br.	ime	prezime	br.bodova

VIS-2.KOLOKVIJ 2.6.2007.

1. (2 boda) Neka je $X \sim N(\mu, \sigma^2 = 4)$. Na uzorku veličine $n = 9$ dobivena je uzoračka aritmetička sredina $\bar{x} = 4,2$. Odredite vrijednost statističkog testa ako testiramo nulhipotezu $H_0(\mu = \mu_0 = 4)$.

$t = 0,3$

2. (3 boda) Za slučajni vektor $(\mathbf{X}, \mathbf{Y}) \sim \begin{pmatrix} X/Y & -1 & 0 & 1 \\ 1 & 0,2 & 0,2 & 0,1 \\ 2 & 0,3 & 0,1 & 0,1 \\ & & & \end{pmatrix}$ odredite $E(\frac{Y^2}{X})$.

$E(\frac{Y^2}{X}) = 0,5$

3. (4 boda) Neka je $X \sim B(m, p = 0,4)$. Odredite m tako da bude $P(|\frac{X}{m} - 0,4| < 0,02) \geq 0,9$ koristeći Bernoullijev slabi zakon velikih brojeva.

$m \geq 6000$

br.	ime	prezime	br.bodova

4. (2 boda) Iz tablice $\chi^2(5)$ odredite vrijednost $F(12.83) = 0.975$

5. Graf funkcije gustoće vjerojatnosti studentove distribucije poklapa se s grafom funkcije gustoće vjerojatnosti standardne normalne distibucije za velike n.

6. Diskretni dvodimenzionalni slučajni vektor (X,Y) koji ima sliku $\{(x_i, y_j), i = 1,..,5, j = 1,2,3\}$ i funkciju vjerojatnosti f(x,y) koja je definirana
$f(x_i, y_j) = P(X = x_i, Y = y_j)$.

7. Napišite Čebiševljevu nejednakost za slučajnu varijablu X koja ima konačnu varijancu $Var(X)$:
$\forall \varepsilon > 0$,__$P(|\overline{X} - \mu| \geq \varepsilon) \leq \frac{Var(X)}{\varepsilon^2}$______________________________________

8. Napišite centralni granični teorem za $\overline{X}$, aritmetičku sredinu n nezavisnih jednako distribuiranih slučajnih varijabli koje imaju očekivanje μ i varijancu σ^2:
$P(\alpha < \overline{X} < \beta) = F^*(\frac{\beta-\mu}{\frac{\sigma}{\sqrt{n}}}) - F^*(\frac{\alpha-\mu}{\frac{\sigma}{\sqrt{n}}})$

gdje je F* funkcija distribucije standardne normalne razdiobe.

9. Kvantil z_q za standardnu normalnu distribuciju ako je $q = 0.975$ je 1.96.

10. Uzoračka aritmetička sredina je nepristrani procjenitelj za očekivanje.

11. Interval povjerenja za parametar očekivanje za normalnu razdiobu ako varijanca nije poznata određujemo pomoću tablice studentove razdiobe.

12. (2 boda) Teorem Glivenka o teorijskim i statističkim razdiobama kaže da se za veliki uzorak s vjerojatnošću skoro 1 statistička razdioba malo razlikuje od teorijske.