

# Analiza wariancji

Piotr J. Sobczyk

19 November 2016

Zaczniemy zajęcia od klasycznego przykładu czyli testu Studenta dla dwóch prób.

$$\begin{aligned}x_{1,i} &\sim N(\mu_1, \sigma^2), \quad i = 1, \dots, n_1 \\x_{2,i} &\sim N(\mu_2, \sigma^2), \quad i = 1, \dots, n_2 \\n_1 + n_2 &= n\end{aligned}$$

Weźmy dane o wzroście piłkarzy i koszykarzy.

```
library(dplyr)
library(ggplot2)
wzrost=read.csv2("wzrost.csv")
attach(wzrost)
```


Sprawdzamy założenie normalności

```
wzrost %>%
  group_by(Dyscyplina) %>%
  summarise(shapiro.test(Wzrost)$p.value)
```


```
## # A tibble: 2 × 2
##   Dyscyplina `shapiro.test(Wzrost)$p.value` 
##   <fctr>          <dbl>
## 1 b            0.31967963
## 2 f            0.01609424
```

Jak wyglądają dane?

```
ggplot(wzrost) +
  geom_histogram(aes(x=Wzrost), bins = 10) +
  facet_grid(Dyscyplina~.)
```



```
ggplot(wzrost, aes(sample=Wzrost)) +  
  stat_qq() +  
  facet_grid(Dyscyplina~.)
```



Sprawdzenie założenia o równości wariancji

```
var.test(Wzrost~Dyscyplina)
```

```
## 
## F test to compare two variances
## 
## data: Wzrost by Dyscyplina
## F = 0.73668, num df = 39, denom df = 44, p-value = 0.3343
## alternative hypothesis: true ratio of variances is not equal to 1
## 95 percent confidence interval:
##  0.3993554 1.3747946
## sample estimates:
## ratio of variances
## 0.7366753
```

I testowanie:

```
t.test(Wzrost~Dyscyplina)
```

```
## 
## Welch Two Sample t-test
## 
## data: Wzrost by Dyscyplina
## t = 3.7175, df = 82.907, p-value = 0.0003645
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
##  0.1275687 0.4211535
## sample estimates:
```

```

## mean in group b mean in group f
##          6.453250      6.178889

t.test(Wzrost~Dyscyplina,alternative="greater")

##
##  Welch Two Sample t-test
##
## data: Wzrost by Dyscyplina
## t = 3.7175, df = 82.907, p-value = 0.0001822
## alternative hypothesis: true difference in means is greater than 0
## 95 percent confidence interval:
##  0.1515952      Inf
## sample estimates:
## mean in group b mean in group f
##          6.453250      6.178889

t.test(Wzrost~Dyscyplina,alternative="greater",var.equal=TRUE)

##
##  Two Sample t-test
##
## data: Wzrost by Dyscyplina
## t = 3.6841, df = 83, p-value = 0.0002039
## alternative hypothesis: true difference in means is greater than 0
## 95 percent confidence interval:
##  0.1504837      Inf
## sample estimates:
## mean in group b mean in group f
##          6.453250      6.178889

```

Co zrobić gdybyśmy mieli dodatkowo baseballistów lub golfistów?

Porównania wielokrotne każda grupa przeciwko każdej? Problemem jest testowanie wielokrotne.

Pojedynczy t-test wykonywany jest na poziomie istotności  $p$ , równym np. 0.05. Ale przy wykonaniu serii testów nie możemy powiedzieć o wszystkich na raz, że p-stwo popełnienie błędu pierwszego rodzaju wynosi 0.05.

$$P(\text{odrzucenia jakiejkolwiek hipotezy} \mid \text{wszystkie są prawdziwe}) \leq \sum_i^k P(\text{odrzucenie i-tej hipotezy} \mid \text{i-ta hipoteza jest prawdziwa})$$

Już przy 10 testach (czyli 5 grupach) p-stwo błędu pierwszego rodzaju rośnie nam do 0.5! Do tego zagadnienia wróćmy później, ale zapamiętajmy póki co, że porównania wielokrotne rodzą problemy i wymagają od statystyka wyjątkowej uwagi.

