

10. WERYFIKACJA HIPOTEZ

Definicja. *Hipotezę statystyczną* nazywamy przypuszczenie, dotyczące nieznanego rozkładu badanej cechy populacji, o prawdziwości lub fałszywości którego wnioskuje się na podstawie pobranej próby.

Przykład 10.1.

1. *Wysuwamy hipotezę, że badana cecha ma rozkład normalny.*
2. *Wiemy, że badana cecha ma rozkład normalny o nieznannej wartości średniej μ i znanym odchyleniu standardowym $\sigma = 1$. Wysuwamy hipotezę, że $\mu = 5$.*
3. *Dane są dwa zbiory obserwacji, np. wysokości plonów uzyskane podczas nawożenia nawozem A i nawozem B.*
 - (a) *Wysuwamy hipotezę, że oba zbiory można traktować jako pochodzące z populacji o tym samym rozkładzie.*
 - (b) *Z wcześniejszych badań wiemy, że zbiory te można traktować jako pochodzące z populacji o rozkładach normalnych odpowiednio $\mathcal{N}(\mu_1, \sigma_1^2)$ i $\mathcal{N}(\mu_2, \sigma_2^2)$, gdzie parametry μ_1, μ_2, σ_1 i σ_2 są nieznanne, ale takie, że $\sigma_1 = \sigma_2$. Wysuwamy przypuszczenie, że średnia wartość plonów przy nawożeniu nawozem A jest większa niż średnia wartość plonów przy nawożeniu nawozem B (tzn. że $\mu_1 > \mu_2$).*

Definicja. Hipotezy, które dotyczą wyłącznie wartości parametru lub parametrów rozkładu badanej cechy nazywamy *hipotezami parametrycznymi*. Hipotezy, które nie są hipotezami parametrycznymi nazywamy *hipotezami nieparametrycznymi*.

W przykładzie 10.1 hipotezy 2 i 3(b) są parametryczne, natomiast hipotezy 1 i 3(a) są nieparametryczne.

Definicja. *Hipotezę prostą* nazywamy hipotezę, która jednoznacznie określa rozkład badanej cechy. *Hipotezę złożoną* nazywamy hipotezę, która określa całą grupę rozkładów.

Hipoteza 2 z przykładu 10.1 jest hipotezą prostą. Pozostałe hipotezy w tym przykładzie są złożone.

W praktyce rozważamy dwie hipotezy: *hipotezę zerową* (będziemy ją oznaczać H_0) i *hipotezę alternatywną* (tą będziemy oznaczać H_1). Jeśli odrzucamy hipotezę zerową, to przyjmujemy hipotezę alternatywną i na odwrót.

Przykład 10.2. Wiemy, że wysokość plonów przy nawożeniu starą metodą ma rozkład normalny o wartości średniej 5 i wariancji 1: $\mathcal{N}(5, 1)$ i że wysokość plonów przy nawożeniu nową metodą ma rozkład normalny o tej samej wariancji $\sigma^2 = 1$ ale o nieznannej wartości średniej μ : $\mathcal{N}(\mu, 1)$. Chcemy sprawdzić czy nowa metoda zwiększyła średnią wysokość plonów.

W tym celu będziemy testować $H_0 : \mu = 5$ przeciwko $H_1 : \mu > 5$.

Przeprowadzamy eksperyment losowy. Wynik takiego eksperymentu to próba czyli wektor losowy $\mathbb{X} = (X_1, X_2, \dots, X_n)$ o wartościach w \mathbb{R}^n .

Definicja. Statystyką testową nazywamy funkcję próby $\delta(X_1, X_2, \dots, X_n)$, która służy do weryfikacji H_0 przeciwko H_1 . Zbiór wszystkich możliwych wartości funkcji δ dzielimy na dwa rozłączne zbiory W i W' takie, że:

- jeśli $\delta(x_1, x_2, \dots, x_n) \in W$, to H_0 odrzucamy,
- jeśli $\delta(x_1, x_2, \dots, x_n) \in W'$, to H_0 przyjmujemy.

W nazywamy *zbiorem krytycznym testu* (zbiorem odrzuceń H_0).

