

UNIVERSITETET I OSLO

Det matematisk-naturvitenskapelige fakultet

Eksamen i: STK1100 — Sannsynlighetsregning og statistisk modellering

Eksamensdag: Fredag 3. juni 2022

Tid for eksamen: 09.00 – 13.00

Oppgavesettet er på 4 sider.

Vedlegg: Ingen

Tillatte hjelpemidler: Godkjent kalkulator
Formelsamling for STK1100

Kontroller at oppgavesettet er komplett før
du begynner å besvare spørsmålene.

Oppgave 1

Line har to sekssidede terninger. Terning 1 er en jukse-terning, som er tyngre på den motsatte sida av seksersida, slik at sannsynligheten for å få en sekser når en kaster terningen er $\frac{1}{5}$. Terning 2 er en vanlig, balansert terning der alle sidene har lik sannsynlighet.

Line velger én av terningene helt tilfeldig (med sannsynlighet 0.5 for hver terning) og kaster den.

a

Hva er sannsynligheten for at det blir en sekser?

Du får ikke se resultatet av terningkastet, men du får vite at det *ikke* ble seks.

b

Hva er sannsynligheten for at det var Terning 1 som ble kastet?

Oppgave 2

I et verneområde i Irland, har en har prøvd å måle bestanden til irske steinkobber (en type seldyr). La x_1, \dots, x_n være antall steinkobber som er telt i n påfølgende sesonger. Disse antas å være observerte verdier av de stokastiske variablene X_1, \dots, X_n , som er uavhengige og identisk fordelt. Siden dette er tellevariabler, er Poisson-fordelingen et naturlig valg, og det er også modellen vi antar i denne oppgaven, nærmere bestemt at alle X_i , $i = 1, \dots, n$ er Poisson-fordelt med parameter λ . Punktsannsynligheten til

(Fortsettes på side 2.)

X_i er da gitt ved

$$p(x) = \frac{\lambda^x}{x!} e^{-\lambda}, \quad x = 0, 1, 2, \dots,$$

med momentgenererende funksjon

$$M_X(t) = e^{\lambda(e^t - 1)}.$$

a

Vis at forventningen og variansen til X_i begge er lik λ ved å bruke den momentgenererende funksjonen.

La Y være totalt antall steinkobber over alle sesongene, dvs. $Y = \sum_{i=1}^n X_i$.

b

Finn forventningen og variansen til Y .

c

Vis at også Y er Poisson-fordelt.

(*Hint:* Her kan du også få bruk for den momentgenererende funksjonen fra tidligere i oppgaven.)

d

Sett opp likelihood- og log-likelihood-funksjonen, og vis at maksimum likelihood-estimatoren for λ er $\hat{\lambda}_{mle} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$. Begrunn at momentestimatoren $\hat{\lambda}_{mom}$ er den samme som maksimum-likelihood estimatoren.

Du får oppgitt at det er telt steinkobber over $n = 43$ sesonger, med tilsvarende gjennomsnitt $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = 20.37$.

e

Vis at standardfeilen $\sigma_{\hat{\lambda}}$ til maksimum likelihood-estimatoren for $\hat{\lambda}_{mle}$ (og momentestimatoren $\hat{\lambda}_{mom}$) er $\sqrt{\lambda/n}$. Oppgi maksimum likelihood-estimatet for λ basert på opplysningene over, og gi et estimat for standardfeilen.

Du får i tillegg oppgitt at den empiriske variansen i antall steinkobber per sesong er $s^2 = 448.14$.

f

Sett i lys av resultatet fra Oppgave a, synes du Poisson-fordelingen virker som en passende modell for steinkobbetellingene?

(Fortsettes på side 3.)

Oppgave 3

La X være en normalfordelt variabel med forventning μ og varians σ^2 , som vi også kan skrive $X \sim N(\mu, \sigma^2)$, slik at tettheten til X er gitt ved

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}, \quad x \in \mathbb{R}.$$

a

Vis at fordelingen til $Y = \left(\frac{X-\mu}{\sigma}\right)^2$ er *gamma* $(\frac{1}{2}, 2)$ med formparameter $\alpha = \frac{1}{2}$ og skalaparameter $\beta = 2$, som er det samme som kjikvadratfordelingen med 1 frihetsgrad, dvs. at Y har tettheten

$$f_Y(y) = \begin{cases} \frac{1}{\sqrt{2\pi}} y^{-\frac{1}{2}} e^{-\frac{y}{2}}, & y > 0 \\ 0, & \text{ellers.} \end{cases}$$