## Analiza wariancji

Uproścmy sobie zatem nieco nasz problem, albo inaczej, dokonajmy bardzo konkretnej generalizacji testu Studenta. Zamiast badać wszystkie różnice między średnimi, spróbujmy zbadać czy wszystkie średnie są sobie równe.

Twarzyszyć nam będzie przykład wpływ analogów witaminy D na obecność antygenu CD14 u osób chorych na białaczkę. Dane pochodzą z pakietu **PBImisc**.

```

library(PBImisc)
data(AML)
?AML
summary(AML)

##      Mutation    CD14.control      CD14.D3      CD14.1906
## CBFbeta:15   Min.   : 4.93   Min.   : 1.00   Min.   : 2.00
##  FLT3   :14   1st Qu.:29.93   1st Qu.:30.70   1st Qu.:31.14
##  None   :18   Median :47.05   Median :54.27   Median :47.46
##  Other   :19   Mean   :45.67   Mean   :50.33   Mean   :49.04
##                  3rd Qu.:58.93   3rd Qu.:68.13   3rd Qu.:70.44
##                  Max.   :94.35   Max.   :98.43   Max.   :92.83
##      CD14.2191
##  Min.   : 1.80
##  1st Qu.:24.66
##  Median :46.05
##  Mean   :46.30
##  3rd Qu.:63.90
##  Max.   :99.32

```

Przyglądnijmy się bliżej analogowi 2191

```
AML$change.2191=AML$CD14.2191-AML$CD14.control
```

Interesuje nas czy mutacja, wpływa na change.2191, a więc czy ten konkretny analog jest bardziej odpowiedni dla którejś z mutacji


```

AML %>%
  group_by(Mutation) %>%
  summarise(mean(change.2191))

## # A tibble: 4 × 2
##      Mutation `mean(change.2191)`
##      <fctr>          <dbl>
## 1  CBFbeta       7.8140000
## 2    FLT3        0.8271429
## 3     None      -6.6805556
## 4    Other       1.7531579

ggplot(AML, aes(x=Mutation, y=change.2191)) +
  geom_boxplot()

```



A jak powiemy o tym w języku statystycznym? Mamy  $k$  prób

$$x_{j,i} \sim N(\mu_j, \sigma^2), i = 1, \dots, n_j, j = 1, \dots, k, n_1 + \dots + n_k = n$$

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k \text{ vs. } H_1 : \exists_{l,m} \mu_l \neq \mu_m$$

```
aov.change=aov(change.2191~Mutation-1, data=AML)
summary(aov.change)
```

```
##          Df Sum Sq Mean Sq F value Pr(>F)
## Mutation    4   1787   446.8   3.422 0.0136 *
## Residuals  62   8094   130.6
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

To działa jak model liniowy! Każdy współczynnik odpowiada innemu poziomowi zmiennej objaśniającej. Żeby lepiej to zrozumieć popatrzmy na macierz planu  $X$  w naszym modelu  $y \sim X\beta + \epsilon$ .

```
model.matrix(aov.change)[sample(1:66, 10),]
```

```
##      MutationCBFbeta MutationFLT3 MutationNone MutationOther
## 53            0           0         1           0
## 65            0           0         1           0
## 41            0           0         0           1
## 21            0           1         0           0
## 47            0           0         0           1
## 49            0           0         1           0
```

```

## 63          0          0          1          0
## 66          0          0          1          0
## 51          0          0          1          0
## 22          0          1          0          0

summary(lm(change.2191~Mutation, data=AML))

##
## Call:
## lm(formula = change.2191 ~ Mutation, data = AML)
##
## Residuals:
##    Min     1Q   Median     3Q    Max 
## -27.9394 -9.2113  0.3987  7.6766 20.9260 
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)    
## (Intercept)  7.814     2.950   2.649  0.010236 *  
## MutationFLT3 -6.987     4.246  -1.646  0.104924    
## MutationNone -14.495     3.995  -3.629 0.000578 *** 
## MutationOther -6.061     3.946  -1.536 0.129682    
## ---      
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 11.43 on 62 degrees of freedom
## Multiple R-squared:  0.1787, Adjusted R-squared:  0.1389 
## F-statistic: 4.495 on 3 and 62 DF,  p-value: 0.006427

```

Szczegóły na kursie z modeli liniowych, sprawdzamy czy są różnice w grupach. Jaka hipoteza zerowa?

