



Matematisk Statistik

SF1901 Sannolikhetssteori och statistik: VT 2016

Lab 1 för  
CTFYS, CELTE

## Introduktion

Detta är handledningen till Laboration 1, ta med en en utskriven kopia av den till laborationen. Läs handledningen två gånger. Försäkra dig om att du förstår hur de MATLAB-kommandon som finns i den bifogade koden fungerar. Laborationen bedöms som godkänd eller ej godkänd. För att få delta i laborationen skall svar på förberedelseuppgifter kunna redovisas **individuellt**. Arbete i grupp är tillåtet med **högst två**, personer per grupp. Godkänd laboration ger 3 poäng till ordinarie tentamenstillfälle.

## Förberedelseuppgifter

1. Definiera begreppen sannolikhet, fördelningsfunktion, och täthetsfunktion. Skriv upp sambandet mellan dem.
2. Den stokastiska variabeln  $X$  har täthetsfunktion

$$f_X(x) = \lambda e^{-\frac{x}{\lambda}} + \frac{\lambda}{x}, \quad x \in [1, 10] \quad (1)$$

för ett specifikt  $\lambda$ .

- (a) Bestäm (med ett närmevärde)  $\lambda$  så att  $f_X$  bli en täthetsfunktion.

**Svar:** .....

- (b) Bestäm fördelningsfunktionen för  $X$ .

**Svar:** .....

- (c) Bestäm sannolikheten att  $X$  är mindre än 7. Använd  $\lambda = 0.4267$ .

**Svar:** .....

(d) Bestäm  $E[X]$ .

**Svar:** .....

3. Låt  $U$  vara likformigt fördelad över intervallet  $[0, 2\pi]$ , beräkna

(a)  $E[\cos(U)]$

**Svar:** .....

(b)  $E[\sin(U)^2]$

**Svar:** .....

4. Redogör för Stora talens lag.

5. Redogör för Centrala gränsvärdessatsen.

6. Läs sid. 272-273 om bootstrap i läroboken.

## Syfte och vidare introduktion

Börja laborationen med att ladda ner filerna

1. `plot_mvnpdf.m`
2. `hist_density.m`
3. `birth.dat`
4. `birth.txt` - beskrivning av datat `birth.dat`

från kurshemsidan. Se till att de ligger i den mapp du kommer att arbeta i. För att kontrollera att du har lagt filerna rätt, skriv `ls` och se om filerna ovan listas.

Du kan skriva dina kommandon direkt i MATLAB-prompten men det är absolut att föredra att arbeta i editorn. Om den inte är öppen så kan du öppna den och skapa ett nytt dokument genom att skriva `edit lab1.m`. Koden som ges nedan är skriven i celler. En ny cell påbörjas genom att skriva två procenttecken. **Ctrl+Enter** exekverar innehållet i en cell.

Temat för den här datorlaborationen är simulering. Sannolikhetsteoridelen av kursen handlar om hur man genom beräkningar kan ta fram olika storheter som sannolikheter, väntevärden osv, för en given stokastisk modellen. För mer komplicerade system är det ibland inte alls möjligt att göra exakta beräkningar, eller så är de så tidskrävande att man avstår. I sådana sammanhang kan simulering vara ett alternativ. Simulering innebär att man med hjälp av en dator drar ett antal replikeringar av det stokastiska systemet, och sedan använder t ex medelvärden eller empiriska kvantiler (mer om det nedan) för att uppskatta de storheter man söker. I den här laborationen skall vi göra detta för några enkla problem, men grundprinciperna går att använda på långt mer komplicerade problem som vi inte kan lösa med enkla beräkningar.

### Problem 0 - Beräkna sannolikheter

Läs help för funktionerna `binocdf`, `binopdf`, `normcdf`, `normpdf`, `expcdf` och `exppdf`.

