основу других променљивих које се јављају у једначини.

Пример

- (1) Испитујемо раст биљака (Y) у односу на количину светлости (x)
- (2) Предвиђање масе јединки (Y) на основу више фактора (x_1 количина хране, x_2 температура средине, ...)
- (3) Испитујемо везу између концентрације загађујуће супстанце (x) и броја угинулих јединки (Y)

Сврха: разумевање утицаја фактора средине, издвајање значајних фактора и поређење различитих услова или третмана.



Наш задатак је да на основу посматраних података нађемо линеарну једначину (график је права линија) која изражава средњу вредност од Y преко x .

Ако знамо да независна променљива има конкретну вредност x , који је најбољи избор за предвиђање вредности Y ?

Пример Ако је концентрација загађујуће супстанце у води 50 mg/l , колики је очекивани број угинулих јединки?

Дакле, тражимо $Y|x = 50$ и то је случајна величина јер ће, чак и при истој концентрацији загађења, број угинулих јединки варирати између различитих узорака или популација. Логично предвиђање за Y када је $x = 50$ је средња вредност Y -а за конкретну вредност x .


Дефиниција: Нека је x нека променљива и нека је Y случајна величина. Регресиона крива Y на x је график функције средње вредности Y за различите вредности x , тј. график функције $\mu_{Y|x}$. За регресиону криву Y на x каже се да је линеарна ако је $\mu_{Y|x} = \alpha + \beta x$ за неке реалне бројеве α и β . Број β назива се нагибом линеарне регресије.

Дакле, разматрамо


просту - постоји само једна независна променљива

линеарну - регресиона крива је права линија
регресију

Задатак: оценити α и β на основу x и Y



нелинаерна регресиона крива




линеарна регресиона крива



Пре било какве анализе, треба утврдити да се подаци заиста могу моделовати линеарном функцијом. У ту сврху црта се график тачака (x_i, y_i) .


Пример. Нека x представља број сати које је студент провео у учењу за тест из статистике, а Y број поена коју је добио на тесту. На узорку од 28 студената добијени су резултати:

(0.25,60), (0.75,60), (1.0,65), (1.5,70), (1.75,70), (2.5,75), (3.0,85),
 (0.5,62), (0.75,69), (1.0,70), (1.5,75), (2.0,73), (2.5,82), (3.0,82),
 (0.5,65), (0.75,71), (1.25,68), (1.5,65), (2.0,79), (2.75,85), (3.0,88),
 (0.5,80), (1.0,58), (1.25,71), (1.75,78), (2.0,60), (2.75,79), (3.5,90)



Затим треба одредити једначину праве линеарне регресије на основу случајног узорка $(x_1, Y_1), \dots, (x_n, Y_n)$. Реализација овог узорка је $(x_1, y_1), \dots, (x_n, y_n)$.

Пример (наставак).



Метод најмањих квадрата


Како добити оцелу праве? Узимамо ону праву којој су тачке графика најближе. Меримо вертикална растојања тачака од графика, такозване резидуале

$$e_i = y_i - (a + bx_i),$$

а оцена праве биће за оно a и b за које је збир квадрата резидуала најмањи.

$$SSE = \sum_{i=1}^n (y_i - (a + bx_i))^2$$

Пример (наставак).



★ Оцена регресионе праве је $\hat{\mu}_{Y|X} = \hat{\alpha} + \hat{\beta}x$, где је

$$\hat{\beta} = B = \frac{n \sum_{i=1}^n Y_i x_i - \sum_{i=1}^n Y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} = \frac{\frac{1}{n} \sum_{i=1}^n Y_i x_i - \bar{x} \bar{Y}}{\frac{1}{n} \sum x^2 - \bar{x}^2}, \quad \hat{\alpha} = A = \bar{Y}_n - \hat{\beta} \bar{x}_n$$

Пример (наставак). У нашем случају $\bar{x} = 1.66$, $\bar{y} = 72.68$, $\sum xy = 3556.75$ и $\sum x^2 = 100.375$. Према томе,

$$b = 7.69, \quad a = 59.91$$

и $\hat{\mu}_{Y|X} = 59.91 + 7.69x$. Дакле, ако неко учи 2.2 сата предвиђамо да ће освојити $\hat{\mu}_{Y|2.2} = 59.91 + 7.69 \cdot 2.2 = 76.828$.

