

UNIVERSITETET I OSLO

ØKONOMISK INSTITUTT

Øvelsesoppgave i: **ECON2130 – Statistikk 1**

Dato for utlevering: Mandag 22. mars 2010

Dato for innlevering: Fredag 9. april 2010

Innleveringssted: Ved siden av SV-info-senter **kl. 13.00 – 15.00**

Øvrig informasjon:

- Denne øvelsesoppgaven er **obligatorisk**. Kandidater som har fått den obligatoriske øvelsesoppgaven godkjent i et tidligere semester skal **ikke** levere på nytt. Dette gjelder også i tilfeller der kandidaten ikke har bestått eksamen.
- Denne oppgaven vil **IKKE** bli gitt en tellende karakter. En evt. karakter er kun veiledende
- Du må benytte en ferdig trykket forside som du finner på http://www.oekonomi.uio.no/info/EMNER/Forside_obl_nor.doc
- **Det skal leveres individuelle besvarelser. Det er tillatt å samarbeide, men identiske besvarelser (direkte avskrift) vil ikke bli godkjent!**
- Det er viktig at øvelsesoppgaven blir levert innen fristen (se over). Oppgaver levert etter fristen vil **ikke bli rettet**.*)
- Alle øvelsesoppgaver må leveres på innleveringsstedet som er angitt over. Du må ikke levere øvelsesoppgaven direkte til emnelæreren eller ved e-post. Dersom du ønsker å levere inn oppgaven **før** innleveringsfristen, bes du kontakte instituttets ekspedisjonskontor i 12. etg.
- Dersom øvelsesoppgaven ikke blir godkjent, vil du få en ny mulighet ved at du får en ny oppgave som skal leveres med en svært kort frist. Dersom heller ikke dette forsøket lykkes, vil du ikke få anledning til å avlegge eksamen i dette emnet. Du vil da bli trukket fra eksamen, slik at det ikke vil bli et tellende forsøk.

*) Dersom en student mener at han eller hun har en god grunn for ikke å levere oppgaven innen fristen (for eksempel pga. sykdom) bør han/hun diskutere saken med emnelærer, og søke om utsettelse. Normalt vil utsettelse kun bli innvilget dersom det er en dokumentert grunn (for eksempel legeerklæring).

OBLIGATORISK SEMESTEROPPGAVE

Merk: Det er lov å samarbeide, men hver skal levere egen rapport. Plagiater vil ikke bli godkjent (dette gjelder også den som har latt en annen skrive av sin besvarelse). Det er ikke meningen at alt skal løses på PC. Bruk PC der det er hensiktsmessig. Merk også at vedlagte PC utskrifter bør redigeres og kommenteres. Ta ikke med alt som kommer ut av maskinen, bare det som er av betydning/interesse for besvarelsen! (Det er for eksempel bortkastet å legge ved en utskrift av de 10000 observasjonene som du skal generere i oppgaven). En besvarelse som bare består av en bunke ukommenterte utskrifter blir høyst sannsynlig ikke godkjent.

Merknad til Excel:

Du trenger modulen "Data analysis" for å løse oppgaven. Sjekk at Data analysis ligger på data-menyen. Hvis ikke, må den legges til ("add in"): I siste Excel versjon: Start fra "office button" (en sirkel øverst til venstre på Excel-arket). Klikk så på "excel options" helt nederst på menyen som kommer fram. Og videre:

office button → excel options → add-ins → marker "Analysis toolpack" → Klikk "Go.." → merk av "Analysis toolpack" → klikk OK.

(I eldre Excel: Fra menyen: tools → add-ins → merk av "Analysis toolpack" → klikk OK.)

