1. Funkcija vjerojatnosti je dana sa $g(x) = 0,3$ za $x = 1$, $g(x) = 0,7$ za $x = 4$ i $g(x) = 0$ za sve ostale $x \in \mathcal{R}$.

2. Vjerojatnost da će tokom bilo koje minute proći tri automobila iznosi 0,224, a vjerojatnost da će u istom razdoblju proći bar dva automobila je 0,80085.

3. Vjerojatnost da ´ce jedan od odabranih proizvoda biti neispravan iznosi 0,22436.

4. (2 boda) Ako u kutiji imamo 8 bisera različite boje. Koliko različitih ogrlica možemo napraviti ako su duljine 6 bisera ako biser vraćamo svaki put nakon izbora?

n=8, r=6 $\overline{V}_n^{(r)} = n^r = 8^6 = 262\,144$.

5. Vjerojatnost se aksiomatski definira kao:

$P : F \to R$ , gdje je $F$ sigma algebra događaja iz $\Omega$ (prostora elementarnih događaja) koja ima svojstva : nenegativnosti,normiranosti i prebrojive aditivnosti

6. Ako događaji A i B nisu nezavisni onda je $P(A \bigcap B) = P(A) \cdot P(B/A)$

7. (2 boda) Neka je $X$ slučajna varijabla sa slikom $R(X) = \{1, 2, 3, 4\}$.

Oznaka $X = 3$ označava skup $\{\omega \in \Omega : X(\omega) = 3\}$

Oznaka $X^{-1}(\{3\})$ označava skup $\{\omega \in \Omega : X(\omega) = 3\}$.

$P(X = 3) = P(X^{-1}(\{3\})) = P(\{\omega \in \Omega : X(\omega) = 3\})$

8. Za diskretnu slučajnu varijablu $X$ koja je zadana s

$X \sim \begin{pmatrix} x_1 & x_2 & ... & x_j & ... & x_n... \\ f(x_1) & f(x_2) & ... & f(x_j) & & f(x_n)... \end{pmatrix}$ varijanca slučajne varijable definira se:

$Var(X) = \sum_{j=1}^{\infty}(x_j - E(X))^2 \cdot f(x_j)$.

9. Neka u Bernoullijevoj shemi promatramo događaj A i neka je vjerojatnost događaja A, P(A)=0.8. Koliki je očekivani broj pojava (događanja) događaja A u 10 pokusa?

Slučajne varijable $X$ =broj pojava (događanja) događaja A u 10 pokusa ima binomnu distribuciju s parametrima $B(10, 0.8)$ pa je

$E(X) = 10 \cdot 0.8 = 8$.

10. (3 boda) Neka je $p \in [0, 1], \lambda \in R \backslash \{0\}$. Može li funkcija $f(x) = \frac{\lambda^{x-1}}{x!} \cdot e^{-\lambda}$ za $x = 0, 1, 2, 3, ....,$ biti funkcija vjerojatnosti neke slučajne varijable? DA NE

Provjeri:$\sum_x f(x) = \sum_{k=0}^{\infty} \frac{\lambda^{x-1}}{x!} \cdot e^{-\lambda} = e^{-\lambda} \cdot \frac{1}{\lambda} \sum_{k=0}^{\infty} \frac{\lambda^x}{x!} = \frac{1}{\lambda} e^{-\lambda} \cdot e^{\lambda} \neq 1$.