

**math.e****Hrvatski matematički elektronički časopis**

O primjeni programa Maxima u nastavi predmeta Vjerojatnost i statistika na specijalističkom stručnom studiju graditeljstva

Maxima nastava matematike statistia

Mandi Orlić Bachler

Tehničko veleučilište u Zagrebu, Graditeljski odjel, 10000 Zagreb, Av.
V. Holjevca 15, Hrvatska
mandi.orlic@tvz.hr

Sažetak

U članku se iznose dosadašnja iskustva o primjeni računalnog programa Maxima u nastavi predmeta Vjerojatnost i statistika, koji se izvodi na Politehničkom diplomskom specijalističkom stručnom studiju graditeljstva Tehničkog veleučilišta u Zagrebu. Opisuju se načini postizanja ishoda učenja navedenog predmeta primjenom programa Maxima, te se predlažu mogućnosti dodatne modernizacije spomenutog predmeta korištenjem ovog ili sličnih besplatnih računalnih programa. S ciljem boljeg prikaza teme u članak su uvršteni i zadaci, pri čemu je dana diskusija rješenja, koja su dobivena na dva načina: primjenom programa Maxima i klasičnim ("ručnim") računanjem.

Ključni pojmovi: vjerojatnost, statistika, Maxima, besplatni računalni program

1 Uvod

U prvom semestru Politehničkog diplomskog specijalističkog stručnog studija graditeljstva Tehničkog veleučilišta u Zagrebu izvodi se predmet Vjerojatnost i statistika. Cilj tog predmeta je upoznati studente s osnovnim pojmovima vjerojatnosti i metodama za statističku obradu podataka. Fond sati tog predmeta je 15+13+2, od čega je 15 sati predviđeno za predavanja, 13 sati za auditorne vježbe, a 2 sata za laboratorijske vježbe koje se održavaju u računalnom laboratoriju. Teme predviđene nastavnim planom i programom odnose se na: klasičnu definiciju vjerojatnosti, operacije među događajima, uvjetnu i totalnu vjerojatnost, diskretne i kontinuirane slučajne varijable, statističku populaciju i slučajni uzorak, grafičko prikazivanje statističkih podataka, procjenitelje, intervalnu procjenu očekivanja i

varijance te testiranje hipoteza. Do ove akademske godine u sklopu laboratorijskih vježbi zadaci su se rješavali pomoću MS Excela. Međutim, kako se od akademske godine 2015./2016. u sklopu predmeta Računarstvo u graditeljstvu, koji se izvodi u prvom semestru preddiplomskog stručnog studija graditeljstva, obrađuje program Maxima, ove akademske godine umjesto MS Excela koristili smo program Maxima. Osim na predmetu Vjerojatnost i statistika Maximu koristimo i u sklopu ostalih matematičkih predmeta koji se izvode na studijima graditeljstva Tehničkog veleučilišta u Zagrebu, o čemu smo pisali u [1].

Računalni program Maxima, besplatni je program koji se može preuzeti na web adresi <http://maxima.sourceforge.net/>. Općenito, program je pogodan za različite algebarske operacije sa simboličkim i numeričkim izrazima, kao što su deriviranje, integriranje, razvoj u Taylorov red, Laplaceova transformacija, sustavi linearnih jednažbi, vektori, matrice, statistika itd.

U ovom članku prikazano je kako se pomoću programa Maxima mogu riješiti neki od zadataka koji se obrađuju u sklopu nastave predmeta Vjerojatnost i statistika.

2 Statističke funkcije programa Maxima

U ovom dijelu rada dan je pregled i opis onih funkcija programa Maxima, koje koristimo u sklopu nastave predmeta Vjerojatnost i statistika. To su funkcije iz paketa `descriptive`, `distrib` i `stats`.

Paket `descriptive` sadrži funkcije deskriptivne statistike i funkcije za grafički prikaz podataka. Sljedeće funkcije samo su neke od dostupnih funkcija ovog paketa. Njihov argument x može biti lista ili matrica.