- ★ Предвиђање помоћу регресионе линије важи само тамо где су подаци. Изван овог опсега, немамо евиденцију да је веза и даље линеарна па се не сме користити, а ако бисмо је користили често бисмо добили бесмислене или чак немогуће вредности.
- ★ Методом најмањих квадрата у ствари тачкасто оцењујемо μ_Y (или Y) за сваку вредност x_0 . Али за интервалне оцене и тестирање треба нам бољи модел који поред средње вредности описује и одступања од ње.





- ★ Претпостављамо да је средња вредност $\mu_{Y|x_i} = \alpha + \beta x_i$ за свако i
- ★ Одступање вредности Y_i од њене средње вредности, $\alpha + \beta x_i$, називамо грешком регресије и обележавамо са ε_i
- ★ Претпостављамо да свако ε_i има нормалну расподелу са средњом вредношћу 0 и неком дисперзијом σ^2 и да су међусобно независни

Теорема: Прост линеарни регресиони модел је

$$Y|x_i = (\alpha + \beta x_i) + \varepsilon_i,$$

где су ε_i независне случајне величине са нормалном $\mathcal{N}(0, \sigma^2)$ расподелом.



- ★ Из модела, Y_i зависи од две ствари, $\alpha + \beta x_i$, средње вредности, и ε_i , необјашњене грешке
- ★ Модел има три непозната параметра α, β и σ^2
- ★ α и β оцењујемо методом најмањих квадрата
- ★ Оцена за σ^2 је

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - (A + Bx))^2 = \frac{SSE}{n-2}$$

Треба имати у виду да је у уопштем случају тешко израчунати SSE директно из дефиниције. Уводимо „рачунске пречице“:

$$S_{yy} = \sum (y - \bar{y})^2 = \frac{1}{n} (n \sum y^2 - (\sum y)^2) = \sum y^2 - n\bar{y}^2$$

$$S_{xx} = \sum (x - \bar{x})^2 = \frac{1}{n} (n \sum x^2 - (\sum x)^2) = \sum x^2 - n\bar{x}^2$$

$$S_{xy} = \sum (x - \bar{x})(y - \bar{y}) = \frac{1}{n} (n \sum xy - \sum x \sum y) = \sum xy - n\bar{x}\bar{y}$$

$$\implies B = \frac{S_{xy}}{S_{xx}}, \quad SSE = S_{yy} - BS_{xy}$$

Пример (наставак).



```
x <- c(0.25, 0.75, 1.0, 1.5, 1.75, 2.5, 3.0, 0.5, 0.75, 1.0, 1.5, 2.0,
      2.5, 3.0, 0.5, 0.75, 1.25, 1.5, 2.0, 2.75, 3.0, 0.5, 1.0, 1.25, 1.75,
      2.0, 2.75, 3.5)
y <- c(60, 60, 65, 70, 70, 75, 85, 62, 69, 70, 75, 73, 82, 82, 65, 71, 68,
      65, 79, 85, 88, 80, 58, 71, 78, 60, 79, 90)
model<-lm(y~ x)
summary(model)
```

Call:

```
lm(formula = y ~ x)
```

Residuals:

Min	1Q	Median	3Q	Max
-15.2754	-2.3619	0.1381	3.3567	16.2052

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	59.968	2.289	26.20	< 2e-16 ***
x	7.654	1.209	6.33	1.06e-06 ***

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

Residual standard error: 5.817 on 26 degrees of freedom

Multiple R-squared: 0.6065, Adjusted R-squared: 0.5914

F-statistic: 40.07 on 1 and 26 DF, p-value: 1.056e-06

Интервал поверења за $\mu_{Y|x}$

- ★ Желимо да формирамо интервал поверења за средњу вредност од Y када је $x = x_0$.
- ★ Као и до сада, треба нам нека случајна величина са познатом расподелом која је повезана на неки начин са параметром

