



Matematisk Statistik

SF1901 Sannolikhets teori och statistik, HT 2017
Laboration 3 för CINTE

1 Introduktion

Denna laboration är poänggivande och godkänd laboration kan ge 3 bonuspoäng vid ordinarie tentamenstillfälle. Laborationen bedöms som godkänd eller ej godkänd. Läs först labbspecifikationen två gånger. Försäkra dig om att du förstår hur de MATLAB-kommandon som finns i den bifogade koden fungerar. Svaren på förberedelseuppgifterna ska kunna redovisas **individuellt**. Arbete i grupp är tillåtet (och uppmuntras) med **högst två** personer per grupp. **Ta med** en utskriven kopia av labbspecifikationen till redovisningstillfället för att kunna använda som kvitto på att laborationen är godkänd.

2 Förberedelseuppgifter

1. Definiera likelihood och log-likelihood samt förklara sambandet mellan dessa begrepp. Beskriv idén bakom Minsta-kvadratmetoden (MK) respektive Maximum-likelihoodmetoden (ML).

Svar:
.....
.....

2. En Rayleighfördelad stokastisk variabel X har täthetsfunktionen

$$f_X(x) = \frac{x}{b^2} e^{-\frac{x^2}{2b^2}}.$$

Antag nu att du har n stycken Rayleighfördelade variabler.

- a) Bestäm ML-skattningen av b .

Svar:

- b) Bestäm MK-skattningen av b .

Svar:

3. Beskriv hur du kan ta fram ett approximativt konfidensintervall för parametern b . Motivera varför det är rimligt att göra den approximation som du har gjort. Ledning: Använd MK-skattningen.

Svar:
.....
.....

4. Beskriv idén bakom linjär regression. Förklara vad polynomregression är.

Svar:
.....
.....

5. Beskriv hur man i MATLAB m.h.a. kommandot **regress** kan skatta parametrarna i modellen

$$w = \log(y_k) = \beta_0 + \beta_1 x_k + \varepsilon_k \quad (1)$$

6. Förklara idén bakom bootstrap. Läs sidorna 272-273 om bootstrap i läroboken om nödvändigt.

3 Syfte och vidare introduktion

Börja med att ladda ner följande filer från kurshemsidan.

- `wave_data.mat`
- `resistorer.mat`
- `moore.mat`
- `poly.mat`
- `birth.dat`
- `birth.txt` - beskrivning av datat `birth.dat`

Se till att filerna ligger i den mapp du kommer att arbeta i. För att kontrollera att du har lagt filerna rätt, skriv `ls *.mat` 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 lab3.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.

4 Laborationsuppgifter

Problem 1 - Maximum likelihood/Minsta kvadrat

Scriptet nedan genererar en samling Rayleigh-fördelade stokastiska variabler och plottar sedan skattningen `my_est`. Använd dina två skattningar från förberedelseuppgift 2.

```
1 %% Problem 1: Maximum likelihood/Minsta kvadrat
2     M = 1e4;
3     b = 4;
4     x = raylrnd(b, M, 1);
5     hist_density(x, 40)
6     hold on
7     my_est_ml = % Skriv in din ML-skattning här
8     % my_est_mk =
9     plot(my_est, 0, 'r*')
10    plot(b, 0, 'ro')
11    hold off
```

Ser din skattning bra ut?

Svar:

Kontrollera hur täthetsfunktionen ser ut genom att plotta den med din skattning:

```
1 %% Problem 1: Maximum likelihood/Minsta kvadrat (forts.)
2     plot(0:0.1:6, raylpdf(0:0.1:6, my_est), 'r')
3     hold off
```

Problem 2 - Konfidensintervall

I detta avsnitt kommer en Rayleigh-fördelad signal att undersökas; parameter och konfidensintervall för denna skall skattas. Ladda in data genom att skriva `load wave_data.mat`. Filen innehåller en signal som du kan plotta genom att skriva följande

```
1 %% Problem 2: Konfidensintervall
2     load wave_data.mat
3     subplot(211), plot(y(1:100))
4     subplot(212), hist_density(y)
```

Om du ändrar `y(1:100)` till `y(1:end)` så kan du se hela signalen. Skatta parametern på datat på samma sätt som i föregående uppgift. Spara din

skattning som `my_est`. Ta fram ett konfidensintervall för skattningen och spara övre respektive undre värdet som `upper_bound` respektive `lower_bound`. Skriv ner dina resultat:

Svar:
.....
.....

Plotta nu intervallet för din skattning av parametern

```
1 %% Problem 2: Konfidensintervall (forts.)
2     hold on      % Gör så att ploten hålls kvar
3     plot(lower_bound, 0, 'g*')
4     plot(upper_bound, 0, 'g*')
```

Kontrollera hur täthetsfunktionen ser ut genom att plotta den med din skattning på samma vis som i föregående avsnitt:

```
1 %% Problem 2: Konfidensintervall (forts.)
2     plot(0:0.1:6, raylpdf(0:0.1:6, my_est), 'r')
3     hold off
```

Ser fördelningen ut att passa bra?

