

MS-A0509 Grundkurs i sannolikhetskalkyl och statistik

Sammanfattning, del I

G. Gripenberg

Aalto-universitetet

28 januari 2014

Vad är sannolikhet?

- *Relativ frekvens vid upprepningar: Om en fabrik tillverkat 1000 000 exemplar av en produkt av vilka 5015 har något fel så är sannolikheten för en felaktighet 0.005*
- *Andelen fall då ett något förekommer: Om i en urna finns 6 svarta och 4 vita kulor och man slumpmässigt väljer en kula så är sannolikheten att den är svart $\frac{6}{6+4} = 0.6$.*
- *Ett mått på hur troligt man anser något vara: "Sannolikheten för hård vind imorgon är 70%."*

💡 Sannolikhet, händelser, utfallsrum

- *Mängden av alla tänkbara resultat av ett "experiment" är **utfallstummet**, ofta betecknat med Ω .*
- *Elementen i utfallsrummet, dvs. enskilda resultat av experimentet är **elementarhändelser**.*
- **Händelser** är delmängder av utfallsrummet.
- *För varje händelse $A \subset \Omega$ finns det en sannolikhet $\Pr(A)$ för denna händelse.*
- *Sannolikhetsfunktionen uppfyller följande villkor:*
 - ★ $0 \leq \Pr(A) \leq 1$ för varje händelse A .
 - ★ $\Pr(\Omega) = 1$.
 - ★ $\Pr(\cup_{i=1}^{\infty} A_i) = \sum_{i=1}^{\infty} \Pr(A_i)$ om $A_j \cap A_k = \emptyset$ då $j \neq k$.

💡 Obs

Av antagandena ovan följer bla. också att

- ★ $\Pr(\emptyset) = 0.$
- ★ $\Pr(A \cup B) = \Pr(A) + \Pr(B) - \Pr(A \cap B).$
- ★ $\Pr(\Omega \setminus A) = 1 - \Pr(A).$
- ★ $A \subset B \Rightarrow \Pr(A) \leq \Pr(B).$

😊 Obs!

Då Ω innehåller ändligt många element är det naturligt att alla delmängder av Ω är händelser men i allmänhet är detta inte alltid möjligt eller ens önskvärt och då är \Pr en funktion definierad i en σ -algebra \mathcal{A} i Ω , dvs en mängd \mathcal{A} med följande egenskaper:

- $A \in \mathcal{A} \rightarrow A \subset \Omega,$
- $\Omega \in \mathcal{A},$
- $A \in \mathcal{A} \rightarrow \Omega \setminus A \in \mathcal{A},$
- $A_i \in \mathcal{A}, i = 1, 2, \dots \rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{A}.$

💡💡 Oberoende

Händelserna A och B är oberoende ifall

$$\Pr(A \cap B) = \Pr(A) \cdot \Pr(B),$$

och händelserna $A_j, j \in J$ är oberoende om

$$\Pr(A_{j_1} \cap A_{j_2} \cap \dots \cap A_{j_m}) = \Pr(A_{j_1}) \cdot \Pr(A_{j_2}) \cdot \dots \cdot \Pr(A_{j_m})$$

alltid då $j_k \in J, k = 1, \dots, m, j_p \neq j_q$ då $p \neq q$.

Obs!

Om händelserna $A_j, j \in J$ är oberoende så är A_{j_p} och A_{j_q} oberoende då $j_p \neq j_q$ men om A_{j_p} och A_{j_q} är oberoende för alla $j_p \neq j_q$ så behöver inte händelserna $A_j, j \in J$ vara oberoende.

💡💡 Betingad sannolikhet

Den betingande sannolikheten för händelsen A givet händelsen B är

$$\Pr(A|B) = \frac{\Pr(A \cap B)}{\Pr(B)},$$

då man antar att $\Pr(B) > 0$.

Då händelsen B är given kan man begränsa utfallsrummet från Ω till B och räkna om sannolikheterna för händelserna $A \cap B$ som är delmängder av det nya utfallsrummet.