Теорема: Ако је $\hat{\sigma}^2 = \frac{SSE}{n-2}$, онда случајна променљива

$$\frac{\hat{\mu}_{Y|x_0} - \mu_{Y|x_0}}{\hat{\sigma}_n \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}} \in t_{n-2}.$$

100 β % интервал поверења за $\mu_{Y|x_0}$ је

$$\left(\hat{\mu}_{Y|x_0} - c \cdot \hat{\sigma}_n \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}, \hat{\mu}_{Y|x_0} + c \cdot \hat{\sigma}_n \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}} \right),$$

где је c одређено тако да $P\{T > c\} = \frac{1-\beta}{2}$ где $T \in t_{n-2}$.

Пример (наставак). Желимо да одредимо интервал поверења за средњи број поена на тесту, ако је учено 2.2 сата. Видели смо да је $\bar{x} = 1.66$, $b = 7.69$ и $\hat{\mu}_{Y|2.2} = 76.828$. Израчунајмо још шта је остало:

$$S_{yy} = \sum (y - \bar{y})^2 = 2236.107$$

$$S_{xx} = \sum (x - \bar{x})^2 = 23.15179$$

$$S_{xy} = \sum (x - \bar{x})(y - \bar{y}) = 177.1964$$

$$\implies SSE = S_{yy} - bS_{xy} = 873.4667, \hat{\sigma}^2 = \frac{SSE}{n-2} = 33.59487$$

Према томе, 95% интервал поверења је

$$\left(\hat{\mu}_{Y|x_0} - c \cdot \hat{\sigma}_n \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}, \hat{\mu}_{Y|x_0} + c \cdot \hat{\sigma}_n \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}} \right) = (74.20, 79.45),$$

где је $c = F_{t_{26}}^{-1}(0.975) = 2.055$. Дакле, верујемо са поверењем од 95% да ће студент који учи 2.2 сата имати између 74 и 79 поена.



```
predict(model, data.frame(x=2.2), interval="confidence")
```


```
> predict(model, data.frame(x=2.2), interval="confidence")
      fit      lwr      upr
1 76.80609 74.17873 79.43346
```

Може се формирати и трака поверења регресионе линије тако што се за свако изабрано x одреди интервал поверења а затим се ти интервали споје глатком кривом.

Пример (наставак).



```
yy<-predict(model,interval="confidence",
  data.frame(x=seq(0,3.6,length=51)))
plot(x,y,pch=19,xlab="x", ylab="y")
abline(model)
lines(seq(0,3.6,length=51),yy[,3],col="red")
lines(seq(0,3.6,length=51),yy[,2],col="red")
```



Интервал предвиђања за $Y|x_0$

- ★ Желимо да формирамо интервал који ће, априори, обухватати посматрану вредности $Y|x_0$ са одређеним нивоом поверења
- ★ У овом случају желимо да „ухватимо” будућу вредност случајне променљиве, односно да предвидимо интервалом вредност од $Y|x$

Теорема: Ако је $\hat{\sigma}^2 = \frac{SSE}{n-2}$, онда случајна променљива

$$\frac{\hat{Y}|x_0 - Y|x_0}{\hat{\sigma}_n \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}} \in t_{n-2}.$$

100 β % интервал предвиђања за $\mu_{Y|x_0}$ је

$$\left(\hat{Y}|x_0 - c \cdot \hat{\sigma}_n \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}, \hat{Y}|x_0 + c \cdot \hat{\sigma}_n \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}} \right),$$

где је c одређено тако да $P\{T > c\} = \frac{1-\beta}{2}$ где $T \in t_{n-2}$.