Svar:

Rayleighfördelningen kan t ex användas för att beskriva hur en radiosignal avtar. Experimentella mätningar på Manhattan har visat att Rayleighfördelningen beskriver radiosignalers fädning (engelska: fading) på ett bra sätt i den sortens stadsmiljö [1].

Problem 3- Passning av fördelning

Ladda in `resistorer.mat` och studera datat (som beskriver en uppmätt egenskap hos ett antal resistorer) med hjälp av ett histogram. Undersök också hur det ser ut med kommandot `normplot`. Vilken fördelning tror du att resistorernas motstånd har? Är det någon fördelning du kan utesluta? Varför kan man vara intresserad av fördelningen för någon specifik egenskap hos resistorer?

Svar:
.....

Problem 4 - Linjär regression

Vi kommer att titta på fenomenet som kallas Moores lag. Ladda in datat `moore.mat` på samma sätt som tidigare. I datat så är y antal transistorer/yta medan x representerar årtal. Det betyder att om vi plottar dem mot varandra så ser vi en plot av utvecklingen över tid av antalet transistorer per yta. Inför modellen

$$w_i = \log(y_i) = \beta_0 + \beta_1 x_i + \varepsilon_i. \quad (2)$$

Skatta β_0 och β_1 med hjälp av MATLABs funktion `regress`.

Om du skattar parametrar mha data från 1971 till 2011, vad är då din prediktion för antalet transistorer år 2020?

Svar:

Problem 5 - Polynomregression

Börja med att ladda filen `poly.mat`. Plotta y_1 , y_2 , y_3 , var för sig mot x_1 , x_2 , respektive x_3 . Ser de ut att kunna beskrivas av polynom?

Svar:

Inför modellen

$$y_k = \beta_0 + \beta_1 x + \beta_2 x^2 + \dots + \beta_n x^n. \quad (3)$$

Bilda nu, för var och en av de tre datamängderna, en X -matris på ett lämpligt vis. Alltså studera plottarna och designa sedan ett X sådant att det kan representera ett polynom av den grad du tror passar. I fallet för modellen (3) ovan så ser X ut så här:

$$X = \begin{bmatrix} 1 & x & x^2 & \dots & x^n \\ 1 & x & x^2 & \dots & x^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x & x^2 & \dots & x^n \end{bmatrix}. \quad (4)$$

Ta sedan fram din skattning av $\hat{\beta}$ med hjälp av `regress` och plotta din skattade modell

$$\hat{y} = X\hat{\beta}, \quad (5)$$

I fallet y_1 får vi följande kod.

```
1 %% Problem 4: Regression
2     y_hat = X*beta_hat;
3     plot(y1, '.')
4     hold on
5     plot(y_hat, 'r.')
6     hold off
```

Plotta residualerna på följande sätt.

```
1 %% Problem 4: Regression (forts.)
2     res = y_hat - y1;
3     subplot(211), normplot(res)
4     subplot(212), hist(res)
```

Vilken fördelning ser de ut att komma från?

Svar:

Vad kan du dra för slutsatser om modellen?

Svar:

Linjär regression utvecklades under sent 1700-tal av en ung Gauss. Metoden fick ett genomslag när den förutspådde banan för den genom tiderna först upptäckta asteroiden, Ceres. Linjär regression används än flitigare idag med tillämpningar inom i stort sett all vetenskap som behandlar data. Fördjupning i ämnet ges i kursen "Regressionsanalys".

Problem 6- Deskriptiv statistik

Vi skall nu 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 populationer, 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 funktionen `length` eller kommandot `whos` för att se storleken på vektorerna `x` och `y`. Använd koden nedan för att visuellt inspektera datat.

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

Vad betyder plotarna? Vilka slutsatser kan ni dra?

Svar:
.....

Problem 7 - Bootstrap av skattning av skillnad mellan väntevärden för födelsevikter

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 ska vi studera skillnaden mellan väntevärden i två populationer, i detta fall skillnaden i födelsevikt för barn vars mammor röker respektive inte röker under graviditeten (se föregående problem).

För att skatta skillnaden mellan populationernas väntevärden, använder vi som vanligt skillnaden mellan stickprovsmedelvärdena,

$$\text{mean}(\mathbf{x}) - \text{mean}(\mathbf{y}).$$

För att undersöka osäkerheten i denna skattningen ska vi använda bootstrap och simulera M stycken bootstrapreplikater enligt

```
>> thetaboot = bootstrp(M, @mean, x) - bootstrp(M, @mean, y);
```

Ser bootstrapreplikaten ut att komma från en normalfördelning?

Svar:

Använd

```
>> quantile(thetaboot, [0.025, 0.975])
```

för att bestämma ett konfidensintervall för skillnaden θ mellan väntevärdena?

Svar:

Vad får du med hjälp av metoden i boken, dvs konfidensintervall för skillnad mellan väntevärden?

Svar:

Referenser

- [1] Dmitry Chizhik, Jonathan Ling, Peter W. Wolniansky, Reinaldo A. Valenzuela, Nelson Costa, and Kris Huber (2003). Multiple-input-multiple-output measurements and modeling in Manhattan *IEEE Journal on Selected Areas in Communications*, Vol **21**, p. 321-331.