```

summary(aov(change.2191~Mutation, data=AML))

##           Df Sum Sq Mean Sq F value Pr(>F)    
## Mutation      3   1761   586.9   4.495 0.00643 ** 
## Residuals    62   8094   130.6
## ---      
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Jest wpływ czy go nie ma?

```

anova(lm(change.2191~Mutation, data=AML))

## Analysis of Variance Table
##
## Response: change.2191
##           Df Sum Sq Mean Sq F value Pr(>F)    
## Mutation      3 1760.7  586.89   4.4955 0.006427 ** 
## Residuals    62 8094.1  130.55
## ---      
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
summary(lm(change.2191~Mutation, data=AML))

```

```

##
## Call:
## lm(formula = change.2191 ~ Mutation, data = AML)
##
## Residuals:

```

```

##      Min       1Q     Median      3Q      Max
## -27.9394 -9.2113   0.3987  7.6766 20.9260
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)    7.814     2.950   2.649 0.010236 *
## MutationFLT3   -6.987     4.246  -1.646 0.104924
## MutationNone  -14.495     3.995  -3.629 0.000578 ***
## MutationOther  -6.061     3.946  -1.536 0.129682
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 11.43 on 62 degrees of freedom
## Multiple R-squared:  0.1787, Adjusted R-squared:  0.1389
## F-statistic: 4.495 on 3 and 62 DF,  p-value: 0.006427

```

Jak można te wyniki interpretować?

Trzeba sprawdzić, czy spełnione są założenia. Na szczęście założeń jest mniej niż przy modelu liniowym

```
library(car)
```

```

##
## Attaching package: 'car'
##
## The following object is masked from 'package:dplyr':
## 
##     recode
leveneTest(y = AML$change.2191, group = AML$Mutation)

## Levene's Test for Homogeneity of Variance (center = median)
##          Df F value Pr(>F)
## group     3  0.3931 0.7584
##          62
lm(change.2191~Mutation, data=AML) -> change.lm
```

```
shapiro.test(change.lm$residuals)
```

```

##
## Shapiro-Wilk normality test
##
## data: change.lm$residuals
## W = 0.98394, p-value = 0.5513
```

Co dalej? Na jakie pytania możemy odpowiedzieć? Na przykład czy średnia globalna to 0. Zauważmy, że poprzednio mieliśmy k+1 parametrów (k-klas + intercept), a tylko k-wartości do dopasowania. Dlatego R domyślnie uznał pierwszą klasę za poziom referencyjny.

$$H_0 : \mu_1 = \mu_2 = \dots = \mu_k = 0 \text{ vs. } H_1 : \exists_l \mu_l \neq 0$$

```
summary(aov(change.2191~Mutation-1, data=AML))
```

```

##           Df Sum Sq Mean Sq F value Pr(>F)
## Mutation     4    1787    446.8   3.422 0.0136 *
## Residuals   62    8094    130.6
## ---
```

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

## Różnice między średnimi

Wróćmy do zagadnienia testowanie różnic między średnimi. Niech  $H_{0,i,j} : \mu_i = \mu_j$

$$P(\forall_{i,j} H_{0,i,j} \text{ nie odrzucona gdy prawdziwa}) = 1 - P(\exists i, j H_{0,i,j} \text{ odrzucona gdy prawdziwa})$$

Rozpiszmy dalej:

$$P(\exists i, j H_{0,i,j} \text{ odrzucona gdy prawdziwa}) \leq \sum_{i,j} P(H_{0,i,j} \text{ odrzucona gdy prawdziwa})$$

Zatem,

$$P(\forall_{i,j} H_{0,i,j} \text{ nie odrzucona gdy prawdziwa}) \geq 1 - \sum_{i,j} P(H_{0,i,j} \text{ odrzucona gdy prawdziwa})$$

Jeśli będziemy testować pojedynczą hipotezę na poziomie ufności

$$1 - \frac{\alpha}{\binom{k}{2}},$$

to szansa, że nie odrzucimy żadnej prawdziwej hipotezy zerowej wynosi  $1 - \alpha$ .