Пример (наставак). Желимо да одредимо интервал предвиђања за број поена на тесту, ако је учено 2.2 сата. Користећи претходно добијене резултате, 95% интервал предвиђања је

$$\left(\hat{Y}|_{x_0 - c \cdot \hat{\sigma}_n \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}}, \hat{Y}|_{x_0 + c \cdot \hat{\sigma}_n \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x}_n)^2}{S_{xx}}}} \right) = (64.58, 89.07),$$

где је $c = F_{t_{26}}^{-1}(0.975) = 2.055$. Дакле, верујемо са поверењем од 95% да ће студент који учи 2.2 сата имати између 64.6 и 89 поена.




```
predict(model, data.frame(x=2.2), interval="prediction")
```

```
> predict(model, data.frame(x = 2.2), interval = "prediction")
      fit      lwr      upr
1 76.80609 64.56298 89.04921
```



```
yy2<-predict(model,interval="-
prediction", data.frame(x
=seq(0,3.6,length=51)))
lines(seq(0,3.6,length=51),
yy2[,3],col="blue")
lines(seq(0,3.6,length=51),
yy2[,2],col="blue")
```



Тестирање хипотеза у вези са параметрима регресије

- ★ Видели смо да је први корак у регресионој анализи нацртати график података и, ако је линеарна регресија адекватан избор, онда треба да постоји линеарни тренд са $\beta \neq 0$
- ★ Ако нисмо сигурни да ли је линеарни модел адекватан, можемо то тестирати

хипотезе: $H_0(\beta = 0)$ против $H_1(\beta \neq 0)$, односно Y је исто за свако x и регресиони модел је непотребан против алтернативе да је линеарни регресиони модел користан за предвиђање Y на основу x

тест статистика: $T_0 = \frac{B}{\hat{\sigma}_n} \sqrt{S_{xx}}$ при H_0 има t_{n-2}

p -вредност теста: двострука површина лево од вредности t_0 , ако је $t_0 < 0$ или двострука површина десно од вредности t_0 , ако је $t_0 > 0$, где је t_0 реализована вредност од T_0 .



Пример (наставак). Тестирамо да ли нам је регресиони модел број поена на тесту у односу на број сати учења довољно добар да бисмо могли на основу њега да вршимо предвиђања.

хипотезе: $H_0(\beta = 0)$ против $H_1(\beta \neq 0)$

тест статистика: $T_0 = \frac{B}{\hat{\sigma}_n} \sqrt{S_{xx}}$ при H_0 има t_{n-2}

реализована вредност тест статистике: $T_0 = \frac{7.69}{\sqrt{33.84238}} \sqrt{23.15179} = 6.36$

p-вредност теста: $2P\{T_0 > 6.36\} \approx 0$

Дакле, одбацујемо нулту хипотезу, односно линеарни модел је користан за предвиђање.

```
Call:
lm(formula = y ~ x)

Residuals:
    Min       1Q   Median       3Q      Max
-15.2754  -2.3619   0.1381   3.3567  16.2052

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  59.968     2.289    26.20 < 2e-16 ***
x             7.654     1.209     6.33 1.06e-06 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 5.817 on 26 degrees of freedom
Multiple R-squared:  0.6065,    Adjusted R-squared:  0.5914 
F-statistic: 40.07 on 1 and 26 DF,  p-value: 1.056e-06
```

- ★ У пракси се често дешава да је потребно испитати утицај више предиктора на зависну променљиву

Пример Разматрамо масу јединке (Y) на основу количину хране (x_1), температуре (x_2), старост јединке (x_3).

- ★ Вишеструки линеарни модел, који претпоставља да Y зависи од променљивих $x_1, x_2, \dots, x_p$, је $Y|x_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon_i$, где су ε_i независне случајне величине са нормалном $\mathcal{N}(0, \sigma^2)$ расподелом
- ★ Циљ је моделирање условне расподеле зависне променљиве
- ★ На основу узорка $(x_{11}, \dots, x_{p1}, Y_1), \dots, (x_{1n}, \dots, x_{pn}, Y_n)$ оцењујемо параметре $\beta_0, \dots, \beta_p$ методом најмањих квадрата
- ★ Поред стандардних тачкастих и интервалних оцена, једна од најважнијих ствари у вишеструкој регресији је избор модела, тј. одредити које од x_j треба да постоје у формули регресије
- ★ Пошто није могуће да цртамо вишедимензионе променљиве, морамо да добијемо одговор тестирањем



Пример. Размотримо базу података о биљним врстама на Галапагосу. База се састоји од 30 редова које представљају острва и 7 променљивих:

Species – број различитих биљних врста на острву

Area – површина острва (у km^2)

Elevation – максимална надморска висина острва (у метрима)

Nearest – удаљеност до најближег острва (у km)

Scruz – удаљеност до острва Санта Цруз (у km)

Adjacent – површина суседних острва (у km^2)

Променљиву *Species* узећемо за зависну, а последњих 5 као потенцијалне предикторе (независне променљиве).