Musimy dobrze skonstruować statystykę testową i rozsądnie dobrać zbiór krytyczny, tak by podejmować decyzje zgodne z rzeczywistością. Jednak, ponieważ decyzje podejmujemy jedynie na podstawie próby, nie mamy całkowitej informacji o badanej populacji i w związku z tym zawsze jesteśmy narażeni na popełnienie błędu - podjęcie decyzji niezgodnej z rzeczywistością. Dokładniej, możemy popełnić jeden z dwóch błędów:

1. odrzucić H_0 w sytuacji, gdy jest ona prawdziwa (tzw. *błąd pierwszego rodzaju*);
2. przyjąć H_0 w sytuacji, gdy jest ona fałszywa (tzw. *błąd drugiego rodzaju*).

Definicja. *Poziom istotności testu*, oznaczany α , gdzie $\alpha \in (0, 1)$, to kres górny wszystkich możliwych wartości prawdopodobieństwa błędu I-go rodzaju. Dokładniej, jeśli $H_0 : \theta \in \Theta_0$, to

$$\alpha = \sup_{\theta \in \Theta_0} P(\text{test odrzuci } H_0, \text{ gdy testowany parametr ma wartość } \theta)$$

$$\stackrel{\text{ozn.}}{=} \sup_{\theta \in \Theta_0} P(\text{test odrzuci } H_0 | \theta).$$

Zwyczajowo przyjmuje się $\alpha = 0,01$ lub $\alpha = 0,05$, czasami $\alpha = 0,1$.

Chcielibyśmy by prawdopodobieństwa błędów pierwszego i drugiego rodzaju były jak najmniejsze. Niestety, gdy przy ustalonej statystyce testowej, zmieniamy W tak by malał błąd pierwszego rodzaju, to błąd drugiego rodzaju rośnie i na odwrót. Jedną z metod konstrukcji dobrego testu jest ustalenie poziomu istotności $\alpha \in (0, 1)$, a następnie taki dobór testu by zminimalizować prawdopodobieństwo błędu II-go rodzaju. Takie podejście (jeśli tylko dla danego problemu testowania jest wykonalne) gwarantuje, że zminimalizujemy wartość błędu drugiego rodzaju, jednak nie będziemy wiedzieć do jakiego poziomu. Informację o tym uzyskamy analizując tzw. moc testu.

Definicja. *Moc testu* parametrycznego to funkcja zmiennej θ (gdzie θ to badany parametr) dana wzorem

$$\beta(\theta) = P(\text{test odrzuci } H_0 | \theta), \text{ tzn.}$$

$$\beta(\theta) = P(\text{test odrzuci } H_0, \text{ gdy testowany parametr ma wartość } \theta).$$

W szczególności, jeśli $H_0 : \theta \in \Theta_0$, to

- dla $\theta_0 \in \Theta_0$ mamy

$$\begin{aligned} \beta(\theta_0) &= P(\text{test odrzuci } H_0 | \theta_0) = P(\text{test odrzuci } H_0 | H_0) = \\ &= \text{prawdopodobieństwo błędu pierwszego rodzaju;} \end{aligned}$$

- dla $\theta_1 \notin \Theta_0$ mamy

$$\begin{aligned} \beta(\theta_1) &= P(\text{test odrzuci } H_0 | \theta_1) = P(\text{test odrzuci } H_0 | H_1) = \\ &= 1 - P(\text{test odrzuci } H_1 | H_1) = \\ &= 1 - \text{prawdopodobieństwo błędu drugiego rodzaju.} \end{aligned}$$

Definicja. Najmniejszy poziom istotności, przy którym zaobserwowana wartość statystyki testowej prowadzi do odrzucenia H_0 , nazywamy *p-wartością* (*p-value*) przeprowadzonego testu. Tzn.

$$\begin{aligned} p\text{-value} \leq \alpha &\Rightarrow \text{odrzucaamy } H_0, \\ p\text{-value} > \alpha &\Rightarrow \text{przyjmujemy } H_0. \end{aligned}$$

UWAGA! Do wyników testowania statystycznego powinniśmy podchodzić z pewną rezerwą, zwłaszcza, gdy hipoteza alternatywna H_1 jest złożona. Jeśli statystyka testowa nie wpadnie do zbioru krytycznego, to stwierdzamy, że nie ma podstaw do odrzucenia H_0 , co jeszcze nie oznacza, że H_0 należy uznać za prawdziwą.

Dalej skupimy się na testach statystycznych dla pojedynczej próby, dotyczących średniej i wariancji. Interesujące nas testy zostały zebrane w pliku *Wzory ze statystyki*. Przeanalizujemy teraz parę przykładów ich zastosowania.