Czyli jeśli chcemy być ostrożni, to trudniej nam będzie odrzucać hipotezy zerowe. Jeśli się nad tym zastanowić, to nie może być inaczej. Powyższe rozumownie nazywa się korektą Bonferoniego. Każdy test wykonujemy na poziomie istotności  $\frac{\alpha}{m}$ , gdzie  $m$  jest liczbą testów. Są inne (lepsze) korekty: np. Sidaka, Holma. Ta ostatnia jest domyślnie stosowana przez R przy porównaniach wielokrotnych

```
pairwise.t.test(AML$change.2191, AML$Mutation)
```

```
##
##  Pairwise comparisons using t tests with pooled SD
##
## data:  AML$change.2191 and AML$Mutation
##
##      CBFbeta  FLT3    None
##  FLT3  0.3148  -     -
##  None   0.0035  0.2799  -
##  Other  0.3148  0.8188  0.1420
##
##  P value adjustment method: holm
```

Zauważmy na marginesie, że problem wielokrotnego testowania dotyczy także p-wartości dla współczynników w regresji liniowej. Jeśli chcemy wypowiadać się na temat wszystkich współczynników na raz, wykonujemy wielokrotne testowanie i powinniśmy wziąć odpowiednią korektę.

```
tmp=summary(lm(change.2191~Mutation-1, data=AML))
tmp$coefficients[,4]
```

```
## MutationCBFbeta    MutationFLT3    MutationNone    MutationOther
##          0.01023632      0.78739359      0.01584360      0.50609397
```

```

p.adjust(tmp$coefficients[,4])

## MutationCBFbeta    MutationFLT3    MutationNone    MutationOther
##      0.04094528     1.00000000     0.04753080     1.00000000

```

Dla analizy wariancji możemy jednak zrobić trochę lepsze porównania. Jedna z metod nazywa się „testem uczciwych rzeczywistych różnic” (Honest Significant Differences) Tukeya.

```

TukeyHSD(aov(change.2191~Mutation-1, data=AML))

```

```

##   Tukey multiple comparisons of means
##   95% family-wise confidence level
##
## Fit: aov(formula = change.2191 ~ Mutation - 1, data = AML)
##
## $Mutation
##             diff      lwr      upr      p adj
## FLT3-CBFbeta -6.986857 -18.196705 4.222991 0.3611805
## None-CBFbeta -14.494556 -25.040500 -3.948611 0.0031652
## Other-CBFbeta -6.060842 -16.479875 4.358191 0.4227192
## None-FLT3     -7.507698 -18.257120 3.241723 0.2629856
## Other-FLT3     0.926015 -9.698926 11.550956 0.9956627
## Other-None      8.433713 -1.488263 18.355690 0.1228184


```

```

plot(TukeyHSD(aov(change.2191~Mutation-1, data=AML)))

```

### 95% family-wise confidence level



Na wykresie mamy przedziały ufności na różnicie między grupami z uwzględnioną korektą na wielokrotne testowanie.

## Analiza wariancji wielokrotna

Co się dzieje kiedy mamy więcej niż jedną zmienną kategoryczną objaśniającą? Znowu szczegółowo na kursie z modeli liniowych, ale zasada jest dokładnie taka sama.

$$y_{ijm} \sim N(\mu_{ij}, \sigma^2), i = 1, \dots, k, j = 1, \dots, r, m = 1, \dots, n_{ij}$$

Równoważnie,

$$y_{ijm} = \mu_{ij} + \epsilon_{ijm} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \epsilon_{ijm}, i = 1, \dots, k, j = 1, \dots, r, m = 1, \dots, n_{ij}$$

Znowu liczba parametrów jest zbyt duża, w R domyślnie przyjmujemy:

$$\alpha_1 = 0, \beta_1 = 0, \forall_i \gamma_{1,i}, \forall_j \gamma_{j,1}$$

Jakie hipotezy możemy testować?