- Funkcija `mean(x)` računa uzoračku aritmetičku sredinu.
- Funkcija `var(x)` računa uzoračku varijancu.
- Funkcija `var1(x)` računa korigiranu uzoračku varijancu.
- Funkcija `std(x)` računa uzoračku standardnu devijaciju.
- Funkcija `std1(x)` računa korigiranu standardnu devijaciju.
- Funkcija `histogram(x, opcije)` koristi se za izradu histograma.

Paket `distrib` sadrži funkcije za izračun vjerojatnosti diskretnih i kontinuiranih univarijatnih modela. Dalje su opisane one funkcije koje se odnose na slučajne varijable s normalnom odnosno binomnom razdiobom.

- Za slučajnu varijablu s normalnom razdiobom $N(m, s)$ funkcija:
 - `pdf_normal(x, m, s)` za podatak x računa vrijednost funkcije gustoće vjerojatnosti,
 - `cdf_normal(x, m, s)` za podatak x računa vrijednost funkcije razdiobe vjerojatnosti,

- `mean_normal(m, s)` računa vrijednost očekivanja,
- `var_normal(m, s)` računa vrijednost varijance,
- `std_normal(m, s)` računa vrijednost standardne devijacije.
- Za slučajnu varijablu s binomnom razdiobom $B(n, p)$ funkcija:
 - `pdf_binomial(x, n, p)` za podatak x računa vrijednost funkcije vjerojatnosti,
 - `cdf_binomial(x, n, p)` za podatak x računa vrijednost funkcije razdiobe,
 - `mean_binomial(n, p)` računa vrijednost očekivanja,
 - `var_binomial(n, p)` računa vrijednost varijance,
 - `std_binomial(n, p)` računa vrijednost standardne devijacije.

Paket `stats` sadrži funkcije za izvođenje zaključaka o populaciji na temelju svojstava uzorka.

- Funkcija `test_mean(x, opcije)` koristi se za testiranje hipoteza i određivanje intervala povjerenja za očekivanje s poznatom ili nepoznom varijancom. Argument x može biti lista ili stupac matrice, a odnosi se na jednodimenzionalni slučajni uzorak normalno distribuirane slučajne varijable, dok se pod opcijama mogu unijeti sljedeći podaci:
 - `'mean` poprima vrijednost očekivanja koju se želi provjeriti.
 - `'alternative` odnosi se na alternativnu hipotezu H_1 i mogu se pridodati vrijednosti `'twosided`, `'greater` i `'less`.
 - `'dev` poprima vrijednost `'unknown` ili pozitivan realan broj, ovisno je li varijanca (standardna devijacija) uzorka poznata ili nepoznata.
 - `'conflevel` je razina pouzdanosti za interval povjerenja. Poprima vrijednosti iz intervala $[0, 1]$. Ako se vrijednost razine pouzdanosti ne unese podrazumijeva se da iznosi 0.95.

Izlaz funkcije `test_mean` je objekt koji prikazuje sljedeće rezultate:

- `'mean_estimate` prikazuje vrijednost uzoračke aritmetičke sredine,
- `'conf_level` prikazuje razinu pouzdanosti definiranu od korisnika,
- `'conf_interval` daje interval povjerenja za očekivanje normalne razdiobe,
- `'method` prikazuje osnovne podatke o korištenoj razdiobi,
- `'hypotheses` prikazuje vrijednosti hipoteza H_0 i H_1 ,
- `'statistic` daje vrijednost test-statistike,
- `'distribution` prikazuje podatke o razdiobi statističkog uzorka,
- `'p_value` daje p-vrijednost testa.
- Funkcija `test_variance(x, opcije)` koristi se za testiranje hipoteza te određivanje intervala povjerenja za varijancu. Argument i opcije definiraju se isto kao i kod funkcije `test_mean`.