😊 Total sannolikhet

Om $\cup_{j=1}^n A_j = \Omega$, $A_j \cap A_k = \emptyset$ då $j \neq k$ och $\Pr(A_j) > 0$ då $j = 1, \dots, n$ så gäller

$$\Pr(B) = \sum_{j=1}^n \Pr(A_j) \cdot \Pr(B|A_j).$$

Varför? Eftersom $B = B \cap \Omega = \cup_{j=1}^n B \cap A_j$ och $(B \cap A_j) \cap (B \cap A_k) = \emptyset$ då $j \neq k$ så är $\Pr(B) = \sum_{j=1}^n \Pr(B \cap A_j)$ och enligt definitionen är $\Pr(A_j) \cdot \Pr(B|A_j) = \Pr(B \cap A_j)$.

💡💡 Bayes formel

Om $\cup_{j=1}^n A_j = \Omega$, $A_j \cap A_k = \emptyset$ då $j \neq k$ och $\Pr(A_j) > 0$ då $j = 1, \dots, n$ så gäller

$$\Pr(A_k|B) = \frac{\Pr(A_k) \cdot \Pr(B|A_k)}{\sum_{j=1}^n \Pr(A_j) \cdot \Pr(B|A_j)}.$$

Varför?

$$\Pr(A_k|B) = \frac{\Pr(A_k \cap B)}{\Pr(B)}, \quad \Pr(A_k) \cdot \Pr(B|A_k) = \Pr(A_k \cap B) \quad \text{och}$$

$$\sum_{j=1}^n \Pr(A_j) \cdot \Pr(B|A_j) = \Pr(B).$$

💡💡 Klassisk sannolikhet och kombinatorik

$$\Pr(A) = \frac{\text{Antal fall då } A \text{ inträffar}}{\text{Totala antalet möjliga fall}}$$

Man antar alltså att varje elementarhändelse är lika sannolik och problemet blir att bestämma hur många element det finns i utfallsrummet Ω och hur många av dessa hör som till mängden A .

💡💡 Produktprincipen

Om i en urvalsprocess finns k steg och i steg j finns n_j alternativ, oberoende av vilka val som gjorts i tidigare steg (men vilka alternativen är kan bero på valen) så är det totala antalet alternativ

$$n_1 \cdot n_2 \cdot \dots \cdot n_k.$$

💡 Permutationer, binomialkoefficienter etc.

Om det i en mängd finns n element kan dessa ordnas på

$$n! = 1 \cdot 2 \cdot 3 \cdot \dots \cdot (n-1) \cdot n,$$

olika sätt. (Kom ihåg: $0! = 1$)

Om man ur en mängd med n element väljer k element och beaktar i vilken ordning elementen väljs, kan detta göras på

$$n \cdot (n-1) \cdot \dots \cdot (n-k+1) = \frac{n!}{(n-k)!}$$

olika sätt.

Om man ur en mängd med n element väljer en delmängd med k element, dvs. inte beaktar i vilken ordning elementen väljs, kan detta göras på

$$\binom{n}{k} = \frac{n!}{k!(n-k)!},$$

olika sätt.

I alla dessa fall kan varje element i mängden väljas bara en gång, dvs. om man plockar kulor ur en urna läggs dessa inte tillbaka i urnan.

💡💡 Upprepning av "experiment"

*Antag att ett experiment upprepas n gånger så att händelser vid olika gånger är oberoende.
Då är sannolikheten för att händelsen A inträffar exakt k gånger*

$$\binom{n}{k} \Pr(A)^k (1 - \Pr(A))^{n-k}.$$

Slumpvariabler och fördelningsfunktioner

En (reell) **slumpvariabel** (eller **stokastisk variabel**) är en funktion $X : \Omega \rightarrow \mathbb{R}$ (alltså inte egentligen en variabel) där Ω är ett utfallsrum för ett experiment i vilken en sannolikhet är definierad och $\{\omega \in \Omega : X(\omega) \leq x\}$ är en händelse för alla $x \in \mathbb{R}$.