Przykład 10.3. Czas montowania bębna w pralce jest zmienną losową o rozkładzie normalnym z odchyleniem standardowym równym pół minuty. Norma techniczna przewiduje na tę czynność 6 minut. Wśród załogi panuje jednak przekonanie, że ten normatywny czas jest zbyt krótki. Zmierzono czas montowania bębna przez 6 losowo wybranych robotników i otrzymano następujące wyniki (w minutach): 6.2, 7.1, 6.3, 5.9, 5.5, 7.0. Na poziomie istotności 0,05 stwierdzić czy przekonanie załogi jest słuszne.

Rozwiązanie przykładu 10.3:

Oznaczmy: X - czas montowania bębna w pralce. Z treści zadania wiemy, że X ma rozkład normalny ze znanym odchyleniem standardowym: $\sigma = 0,5$ min. Zapisujemy to natępująco

$$X \sim \mathcal{N}(\mu, \sigma^2), \text{ gdzie } \mu \text{ nieznane, zaś } \sigma = 0,5.$$

Interesuje nas weryfikacja

$$H_0 : \mu = 6 \text{ min}$$

przeciwko

$$H_1 : \mu > 6 \text{ min.}$$

Widzimy, że do analizowanego problemu pasuje model oznaczony jako model I w tabeli Weryfikacje hipotez dotyczących wartości średniej. Aby przeprowadzić opisany tam test, wyznaczmy wartość statystyki testowej i zbiór krytyczny a następnie sprawdzimy czy statystyka testowa należy do zbioru krytycznego. Zaczniemy od statystyki testowej:

$$U = \frac{\bar{X} - \mu_0}{\sigma} \sqrt{n}.$$

Obliczenia przeprowadzimy w R:

```
> czas <- c( 6.2, 7.1, 6.3, 5.9, 5.5, 7.0)
> (mean(czas)-6)/0.5*sqrt(6)
```

Otrzymujemy $u \approx 1,633$. Teraz przejdźmy do wyznaczenia zbioru krytycznego:

$$W = \langle u_{1-\alpha}; +\infty \rangle.$$

Mamy poziom istotności $\alpha = 0,05$, stąd $1 - \alpha = 0,95$ i $u_{1-\alpha} = u_{0,95}$:

```
> qnorm(0.95)
```

Otrzymujemy $u_{1-\alpha} \approx 1,645$, co daje $W \approx \langle 1,645; +\infty \rangle$. Pozostaje wyciągnąć wnioski.

$$u \approx 1,633 \notin W \approx \langle 1,645; +\infty \rangle \Rightarrow \text{brak podstaw do odrzucenia } H_0.$$

Przekonanie załogi nie jest słuszne.

Przykład 10.4. Dział kontroli jakości w zakładach chemicznych chce oszacować średnią wagę proszku do prania sprzedawanego w pudełkach o nominalnej wadze 3 kg. Pobrano w tym celu próbkę losową 7 pudełek i otrzymano wyniki (w kg): 2.93, 2.97, 3.05, 2.91, 3.02, 2.87, 2.92. Wiadomo, że rozkład wagi pudełka proszku do prania jest normalny.

(a) Czy na poziomie istotności 0,05 można twierdzić, że faktyczna średnia waga pudełka proszku do prania jest mniejsza niż 3 kg?

(b) Zakładając, że rzeczywista średnia waga pudełka proszku do prania wynosi 2,9 kg, wyznaczyć prawdopodobieństwo, że przeprowadzając test na poziomie istotności 0,05 i na podstawie 7 obserwacji, błędnie uznamy, że średnia waga pudełka jest zgodna z podaną na pudełku.

(c) Jak liczną próbkę trzeba by pobrać, by przeprowadzony test (na poziomie istotności 0,05), w sytuacji, gdy rzeczywista średnia waga pudełka proszku do prania wynosi 2,9 kg, odrzucił hipotezę, że średnia waga pudełka jest zgodna z podaną na pudełku, z prawdopodobieństwem nie mniejszym niż 0,9.

Rozwiązanie przykładu 10.4:

Oznaczmy: X -waga proszku do prania. Z treści zadania wiemy, że X ma rozkład normalny, ale parametrów tego rozkładu nie znamy. Zapisujemy to natępująco

$$X \sim \mathcal{N}(\mu, \sigma^2), \text{ gdzie } \mu \text{ i } \sigma \text{ są nieznane.}$$

Stąd widzimy, że będzie nam pasować model oznaczony jako model II w tabeli Weryfikacje hipotez dotyczących wartości średniej.