Prije zadavanja bilo koje funkcije iz navedenih paketa potrebno je

učitati odgovarajući paket i to jednom od naredbi:

`load("descriptive") $`, `load("distrib") $` ili `load("stats") $`.

Unutar jednog radnog lista paket je dovoljno učitati jednom bez obzira koliko se funkcija iz njega poziva. Više o ovim i ostalim funkcijama dostupnim u navedenim paketima može se pronaći u [2].

3 Primjeri zadataka

U ovom poglavlju dani su primjeri zadataka i njihova rješenja koji se rješavaju u sklopu auditornih ("ručnim" putem) i laboratorijskih vježbi (upotrebom računalnog programa) na predmetu Vjerojatnost i statistika. Budući da se zbog ograničena vremena na laboratorijskim vježbama ne stigne u sklopu zadataka ponavljati teorijska podloga, rješavamo iste zadatke kao i na auditornim vježbama. Na taj način ne "trošimo" vrijeme na razumijevanje teksta zadatka i postavljanje problema, već su studenti usmjereni na razumijevanje naredbi programa Maxima i interpretaciju dobivenih rezultata. Najčešći problem s kojim se susrećemo na laboratorijskim vježbama vezan je uz poznavanje sintakse programa odnosno uz ispravan unos početnih podataka i interpretaciju dobivenih rezultata.

Zadatak 1. *Godišnja količina oborina u nekom mjestu, izražena u l/m^2 , je normalno distribuirana slučajna varijabla $X \sim N(250, 40)$. Kolika je vjerojatnost da godišnja količina oborina bude između 235 i 260?*

Rješenje:

Za slučajnu varijablu $X \sim N(\mu, \sigma^2)$, slučajna varijabla sa standardnom normalnom razdiobom je $X^* = \frac{X - \mu}{\sigma}$, a vjerojatnost da normalno distribuirana slučajna varijabla X poprimi vrijednosti unutar segmenta $[a, b]$ je

$$P(a \leq X \leq b) = P\left(\frac{a - \mu}{\sigma} \leq X^* \leq \frac{b - \mu}{\sigma}\right) = F^*\left(\frac{b - \mu}{\sigma}\right) - F^*\left(\frac{a - \mu}{\sigma}\right),$$

pri čemu je $F^*(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$.

Podintegralna funkcija $f^*(x)$ je funkciju gustoće vjerojatnosti standardne normalne razdiobe ([3]). Vrijednosti funkcija F^* i $f^*(x)$ čitaju se iz odgovarajućih tablica (vidjeti tablice u [4]).

Stoga, primjenom formule 1 vjerojatnost da godišnja količina oborina bude između 235 i 260 je:

$$\begin{aligned} P(235 \leq X \leq 260) &= P\left(\frac{235 - 250}{\sqrt{40}} \leq X^* \leq \frac{260 - 250}{\sqrt{40}}\right) = P(-2.37 \leq X^* \leq 1.58) \\ &= F^*(1.58) - F^*(-2.37) = 0.942947 - 0.008894 = 0.9341. \end{aligned}$$

U programu Maxima vrijednosti funkcije $F^*(x)$ mogu se izračunati, i to nešto preciznije, na sljedeći način. Najprije izračunamo vrijednosti

$\frac{a-\mu}{\sigma}$ i $\frac{b-\mu}{\sigma}$ unošenjem naredbi:

`(235 - 250)/sqrt(40), numer;`

`(260 - 250)/sqrt(40), numer;`

Nakon što stisnemo zajedno tipke `SHIFT+ENTER` Maxima će ispisati:

`- 2.371708245126`

`1.58113883008 .`

Za izračun vrijednosti funkcije F^* koristimo funkciju `cdf_normal(x, m, s)`, gdje x odgovara vrijednosti $\frac{X-\mu}{\sigma}$, $m = 0$ i $s=1$.

