


TMA4245 Statistikk

Uke 4 - mandag



Uke 4 (man 22. jan - fredag 26. januar)



Introvideoer

Stokastisk simulering og pseudo-tilfeldige tall

TMA4240/TMA4245 Statistikk
Håkon Tjelmeland
Institutt for matematiske fag
Norges teknisk-naturvitenskapelige universitet


Simulere fra diskrete og kontinuerlige fordelinger

TMA4240/TMA4245 Statistikk
Håkon Tjelmeland
Institutt for matematiske fag
Norges teknisk-naturvitenskapelige universitet

Oppgaver

STACK 3: Opppg. 1-2
INNLL. 2: Opppg. 1 og 2

Eksempel 1: Stigespill



Hva er sannsynligheten
for å vinne dersom man
starter først?
(2 spillere)

Repetisjon fra forrige uke


Tolkning av sannsynlighet

- ★ Eks: Kast terning, registrer antall øyne, $S = \{1, 2, 3, 4, 5, 6\}$
 - la $A = \{5, 6\}$, hva betyr det at $P(A) = 1/3$?

- ★ Stokastisk forsøk:

- gjenta forsøket n ganger
- $s(n)$: antall ganger hendelsen A skjer
- relativ hyppighet av A : $\frac{s(n)}{n}$

- simulering:



Dersom vi simulerer stigespill veldig mange ganger kan vi approksimere sannsynligheten for at spiller 1 vinner

Python: kode terningkast

```
# kaster terning med unif[0,1]-fordeling  
def kaste_terning_unif():  
    u = np.random.rand()  
    x = int(min(6,np.floor(6*u)+1))  
    return x
```

← Fra video

```
terningkast = kaste_terning_unif()  
print(terningkast)
```

4

```
# kaster terning med innebygd randint-funksjon  
def kaste_terning():  
    return np.random.randint(1, 7)
```

```
terningkast = kaste_terning()  
print(terningkast)
```

6

Python: kode stigespill

```
def stigespill_2player():  
    spiller1 = 0  
    spiller2 = 0  
    vinner = 0  
  
    while spiller1 < 90 and spiller2 < 90:  
        kast_resultat1 = kaste_ternung()  
        kast_resultat2 = kaste_ternung()  
  
        spiller1 = flyttere regler(spiller1, kast_resultat1)  
        spiller2 = flyttere regler(spiller2, kast_resultat2)  
  
    if spiller1 == 90:  
        vinner = 1  
    elif spiller2 == 90:  
        vinner = 2  
  
    return vinner
```

Python: kode stigespill

```
# Spesielle felter (stiger og avslutning)
def flyttere regler(posisjon, kast_resultat):
    spesielle_felter = [1, 8, 24, 33, 36, 42, 43, 49, 56, 64, 65, 68, 74, 87]
    nye_posisjoner = [40, 10, 5, 3, 52, 30, 62, 79, 37, 27, 82, 85, 12, 70]

    ny_posisjon = posisjon + kast_resultat


    if ny_posisjon in spesielle_felter:
        ny_posisjon_indeks = spesielle_felter.index(ny_posisjon)
        ny_posisjon = nye_posisjoner[ny_posisjon_indeks]
        return ny_posisjon
    elif ny_posisjon > 90:
        gå_tilbake = ny_posisjon - 90
        return (90 - gå_tilbake)
    else:
        return ny_posisjon
```

Python: simulere mange stigespill

```
# approksimert sannsynlighet for at spiller1 vinner  
n = 1000  
teller_spiller1_vinn = 0  
for _ in range(n):  
    vinner = stigespill_2player()  
    if vinner == 1:  
        teller_spiller1_vinn += 1  
print(teller_spiller1_vinn/n)
```


0.47

Python: simulere mange stigespill



Stokastisk simulering, kort oppsummert

1. Vi kan bruke datamaskinen til å generere pseudo-tilfeldige tall



↑
som hovedregel fra
en Unif[0,1]-fordeling

2. Vi kan **transformere** uniformfordelte stokastiske variabler slik at vi også kan generere tall fra mer interessante sannsynlighetsfordelinger, både diskrete og kontinuerlige

Oppgave 1 og 2 i dag

<https://docs.python.org/3/library/random.html#module-random>

<https://numpy.org/doc/stable/reference/random/generator.html>

Oppgave 1: Simulere fra en diskret fordeling

En stokastisk variabel X har verdimengde $\{0, 1, 2, 3\}$ med punktsannsynligheter $P(X=0) = 0.44$, $P(X=1) = 0.40$, $P(X=2) = 0.13$ og $P(X=3) = 0.03$.

- a) Hvordan kan vi, fra en $\text{Unif}(0,1)$ -fordeling, generere realisasjoner av X ?
- b) Dersom vi genererer $u = 0.52$, hva blir realisasjonen x av X ?

