

DATORÖVNING 3  
MATEMATISK STATISTIK FÖR E — FMSF20

---

**Syfte:**

Syftet med dagens laborationen är att du skall:

- få förståelse för punkt- och intervallskattningar.
- få förståelse för hypotestest och styrkefunktioner.
- arbeta igenom ett riktigt exempel baserat på Radon mätningar.

Specialrutiner finns att hämta på: [www.maths.lu.se/kurshemsida/fmsf45masb03/](http://www.maths.lu.se/kurshemsida/fmsf45masb03/)

## 1 Bakgrund

Under den här laborationen kommer vi arbeta igenom ett exempel på en statistisk analys av Radon-mätningar samt illustrera de teoretiska egenskaperna hos skattningar och hypotestest. Uppgifterna i laborationen växlar mellan analysen av Radon-mätningarna och simulerings baserade illustrationer av punkt- och intervallskattningar, hypotestest och styrkefunktioner

### 1.1 Något om Radon och Radonmätningar

Radon är en ädelgas som är radioaktiv där den vanligast förekommande isotopen har en halveringstid på 3.8 dygn. Vid sönderfallen bildas alfa-partiklar, som kan orsaka (stor) skada i sin allra närmaste omgivning. Om gasen har inandats utgör lungvävnaden den närmaste omgivningen och Radon i inomhusmiljö beräknas orsaka 400 fall av lungcancer per år. 2004 sänktes riktvärden för bostäder från 400 Bq/m<sup>3</sup> till 200 Bq/m<sup>3</sup> (1 Bq/m<sup>3</sup> innebär att en atom sönderfaller per sekund i varje kubikmeter luft). Socialstyrelsens mål är att alla bostäder och offentliga utrymmen ska uppnå riktvärden senast 2020 (Världshälsoorganisationen, WHO, rekommenderar högst 100 Bq/m<sup>3</sup>; enligt en analys från Boverket<sup>1</sup> är 100 Bq/m<sup>3</sup> inte ”*samhällsekonomiskt rimligt*”).

Ett sätt att mäta radonkoncentrationen i inomhusluften är att hänga upp en alfa-känslig film. När filmen träffas av alfa-partiklar uppstår hål i filmen, antalet hål på en yta är ett mått på radonkoncentrationen.

### 1.2 Statistisk modell

För att kunna göra en ordentlig statistisk analys av ett mätmaterial behöver vi en statistisk modell för radioaktivt sönderfall. Det visar sig att sönderfallen bildar en **poisson-process**, där antalet sönderfall under en tidsperiod är Poissonfördelat enligt  $PO(\lambda \cdot T)$ , där  $\lambda$  beror av ämnets koncentration och halveringstid;  $T$  är längden av tidsperioden.

För våra filmer blir nu antalet hål på en given yta också Poisson-fördelat med ett väntevärde som är proportionellt mot Radonkoncentrationen, exponeringstiden och ytans storlek. Vidare är antalet hål på disjunkta (ej överlappande) ytor på en film **oberoende** stokastiska variabler.

---

<sup>1</sup>[www.boverket.se/globalassets/publikationer/dokument/2011/radon-i-inomhusmiljon.pdf](http://www.boverket.se/globalassets/publikationer/dokument/2011/radon-i-inomhusmiljon.pdf)

### 1.3 Förberedelseuppgifter

1. Repetera teorin för punkt- och intervallskattningar.
2. **Mozquizto 1:** Om  $X_i \in \text{Po}(\mu_i)$  och oberoende vilken fördelning har då summan  $Y = \sum_{i=1}^n X_i$ ?
3. **Mozquizto 2:** Givet ett stickprov  $x$  från  $X \in \text{Po}(\lambda \cdot T)$  ange en skattning av  $\lambda$  och skattningens medelfel.
4. Givet ett stickprov  $x_1, \dots, x_5$  från  $X_i \in \text{Po}(\lambda \cdot T)$  när kan skattningen  $\lambda^* = \frac{\bar{x}}{T}$  normalapproximeras?
5. **Mozquizto 3:** Vi har ett stickprov  $x_1, \dots, x_5$  från  $X_i \in \text{N}(\mu, 3)$ . En lämplig skattning av det okända väntevärdet  $\mu$  är  $\mu^* = \bar{x}$ . Vilken fördelning kommer skattningen  $\mu^* = \bar{x}$  att följa?
6. **Mozquizto 4:** Givet stickprovet i fråga 5, hur konstrueras ett 95%-igt konfidensintervall för  $\mu$ ? Vad händer om  $\sigma$  är okänd?
7. Förvissa dig om att du förstår hur hypotesprövning går till och vad styrkefunktionen innebär.
8. **Mozquizto 5:** Givet stickprovet och skattningen i fråga 5, vill vi testa  $H_0: \mu = 0$  mot  $H_1: \mu \neq 0$  på signifikansnivån  $\alpha = 0.05$  med hjälp av en teststorhet. Hur ser teststorheten och när ska  $H_0$  förkastas?
9. Givet en observation  $x = 3$  från  $X \in \text{Po}(\mu)$  där vi vill test  $H_0: \mu = 8$  mot  $H_1: \mu < 8$  på signifikansnivån  $\alpha = 0.05$  med hjälp av direktmetoden. Beräkna testets P-värde och avgör om  $H_0$  ska förkastas eller ej.

