

Tentamenskrivning: TMS145 - Grundkurs i matematisk statistik och bioinformatik, 7,5 hp.

Tid: Lördag den 18 april 2009, kl 14:00-18:00 Väg och vatten

Examinator: Olle Nerman, tel 7723565.

Jour: Frank Eriksson, tel 073-7263051.

Hjälpmedel: Egen handskriven formelsamling (fyra A4-sidor) samt med skrivningen utdelade tabellsidor.

Maxpoäng: 32. För godkänt krävs minst 15 poäng totalt och minst 4 poäng på sannolikhetsteori- och statistik-delen vardera samt minst 3 poäng på bioinformatikdelen. För betyget 4 krävs 20 poäng och för betyget 5 25 poäng.

Sannolikhetsteori

1. Vad är sannolikheten för två oberoende händelser A och B med sannolikheterna $P(A) = 0,2$ resp $P(B) = 0,9$ att

a de inträffar båda två?

(1p)

b inte någon inträffar?

(1p)

c inte någon av dem inträffar någon enda gång vid 3 oberoende upprepningar av försöket?

(2p)

2. Avrundningsfelen vid en viss typ av vägningar kan antas vara likformigt fördelade i intervallet $-0,005$ och $0,005$. Om verkliga vikterna varierar mycket mellan 100 olika enheter som vägs, så kan de 100 mätfelen dessutom betraktas som oberoende.

a Vilket väntevärde har mätfelen för en enskild enhet?

(1p)

b Vilken varians har mätfelen för en enskild enhet?

(1p)

c Bestäm approximativt sannolikheten att absolutbeloppet av summan av mätfelen för de hundra enheterna är $< 0,02$

(2p)

Vänd!

3. Antag att du har en kontinuerligt fördelad stokastisk variabel X med frekvensfunktionen $f(x) = (2x + 2)C$ på intervallet $[-1, 1]$
- Bestäm konstanten C .
(1p)
 - Bestäm frekvensfunktionen för $10X$
(1p)
 - Bestäm fördelningsfunktionen för $10X$
(2p)

Statistik

4. Låt x_1, \dots, x_n vara ett stickprov från oberoende $Gamma(k, \theta)$ -fördelade variabler. $X \sim Gamma(k, \theta)$ innebär att X har frekvensfunktion $f_X(s) = s^{k-1} \frac{e^{-s/\theta}}{\theta^k \Gamma(k)}$, $s > 0$, $k > 0$, $\theta > 0$ samt $E[X] = k\theta$.
- Härled maximum likelihoodskattaren för θ .
(2p)
 - Är detta en väntevärdesriktig (unbiased) skattare?
(1p)
5. En forskare hävdar att åtminstone 10% av alla hockeyhjälmar har ett visst tillverkningsfel som skulle kunna ge upphov till skador hos bäraren. Då man kontrollerar 400 hjälmar upptäcker man att 32 av dessa har det påtalade felet.
- Ta reda på, med hjälp av ett lämpligt hypotestest på signifikansnivå 0,01, om detta stödjer forskarens påstående.
(2p)
 - Finn testets p-värde.
(1p)
 - Vilken bredd skulle ett 99%-igt konfidensintervall baserat på informationen ovan ha?
(1p)

Vänd!

6. För att undersöka hur temperaturen förändras ju längre norrut i Sverige som man kommer, så mättes årsmedeltemperaturen år 2004 i 11 svenska orter. De återges i följande tabell tillsammans med orternas latituder.

Ort	Latitud	Medeltemperatur —
Jokkmokk	66,6	-0,6
Umeå	63,5	4,0
Östersund	63,1	4,2
Gävle	60,4	5,8
Karlstad	59,2	7,0
Stockholm	59,3	7,6
Göteborg	57,8	7,7
Jönköping	57,4	6,0
Visby	57,6	7,6
Kalmar	56,7	7,5
Lund	55,7	8,5

Sambandet mellan årsmedeltemperatur och latitud kan sammanfattas med en regressionsmodell

```
lm(formula = y ~ x)
```

Residuals:

Min	1Q	Median	3Q	Max
-1.6397	-0.5078	0.3306	0.6731	1.3348

Coefficients:

	Estimate	Std. Error
(Intercept)	49.16360	5.72184
x	-0.72341	0.09562

Residual standard error: 1.015 on 9 degrees of freedom

Analysis of Variance Table

Response: y

	Df	Sum Sq	Mean Sq
x	1	59.025	59.025
Residuals	9	9.281	1.031

Vänd!

- a Ange uttrycket (som en ekvation) för den linjära regressionsmodellen i exemplet ovan. Ange skattningarna av samtliga parametrar.

(2p)

- b Testa på signifikansnivå $\alpha = 0.01$ hurivida årsmedeltemperaturen 2004 sjönk ju längre norrut man kom.

(1p)

- c I en regressionsanalys arbetar man ofta med kvadratsummor. Beskriv de intressanta kvadratsummor som man tittar på och vilken information man kan få från dessa.

(2p)

Bioinformatik

7. Sekvensbioinformatik

- a Assuming a match score of 2, a mismatch score of -1 and a gap score of -2, derive the score matrix for a global alignment of "GTTA" and "GTCCA".

In this case, what is the score of an optimal global alignment? How many alignments have this optimal score (remember: each path represents a different alignment)? What are these alignments?

(2p)

- b The BLOSUM62 is shown below. Comment on the score between W and Y, and the score between L and D.

(1p)

- c Calculate the score of the following multiple alignment using the BLOSUM62 matrix and the sum of pairs method:

Sequence 1: GAHV
Sequence 2: GATA
Sequence 3: GSSV

(1p)

Vänd!

BLOSUM62 Matrix:

	A	R	N	D	C	Q	E	G	H	I	L	K	M	F	P	S	T	W	Y	V
A	4																			
R	-1	5																		
N	-2	0	6																	
D	-2	-2	1	6																
C	0	-3	-3	-3	9															
Q	-1	1	0	0	-3	5														
E	-1	0	0	2	-4	2	5													
G	0	-2	0	-1	-3	-2	-2	6												
H	-2	0	1	-1	-3	0	0	-2	8											
I	-1	-3	-3	-3	-1	-3	-3	-4	-3	4										
L	-1	-2	-3	-4	-1	-2	-3	-4	-3	2	4									
K	-1	2	0	-1	-3	1	1	-2	-1	-3	-2	5								
M	-1	-1	-2	-3	-1	0	-2	-3	-2	1	2	-1	5							
F	-2	-3	-3	-3	-2	-3	-3	-1	0	0	-3	0	6							
P	-1	-2	-2	-1	-3	-1	-1	-2	-2	-3	-3	-1	-2	-4	7					
S	1	-1	1	0	-1	0	0	0	-1	-2	-2	0	-1	-2	-1	4				
T	0	-1	0	-1	-1	-1	-1	-2	-2	-1	-1	-1	-1	-2	-1	1	5			
W	-3	-3	-4	-4	-2	-2	-3	-2	-2	-3	-2	-3	-1	1	-4	-3	-2	11		
Y	-2	-2	-2	-3	-2	-1	-2	-3	2	-1	-1	-2	-1	3	-3	-2	-2	2	7	
V	0	-3	-3	-3	-1	-2	-2	-3	-3	3	1	-2	1	-1	-2	-2	0	-3	-1	4

8. Strukturbioinformatik.

- a i Describe how an anti-parallel beta-sheet can be identified by the DSSP program.
ii Explain whether a proline residue can be present in an anti-parallel beta-sheet.
- b Describe one of the planarity checks performed by PROCHECK. State which atoms are involved in this check.

(3p)

(1p)