Om X är en (reell) slumpvariabel så är dess (kumulativa) fördelningsfunktion funktionen

$$F_X(x) = \Pr(X \leq x) = \Pr(\{\omega \in \Omega : X(\omega) \leq x\}).$$

En funktion $F : \mathbb{R} \rightarrow [0, 1]$ är en fördelningsfunktion om och endast om

- $0 \leq F(x) \leq F(y) \leq 1$ då $x < y$,
- $\lim_{x \rightarrow -\infty} F(x) = 0$ och $\lim_{x \rightarrow \infty} F(x) = 1$,
- $\lim_{y \rightarrow x+} F(y) = F(x)$ då $x \in \mathbb{R}$.

När F är en fördelningsfunktion för X så gäller dessutom att

- $\lim_{y \rightarrow x-} F(y) = \Pr(X < x)$,
- $\lim_{y \rightarrow x+} F(y) - \lim_{y \rightarrow x-} F(y) = \Pr(X = x)$.

Obs!

Uttryck som $X \leq x$ och $X < x$ är formellt sett inte händelser (dvs. delmängder i Ω) men man skriver oftast $\Pr(X \leq x)$ istället för det längre uttrycket $\Pr(\{\omega \in \Omega : X(\omega) \leq x\})$.

Oberoende slumpvariabler

De (reella) slumpvariablerna $X_j, j \in J$ definierade i samma utfallsrum är oberoende om händelserna $\{X_j \leq a_j\}, j \in J$ är oberoende för alla $a_j \in \mathbb{R}, j \in J$.

💡💡 Diskreta slumpvariabler

En (reell) slumpvariabel X är diskret om det finns en mängd $A \subset \mathbb{R}$ och positiva tal $f(a)$, $a \in A$ så att

$$F_X(x) = \sum_{\substack{a \leq x \\ a \in A}} f(a).$$

Detta innebär att $\Pr(X = a) = f(a)$ då $x \in A$ och $\sum_{a \in A} f(a) = 1$ så att $\Pr(X \notin A) = 0$ och mängden A innehåller högst numrerbart många element liksom oftast också utfallsrummet Ω . Funktionen f är **frekvensfunktionen** eller sannolikhetsfunktionen för X .

Kontinuerliga slumpvariabler

En slumpvariabel är kontinuerlig om fördelningsfunktionen är kontinuerlig, dvs. om $\Pr(X = a) = 0$ för alla $a \in \mathbb{R}$. Oftast använder man sig ändå av absolut kontinuerliga slumpvariabler för vilka det finns en **täthetsfunktion** f så att

$$F_X(x) = \int_{-\infty}^x f(t) dt.$$

Detta innebär att $f(x) \geq 0$ och $\int_{-\infty}^{\infty} f(t) dt = 1$.

💡💡 Väntevärde och varians

Om X är en slumpvariabel så är dess väntevärde

$$E(X) = \sum_x x \Pr(X = x) = \sum_x x f_X(x),$$

då X är en diskret slumpvariable med frekvensfunktion f_X och

$$E(X) = \int_{-\infty}^{\infty} x f_X(x) dx,$$

då X är en *absolut* kontinuerlig slumpvariabel med täthetsfunktion f_X , i båda fallen förutsatt att summan eller integralen existerar (i annat fall kan man skriva $E(X) = \text{NaN}$).

Om g är en *mätbar* funktion så är

$$E(g(X)) = \int_{-\infty}^{\infty} g(x) f_X(x) dx.$$

Om slumpvariabeln X har ett väntevärde så är dess **varians**

$$\text{Var}(X) = E\left((X - E(X))^2\right).$$

Väntevärde och varians, forts.