Пре учитавања базе треба инсталирати пакет *faraway*.



```
library(faraway)  
data(gala)
```

Направимо прво модел са свим променљивим.



```
model<-lm(Species ~ Area + Elevation + Nearest + Scrutz + Adjacent,
data=gala)
summary(model)
```

```
Call:
lm(formula = Species ~ Area + Elevation + Nearest + Scrutz + Adjacent,
    data = gala)

Residuals:
    Min       1Q   Median       3Q      Max
-111.679  -34.898   -7.862   33.460  182.584

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.068221   19.154198   0.369  0.715351
Area        -0.023938    0.022422  -1.068  0.296318
Elevation    0.319465    0.053663   5.953 3.82e-06 ***
Nearest      0.009144    1.054136   0.009  0.993151
Scrutz      -0.240524    0.215402  -1.117  0.275208
Adjacent     -0.074805    0.017700  -4.226  0.000297 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 60.98 on 24 degrees of freedom
Multiple R-squared:  0.7658,    Adjusted R-squared:  0.7171
F-statistic: 15.7 on 5 and 24 DF,  p-value: 6.838e-07
```

коэффициент β_j уз x_j
 представља за колико се
 повећава μ_y када се x_j
 повећа за 1, а остали
 x -еви остану
 непромењени

Проблем је што се често мењањем једног x_j у пракси мењају и други, тј.
 предиктори нису у општем случају независни.

Оцењивање и закључивање на основу модела зависе од неколико претпоставки:

грешке претпоставља се да су грешке ε_i нормално расподељене, са истом дисперзијом и независне

модел претпостављамо да је структура модела $\mu_{Y|x} = x\beta$ добра

неуобичајне тачке неколико тачака које не одговарају моделу могу значајно променити модел

Бавићемо се само провером претпоставки у вези са грешкама. Како проверавамо?

нормална расподељеност QQ —дијаграм резидуала

једнака дисперзија график тачкастих оцена $\hat{y}_i$ и ε_i

независност проверава се зависност суседних резидуала (ово има смисла ако су Y_i дати неким редоследом, нпр. временски следе један другог)



QQ—дијаграм

- ★ QQ-дијаграм служи да се испита да ли се за неки узорак може сматрати да је из нормалне расподеле
- ★ На овом дијаграму на x —оси налазе се теоријски квантили стандардне нормалне расподеле, а на y —оси узорачки квантили, односно упоређујемо резидуале са „идеално” нормалним вредностима
- ★ Користи се чињеница да је свака нормална случајна променљива линеарна функција стандардне нормалне, па и квантили случајног узорка се претпоставља да неће много одступати од праве
- ★ Уколико тачке дијаграма не одступају много од праве, можемо сматрати да је расподела нормална, у супротном не можемо







нормална расподела грешке

⇒ може се користити линеарни модел

несиметрична расподела грешке

⇒ препоручује се трансформација
 квадратним кореном или логаритмом



симетрична расподела „тешких репова“

⇒ не може се користити линеарни
 модел

ограничена симетрична расподела грешке

⇒ може се користити линеарни модел


- ★ Проверавамо да ли је дисперзија у резидуалима повезана са неком другом величином
- ★ Цртамо график $\hat{u}$ и $\hat{\varepsilon}$
- ★ Ако су дисперзије једнаке, требало би да се види константност у вертикалном правцу, а тачке треба да буду симетричне око хоризонталне линије у 0