Låt  $X_1$  vara  $\text{Bin}(10, 0.3)$ ,  $X_2 \in N(5, 3)$ ,  $X_3 \in \text{Exp}(7)$ , bestäm (med hjälp av funktionerna ovan) för  $k = 1, 2, 3$

1.  $P(X_k \leq 3)$

**Svar:** .....

2.  $P(X_k > 7)$

**Svar:** .....

3.  $P(3 < X_k \leq 4)$

**Svar:** .....

### Problem 1 - Täthetsfunktioner

Plotta täthetsfunktionen för en exponential-fördelad stokastisk variabel med väntevärde  $\mu$ .

```
1 %% Problem 1: exp-pdf
2     dx = 0.1;
3     x = 0:dx:15;          % Skapar en vektor med dx som inkrement
4     mu = 1;
5     y = exppdf(x, mu);    % exponential-fordelningen
6     plot(x,y)
```

Gör nu samma sak för täthetsfunktionen du jobbat med i förberedelseuppgifterna.

```
1 %% Problem 1: lambda-plot
2     lambda = 0.4267;
3     f=(lambda*exp(-x/lambda)+lambda./x).*(x >= 1 & x <= 10);
4     plot(x, f)
```

Diskutera skillnaden mellan fördelningarna.

**Kommentar:** .....

.....

### Problem 2 - Multivariat Normalfördelning

Den multivariata normalfördelningen ritas upp av `plot_mvnpdf`, undersök hur funktionen fungerar och testa med lite olika parametervärden.

```
1 %% Problem 2: Multivariat normal
2     mux = 0; muy = 100; sigmax = 1; sigmay = 4; rho = 0.7;
3     plot_mvnpdf(mux, muy, sigmax, sigmay, rho)
```

Hur påverkar olika parametervärden utseendet på plotten?

**Kommentar:** .....

.....

### Problem 3 - Simulering av slumpstal

I denna övning så genererar vi ett stort antal slumpstal, ritar upp deras histogram och plottar slutligen den sanna täthetsfunktionen ovanpå.

```
1 %% Problem 3: Simulering av slumpstal
2 mu = 10;
3 N = 1e4;
4 y = exprnd(mu, N, 1); % Genererar N exp-slumpstal
5 hist_density(y); % Skapar ett normaliserat histogram
6 t = linspace(0, 100, N/10); % Vektor med N/10 punkter
7 hold on
8 plot(t, exppdf(t, mu), 'r') % 'r' betyder rod linje
9 hold off
```

Noter att MATLABs `exprnd` har väntevärdet  $\mu$  som parameter i motsats till [2] som har parameter  $1/\mu$ . Upprepa simuleringarna och studera hur histogrammet förändras. Hur förhåller sig histogrammet till den röda linjen och hur förklaras variationen kring denna linje?

**Kommentar:** .....

.....

### Problem 4 - Stora talens lag, Monte Carlo och CGS

I detta avsnitt kommer vi igen att generera stora mängder slumpstal, nu för att beräkna väntevärden och sannolikheter. Antag att man vill veta väntevärdet på en tärning, det är inte svårt att beräkna för hand men det går också att kasta tärningen många gånger och sedan räkna ut medelvärdet på dessa kast. Om  $X_1, X_2, \dots, X_n$  är likafördelade med väntevärde  $\mu$  så gäller enligt stora talens lag i [2] att

$$P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| < \varepsilon\right) \rightarrow 1 \quad (2)$$

för varje  $\varepsilon > 0$  när  $n \rightarrow \infty$ . Det vill säga, sannolikheten att skillnaden mellan medelvärdet och det sanna väntevärdet är mindre än  $\varepsilon$  går mot ett när antalet observationer går mot oändligheten. Detta sätt att beräkna väntevärden kallas för Monte Carlo-metoder.