- o braku interakcji  $H_0 : \forall_{i,j} \gamma_{ij} = 0$  vs.  $H_1 : \exists_{i,j} \gamma_{ij} \neq 0$
- o braku efektu pierwszej zmiennej  $H_0 : \forall_i \alpha_i = 0$  vs.  $H_1 : \exists_i \alpha_i \neq 0$
- o braku efektu drugiej zmiennej  $H_0 : \forall_j \beta_j = 0$  vs.  $H_1 : \exists_j \beta_j \neq 0$

## Przykład

Zbiór danych zawiera informacje o pacjentkach pewnego oddziału dla osób chorych psychicznych.

- dr** to digit ratio - średnia arytmetyczna stosunku długości palca wskazującego do długości palca serdecznego w lewej i prawej dłoni.
- c** to oznaczenie (grupy zaburzeń psychicznych)[[https://pl.wikipedia.org/wiki/Zaburzenia\\_psychiczne#Podzia.C5.82\\_zaburze.C5.84\\_psychicznych\\_wed.C5.82ug\\_klasifikacji\\_ICD-10](https://pl.wikipedia.org/wiki/Zaburzenia_psychiczne#Podzia.C5.82_zaburze.C5.84_psychicznych_wed.C5.82ug_klasifikacji_ICD-10)]. A to zaburzenia F00-F29, B to zaburzenia F30-F99.
- as** to rodzaj asymetrii twarzy pacjentek.

```
palce=read.table("palce.csv",sep=";",dec=",",head=TRUE)
attach(palce)
head(palce)
```

```
##      dr   as   ch
## 1 0.97    S    A
## 2 1.00    S    A
## 3 0.97   PA   B
## 4 1.02   PA   B
## 5 1.02   PA   A
## 6 0.96  LA   A
```

Jednoczynnikowa analiza wariancji raz jeszcze

```
m1=lm(dr~as)
head(model.matrix(m1))
```

```
## (Intercept) asPA asS
## 1           1   0   1
## 2           1   0   1
## 3           1   1   0
## 4           1   1   0
## 5           1   1   0
## 6           1   0   0
```

```

summary(m1)

##
## Call:
## lm(formula = dr ~ as)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -0.078889 -0.019474  0.002654  0.021111  0.070526
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept) 0.985217  0.006801 144.854 <2e-16 ***
## asPA        0.003671  0.010265  0.358   0.722
## asS         0.004256  0.010112  0.421   0.675
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.03262 on 57 degrees of freedom
## Multiple R-squared:  0.003728, Adjusted R-squared:  -0.03123
## F-statistic: 0.1066 on 2 and 57 DF, p-value: 0.899

sum(m1$residuals^2)

## [1] 0.06064643

sum(lm(dr~1)$residuals^2)

## [1] 0.06087333

anova(lm(dr~1),m1)

## Analysis of Variance Table
##
## Model 1: dr ~ 1
## Model 2: dr ~ as
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1     59 0.060873
## 2     57 0.060646  2 0.00022691 0.1066  0.899

anova(m1)

## Analysis of Variance Table
##
## Response: dr
##             Df   Sum Sq   Mean Sq F value Pr(>F)
## as          2 0.000227 0.00011345  0.1066  0.899
## Residuals 57 0.060646 0.00106397

anova(lm(dr~ch))

## Analysis of Variance Table
##
## Response: dr
##             Df   Sum Sq   Mean Sq F value Pr(>F)
## ch          1 0.000934 0.00093444  0.9042 0.3456
## Residuals 58 0.059939 0.00103343

```

```

summary(lm(dr~ch))

##
## Call:
## lm(formula = dr ~ ch)
##
## Residuals:
##    Min     1Q   Median     3Q    Max
## -0.08250 -0.02250 -0.00250  0.02556  0.07556
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept) 0.984444  0.005358 183.739 <2e-16 ***
## chB         0.008056  0.008471   0.951   0.346
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.03215 on 58 degrees of freedom
## Multiple R-squared:  0.01535, Adjusted R-squared:  -0.001626
## F-statistic: 0.9042 on 1 and 58 DF, p-value: 0.3456

t.test(dr~ch,var.equal=TRUE)

##
## Two Sample t-test
##
## data: dr by ch
## t = -0.9509, df = 58, p-value = 0.3456
## alternative hypothesis: true difference in means is not equal to 0
## 95 percent confidence interval:
## -0.025013058 0.008901947
## sample estimates:
## mean in group A mean in group B
##          0.9844444        0.9925000