Пример (наставак).



```
qqnorm(residuals(model),ylab="Residuals")
qqline(residuals(model))
plot(fitted(model), residuals(model),xlab="Fitted",ylab="Residuals")
```




Оба дијаграма нам говоре да наше претпоставке нису лоше, али можемо пробати да побољшамо модел трансформацијом



Пример (наставак).



```
model.koren <- lm(sqrt(Species) ~ Area + Elevation + Scrub + Nearest +  
  Adjacent, gala)
```



Можемо видети да су сада претпоставке боље задовољене, међутим нови модел је обично тежи за интерпретацију



- ★ Циљ нам је доћи до што једноставнијег модела (тј. са што мање променљивих) који је једнако добар као и модел са свим предикторима
- ★ Најчешће кренемо од модела са свим потенцијалним предикторима па избацујемо један по један
- ★ Избацивање једног предиктора мења модел (вредности коефицијената и њихову значајност), тако да се може догодити да предиктор који није био значајан у ширем моделу сада то буде, и обрнуто
- ★ За упоређивање два модела користимо Фишеров F —тест
 - ★ Претпоставимо да имамо два модела (ω се може добити од Ω стављањем да су неки параметри једнаки нули) и нека Ω има p непознатих параметара, а ω q непознатих параметара, $q < p$.
 - ★ Желимо да тестирамо H_0 да су оба модела једнако добра против алтернативе да су модели једнако добри, односно $H_0 : \beta_{q+1} = 0, \dots, \beta_p = 0$ против алтернативе $H_1 : \exists i \beta_i \neq 0$.
 - ★ Тест статистика: $F_0 = \frac{SSE_{\omega} - SSE_{\Omega}}{SSE_{\Omega}} \frac{n-p}{p-q}$ при H_0 има $F_{p-q, n-p}$, где су SSE_{Ω} и SSE_{ω} редом збирове квадрата грешака модела
 - ★ p —вредност теста је површина десно од вредности f_0 коју F_0 узме у узorkу



Пример (наставак).



```
model2 <- lm(Species~ Elevation + Adjacent, data=gala)
```

```
> summary(model)
```

```
Call:
lm(formula = Species ~ Area + Elevation + Nearest + Scruz + Adjacent,
    data = gala)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-111.679  -34.898   -7.862   33.460  182.584
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.068221   19.154198   0.369  0.715351
Area        -0.023938   0.022422  -1.068  0.296318
Elevation    0.319465   0.053663   5.953 3.82e-06 ***
Nearest      0.009144   1.054136   0.009  0.993151
Scruz        -0.240524   0.215402  -1.117  0.275208
Adjacent     -0.074805   0.017700  -4.226  0.000297 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 60.98 on 24 degrees of freedom
Multiple R-squared:  0.7658,    Adjusted R-squared:  0.7171
F-statistic: 15.7 on 5 and 24 DF,  p-value: 6.838e-07
```

```
> summary(model2)
```

```
Call:
lm(formula = Species ~ Elevation + Adjacent, data = gala)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-103.41  -34.33  -11.43   22.57   203.65
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.43287    15.02469   0.095  0.924727
Elevation    0.27657    0.03176   8.707 2.53e-09 ***
Adjacent     -0.06889    0.01549  -4.447 0.000134 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 60.86 on 27 degrees of freedom
Multiple R-squared:  0.7376,    Adjusted R-squared:  0.7181
F-statistic: 37.94 on 2 and 27 DF,  p-value: 1.434e-08
```



```
anova(model,model2)
```

Analysis of Variance Table

```
Model 1: Species ~ Area + Elevation + Nearest + Scruz + Adjacent
```

```
Model 2: Species ~ Elevation + Adjacent
```

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	24	89231				
2	27	100003	-3	-10772	0.9657	0.425

Видимо да је p -вредност велика па сматрамо да су модели једнако добри, а пошто је други модел једноставнији одределићемо се за њега

Да ли можемо још смањити број променљивих?



```
> model3 <- lm(Species ~ Elevation, data=gala)
> anova(model2,model3)
> model3 <- lm(Species ~ Adjacent, data=gala)
> anova(model2,model4)
```

Добијају се p -вредности F -теста 0.0001344 и 2.533e-09, редом, што значи да у оба случаја одбацујемо H_0 .



