

MVE051/MSG810 2016 Föreläsning 1

Petter Mostad

Chalmers

November 1, 2016

Introduktion till statistik

- ▶ En vanlig definition av statistik: Sammanställningar och visualiseringar av data.
- ▶ Matematisk statistik: Ett sätt att göra vetenskapliga modeller för verkligheten som tar hänsyn till osäkerhet.
- ▶ Vetenskapliga modeller för verkligheten:
 - ▶ Beskriver en specificerad del av verkligheten.
 - ▶ Använder ofta ett matematisk ramverk.
 - ▶ Används för att *predikera* nya observationer: En modell är bättre än en annan om den predikerar bättre.
 - ▶ "All models are wrong but some models are useful" (G. Box)
- ▶ För många delar av verkligheten är det naturligt att prediktionerna görs *med osäkerhet* (Exempel "Det är 90% chans för soligt väder i morgon"). Modeller som gör prediktioner med osäkerhet kallas *stokastiska modeller* (eller statistiska modeller).
- ▶ Första delen (största delen) av vår kurs handlar om *sannolikhetsteori*, det matematiska språket för stokastiska modeller.

Vad är sannolikhet?

- ▶ Sannolikhets teori är en väletablerad matematisk teori. Men när det gäller *tolkningen* av prediktioner från stokastiska modeller, så finns det olika åsikter, eller skolor. Exempel: Hur tolkas
 1. Sannolikheten för att denna geologiska formationen innehåller olja är 34%.
 2. Sannolikheten för lyckad hjärtoperation är ca. 96%.
- ▶ I en *subjektiv/personlig* eller *Bayesiansk* modell anser man att den stokastiska modellen modellerar en enskild persons *kunskap* om verkligheten. Dock på ett sådant sätt att två fornuftiga personer som har samma information bör få samma sannolikheter. Därmed kan man prata om sannolikheten för händelser som inte kan repeteras, som i (1) över.
- ▶ En *frekventistisk* synpunkt anser att bara händelser som på något sätt kan repeteras kan ges en sannolikhet; sannolikheten är då gränsen för *frekvensen* av händelsen när antalet repetitioner närmar sig oändligheten. I (2) kan 96% ha framkommit som en frekvens.

Hur kan man ta fram en sannolikhet?

- ▶ Vanligtvis hittar man en modell för verkligheten som man argumenterar är rimlig, och härleder sen sannolikheter från denna.
- ▶ Det enklaste exemplet:
 - ▶ Man anser att det finns ett ändligt antal möjliga utfall, och att varje av dessa utfall har samma sannolikhet.
 - ▶ Sannolikheten för en händelse som motsvarar en delmängd av de möjliga utfallen är summan av antalet utfall i delmängden delat på det totala antalet utfall.
- ▶ Exempel: Sannolikheten för att nästa kast med tärningen blir 4 är $1/6$, därför att det är 6 olika utfall, och alla borde ha samma sannolikhet.
- ▶ Exempel: Sannolikheten för att nästa kast med tärningen ger mindre än 4 är $1/2$, därför att denna händelse motsvarar 3 av 6 möjliga utfall.

Några viktiga begrepp

- ▶ Utfall (eng. outcome (eller "sample point")): En specifik möjlighet för den delen av verkligheten vi beskriver.
- ▶ Utfallsrum (eng. sample space): Samlingen av alla utfall som vi anser möjliga.
- ▶ Händelse (eng. event): En delmängd av utfallsrummet.
- ▶ Trädiagram (eng. tree diagram): Ett sätt att beskriva vissa utfallsrum.

Axiomer för sannolikhetsteori

Låt S vara ett utfallsrum. En sannolikhetsfördelning är en funktion som till alla ("mätbara") delmängder A av S tillordnar ett tal $\Pr[A]$, så att

- ▶ $\Pr[S] = 1$
- ▶ $\Pr[A] \geq 0$
- ▶ Låt $A_1, A_2, \dots, A_k, \dots$ vara händelser (delmängder av S) så att $A_i \cap A_j = \emptyset$ (de är icke-överlappande) om $i \neq j$. Då är

$$\Pr[A_1 \cup A_2 \cup \dots \cup A_k \cup \dots] = \Pr[A_1] + \Pr[A_2] + \dots + \Pr[A_k] + \dots$$