U novi red unesemo naredbu za učitavanje paketa `distrib`, a potom zadamo odgovarajuću naredbu.

`load(distrib)$`

`cdf_normal(1.58113883008, 0, 1) - cdf_normal(-2.371708245126, 0, 1);`

Kao izlaz zadane naredbe Maxima će ispisati:

`0.9342238180929876 .`

Zadatak 2. Broj pogodaka u cilj u 10 gađanja je binomno distribuirana slučajna varijabla $X \sim B\left(10, \frac{57}{100}\right)$. Kolika je vjerojatnost da se pogodi cilj barem 2 puta?

Rješenje:

Za binomno distribuiranu slučajnu varijablu $X \sim B(n, p)$ funkcija vjerojatnosti dana je izrazom

$$P(X = k) = b(k; n, p) = \binom{n}{k} p^k (1-p)^{n-k}, \quad (2)$$

gdje je n proizvoljan prirodan broj, $k \leq n$ prirodan broj i $p(0 < p < 1)$ realan broj ([3]).

Vjerojatnost da se pogodi cilj barem 2 puta, uključuje događaje da se cilj pogodi dva ili tri ili četiri, ..., ili deset puta. U ovom slučaju jednostavnije je izračunati vjerojatnost suprotnog događaja, koji uključuje događaje da se cilj nije pogodio te da se pogodio jednom. Stoga, primjenom formule 2 tražena vjerojatnost iznosi:

$$\begin{aligned} P(X \geq 2) &= 1 - P(X = 0) - P(X = 1) = \\ &= 1 - \binom{10}{0} \left(\frac{57}{100}\right)^0 \left(1 - \frac{57}{100}\right)^{10} - \binom{10}{1} \left(\frac{57}{100}\right)^1 \left(1 - \frac{57}{100}\right)^9 = 0.9969 . \end{aligned}$$

U programu Maxima ovo možemo izračunati unošenjem sljedećih naredbi:

`load(distrib)$`

`1 - pdf_binomial(0, 10, 57/100) - pdf_binomial(1, 10, 57/100), numer;`

Izlaz ove naredbe je:

0.9969191072888272 .

Zadatak 3. Stroj proizvodi limene ploče debljine 9.5 mm. Slučajno odabrane ploče na tom stroju imaju debljinu redom

8.65, 9.90, 9.71, 9.60, 9.61, 10.21, 11.29, 9.70, 11.24, 9.10, 11.35, 9.43 .

Pretpostavimo li da je debljina ploče slučajna varijabla normalne razdiobe može li se uz razinu značajnosti od $\alpha = 0.05$ tvrditi da stroj proizvodi ploče debljine manje od propisane?

Rješenje:

Test-statistika

$$T = \frac{\bar{X} - \mu}{S} \sqrt{n} \sim t(n - 1)$$

ima Studentovu t -razdiobu s $n - 1$ stupnjeva slobode. Za određivanje vrijednosti test-statistike potrebno je odrediti aritmetičku sredinu i korigiranu standardnu devijaciju:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^m x_i \cdot f_i = 9.9825$$

$$s^2 = \frac{1}{n - 1} \sum_{i=1}^m (x_i - \bar{x})^2 \cdot f_i = 0.7744 \quad \Rightarrow \quad s = 0.87999.$$

Tada test-statistika iznosi:

$$t = \frac{\bar{x} - \mu_0}{s} \sqrt{n} = \frac{9.9825 - 9.5}{0.87999} \sqrt{12} = 1.8994 .$$

Digresija: Vrijednosti aritmetičke sredine i standardne devijacije u programu Maxima mogu se izračunati na sljedeći način:

```
load(descriptive)$
```

```
x: [8.65, 9.90, 9.71, 9.60, 9.61, 10.21, 11.29, 9.70, 11.24, 9.10, 11.35, 9.43];
```

```
mean (x);
```

```
std1 (x);
```

Izlazi ovih naredbi su:

9.9825

0.8799909606973759 .