- ★ Колико добро наш модел описује зависност између предиктора и зависне променљиве?
- ★ Удео објашњеног варијабилитета R^2 у моделу назива се коефицијент детерминације
- ★ Бољем моделу одговара већи коефицијент детерминације

Пример (наставак).

```
> summary(model)

Call:
lm(formula = Species ~ Area + Elevation + Nearest + Scrub + Adjacent,
    data = galea)

Residuals:
    Min       1Q   Median       3Q      Max
-111.679  -34.898   -7.862   33.460   182.584

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  7.068221  19.154198   0.369  0.715351
Area         -0.023928  0.022422  -1.068  0.296318
Elevation     0.319465  0.053663   5.953 3.82e-06 ***
Nearest       0.009144  1.054136   0.009  0.993151
Scrub        -0.240524  0.215402  -1.117  0.275208
Adjacent     -0.074805  0.017700  -4.226  0.000297 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 60.98 on 24 degrees of freedom
Multiple R-squared:  0.7658    Adjusted R-squared:  0.7171
F-statistic: 15.7 on 5 and 24 DF, p-value: 6.838e-07
```

```
> summary(model2)

Call:
lm(formula = Species ~ Elevation + Adjacent, data = galea)

Residuals:
    Min       1Q   Median       3Q      Max
-103.41  -34.33  -11.43   22.57  203.65

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.43287   15.02469   0.095  0.924727
Elevation     0.27657   0.03176   8.707 2.53e-09 ***
Adjacent     -0.06889   0.01549  -4.447 0.000134 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 60.86 on 27 degrees of freedom
Multiple R-squared:  0.7376    Adjusted R-squared:  0.7181
F-statistic: 37.94 on 2 and 27 DF, p-value: 1.434e-08
```

Видимо да се врло мало разликују вредности.

Пример (наставак).

```
> summary(model3)
```

```
Call:
lm(formula = Species ~ Elevation, data = gala)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-218.319  -30.721  -14.690   4.634  259.180
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 11.33511   19.20529   0.590   0.56
Elevation    0.20079    0.03465   5.795 3.18e-06 ***
```

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

```
Residual standard error: 78.66 on 28 degrees of freedom
Multiple R-squared:  0.5454,    Adjusted R-squared:  0.5291
F-statistic: 33.59 on 1 and 28 DF,  p-value: 3.177e-06
```

```
> summary(model4)
```

```
Call:
lm(formula = Species ~ Adjacent, data = gala)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
 -85.46  -71.41  -42.60   7.62  359.67
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 84.32743   22.27411   3.786 0.000744 ***
Adjacent     0.00347    0.02505   0.139 0.890831
```

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

```
Residual standard error: 116.6 on 28 degrees of freedom
Multiple R-squared:  0.0006847, Adjusted R-squared: -0.03501
F-statistic: 0.01918 on 1 and 28 DF,  p-value: 0.8908
```

На основу коефицијента детерминације видимо да је модел 4 потпуно бесмислен, а модел 3 доста лошији него када имамо оба предиктора.

```
Call:
lm(formula = Species ~ Area, data = gala)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-99.495  -53.431  -29.045   3.423  306.137
```

```
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 63.78286   17.52442   3.640 0.001094 **
Area         0.08196    0.01971   4.158 0.000275 ***
```

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

```
Residual standard error: 91.73 on 28 degrees of freedom
Multiple R-squared:  0.3817,    Adjusted R-squared:  0.3596
F-statistic: 17.29 on 1 and 28 DF,  p-value: 0.0002748
```

```
> anova(model6, model12)
```

Analysis of Variance Table

Model 1: Species ~ Area + Elevation + Adjacent

Model 2: Species ~ Elevation + Adjacent

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	26	96776				
2	27	100003	-1	-3227.3	0.8671	0.3603

Видимо да је променљива *Area* значајна у простом моделу, али када је додамо у модел 2 показује се да она не доноси нове информације у модел.