Några konsekvenser av axiomen

- ▶ $\Pr[\emptyset] = 0$
- ▶ $\Pr[A'] = 1 - \Pr[A]$, där A' är komplementet till A i S (skrivs även A^c eller $S \setminus A$).
- ▶ Om A_1 och A_2 är två händelser så har vi

$$\Pr[A_1 \cup A_2] = \Pr[A_1] + \Pr[A_2] - \Pr[A_1 \cap A_2]$$

Betingade sannolikheter

- ▶ Den *betingade* sannolikheten för A_2 givet A_1 , där $\Pr(A_1) > 0$, är definierad som

$$\Pr[A_2 \mid A_1] = \frac{\Pr[A_1 \cap A_2]}{\Pr[A_1]}$$

- ▶ Tolkning: OM vi vet att A_1 händer (eller: givet att A_1 händer), vad är då sannolikheten för A_2 ?
- ▶ Lär dig att skilja mellan $\Pr[A_1 \mid A_2]$ och $\Pr[A_2 \mid A_1]$!
- ▶ Från definitionen får vi att

$$\Pr[A_1 \cap A_2] = \Pr[A_1] \cdot \Pr[A_2 \mid A_1]$$

Viktiga räkneregler

- ▶ En viktig räkneregel (om $0 < \Pr[A_1] < 1$) blir

$$\begin{aligned}\Pr[A_2] &= \Pr[(A_2 \cap A_1) \cup (A_2 \cap A'_1)] = \Pr[A_2 \cap A_1] + \Pr[A_2 \cap A'_1] \\ &= \Pr[A_2 \mid A_1] \cdot \Pr[A_1] + \Pr[A_2 \mid A'_1] \cdot \Pr[A'_1]\end{aligned}$$

- ▶ Mera generellt, om $S = B_1 \cup B_2 \cup \dots \cup B_k$ och $B_1, \dots, B_k$ är icke-överlappande (så $B_i \cap B_j = \emptyset$ om $i \neq j$) och $\Pr[B_i] > 0$ så har vi

$$\begin{aligned}\Pr[A] &= \Pr[(A \cap B_1) \cup (A \cap B_2) \cup \dots \cup (A \cap B_k)] \\ &= \Pr[A \cap B_1] + \Pr[A \cap B_2] + \dots + \Pr[A \cap B_k] \\ &= \Pr[A \mid B_1] \Pr[B_1] + \Pr[A \mid B_2] \Pr[B_2] + \dots + \Pr[A \mid B_k] \Pr[B_k]\end{aligned}$$

Flera räkneregler



$$\Pr[A \mid B \cap C] = \frac{\Pr[A \cap B \cap C]}{\Pr[B \cap C]} = \frac{\Pr[A \cap B \mid C]}{\Pr[B \mid C]}$$



$$\Pr[A \cap B \mid C] = \Pr[A \mid B \cap C] \Pr[B \mid C]$$



$$\begin{aligned} \Pr[A_1 \cap A_2 \cap A_3] &= \Pr[A_1] \Pr[A_2 \cap A_3 \mid A_1] \\ &= \Pr[A_1] \Pr[A_2 \mid A_1] \Pr[A_3 \mid A_1 \cap A_2] \end{aligned}$$



Oberoende händelser

- ▶ Två händelser A_1 och A_2 kallas oberoende om

$$\Pr[A_1 \cap A_2] = \Pr[A_1] \cdot \Pr[A_2]$$

- ▶ Vi får att A_1 och A_2 (med $\Pr[A_1] > 0$) är oberoende om och endast om

$$\Pr[A_2 \mid A_1] = \Pr[A_2]$$

- ▶ $A_1, A_2, \dots, A_n$ är oberoende händelser om, för alla urval $A_{(1)}, A_{(2)}, \dots, A_{(k)}$ av dessa gäller

$$\Pr[A_{(1)} \cap A_{(2)} \cap \dots \cap A_{(k)}] = \Pr[A_{(1)}] \Pr[A_{(2)}] \dots \Pr[A_{(k)}]$$

Bayes teorem

- För händelser A och B med $\Pr[A] > 0$ och $\Pr[B] > 0$ får vi direkt att

$$\Pr[A | B] = \frac{\Pr[B | A] \Pr[A]}{\Pr[B]} = \frac{\Pr[B | A] \Pr[A]}{\Pr[B | A] \Pr[A] + \Pr[B | A'] \Pr[A']}$$

Detta kallas Bayes formel.

- Mera generellt har vi, om $S = A_1 \cup A_2 \cup \dots \cup A_k$, $A_1, \dots, A_k$ är icke-överlappande och $\Pr[A_j] > 0$, $\Pr[B] > 0$, så har vi

$$\Pr[A_j | B] = \frac{\Pr[B | A_j] \Pr[A_j]}{\Pr[B]} = \frac{\Pr[B | A_j] \Pr[A_j]}{\sum_{i=1}^k \Pr[B | A_i] \Pr[A_i]}$$

- Delar vi Bayes former för $\Pr[A | B]$ på formeln för $\Pr[A' | B]$ får vi

$$\frac{\Pr[A | B]}{\Pr[A' | B]} = \frac{\Pr[B | A]}{\Pr[B | A']} \cdot \frac{\Pr[A]}{\Pr[A']}$$