Anta at du har observasjonene x_1, \dots, x_n av de stokastiske variablene X_1, \dots, X_n , som er uavhengige og identisk normalfordelt med forventning μ og varians σ^2 . Videre antar vi at μ er kjent, mens σ^2 er ukjent, slik at vi ønsker å estimere den. Nærmere bestemt, vil vi bruke den forventningsrette

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2.$$

b

Vis at $n\frac{\hat{\sigma}^2}{\sigma^2}$ kan skrives som $\sum_{i=1}^n Y_i$ med $Y_i = \left(\frac{X_i - \mu}{\sigma}\right)^2$, og bruk det sammen med resultatet fra Oppgave a til å argumentere for at $n\frac{\hat{\sigma}^2}{\sigma^2} \sim \text{gamma}\left(\frac{n}{2}, 2\right)$, som er det samme som kjikvadratfordelingen med n frihetsgrader. (*Hint:* Husk at fordelingen til en sum av uavhengige $\text{gamma}(\alpha_i, \beta)$ -fordelte variabler med samme skalaparameter β er $\text{gamma}(\sum_i \alpha_i, \beta)$ -fordelt).

c

Bruk resultatene fra Oppgave b til å lage et 95% konfidensintervall for σ^2 når du får vite at $\chi_{n,0.975}^2$ og $\chi_{n,0.025}^2$ er henholdsvis 2.5%- og 97.5%-persentilene i kjikvadratfordelingen med n frihetsgrader (som er det samme som $\text{gamma}\left(\frac{n}{2}, 2\right)$ -fordelingen).

Oppgave 4

De to variablene X og Y er binormalfordelt med parametere $\mu_1, \mu_2, \sigma_1, \sigma_2$ og ρ . De har dermed simultan sannsynlighetstetthet

$$f_{X,Y}(x,y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left(\left(\frac{x-\mu_1}{\sigma_1}\right)^2 + \left(\frac{y-\mu_2}{\sigma_2}\right)^2 - 2\rho\left(\frac{x-\mu_1}{\sigma_1}\right)\left(\frac{y-\mu_2}{\sigma_2}\right)\right)}, \quad (x,y) \in \mathbb{R}^2.$$

(Fortsettes på side 4.)

Her er $\mu_1 = E(X)$, $\mu_2 = E(Y)$, $\sigma_1^2 = V(X)$, $\sigma_2^2 = V(Y)$ og $\rho = \text{Corr}(X, Y)$.

Et kjennetegn ved binormalfordelingen er at marginalfordelingen til både X og Y er normalfordelinger, nærmere bestemt er $X \sim N(\mu_1, \sigma_1^2)$ og $Y \sim N(\mu_2, \sigma_2^2)$ (dette kan du bruke uten å vise det).

Videre er det velkjent at dersom to stokastiske variabler V og W er uavhengige, så er korrelasjonen $\text{Corr}(V, W)$ mellom dem lik 0. Det motsatte er generelt ikke tilfelle; det vil si at korrelasjonen $\text{Corr}(V, W) = 0$, selv om V og W er avhengige. Binormalfordelingen er imidlertid et unntak, og er slik at dersom korrelasjonen er 0, så er de to variablene uavhengige.

a

Vis at når $\rho = 0$, dvs. at korrelasjonen mellom X og Y er lik 0, så er X og Y uavhengige.

Et annet kjennetegn ved den binormale fordelingen er at den betingede fordelingen til Y gitt $X = x$ er normalfordelingen med forventning $\mu_2 + \rho \frac{\sigma_2}{\sigma_1}(x - \mu_1)$ og varians $\sigma_2^2(1 - \rho^2)$, dvs. at

$$[Y|X = x] \sim N\left(\mu_2 + \rho \frac{\sigma_2}{\sigma_1}(x - \mu_1), \sigma_2^2(1 - \rho^2)\right). \quad (1)$$

En alternativ måte å modellere sammenhengen mellom Y og X på, betinget på en gitt verdi av x av X , er en lineær regresjonsmodell, som altså her er en modell for $[Y|X = x]$, og er gitt ved

$$Y = \beta_0 + \beta_1 x + \epsilon, \quad \epsilon \sim N(0, \psi^2).$$

b

Argumentér for at $[Y|X = x]$ i den lineære regresjonsmodellen over er normalfordelt og vis at

$$E(Y|X = x) = \beta_0 + \beta_1 x \quad \text{og} \quad V(Y|X = x) = \psi^2.$$

c

Forklar at den betingede fordelingen til $[Y|X = x]$ i den binormale fordelingen, altså modellen i (1), er en lineær regresjonsmodell, og oppgi hva β_0 , β_1 og ψ^2 er i denne modellen.