Om X_1 och X_2 är två slumpvariabler så är

$$E(c_1X_1 + c_2X_2) = c_1E(X_1) + c_2E(X_2),$$

och om X_1 och X_2 är två **oberoende** slumpvariabler så är

$$\text{Var}(c_1X_1 + c_2X_2) = c_1^2\text{Var}(X_1) + c_2^2\text{Var}(X_2).$$

😊 Chebyshevs olikhet

$$\Pr\left(|X - E(X)| \geq k\sqrt{\text{Var}(X)}\right) \leq \frac{1}{k^2}, \quad k > 1.$$

Varför?

Låt $g(x) = 1$ om $\frac{|x - E(X)|}{k\sqrt{\text{Var}(X)}} \geq 1$ och 0 annars. Detta betyder att

$E(g(X)) = \Pr(|X - E(X)| \geq k\sqrt{\text{Var}(X)})$. Nu är $g(x) \leq \left(\frac{|x - E(X)|}{k\sqrt{\text{Var}(X)}}\right)^2$ så att

$$\begin{aligned}\Pr\left(|X - E(X)| \geq k\sqrt{\text{Var}(X)}\right) &= E(g(X)) \\ &\leq E\left(\left(\frac{|x - E(X)|}{k\sqrt{\text{Var}(X)}}\right)^2\right) = \frac{1^2 \text{Var}(X)}{k^2 \text{Var}(X)} = \frac{1}{k^2}.\end{aligned}$$

Några viktiga diskreta slumpvariabler och deras fördelningar

- *Jämn diskret fördelning*: $\Pr(X = x_i) = \frac{1}{n}, i = 1, 2, \dots, n.$
- *Bernoullifördelning*: $\Pr(X = 1) = p, \Pr(X = 0) = (1 - p).$ I detta fall är $X(\omega) = 1$ då $\omega \in A \subset \Omega$ och $X(\omega) = 0$ då $\omega \in \Omega \setminus A$ där $\Pr(A) = p.$ Väntevärdet p och variansen $p(1 - p).$
- *Binomialfördelning* $X \sim \text{Bin}(n, p): \Pr(X = k) = \binom{n}{k} p^k (1 - p)^{n-k},$
 $k = 0, 1, \dots, n,$ dvs. X är summan av n oberoende Bernoulli-fördelade slumpvariabler. $E(X) = np$ och $\text{Var}(X) = np(1 - p).$
- *Poissonfördelning* $X \sim \text{Poisson}(\lambda): \Pr(X = k) = e^{-\lambda} \frac{\lambda^k}{k!},$
 $k = 0, 1, 2, \dots.$ Fås som gränsvärde av binomialfördelningen då $np \rightarrow \lambda.$ Väntevärdet och variansen är $\lambda.$
- *Två varianter av geometrisk fördelning*: Ett experiment upprepas tills händelsen A med sannolikheten p inträffar. X_1 är antalet upprepningar och X_2 är antalet upprepningar innan A inträffar så att $X_1 = X_2 + 1,$
 $\Pr(X_1 = k) = (1 - p)^{k-1} p, k \geq 1$ och $\Pr(X_2 = k) = (1 - p)^k p,$
 $k \geq 0.$ $E(X_1) = \frac{1}{p}, E(X_2) = \frac{1-p}{p}$ och båda har variansen $\frac{1-p}{p^2}.$

Några viktiga kontinuerliga slumpvariabler och deras fördelningar

- *Likformig kontinuerlig fördelning* (där $-\infty < a < b < \infty$):

$$f_X(x) = \begin{cases} \frac{1}{b-a}, & a < x < b, \\ 0, & x \leq a \text{ eller } x \geq b. \end{cases}$$

Väntevärdet är $\frac{1}{2}(a + b)$ och variansen $\frac{1}{12}(b - a)^2$.

- *Normalfördelning* $X \sim N(\mu, \sigma^2)$:

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}.$$

Väntevärdet är μ och variansen σ^2 .

- *Exponentialfördelning* $X \sim \text{Exp}(\lambda)$ med $\lambda > 0$:

$$f_X(x) = \begin{cases} \lambda e^{-\lambda x}, & x > 0, \\ 0, & x \leq 0. \end{cases}$$

Väntevärdet är $\frac{1}{\lambda}$ och variansen $\frac{1}{\lambda^2}$.