Wpisujemy dane do R:

```
> waga.proszku <- c(2.93, 2.97, 3.05, 2.91, 3.02, 2.87, 2.92)
```

(a) Stawiamy hipotezy:

$$H_0 : \mu = 3 \text{ kg}$$

$$H_1 : \mu < 3 \text{ kg}$$

Do weryfikacji H_0 przeciwko H_1 użyjemy `t.test`:

```
> t.test(x=waga.proszku, alternative="less", mu=3)
```

$$p\text{-value} = 0,04952 < \alpha = 0,05 \Rightarrow \text{odrzucaamy } H_0.$$

Zatem uznajemy, że rzeczywiście faktyczna średnia waga pudełka proszku do prania jest mniejsza niż 3 kg.

Powyższy test można przeprowadzić także w inny sposób: wyznaczając wartość statystyki testowej i zbiór krytyczny oraz sprawdzając czy statystyka testowa należy do zbioru krytycznego. Zaczniemy od statystyki testowej:

$$T = \frac{\bar{X} - \mu_0}{s} \sqrt{n},$$

gdzie \bar{X} to średnia z próby, s to odchylenie standardowe z próby, zaś n to liczność próby. Do rachunków użyjemy R:

> (mean(waga.proszku)-3)/sd(waga.proszku)*sqrt(7)

Otrzymujemy $t \approx -1,95$. Przechodzimy do wyznaczenia zbioru krytycznego W :

$$W = (-\infty; -t_{1-\alpha, n-1}),$$

gdzie $\alpha = 0,05$ to poziom istotności, co daje $1 - \alpha = 0,95$. Kwantyl $t_{1-\alpha, n-1}$ wyznaczymy przy pomocy R:

> qt(0.95, 7-1)

Mamy $t_{1-\alpha, n-1} \approx 1,943$, co daje $W \approx (-\infty; -1,943)$. Widzimy, że

$$t \approx -1,95 \in W \approx (-\infty; -1,943),$$

więc odrzucamy H_0 i stwierdzamy, że faktyczna średnia waga pudełka proszku do prania jest mniejsza niż 3 kg.

(b) Zakładamy, że $\mu = \mu_1 = 2,9$. Przy tym założeniu chcemy policzyć prawdopodobieństwo, że uznamy, że średnia waga pudełka jest zgodna z podaną na pudełku. Zatem szukamy prawdopodobieństwa, że przyjmujemy H_0 w sytuacji, gdy wartość badanego parametru to 2,9:

$$P(\text{przyjmujemy } H_0 | \mu = 2,9) = ?$$

Przypomnijmy, że

$$\text{moc.testu}(\beta) = P(\text{odrzućmy } H_0 | \text{badany parametr} = \beta).$$

Stąd

$$P(\text{przyjmujemy } H_0 | \mu = 2,9) = 1 - P(\text{odrzućmy } H_0 | \mu = 2,9) = 1 - \text{moc.testu}(2,9).$$

Użyjemy funkcji `power.t.test()`, która jest związana z mocą t -testu. Ma ona następujące argumenty:

- `power` - moc testu,
- `n` - liczność próby,
- `delta` = $|\mu_0 - \mu_1|$,
- `sd` - odchylenie standardowe badanej cechy (tutaj wagi pudełka proszku do prania), nie znamy go, więc go przybliżamy odchyleniem standardowym z próby, mając jednak świadomość, że doprowadzi to nas do wyniku przybliżonego; argument `sd` jest domyślnie ustawiony na 1,
- `sig.level` - poziom istotności testu, domyślnie ustawiony na 0.05,
- `type` - mamy do wyboru `type="one.sample"`, `"two.sample"` lub `"paired"`; na razie zajmujemy się testami dla jednej populacji, więc wybieramy `"one.sample"`,

- `alternative` - mamy do wyboru `alternative="one.sided"` lub `"two.sided"`:
 - `"one.sided"` używamy, gdy H_1 jest postaci $H_1 : \mu < \mu_0$ lub $H_1 : \mu > \mu_0$,
 - `"two.sided"` używamy, gdy H_1 jest postaci $H_1 : \mu \neq \mu_0$.

Jeden z pięciu pierwszych wyżej wymienionych argumentów funkcji `power.t.test()` musimy zostawić pusty i właśnie ten argument zostanie wyliczony. Chcąc wyznaczyć `sd` lub `sig.level` należy napisać `sd=NULL` lub odpowiednio `sig.level=NULL`, aby do tych argumentów nie została automatycznie przypisana ich wartość domyślna.