Oppgave

Vi tar utgangspunkt i følgende eksperiment: En rettferdig terning kastes tre ganger. La X være antall seksere som oppnås og Y antall enere. Begge variablene har dermed verdimengden $\{0,1,2,3\}$. Det kan vises (du trenger ikke å gjøre det her) at simultanfordelingen for (X,Y) er gitt ved følgende formel

$$(1) \quad f(x, y) = P(X = x \cap Y = y) = \frac{3!}{x!y!(3-x-y)!} \cdot \left(\frac{1}{6}\right)^{x+y} \cdot \left(\frac{4}{6}\right)^{3-x-y}$$

for $x, y = 0,1,2,3$ og slik at $0 \leq x + y \leq 3$. For alle andre kombinasjoner av (x, y) er $f(x, y) = 0$.

A. Skriver vi ut fordelingen i en tabell, får vi

Tabell 1. ($f(x, y)$)

	$y = 0$	$y = 1$	$y = 2$	$y = 3$	Sum
$x = 0$	$8/27$	$2/9$	$1/18$	$1/216$	$125/216$
$x = 1$	$2/9$	$1/9$	$1/72$	0	$75/216$
$x = 2$	$1/18$	$1/72$	0	0	$15/216$
$x = 3$	$1/216$	0	0	0	$1/216$
Sum	$125/216$	$75/216$	$15/216$	$1/216$	1

Verifiser ved innsetting i formelen (1) at $f(0,0) = 8/27$ og $f(2,1) = 1/72$.
Forklar hvorfor X og Y , hver for seg, må være binomisk fordelte. Sett opp formler for de to fordelingene og verifiser at de faller sammen med marginalfordelingene i tabell 1.

B. Finn $E(X)$, $E(Y)$, $\text{var}(X)$, $\text{var}(Y)$. Verifiser at $\text{cov}(X, Y) = -1/12$ og korrelasjonen, $\rho = \text{Corr}(X, Y) = -1/5$.

C. Følgende spill blir tilbudt. Mot å betale 100 kr. i spilleavgift, kan spilleren kaste en (rettferdig) terning tre ganger. For hver sekser som oppnås får spilleren utbetalt 200 kr., men må (i tillegg til spilleavgiften) betale 20 kr for hver ener som måtte dukke opp. Uttrykt ved X og Y , blir dermed gevinsten (V) for spilleren, $V = 200X - 20Y - 100$ for et spill. Fortjenesten for et spill for tilbyderer er $-V$ kr.

Verifiser at $E(V) = -10$ og $\text{var}(V) = 17500$

[Hint: Bruk for eksempel regel 4.15 i boka].

Hva blir forventningen og variansen til fortjenesten (for et spill) for tilbyderer?

D. Finn sannsynligheten for at V er større enn 50 kr.

[Hint: Det kan, f.eks., være lurt å lage en tabell, som tabell 1, som viser verdien av V for alle mulige kombinasjoner av X og Y , og deretter utnytte tabell 1.]

E. Finn fordelingen til V . Det vi er ute etter er en tabell av formen

v	v_1	v_2	\dots	v_k
$h(v) = P(V = v)$	$h(v_1)$	$h(v_2)$	\dots	$h(v_k)$

der første rad gir verdimengden for V , og annen rad de tilhørende sannsynlighetene.

Lag et histogram over fordelingen. (Hvis du ikke får Excel til å gi noe tilfredsstillende histogram, skisser et for hånd.)

F. La U være total gevinst etter 20 spill. Dvs. la V_1, V_2, \dots, V_{20} være uavhengige og identisk fordelte som V . Da er $U = V_1 + V_2 + \dots + V_{20}$. Finn forventningen og standardavviket til U . Nevn hvilken eller hvilke regler i boka du bruker til dette.

Vi er interessert i sannsynligheten for at tilbyderer får positiv fortjeneste på 20 spill, med andre ord $P(U < 0)$. Den eksakte fordelingen til U er meget komplisert, men i følge sentralgrenseteoremet (jfr. regel 5.18 i boka), kan vi regne U som tilnærmet normalfordelt. Bruk dette til å beregne $P(U < 0)$ tilnærmet.