💡💡 Centrala gränsvärdessatsen

Ifall slumpvariablerna X_1, X_2, \dots är oberoende och har samma fördelning så att $E(X_j) = \mu$ och $\text{Var}(X_j) = \sigma^2$, $j = 1, 2, \dots$, så gäller

$$\frac{\sum_{j=1}^n X_j - n\mu}{\sigma\sqrt{n}} \underset{a}{\sim} N(0, 1) \quad \text{då } n \rightarrow \infty,$$

dvs.

$$\lim_{n \rightarrow \infty} \Pr \left(\frac{\sum_{j=1}^n X_j - n\mu}{\sigma\sqrt{n}} \leq x \right) = F_{N(0,1)}(x) \stackrel{\text{def}}{=} \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt.$$

Normalapproximation

Om X är summan av "tillräckligt" många oberoende slumpvariabler med ändlig varians så är $\frac{X - E(X)}{\sqrt{\text{Var}X}}$ ungefär $N(0, 1)$ -fördelad.



Tvådimensionella slumpvariabler och fördelningar

- *Ifall Ω är ett utfallsrum på vilket en sannolikhetsfunktion är definierad så är $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ en tvådimensionell slumpvariabel med fördelningsfunktion $F_{XY}(x, y) = \Pr(X \leq x, Y \leq y)$ förutsatt att $\{\omega \in \Omega : X(\omega) \leq x, Y(\omega) \leq y\}$ är en mängd för vilken sannolikheten är definierad.*
- *En tvådimensionell slumpvariabel (X, Y) är diskret och den har frekvensfunktionen $f_{XY}(x, y)$ ifall $f_{XY}(x, y) \geq 0$ för alla x och y , $\sum_x \sum_y f_{XY}(x, y) = 1$ och $\Pr(X = x, Y = y) = f_{XY}(x, y)$ för alla x och y .*
- *En tvådimensionell slumpvariabel (X, Y) är kontinuerlig och har täthetsfunktion $f_{XY}(x, y)$ ifall $f_{XY}(x, y) \geq 0$ för alla x och y , $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{XY}(x, y) dx dy = 1$ och $F_{XY}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{XY}(s, t) dt ds$ för alla x och y .*



Marginalfördelningar

- Ifall $f_{XY}(x, y)$ är frekvensfunktionen för den diskreta tvådimensionella slumpvariabeln (X, Y) så är marginalfrekvensfunktionerna för slumpvariablerna X och Y

$$f_X(x) = \Pr(X = x) = \sum_y f_{XY}(x, y) \quad \text{och}$$

$$f_Y(y) = \Pr(Y = y) = \sum_x f_{XY}(x, y).$$

- Ifall $f_{XY}(x, y)$ är täthetsfunktionen för den kontinuerliga tvådimensionella slumpvariabeln (X, Y) så är marginaltäthetsfunktionerna för slumpvariablerna X och Y

$$f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy \quad \text{och} \quad f_Y(y) = \int_{-\infty}^{\infty} f_{XY}(x, y) dx.$$

💡💡 Oberoende slumpvariabler

Om (X, Y) är en diskret tvådimensionell slumpvariabel eller en kontinuerlig tvådimensionell slumpvariabel med täthetsfunktion så gäller

$$X \text{ och } Y \text{ är oberoende} \Leftrightarrow f_{XY}(x, y) = f_X(x)f_Y(y).$$

Om X och Y är oberoende och f och g är mätbara funktioner så gäller

$$E(f(X)g(Y)) = E(f(X))E(g(Y)).$$

💡 Kovarians och korrelation

- *Kovarians:*

$$\text{Cov}(X, Y) = E((X - E(X))(Y - E(Y))) = E(XY) - E(X)E(Y).$$

- *Korrelation:* $\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}$, $-1 \leq \text{Cor}(X, Y) \leq 1$.

- Om X och Y är oberoende så är $\text{Cov}(X, Y) = \text{Cor}(X, Y) = 0$.