Postavljamo hipoteze

$$\begin{cases} H_0 : \mu = 9.5 \\ H_1 : \mu < 9.5 \end{cases}$$

Za ovako postavljene hipoteze kritično područje ili područje odbacivanja hipoteze H_0 je $[-\infty, t_\alpha)$. Vrijednost t_α odredimo iz tablice Studentove t -razdiobe za $n - 1 = 11$ stupnjeva slobode

(vidjeti tablicu u [4] na stranici 231.):

$$t_{\alpha} = t_{0.05} = -t_{1-0.05} = -t_{0.95} = -1.85955,$$

odnosno kritično područje je $(-\infty, -1.85955)$. Kako vrijednost test-statistike t ne upada u kritično područje prihvaćamo hipotezu H_0 , te odbacujemo hipotezu H_1 , na razini značajnosti od 5%. Prema tome, možemo reći da stroj ne proizvodi ploče debljine manje od propisanih 9.5 mm.

Zadatak ćemo u programu Maxima riješiti tako da ćemo prvo učitati paket `stats`, definirat ćemo skup podataka te potom zadati naredbu za lijevi jednostrani test. To činimo na sljedeći način:

```
load("stats")$
x: [8.65, 9.90, 9.71, 9.60, 9.61, 10.21, 11.29, 9.70, 11.24, 9.10, 11.35, 9.43];
test_{m}ean(x, 'mean=9.5, 'alternative='less, 'confllevel=0.95);
```

Napomena: `'confllevel=0.95` je razina pouzdanosti i njegova vrijednost jednaka je $1 - \alpha$.

Maxima će rezultat zadane naredbe ispisati u obliku:

```
MEAN TEST
mean_estimate=9.9825
conf_level=0.95
conf_interval=[-inf,10.43871131438427]
method="Exact t-test. Unknown variance."
hypotheses="H0: mean = 9.5 , H1: mean < 9.5"
statistic = 1.899370679875383
distribution = [student_t,11]
p_value = 0.9579800520853199
```

Na temelju dobivenih rezultata odgovor o odbacivanju ili prihvaćanju hipoteze H_0 dajemo na temelju p -vrijednosti testa. Kako na auditornim vježbama, kao što je prethodno prikazano, odgovor o prihvaćanju hipoteze H_0 dajemo na temelju vrijednosti test-statistike i kritičnog područja te se pojam p -vrijednosti ne spominje, ovdje je potrebno studentima dodatno pojasniti što ona predstavlja. U slučaju lijevog jednostranog t -testa p -vrijednost jednaka je $p = \mathbb{P}(T \leq t | H_0)$, desnog jednostranog testa jednaka je $p = \mathbb{P}(T \geq t | H_0)$, dok je kod dvostranog testa p -vrijednost manja od brojeva $2 \cdot \mathbb{P}(T \leq t | H_0)$ i $2 \cdot \mathbb{P}(T \geq t | H_0)$. Na temelju p -vrijednosti možemo dati sljedeće zaključke:

- ako je $p \leq \alpha$, onda se t nalazi u kritičnom području, pa odbacujemo H_0 na razini značajnosti α ,
- ako je $p > \alpha$, onda se t ne nalazi u kritičnom području, pa prihvaćamo H_0 na razini značajnosti α .

U našem slučaju je $p = 0.96 > 0.05$, pa stoga hipotezu H_0 prihvaćamo na razini značajnosti od 0.05.

Zadatak 4. Za podatke dane u Zadatku 3. uz pouzdanost od 95% odrediti interval povjerenja za očekivanje $\mu = 9.5$.