## 2 Skattningar av Radonkoncentrationen

Det datamaterial som vi skall arbeta med har uppmätts genom att ett antal rum i en bostad har försetts med var sin film. Dessa filmer har efter framkallning avlästs på tio, lika stora, icke överlappande ytor. Vi inför följande beteckningar:

$$\begin{aligned} n &= \text{antalet upphängda filmer, dvs antalet rum,} \\ \gamma_i &= \text{radonkoncentrationen i rum } i, \text{ mätt i Bq/m}^3, \\ X_{ij} &= \text{antalet hål i film } i \text{ på yta } j, i = 1, \dots, n, j = 1, \dots, 10. \end{aligned}$$

Enligt ovan gäller då  $X_{ij} \in \text{Po}(K \gamma_i)$ , där proportionalitetskonstanten  $K$  beror på avläsningsytornas storlek, exponeringstiden och framkallning/avläsningen av filmerna.

### 2.1 Radonmätningarna

Datamaterialet är uppmätt i en nybyggd bostad under 32 dagar i mars och april.

$i$	Rum	$X_{ij}$									
1	Vardagsrum	20	17	22	15	20	22	24	22	34	20
2	Sovrum	14	15	17	13	14	11	15	16	22	15
3	Mikaels rum	11	17	19	14	25	17	18	16	23	21

Datamaterialet finns i radon200.dat och läses in i Matlab med

```
>> radon=load('radon200.dat')
```

Kolonn 1 i variabeln radon innehåller nu mätvärdena för vardagsrummet, kolonn 2 sovrummet och kolonn 3 Mikaels rum.

**Efter förberedelse uppgifterna i Mozquizto kommer du att få ett eget värde på  $K$  att arbeta med.**

>> K = ? %värde från Mozquizto

Syftet med analysen av datamaterialet är att utreda om riktvärdet på 200 Bq/m<sup>3</sup> överskrids eller inte.

## 2.2 Punktskattningar

Vi startar med att studera de tre rummen var för sig. Tänk igenom att en väntevärdesriktig punktskattning  $\gamma_i^*$  av  $\gamma_i$ ,  $i = 1, 2, 3$ , ges av

$$\gamma_i^* = \frac{1}{10K} \sum_{j=1}^{10} X_{ij} = \frac{\bar{X}_i}{K} \quad \text{där } \bar{X}_i \text{ är medelvärdet i rum } i.$$

Beräkna skattningarna för datamaterialet ovan:

>> g3rum = mean(radon)/K

**Mozquizto 6:** Vad blev de tre  $\gamma$ -skattningarna?

För att kunna beräkna konfidensintervall behöver vi ta reda på de statistiska egenskaperna hos punktskattningarna. Vi har att

$$V(\gamma_i^*) = V\left(\frac{1}{10K} \sum_{j=1}^{10} X_{ij}\right) = \frac{1}{(10K)^2} \cdot \sum_{j=1}^{10} V(X_{ij}) = \frac{10K\gamma_i}{(10K)^2} = \frac{\gamma_i}{10K}$$

vilket ger medelfelet  $d(\gamma_i^*)$  för vart och ett av de tre rummen:

>> d3rum = sqrt(g3rum/(10\*K))

**Mozquizto 7:** Vad blev de tre medelfelen?

## 2.3 Intervallskattningar

För att få en uppfattning om hur stor radonkoncentrationen kan tänkas vara i de olika rummen gör vi 95 % konfidensintervall för  $\gamma_i$ . Det förutsätter att vi kan normalapproximera, dvs att

$$Y_i = \sum_{j=1}^{10} X_{ij} \in \text{Po}(10K\gamma_i) \quad \text{där } 10K\gamma_i > 15$$

>> g3rum\*10\*K

**Uppgift:** Kan vi normalapproximera i alla tre rummen?

Eftersom  $\gamma_i^* \in \mathbf{N}\left(\gamma_i, \sqrt{\gamma_i/(10K)}\right)$  ges konfidensintervallet av  $I_{\gamma_i} = \gamma_i^* \pm \lambda_{\alpha/2} \cdot d(\gamma_i^*)$ :

>> I3rum = [g3rum-norminv(1-0.05/2)\*d3rum; g3rum+norminv(1-0.05/2)\*d3rum]

Den första raden ger de lägre gränserna i de tre intervallen, den andra raden ger de övre gränserna.