```

### Dwuczynnikowa analiza wariancji

```

m2=lm(dr~as+ch)
head(model.matrix(m2))

## (Intercept) asPA assS chB
## 1           1   0   1   0
## 2           1   0   1   0
## 3           1   1   0   1
## 4           1   1   0   1
## 5           1   1   0   0
## 6           1   0   0   0

anova(m2)

## Analysis of Variance Table
##
## Response: dr
##              Df  Sum Sq  Mean Sq F value Pr(>F)
## as            2 0.000227 0.00011345  0.1071 0.8987

```

```
## ch           1 0.001303 0.00130300  1.2296 0.2722
## Residuals  56 0.059343 0.00105970
```

Można porównywać modele zagnieżdżone

```
anova(lm(dr~as),m2)
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ as
## Model 2: dr ~ as + ch
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      57 0.060646
## 2      56 0.059343  1 0.001303 1.2296 0.2722
```

```
anova(lm(dr~1),lm(dr~as))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ 1
## Model 2: dr ~ as
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      59 0.060873
## 2      57 0.060646  2 0.00022691 0.1066 0.899
## anova(lm(dr~as+ch))
```

```
## Analysis of Variance Table
##
## Response: dr
##             Df  Sum Sq  Mean Sq F value Pr(>F)
## as          2 0.000227 0.00011345  0.1071 0.8987
## ch          1 0.001303 0.00130300  1.2296 0.2722
## Residuals  56 0.059343 0.00105970
```

```
anova(lm(dr~1),lm(dr~as),lm(dr~as+ch))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ 1
## Model 2: dr ~ as
## Model 3: dr ~ as + ch
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      59 0.060873
## 2      57 0.060646  2 0.00022691 0.1071 0.8987
## 3      56 0.059343  1 0.00130300 1.2296 0.2722
```

Za pomocą funkcji **anova** możemy porównywać jedynie modele zagnieżdżone

```
anova(lm(dr~ch),lm(dr~as)) # tak nie wolno!!!
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ ch
## Model 2: dr ~ as
##   Res.Df   RSS Df Sum of Sq F Pr(>F)
## 1      58 0.059939
## 2      57 0.060646  1 -0.00070754
```

Coś sie liczy, ale nie ma on sensu, nie możemy wnioskować na tej podstawie

Decyzję, o tym czy chcemy dodać, odjąć zmienną możemy podjąć na podstawie wartości kryterium informacyjnego (więcej na ten temat w kolejnych tygodniach zajęć).

```
anova(lm(dr~as),lm(dr~as+ch))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ as
## Model 2: dr ~ as + ch
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      57 0.060646
## 2      56 0.059343  1  0.001303 1.2296 0.2722
```

```
anova(lm(dr~ch),lm(dr~as+ch))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ ch
## Model 2: dr ~ as + ch
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      58 0.059939
## 2      56 0.059343  2  0.00059546 0.281 0.7561
drop1(lm(dr~as+ch),test="F")
```

```
## Single term deletions
##
## Model:
## dr ~ as + ch
##   Df Sum of Sq   RSS   AIC F value Pr(>F)
## <none>          0.059343 -407.13
## as     2 0.00059546 0.059939 -410.53  0.2810 0.7561
## ch     1 0.00130300 0.060646 -407.82  1.2296 0.2722
```

```
anova(lm(dr~1),lm(dr~as))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ 1
## Model 2: dr ~ as
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      59 0.060873
## 2      57 0.060646  2  0.00022691 0.1066  0.899
```

```
anova(lm(dr~1),lm(dr~ch))
```

```
## Analysis of Variance Table
##
## Model 1: dr ~ 1
## Model 2: dr ~ ch
##   Res.Df   RSS Df Sum of Sq    F Pr(>F)
## 1      59 0.060873
## 2      58 0.059939  1 0.00093444 0.9042 0.3456
add1(lm(dr~1),scope=~as+ch,test="F")
```

```
## Single term additions
```

```

## 
## Model:
## dr ~ 1
##      Df  Sum of Sq      RSS      AIC F value Pr(>F)
## <none>          0.060873 -411.60
## as      2 0.00022691 0.060646 -407.82  0.1066 0.8990
## ch      1 0.00093444 0.059939 -410.53  0.9042 0.3456