😊 Betingade fördelningar

- *Ifall (X, Y) är en diskret tvådimensionell slumpvariabel med frekvensfunktion $f_{XY}(x, y)$ eller en kontinuerlig tvådimensionell slumpvariabel med täthetsfunktion $f_{XY}(x, y)$ så är*

$$f_{Y|X}(y|x) = \frac{f_{XY}(x, y)}{f_X(x)}, \quad \text{då } f_X(x) > 0,$$

den betingande frekvensfunktionen respektive täthetsfunktionen för Y givet $X = x$.

- $E(Y|X = x) = \begin{cases} \sum_y y f_{Y|X}(y|x) & \text{eller} \\ \int_{-\infty}^{\infty} y f_{Y|X}(y|x) dy \end{cases}$
- $E(Y|X)$ är en slumpvariabel så att $E(Y|X)(\omega) = E(Y|X = X(\omega))$ då $\omega \in \Omega$.
- $E(E(Y|X)) = E(Y)$.

💡 Den tvådimensionella normalfördelningen

Slumpvariabeln (X, Y) sägs vara normalfördelad om varje linär kombination $\alpha X + \beta Y$ är normalfördelad och slumpvariabeln (X, Y) har då, ifall $\rho = \text{Cor}(X, Y) \neq \pm 1$, $\sigma_X^2 = \text{Var}(X) > 0$ och $\sigma_Y^2 = \text{Var}(Y) > 0$, en täthetsfunktion med formen

$$f_{XY}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_X)^2}{\sigma_X^2} + \frac{(y-\mu_Y)^2}{\sigma_Y^2} - \frac{2\rho(x-\mu_X)(y-\mu_Y)}{\sigma_X\sigma_Y}\right)}.$$

Då är $X \sim N(\mu_X, \sigma_X^2)$, $Y \sim N(\mu_Y, \sigma_Y^2)$ och

$$f_{Y|X}(y|x) = \frac{1}{\sqrt{2\pi}\sigma_Y\sqrt{1-\rho^2}} e^{-\frac{1}{2}\left(\frac{y-\mu_Y-\rho\frac{\sigma_Y}{\sigma_X}(x-\mu_X)}{\sigma_Y\sqrt{1-\rho^2}}\right)^2}$$

så att $(Y|X = x) \sim N\left(\mu_Y + \rho\frac{\sigma_Y}{\sigma_X}(x - \mu_X), (1 - \rho^2)\sigma_Y^2\right)$.

Om $\rho = 0$ är X och Y oberoende.

💡 Obs!

Observera att om (X, Y) är en slumpvariabel så att X är normalfördelad och Y är normalfördelad så behöver inte (X, Y) nödvändigtvis vara normalfördelad men om tex. X och Y är oberoende så är också (X, Y) normalfördelad.

😊 Ett annat uttryck för täthetsfunktionen då (X, Y) är normalfördelad

Ett annat sätt att skriva täthetsfunktionen som gör det lättare att generalisera till det m -dimensionella fallet är

$$f_{XY}(x, y) = \frac{1}{\sqrt{2\pi}^2 \sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(\mathbf{z}-\boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{z}-\boldsymbol{\mu})}, \quad \mathbf{z} = \begin{bmatrix} X \\ Y \end{bmatrix}, \quad \boldsymbol{\mu} = \begin{bmatrix} \mu_X \\ \mu_Y \end{bmatrix},$$

$$\text{där } \Sigma = \begin{bmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{bmatrix}, \text{ så att } \Sigma^{-1} = \frac{1}{1-\rho^2} \begin{bmatrix} \frac{1}{\sigma_X^2} & -\frac{\rho}{\sigma_X\sigma_Y} \\ -\frac{\rho}{\sigma_X\sigma_Y} & \frac{1}{\sigma_Y^2} \end{bmatrix} \text{ och}$$

$$\det(\Sigma) = \sigma_X^2 \sigma_Y^2 (1 - \rho^2).$$