*Idén bakom Monte Carlo är gammal och har funnits inom matematiken åtminstone sedan 1700-talet, men synen kom att förändras under andra halvan av 1900-talet då det på allvar blev möjligt att utföra stora beräkningar. Under sent 1940-tal utvecklade Stanislaw Ulam och John von Neumann metoder för att göra dessa "tärningskast" med hjälp av dator enligt [1]. Metoden*

*namngavs efter casinot Monte Carlo i Monaco och användes senare under Manhattanprojektet vars syfte var att ta fram den första atombomben.*

### Illustration av Stora talens lag

Koden nedan simulerar  $M$  stycken exponentialfördelade stokastiska variabler. Efter detta plottas medelvärdet efter hand. Dvs. plotten som visas är din skattning av medelvärdet upp till och med variabel nummer  $k$ .

```
1 %% Stora talens lag
2 mu = 0.5;
3 M = 500;
4 X = exprnd(mu, M, 1);
5 plot(ones(M, 1)*mu, 'r-.')
6 hold on
7 for k = 1:M
8     plot(k, mean(X(1:k)), '.')
9     if k == 1
10        legend('Sant \mu', 'Skattning av \mu')
11    end
12    xlabel(num2str(k)), pause(0.001)
13 end
14 hold off
```

Om du tröttnar på att vänta så kan du kommentera bort `pause`-raden. Ser det ut som du förväntat dig?

Svar: .....

### Illustration av Centrala Gränsvärdessatsen

Koden nedan simulerar exponential fördelade slumpstal och summerar sedan dessa. Studera koden och förklara vad  $N$  representerar

Svar: .....

```
1 %% CGS
2 M = 1e3;
3 N = 4;
4 mu = 5;
5 X = exprnd(mu, M, N);
6 S = cumsum(X, 2);
7 for k = 1:N
8     hist(S(:, k), 30)
```

```
9      xlabel(num2str(k))
10     pause(0.1)
11 end
```

Justera  $N$ , vad händer när du ökar respektive minskar värdet? Varför?

**Kommentar:** .....

.....

Vid vilket  $N$  ser det ut som att det inte länge gör någon skillnad om du ökar det?

**Svar:** .....

Vilken fördelning verkar summorna ha? Varför har de denna fördelning?

**Svar:** .....

### Väntevärden

Uppgiften är nu att beräkna samma väntevärden som gjorts i förberedelseuppgift 3. Det första kan du beräkna enligt nedan,

```
1      %% Monte Carlo
2      N = 1e5;
3      U = rand(N, 1)*2*pi;
4      mean(sin(U).^2);
```

Kontrollera att resultatet stämmer med vad du förväntade dig i båda fallen. Låt  $X$  och  $Y$  vara oberoende stokastiska variabler där  $X \sim \exp(\lambda)$ ,  $\lambda = 4$  och  $Y$  är normalfördelad med väntevärde 0 och standardavvikelse 1. Använd nu Monte Carlo för att beräkna  $E[(e^X)^{\cos(Y)}]$ .

**Svar:** .....

### Problem 5 - Deskriptiv statistik

Vi skall nu gå vidare till att studera skillnaden mellan väntevärden i två populationer, t ex skillnaden i födelsevikt för barn vars mammor röker respektive inte röker under graviditeten. (Om ni vill kan ni ta två andra po-

pulationer, och/eller andra variabler att studera!).

I filen `birth.txt` ser man att kolonn 20 i `birth.txt` innehåller rökvanor, och att värdena 1 och 2 betyder att mamman inte röker under graviditeten, medan värdet 3 betyder att hon gör det. Ni kan skapa två variabler `x` och `y` för födelsevikter hörande till icke-rökande respektive rökande mammor enligt

```
>> x = birth(birth(:, 20) < 3, 3);  
>> y = birth(birth(:, 20) == 3, 3);
```

Vad som händer här är att `birth(:, 20) < 3` returnerar en vektor av "sant" och "falskt", och att bara de rader av kolonn 3 (födelsevikterna i `birth` för vilka jämförelsen är sann, väljs ut.