W celu rozwiązania naszego problemu napiszemy ($\text{delta} = |\mu_0 - \mu_1| = |3 - 2,9| = 0,1$):

```
> power.t.test(n=7,delta=0.1,sd=sd(waga.proszku),sig.level=0.05,
               type="one.sample",alternative="one.sided")
```

R wypisze podane przez nas wartości argumentów i wyliczoną wartość mocy testu (`power`). Aby uzyskać szukane prawdopodobieństwo musimy od 1 odjąć wyliczoną wartość mocy testu. Możemy to zrobić automatycznie pisząc

```
> 1-power.t.test(n=7,delta=0.1,sd=sd(waga.proszku),sig.level=0.05,
                 type="one.sample",alternative="one.sided")$power
```

Otrzymujemy 0,0241. Jest to prawdopodobieństwo przyjęcia $H_0 : \mu = 3$ kg w sytuacji, gdy $\mu = 2,9$ kg czyli prawdopodobieństwo popełnienia błędu. Zatem dobrze, że jest całkiem małe.

(c) Nadal zakładamy, że $\mu = \mu_1 = 2,9$. Przy tym założeniu szukamy n takiego by prawdopodobieństwo odrzucenia H_0 było nie mniejsze niż 0,9:

$$\text{szukamy } n \text{ takiego by } P(\text{odrzućmy } H_0 | \mu = 2,9) \geq 0,9$$

czyli

$$\text{szukamy } n \text{ takiego by } \text{moc.testu}(2,9) \geq 0,9.$$

Użyjemy funkcji funkcji `power.t.test()`:

```
> power.t.test(power=0.9, delta=0.1, sd=sd(waga.proszku),
               sig.level=0.05, type="one.sample",
               alternative="one.sided")
```

Otrzymujemy $n = 5,186$ co oznacza, że potrzebujemy próbkę o liczności $n = 6$ (zaokrąglamy do góry, aby moc testu nie spadła poniżej 0,9).

Przykład 10.5. Ogrodnik ma 5000 nasion białych i czerwonych tulipanów. Chciałby wiedzieć jaki procent owych nasion to nasiona tulipanów białych. Nasiona te przeznaczone są do sprzedaży, więc nie może ich wszystkich wysiać i sprawdzić, ile z nich zakwitnie na biało. Wybrał zatem losowo 100 nasion, posiał je i okazało się, że 13 z nich ma białe kwiaty.

(a) Czy na poziomie istotności 0,01 ogrodnik może stwierdzić, że nasiona białych tulipanów stanowią 10% wszystkich nasion?

(b) Czy zmieni się odpowiedź w punkcie (a) jeśli ogrodnik posieje jedynie 10 nasion i 2 z nich wykiełkują na biało?

Rozwiązanie przykładu 10.5:

Dane nasiono może być nasieniem tulipana białego lub czerwonego. Mamy zatem do czynienia z rozkładem dwupunktowym. Oznaczmy:

$$X = \begin{cases} 1 & \text{jeśli wybrane nasiono to nasiono białego tulipana,} \\ 0 & \text{jeśli wybrane nasiono to nasiono czerwonego tulipana,} \end{cases}$$

zaś p niech będzie prawdopodobieństwem trafienia na nasiono tulipana białego, tzn. $p = P(X = 1)$.

(a) $\hat{p} = \frac{k}{n} = \frac{\text{liczba sukcesów}}{\text{liczba prób}} = \frac{13}{100} = 0,13$. Sukcesem jest wylosowanie nasiona tulipana białego, bo oznaczyliśmy że $X = 1$ właśnie wtedy, gdy wybrane nasiono to nasiono białego tulipana.

Teraz szukamy w tabeli zatytuowanej Weryfikacje hipotez dotyczących wartości średniej, modelu, który pasuje do naszej sytuacji. Jest to model oznaczony numerem IV. Stawiamy hipotezy:

$$H_0 : p = 0,1$$

$H_1 : p > 0,1$ (wybrałam wersję $>$, bo $\hat{p} = 0,13$ sugeruje, że p może być większe niż 0,1.)

Zauważmy, że

- $n\hat{p} = 13 \geq 5$ ($n\hat{p}$ to liczba sukcesów, czyli liczba wylosowanych nasion tulipanów białych),
- $n\hat{q} = 87 \geq 5$ ($\hat{q} = 1 - \hat{p}$, więc $n\hat{q}$ to liczba porażek, czyli liczba wylosowanych nasion tulipanów czerwonych).