Rješenje:

Interval povjerenja za očekivanje s nepoznatom varijancom i pouzdanošću γ je

$$\left\langle \bar{X} - t_{\frac{1+\gamma}{2}} \cdot \frac{S}{\sqrt{n}}, \bar{X} + t_{\frac{1+\gamma}{2}} \cdot \frac{S}{\sqrt{n}} \right\rangle, \quad (3)$$

gdje je $t_{\frac{1+\gamma}{2}}$ kvantil Studentove t -razdiobe s $n - 1$ stupnjeva slobode. Vrijednost kvantila $t_{\frac{1+\gamma}{2}}$ odredimo iz tablice Studentove t -razdiobe za $n - 1 = 11$ stupnjeva slobode (vidjeti tablicu u [4] na stranici 231.):

$$t_{\frac{1+\gamma}{2}} = t_{\frac{1+0.95}{2}} = t_{0.975} = 2.201.$$

Tada je interval povjerenja na temelju formule 3 jednak:

$$\left\langle 9.9825 - 2.201 \cdot \frac{0.87999}{\sqrt{12}}, 9.9825 + 2.201 \cdot \frac{0.87999}{\sqrt{12}} \right\rangle = \langle 9.4234, 10.5416 \rangle.$$

U programu Maxima interval povjerenja određuje se pomoću naredbe za određivanje dvostranog t -testa. U novi red unesemo naredbu:

```
test_mean(x,'mean=9.5,'alternative='twosided','conflevel=0.95);
```

Maxima će rezultat zadane naredbe ispisati u obliku:

```
MEAN TEST
mean_estimate=9.9825
conf_level=0.95
conf_interval=[9.423380425654932,10.54161957434507]
method="Exact t-test. Unknown variance."
hypotheses="H0: mean = 9.5 , H1: mean ≠ 9.5 "
statistic = 1.899370679875383
distribution = [student_t,11]
p_value = 0.08403989582936022
```

Sada je u četvrtom redu ispisan interval povjerenja za očekivanje s nepoznatom varijancom s pouzdanošću od 95%.

4 Zaključak

Od akademske godine 2015./2016. na stručnom studiju graditeljstva Tehničkog veleučilišta u Zagrebu računalni program Maxima obrađuje se u sklopu predmeta Računarstvo u graditeljstvu. U posljednje tri godine pokazalo se da ga studenti s lakoćom savladavaju te da ga uspješno primjenjuju u rješavanju zadataka u sklopu ostalih matematičkih predmeta (bilo na nastavi ili samostalno u sklopu seminarskih radova). Iz tog razloga, ali i zato što imamo mali broj sati predviđen za rad na računalu iz predmeta Vjerojatnost i statistika, odlučili smo se koristiti program Maxima, a ne neki, možda, prikladniji

program za statističku obradu podataka (R, SPS i sl.).

U ovom trenutku postoje prijedlozi da se broj laboratorijskih vježbi poveća. Na taj način imali bi mogućnost raditi s oba programa, Excelom (kojeg smo do ove godine koristili) i Maximom. Iako se pokazalo da program Maxima u potpunosti zadovoljava sve nastavne potrebe matematičkih predmeta, koji se izvode na studijima graditeljstva, Excel je program koji će studenti u svom budućem poslu koristiti na svakodnevnoj razini i stoga je dobro u što većoj mjeri i u što različite svrhe koristiti ga u sklopu nastave.

Bibliografija

- [1] L. Marohnić, M. Orlić Bachler: Applications of free computational software in math courses at Zagreb University of Applied Sciences, Mathematics Education as a Science and a Profession, Mathematics and Children 2017, Osijek, Hrvatska, 2017.
- [2] Maxima Manual, Version 5.41.0
Dostupno na: <http://superk.physics.sunysb.edu/mcgrew/phy310/documentation/maxima-reference.pdf>
- [3] M. Orlić, T. Perkov: Repetitorij matematike za studente graditeljstva, Tehničko veleučilište u Zagrebu, Zagreb, 2014.
- [4] S. Suljagić: Vjerojatnost i statistika, interna skripta, Tehničko veleučilište u Zagrebu, Zagreb, 2003.