```

### Dwuczynnikowa analiza wariancji z interakcjami

```

m3=lm(dr~as*ch) # alternatywnie: lm(dr~as+ch+as:ch)
head(model.matrix(m3))

```

```

##   (Intercept) asPA asS chB asPA:chB asS:chB
## 1           1   0   1   0       0       0
## 2           1   0   1   0       0       0
## 3           1   1   0   1       1       0
## 4           1   1   0   1       1       0
## 5           1   1   0   0       0       0
## 6           1   0   0   0       0       0
drop1(m3,test="F")

```

## Single term deletions

```

## 
## Model:
## dr ~ as * ch
##      Df  Sum of Sq      RSS      AIC F value Pr(>F)
## <none>          0.058931 -403.54
## as:ch  2 0.00041288 0.059343 -407.13  0.1892 0.8282
anova(lm(dr~as+ch),lm(dr~as*ch))

```

```

## Analysis of Variance Table
## 
## Model 1: dr ~ as + ch
## Model 2: dr ~ as * ch
##      Res.Df      RSS Df  Sum of Sq      F Pr(>F)
## 1     56 0.059343
## 2     54 0.058931  2 0.00041288 0.1892 0.8282
step(m3)

```

```

## Start:  AIC=-403.54
## dr ~ as * ch
## 
##      Df  Sum of Sq      RSS      AIC
## - as:ch  2 0.00041288 0.059343 -407.13
## <none>          0.058931 -403.54
## 
## Step:  AIC=-407.13
## dr ~ as + ch
## 
##      Df  Sum of Sq      RSS      AIC
## - as    2 0.00059546 0.059939 -410.53
## - ch    1 0.00130300 0.060646 -407.82

```

```

## <none>          0.059343 -407.13
##
## Step: AIC=-410.53
## dr ~ ch
##
##       Df  Sum of Sq      RSS      AIC
## - ch     1 0.00093444 0.060873 -411.60
## <none>           0.059939 -410.53
##
## Step: AIC=-411.6
## dr ~ 1

##
## Call:
## lm(formula = dr ~ 1)
##
## Coefficients:
## (Intercept) 0.9877
step(lm(dr~1),scope=~as*ch)

## Start: AIC=-411.6
## dr ~ 1
##
##       Df  Sum of Sq      RSS      AIC
## <none>           0.060873 -411.60
## + ch     1 0.00093444 0.059939 -410.53
## + as     2 0.00022691 0.060646 -407.82

##
## Call:
## lm(formula = dr ~ 1)
##
## Coefficients:
## (Intercept) 0.9877

```

### Sprawdzanie założeń modelu m3

normalność


```

m3$residuals->e
shapiro.test(e)

##
##  Shapiro-Wilk normality test
##
## data: e
## W = 0.98207, p-value = 0.5219
qqnorm(e)


```

### Normal Q-Q Plot



```
hist(e)
```

### Histogram of e



homoskedastyczność

```
bartlett.test(dr~as)

##
##  Bartlett test of homogeneity of variances
##
## data: dr by as
## Bartlett's K-squared = 1.2857, df = 2, p-value = 0.5258

bartlett.test(dr~ch)

##
##  Bartlett test of homogeneity of variances
##
## data: dr by ch
## Bartlett's K-squared = 0.33422, df = 1, p-value = 0.5632

bartlett.test(dr~paste(as,ch))

##
##  Bartlett test of homogeneity of variances
##
## data: dr by paste(as, ch)
## Bartlett's K-squared = 4.2924, df = 5, p-value = 0.5081
```