Zatem możemy użyć `prop.test()`, czyli testu, w którym rozkład statystyki testowej jest przybliżany rozkładem normalnym:

```
> prop.test(x=13,n=100,p=0.1,alternative="greater")
```

Powyżej argument `x` oznacza liczbę otrzymanych sukcesów, a `n` - liczbę wszystkich prób. Odczytujemy p wartość:

$$p - \text{value} = 0,2023 > \alpha = 0,01 \Rightarrow \text{nie ma podstaw do odrzucenia } H_0,$$

gdzie $\alpha = 0,01$ to poziom istotności testu. Wyciągamy więc wniosek, że ogrodnik może stwierdzić, że nasiona białych tulipanów stanowią 10% wszystkich nasion.

(b) Nadal testujemy $H_0 : p = 0,1$ przeciwko $H_1 : p > 0,1$. Jednak teraz $n = 10$ i $k = 2$, więc mamy

$$n\hat{p} = 2 \not\geq 5$$

i nie możemy zastosować `prop.test()` (wynika to stąd, że nie będzie działać przybliżenie rozkładem normalnym; aby ono działało muszą jednocześnie być spełnione oba warunki: $n\hat{p} \geq 5$ i $n\hat{q} \geq 5$). W tej sytuacji należy użyć testu dokładnego `binom.test()`:

```
> binom.test(x=2,n=10,p=0.1,alternative="greater")
```

$p - value = 0,2639 > \alpha = 0,01 \Rightarrow$ nie ma podstaw do odrzucenia H_0 ,

zatem odpowiedź z punktu (a) nie ulega zmianie: ogrodnik może stwierdzić, że nasiona białych tulipanów stanowią 10% wszystkich nasion.

Przykład 10.6. Otrzymano następujące wyniki pomiarów grubości 6 wylosowanych detali wyprodukowanych przez zakupiony agregat (w mm.): 1.6, 1.7, 1.4, 1.5, 1.9, 1.5. Zakładamy, że rozkład grubości tego detalu jest normalny. Na poziomie istotności 0,05 zweryfikować hipotezę, że wariancja grubości detalu wykonanego przez agregat przekracza 0.03 mm^2 .

Rozwiązanie przykładu 10.6:

Oznaczmy: X - grubość detalu. Z treści zadania wiemy, że X ma rozkład normalny, ale parametrów tego rozkładu nie znamy. Zapisujemy to natępująco

$$X \sim \mathcal{N}(\mu, \sigma^2), \text{ gdzie } \mu \text{ i } \sigma \text{ są nieznanne.}$$

Interesuje nas weryfikacja

$$H_0 : \sigma^2 = 0,03 \text{ mm}^2$$

przeciwko

$$H_1 : \sigma^2 > 0,03 \text{ mm}^2.$$

Powyższe hipotezy dotyczą wariancji. Patrzymy więc na dolną tabelę Weryfikacja hipotezy dotyczącej jednej wariancji. Przedstawiony w niej jeden model pasuje do naszej sytuacji. Aby przeprowadzić opisany tam test, wyznaczymy wartość statystyki testowej i zbiór krytyczny a następnie sprawdzimy czy statystyka testowa należy do zbioru krytycznego. Zaczniemy od statystyki testowej:

$$\chi^2 = \frac{(n-1)s^2}{\sigma_0^2},$$

gdzie s^2 to wariancja z próby. Rachunki wykonujemy w R:

```
> grubosc <- c(1.6, 1.7, 1.4, 1.5, 1.9, 1.5)
```

> (6-1)*var(grubosc)/0.03

Statystyka testowa $\chi^2 \approx 5,333$. Teraz zajmijmy się zbiorem krytycznym

$$W = \langle \chi_{1-\alpha; n-1}^2; +\infty \rangle.$$

Poziom istotności $\alpha = 0,05$, zatem $1 - \alpha = 0,95$. Liczymy $\chi_{1-\alpha; n-1}^2 = \chi_{0,95; 5}^2$:

> qchisq(0.95, 5)

Otrzymujemy $\chi_{1-\alpha; n-1}^2 \approx 11,0705$, co daje $W \approx \langle 11,0705; \infty \rangle$. Widzimy, że

$$\chi^2 \approx 5,333 \notin W \approx \langle 11,0705; \infty \rangle,$$

więc nie ma podstaw do odrzucenia hipotezy zerowej. Uznajemy, że wariancja grubości detalu wykonanego przez agregat nie przekracza $0,03 \text{ mm}^2$.