G. I boka er det angitt en tommelfingerregel at antall ledd i summen (U) bør være minst 20 for at tilnærmelsen til normalfordelingen skal være tilfredsstillende. Vår U er basert på 20 spill og representerer dermed et grensetilfelle. Du skal nå bruke datamaskinen til å simulere 500 observasjoner av U . For hver observasjon av U trenger du 20 uavhengige observasjoner av V , som summeres for å gi U .

I Excel er det mulig å trekke observasjoner fra fordelingen til V i punkt **E**. Du lager først to kolonner ved siden av hverandre, der verdimengden for V utgjør første kolonne og de tilhørende sannsynlighetene den andre kolonnen. Deretter går du inn i "Random Number Generation" under "Data Analysis" på Data-menyen (under "Tools" i eldre Excel). I menyen som kommer fram velger du *Discrete* som fordeling, Number of Variables = 20, Number of Random Numbers = 500. Deretter markerer du området der fordelingen for V står, i vinduet for "Value and Probability Input Range", og, til slutt, den første cellen i "Output Range".

Du har nå generert (simulert) $500 \times 20 = 10000$ uavhengige observasjoner av V , organisert i 20 kolonner. Hver rad representerer et observasjonssett av V_1, V_2, \dots, V_{20} . Beregn summen av hver rad i en ny kolonne, og du har oppnådd 500 uavhengige observasjoner av U . Finn gjennomsnitt og empirisk standardavvik for U -observasjonene og sammenlign med de teoretiske størrelsene, $E(U)$, $SD(U)$. Lag et histogram for U -ene basert på ca. 15 intervaller (finn minimum og maksimum for U -ene og velg for eksempel 15 passende intervallgrenser ("bins"), som du legger inn i en kolonne i Excel osv.).

H. Lag også et histogram for U -observasjonene som figur 5.23 i boka der tettheten for den tilnærmende normalfordelingen fra sentralgrenseteoremet er tegnet inn. Dette er

vanskelig å få til i Excel, så tegn et for hånd på rutepapir. Husk å velge riktig skala på Y-aksen. Virker tilnærmelsen til normalfordelingen rimelig?

[**Hint:** Funksjonsverdier for den aktuelle normalfordelingstettheten kan du enklest beregne med NORMDIST-funksjonen i Excel som du finner under *statistical functions*.]

I. Finn den relative frekvensen av U -observasjoner som er negative (dvs. som gir positiv fortjeneste for tilbyderen). I følge de store talls lov vil dette tallet ligge i nærheten av $P(U < 0)$ og kan derfor ses på som et anslag (estimat) på den sanne verdien av $P(U < 0)$. Sammenlign den relative frekvensen med tilnærmingen til den teoretiske verdien av $P(U < 0)$ beregnet i punkt **F**. Gir dette, synes du, grunnlag for å tvile på tilnærmingen foretatt i punkt **F**?

[**Hint:** Du trenger å telle opp hvor mange av U -observasjonene er negative. Dette kan du, for eksempel, la Excel gjøre på følgende måte: Lag en ny kolonne ved siden av U -kolonnen med 0-er og 1-ere slik at det står et 1-tall ved siden av U -er som negative og 0 ved siden av de andre. Ved å summere denne kolonnen får du antall negative U -er. Kolonnen kan lages med IF-funksjonen. For eksempel, hvis første U -tall står i celle "X2", skriv i cellen ved siden av, =IF(X2<0;1;0). (Merk at det er semikolon i formelen – ikke komma.) Kopier deretter denne cellen til resten av kolonnen.]

J. Beregn $P(U < 0)$ der U nå utgjør totalgevinsten for 500 spill ($U = V_1 + V_2 + \dots + V_{500}$). Du kan nå, uten tap av realisme, regne at U er normalfordelt. Finn også det mest sannsynlige variasjonsområdet for U , i følgende forstand: Bestem c_1 og c_2 slik at $P(c_1 < U < c_2) = 0,90$. Forklar hvorfor det gir riktig svar hvis vi bestemmer c_1 slik at $P(U \leq c_1) = 0,05$ og c_2 slik at $P(U \leq c_2) = 0,95$.