**Mozquizto 8:** Finns det en risk att radonkoncentrationen över 200 Bq/m<sup>3</sup> i något av rummen (d.v.s. innehåller intervallet 200 Bq/m<sup>3</sup>)?

### 3 Skattningars egenskaper

Konfidensintervallet för radonkoncentrationen ovan bygger på en normalapproximation av Poissonfördelningen. För att få en uppfattning om hur punkt- och intervallskattningar fungerar studerar vi därför ett simulerings exempel med normalfördelad data.

#### 3.1 Punktskattningar

Antag att vi har ett stickprov  $x_1, \dots, x_n$  från  $X_i \in \mathbf{N}(\mu, 3)$ . En lämplig skattning av det okända väntevärdet  $\mu$  är nu  $\mu^* = \bar{x}$ . En viktig fråga är hur bra skattningen blir för olika värden på  $n$  och  $\sigma$ . Matlab rutinen `skattningar` simulerar 1 000 olika stickprov och jämför skattningarna med det sanna värdet. Låts se vad som händer om vi har  $n_1 = 5$  eller  $n_2 = 25$  observationer med sant  $\mu = 1$

```
>> skattningar(1, 3, 5, 25, 'muskatt')
```

Använd rutinen för att undersöka vad som händer när antalet observationer,  $n$ , och osäkerheten,  $\sigma$ , ändras.

**Mozquizto 9:** Hur bör vi välja antalet observationer,  $n$ , och standardavvikelsen,  $\sigma$  för att få en så bra skattning som möjligt?

#### 3.2 Intervallskattningar

Med rutinen `skattningar` kan vi också illustrera de konfidensintervall för  $\mu$  som våra 1 000 stickprov genererar. Intervallet för  $\mu$  ges ju av (känt  $\sigma$ )

$$I_\mu = \mu^* \pm \lambda_{\alpha/2} \cdot D(\mu^*) = \mu^* \pm \lambda_{\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}$$

För att plotta 100 intervall baserade på  $n_1 = 5$  eller  $n_2 = 25$  observationer med sant  $\mu = 1$  kan vi använda

```
>> skattningar(1, 3, 5, 25, 'konfint')
```

Använd rutinen för att undersöka vad som händer när antalet observationer,  $n$ , och osäkerheten,  $\sigma$ , ändras. Ändras antalet intervall som **inte** innehåller rätt värde på  $\mu$  (de röda intervallen)?

**Mozquizto 10:** Hur påverkas intervallbredden av antalet observationer och standardavvikelsen?

## 4 Test av Radonkoncentrationen

### 4.1 Hypotesprövning med direktmetoden

Man kan också välja att utföra analysen som ett hypotesprövningsproblem. Den som ska bo i ett rum vill testa

$$H_0 : \gamma_i = 200 \text{ Bq/m}^3, \quad \text{mot} \quad H_1 : \gamma_i < 200 \text{ Bq/m}^3.$$

**Mozquizto 11:** Varför vill invånarna ha ett ensidigt test åt detta hållet?

Tidigare gjorde vi punkt- och intervallskattningar av  $\gamma_i$ , vilket ger kvantitativ information om var de sanna värdena kan tänkas ligga. För att göra hypotestest kan vi i det här fallet använda direktmetoden, d.v.s. vi räknar ut ett  $p$ -värde som

$$p = \mathbf{P}(\text{Få det vi fått eller värre om } H_0 \text{ är sann})$$

och förkastar  $H_0$  om  $p < \alpha$ . För att räkna utan normalapproximation kan vi räkna direkt med observationerna  $X_{ij} \in \mathbf{Po}(K\gamma_i)$  och framförallt utnyttja att summan av observationerna i ett rum också är Poissonfördelad,

$$Y_i = \sum_{j=1}^{10} X_{ij} \in \mathbf{Po}(10K\gamma_i).$$

```
>> gamma0 = 200;
>> mu03rum = 10*K*gamma0           % väntevärdet för summan när H0 är sann
>> y3rum = sum(radon)              % summorna i de tre rummen
>> P3rum = poisscdf(y3rum,mu03rum) % P(Y_i <= y_i)
```

**Mozquizto 12:** Kan nollhypotesen förkastas på signifikansnivån 5% i något av rummen?

Summan av samtliga observationer i alla rummen är också poissonfördelad. Vi räknar ut ett  $p$ -värde som gäller för hela huset och avgör med direktmetoden om  $H_0: \gamma = 200$  skall förkastas, där  $\gamma$  är medelradonkoncentrationen i hela huset. Utgå från koden ovan och ertsätt ... nedan för beräkna  $p$ -värdet

```
>> mu0hus = ...           % väntevärdet för hela huset när H0 är sann
>> yhus = ...            % summan för hela huset
>> Phus = ...           % använd poisscdf för att beräkna p-värdet
```