Oppgave 1: Simulere fra en diskret fordeling

```
[1]: import numpy as np
```

```
[2]: #verdimengde
x = np.arange(4)
#punktsannsynligheter
f_x = np.array([0.44, 0.40, 0.13, 0.03])
# kumulative sannsynligheter
F_x = np.cumsum(f_x)
print(F_x)
```

```
[0.44 0.84 0.97 1.  ]
```


```
[3]: u = np.random.uniform()
if(u < F_x[0]): # dersom u er mindre enn 0.44 vil vi at realisasjonen av X skal være 0
    x = 0
elif(u <= F_x[1]): # hvis u er mindre enn 0.84 vil vi at realisasjonen av X skal være 1
    x = 1
elif(u <= F_x[2]):
    x = 2
elif(u > F_x[2]):
    x = 3

print("u ble", u, "og x ble dermed", x)
```

```
u ble 0.4642365102448054 og x ble dermed 1
```

Fra video: Simulere fra en diskret fordeling

$$U \sim \text{Unif}[0, 1]$$
$$X = \min\{x : F_X(x) \geq U\}$$



Oppgave 2a: Simulere fra kontinuerlige fordelinger

Oppgave 2

I figur 1 er det gitt en python-funksjon med to input-parametre, et positivt heltall n og en parameter ϕ (φ) som må være større enn null. Funksjonen genererer n uavhengige realisasjoner av en kontinuerlig stokastisk variabel Y . Ut fra denne koden, bestem sannsynlighetstettheten til Y , dvs $f_Y(y)$ for $-\infty < y < \infty$.

```
import numpy as np

def simY(n, phi):
    u = np.random.uniform(size=n)
    y = phi * np.sqrt(u)

    return y
```

Figur 1: Python-funksjon som genererer n uavhengige realisasjoner av en kontinuerlig stokastisk variabel Y , der ϕ (φ) er en parameter i sannsynlighetsfordelingen til Y .

- i. Hva er $F_U(u) = P(U \leq u)$?
- ii. I hvilket intervall vil Y ta tallverdier?
- iii. Hva blir $F_Y(y) = P(Y \leq y)$, uttrykt ved $F_U(u) = P(U \leq u)$?
- iv. Hva blir $f_Y(y)$?

Oppgave 2a: Simulere fra kontinuerlige fordelinger

```
: import numpy as np
```


```
: def simY(n,phi):  
    u = np.random.uniform(size=n)  
    y = phi*np.sqrt(u)  
    return(y)
```

```
: sim1 = simY(n=1000,phi=5)  
print(sim1[0:5])
```

```
[3.58275121 4.49293669 4.46034152 4.96549151 3.10240576]
```

```
: import matplotlib.pyplot as plt
```

```
plt.hist(sim1, density=True,bins=10,edgecolor="black") #density=True gjør at vi får et sannsynlighetshistogram  
plt.ylabel('Approksimert tetthet'); plt.xlabel('y')  
plt.show()
```




Oppgave 2b: Simulere fra kontinuerlige fordelinger

La en annen kontinuerlig stokastisk variabel X ha kumulativ fordelingsfunksjon gitt ved

$$F_X(x) = \begin{cases} 1 - \exp\left\{-\frac{x^2}{\theta}\right\} & \text{dersom } x \geq 0, \\ 0 & \text{ellers,} \end{cases}$$

der $\theta > 0$ er en parameter. Utled hvordan man ved å ta utgangspunkt i en uniformfordelt variabel på intervallet $[0, 1]$ kan generere en realisasjon av X . Skriv så en python-funksjon, `simX`, som genererer n uavhengige realisasjoner av X .

$$U \sim \text{Unif}[0, 1]$$
$$X = F_X^{-1}(U)$$



```
import numpy as np

def simY(n, phi):
    u = np.random.uniform(size=n)
    y = phi * np.sqrt(u)

    return y
```




Hvorfor er det nyttig at en datamaskin kan generere (pseudo-)tilfeldige tall?

1. Vi kan bruke datamaskiner til å approksimere sannsynligheter i komplekse situasjoner (vanskelig/umulig å regne for hånd)
2. Vi kan bruke datamaskiner til å generere (fra en passende sannsynlighetsfordeling) tilfeldig "output" til brukere
3. Vi kan bruke datamaskinen til å visualisere stokastiske forsøk for å bedre forstå hvordan innsamlede data *kan* komme til å se ut

Hvorfor er det nyttig at en datamaskin kan generere (pseudo-)tilfeldige tall?

1. Vi kan bruke datamaskiner til å approksimere sannsynligheter i komplekse situasjoner (vanskelig/umulig å regne for hånd)
2. Vi kan bruke datamaskiner til å generere (fra en passende sannsynlighetsfordeling) tilfeldig "output" til brukere
3. Vi kan bruke datamaskinen til å visualisere stokastiske forsøk for å bedre forstå hvordan innsamlede data *kan* komme til å se ut

Eksempel 2: Språkmodeller





hvor er

hvor er **bussen**

hvor er **toget**

hvor er **det varmt i februar**

hvor er **jul i svingen spilt inn**

hvor er **det varmt i januar**

 **Hvor er Willy?**
Bok av Martin Handford

hvor er **det varmt i desember**

hvor er **side om side spilt inn**

hvor er **snøfall 2 spilt inn**

hvor er **det varmt i mars**

18. januar 2024

hvor er

hvor er

hvor er **bekkenet**

hvor er **trondheim**

hvor er **tiller**

hvor er **iphone**

hvor er **min iphone**

hvor er **bussen**

hvor er **toget**

hvor er **jeg nå gps**

hvor er **det varmt i februar**

Ingeborg

Hvorfor er det nyttig at en datamaskin kan generere (pseudo-)tilfeldige tall?

1. Vi kan bruke datamaskiner til å approksimere sannsynligheter i komplekse situasjoner (vanskelig/umulig å regne for hånd)
2. Vi kan bruke datamaskiner til å generere (fra en passende sannsynlighetsfordeling) tilfeldig "output" til brukere
3. Vi kan bruke datamaskinen til å visualisere stokastiske forsøk for å bedre forstå hvordan innsamlede data *kan* komme til å se ut

Eksempel 3: Hvor mange søsken har dere?

<https://www.ssb.no/befolkning/artikler-og-publikasjoner/slik-er-norske-barnefamilier>

Statistikken er basert på barn under 18 år i 2018