Använd koden nedan för att visuellt inspektera datat.

```
1 load lab2data/birth.dat  
2 x = birth(birth(:, 20) < 3, 3);  
3 y = birth(birth(:, 20) == 3, 3);  
4 subplot(2,2,1)  
5 boxplot(x)  
6 axis([0 2 500 5000])  
7 subplot(2,2,2)  
8 boxplot(y)  
9 axis([0 2 500 5000])  
10 subplot(2,2,3:4)  
11 ksdensity(x)  
12 hold on  
13 [fy, ty] = ksdensity(y);  
14 plot(ty, fy, 'r')  
15 hold off
```

Vad betyder plotarna? Vilka slutsatser kan ni dra?

## Problem 6 - Bootstrap (gör i mån av tid)

Namnet bootstrap syftar till metaforen att dra sig upp ur ett knivig situation genom att ta tag i sina stövelskaft. Ett klassiskt exempel är historien om Baron von Münchhausen i vilken han ska ha räddat sig och sin häst ur ett träsk genom att dra ur de båda genom att lyfta sig själv i håret. Detta förfarande beskriver idén bakom den statistiska varianten av metoden mycket väl: Man har observerat en begränsad mängd data och man vill bilda sig en uppfattning om vad som hade hänt om man hade haft fler observationer. I vårt fall innebear det att vi gör upprepade slumpvisa dragningar från vårt observerade data med funktionen `randsample`.

Vi ska börja med att titta på ett simulerat exempel där vi vet vad som *borde* hända och fortsätter sedan i nästa laboration med att titta på riktiga data, vilket är det som vi huvudsakligen är intresserade av.



**Simulering av summerade exponential-fördelade variabler**

Om  $X_1, X_2, \dots, X_n$  alla är oberoende och exponentialfördelade med intensitet  $\lambda$  så gäller det att

$$Y_n = \sum_{k=1}^n X_k \in \Gamma(n, \frac{1}{\lambda}). \quad (3)$$

Med andra ord, summan av de exponentialfördelade variablerna är gamma-fördelad. (Specialfallet när  $\Gamma$ -fördelningen har ett positivt heltal  $n$  som första parameter kallas mer specifikt för *Erlang*-fördelning.)

Vi ska nu simulera  $M$  stycken summor av typen (3), med  $n$  noterat som `n_sum` i koden nedan, och studera ett histogram för dem. Börja med att studera koden nedan. Läs `help randsample` och testa hur funktionen fungerar. Kommandot `reshape` används nedan för att omforma matrisen `x` till en vektor så att den ska kunna användas i `randsample`. Notera att vi använder väntevärdet  $\mu = \frac{1}{\lambda}$  i koden nedan.

```
1      %% Bootstrap - Simulering
2      % lambda = 1/5;
3      mu = 5;
4      M = 1e3;
5      n_sum = 5;
6      X = exprnd(mu, M, n_sum);
7      g = sum(X, 2);
8      subplot(211)
9      hist_density(g)
10     hold on
11     t = 0:0.01:mu*10;
12     plot(t, gampdf(t, n_sum, mu), 'r')
13     hold off
14     B = 1e3;      % Antal bootstrapreplikat
15     totalNoSamples = M*n_sum;
16     X = reshape(X, totalNoSamples, 1); % Gör om X till vektor
17     yBoot = zeros(B, 1);
18     for j = 1:B
19         sampleDraws = X(randsample(totalNoSamples, n_sum, 1));
20         yBoot(j) = sum(sampleDraws);
21     end
22     subplot(212)
23     hist_density(yBoot)
24     hold on
25     plot(t, gampdf(t, n_sum, mu), 'r')
26     hold off
```

Förklara vad de två raderna i for-loopen gör!

**Kommentar:** .....

.....

Justera B, M, respektive mu. Vad händer? Varför?

**Kommentar:** .....

.....

## Referenser

- [1] Eckhardt, Roger (1987) Stan Ulam, John Von, Neumann, and the Monte Carlo, Method *Los Alamos Sci.*, Vol **15**, p. 131-43.
- [2] Blom, G., Enger, J., Englund, G., Grandell, J., och Holst, L., (2005). Sannolikhetssteori och statistikteori med tillämpningar.