**Mozquizto 13:** Vad blir  $p$ -värdet för testet av medelradonkoncentrationen i hela huset?

## 5 Hypotestest — Grundläggande egenskaper

Ett alternativ till direktmetoden är att räkna med normalapproximation och teststorhet. Vi behöver då vara försiktiga med att räkna medelfelet **under**  $H_0$ . Om  $H_0$  är sann gäller att

$$\gamma^* = \frac{\bar{X}_1 + \bar{X}_2 + \bar{X}_3}{3K} \underset{\approx}{\in} \mathbf{N}\left(\gamma_0, \sqrt{\frac{\gamma_0}{30K}}\right)$$

och teststorheten blir

$$T = \frac{\gamma^* - \gamma_0}{\mathbf{d}_0(\gamma^*)} = \frac{\gamma^* - \gamma_0}{\sqrt{\gamma_0/30K}}$$

**Uppgift:** Blir det någon skillnad i resultatet jämfört med direktmetoden?

Precis som för konfidensintervallet ser vi att hypotestestet kan genomföras genom normalapproximation av Poisson-fördelningen. För data som är normalfördelad från början kan vi använda styrkefunktionen för att undersöka hur stora skillnader som testet kan upptäcka. (Det går att räkna ut styrka även för Poisson baserade test, men det är lite krångligare.)

### 5.1 Styrkefunktion för normalfördelningar med känt $\sigma$

Funktionen styrkefkn illustrerar styrkefunktionen om

$$h(\mu) = \mathbf{P}(\text{förfasta } H_0 \text{ om } \mu \text{ är det rätta värdet})$$

för test av nollhypotesen  $H_0: \mu = \mu_0$  om observationerna är  $X_i \in \mathbf{N}(\mu, \sigma)$  med känd standardavvikelse  $\sigma$  och  $\mu^* = \bar{x}$ .

För att illustrera  $h(\mu)$  vid ett test av  $H_0: \mu = 0$  mot  $H_0: \mu \neq 0$  på signifikansnivån  $\alpha = 0.05$  med  $n = 10$  observationer och  $\sigma = 1$

```
>> styrkefkn(1, 10, 0, 0.05, '!=')
```

För ensidiga test har vi

```
>> styrkefkn(1, 10, 0, 0.05, '<')
```

```
>> styrkefkn(1, 10, 0, 0.05, '>')
```

**Uppgift:** Hur påverkas styrkefunktionen av antalet observationer,  $n$ , standardavvikelsen,  $\sigma$ , och konfidsgraden,  $\alpha$ ?

**Mozquizto 14:** Undersök också hur styrkan ser ut för ensidiga test. För vilka värden är blir  $h(\mu)$  stor eller liten, verkar det rimligt?

Genom att ange ytterligare en parameter beräknas styrkan i en punkt. T.ex. så ger

```
>> styrkefkn(1, 10, 0, 0.05, '!=', 0.5)
```

värdet av  $h(0.5)$  och illustrerar regionerna för typ 1 och typ 2 fel.

**Uppgift:** Vad illustrerar de blå och röda området i den övre figuren?

**Mozquizto 15:** Vad är sannolikheten att upptäcka att  $\mu \neq 0$  om det sanna värdet är  $\mu = 0.5$ ?

### 5.2 Styrkefunktion för normalfördelning med okänt $\sigma$

I de flesta praktiska situationer känner vi inte  $\sigma$  utan den måste skattas med  $\sigma^* = s$ . Det gör att teststorheten  $T = \frac{\mu^* - \mu_0}{d(\mu^*)}$ , där  $d(\mu^*) = s/\sqrt{n}$  blir  $t(n-1)$ -fördelad när  $H_0$  är sann. Den kommer då att variera mer än tidigare, eftersom  $s$  i nämnaren också varierar slumpmässigt. Det gör det något besvärligare att beräkna styrkan. Som tidigare vet vi att teststorheten

$$T = \frac{\mu^* - \mu_0}{d(\mu^*)} = \frac{\mu^* - \mu_0}{s/\sqrt{n}}$$

följer en  $t(n-1)$ -fördelning som är symmetrisk kring 0. I allmänhet, kan styrkan (d.v.s.  $h(\mu)$  när  $\mu \neq \mu_0$ ) beräknas med hjälp av en icke-central  $t$ -fördelning med  $f = n - 1$  frihetsgrader och centeringsparameter  $\Delta = \frac{\mu_1 - \mu_0}{\sigma/\sqrt{n}}$ . Den intresserade kan läsa mer på [en.wikipedia.org/wiki/Noncentral\\_t-distribution](http://en.wikipedia.org/wiki/Noncentral_t-distribution).