

# MS-A0509 Grundkurs i sannolikhetskalkyl och statistik

## Sammanfattning, del I

G. Gripenberg

Aalto-universitetet

6 februari 2015

### 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%."*

- 1 Sannolikheter
  - Oberoende
  - Betingad sannolikhet
  - Bayes formel
  - Klassisk sannolikhet och kombinatorik

- 2 Slumpvariabler
  - Väntevärde
  - Varians
  - Kvantiler
  - Viktiga diskreta fördelningar
  - Viktiga kontinuerliga fördelningar
  - Centrala gränsvärdesatsen

- 3 Tvådimensionella slumpvariabler och fördelningar
  - Kovarians och korrelation
  - Normalfördelning

### 💡 Sannolikhet, händelser, utfallsrum

- *Mängden av alla tänkbara resultat av ett "experiment" eller ett "sluppmässigt försök" är **utfallsrummet**, ofta betecknat med  $\Omega$ .*
- *Elementen i utfallsrummet, dvs. enskilda resultat av experimentet är **elementarhändelser**.*
- ***Händelser** är delmängder av utfallsrummet och när man säger att händelsen  $A$  inträffar, menar man alltid att någon elementarhändelse som hör till  $A$  inträffar.*
- *För varje händelse  $A \subset \Omega$  finns det en sannolikhet  $\Pr(A)$ .*
- *Sannolikhetsfunktionen skall uppfylla 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  $j \neq k$ .

*Då gäller också följande:*

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

## 💡 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 betingade 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  $\Omega$  till  $B$  och räkna om sannolikheterna för händelserna  $A \cap B$  som är delmängder av det nya utfallsrummet.

## 💡 Produktregeln för betingad sannolikhet

Av definitionen för betingad sannolikhet följer den sk. produktregeln

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

och mera allmänt

$$\Pr(A_1 \cap \dots \cap A_k) = \Pr(A_1) \cdot \Pr(A_2|A_1) \cdot \Pr(A_3|A_1 \cap A_2) \cdot \dots \cdot \Pr(A_k|A_1 \cap \dots \cap A_{k-1}).$$

## 😊 Total sannolikhet

Om  $\bigcup_{j=1}^n A_j = \Omega, A_j \cap A_k = \emptyset$  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  $B = B \cap \Omega = \bigcup_{j=1}^n B \cap A_j$  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  $\bigcup_{j=1}^n A_j = \Omega, A_j \cap A_k = \emptyset$  då  $j \neq k, \Pr(B) > 0$  och  $\Pr(A_j) > 0, j = 1, \dots, n$  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  $\Omega$  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 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. Av dethär följer att om ett experiment upprepas  $n$  gånger så att händelser vid olika gånger är oberoende så är sannolikheten för att händelsen  $A$  inträffar exakt  $k$  gånger  $\binom{n}{k} \Pr(A)^k (1 - \Pr(A))^{n-k}$ .

## 💡 Plocka kulor med eller utan återläggning

Antag att i en urna finns  $s$  svarta och  $v$  vita kulor och att vi plockar  $n$  kulor ur urnan.

- (a) Om vi för varje kula noterar vilken färg den har och sedan lägger den tillbaka i urnan så använder vi återläggning. Sannolikheten att vi plockar en svart kula är  $\frac{s}{s+v}$  och för en vit är den  $\frac{v}{s+v}$  så att sannolikheten att vi plockar  $k$  svarta och  $n-k$  vita i en viss given ordning är  $\left(\frac{s}{s+v}\right)^k \left(\frac{v}{s+v}\right)^{n-k}$  och då är sannolikheten att vi plockar  $k$  svarta och  $n-k$  vita i vilken ordning som helst

$$\binom{n}{k} \left(\frac{s}{s+v}\right)^k \left(\frac{v}{s+v}\right)^{n-k}$$

- (b) Om vi däremot inte använder återläggning så kommer sannolikheten att vi plockar en svart kula att bero på vilka kulor vi redan plockat och sannolikheten att vi plockar  $k$  svarta och  $n-k$  vita är  $\frac{\binom{s}{k} \cdot \binom{v}{n-k}}{\binom{s+v}{n}}$  eftersom vi kan plocka  $k$  svarta bland  $s$  svarta på  $\binom{s}{k}$  olika sätt och  $n-k$  vita bland  $v$  vita på  $\binom{v}{n-k}$  olika sätt.

## 💡 Slumpvariabler och fördelningsfunktioner

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

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

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

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

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

När  $F$  är en fördelningsfunktion för  $X$  så gäller dessutom att

- $F(t) - F(s) = \Pr(s < X \leq t)$  då  $s < t$ ,
- $\lim_{s \rightarrow t-} F(s) = \Pr(X < t)$ ,
- $\lim_{s \rightarrow t+} F(s) - \lim_{s \rightarrow t-} F(s) = F(t) - \lim_{s \rightarrow t-} F(s) = \Pr(X = t)$ .

## 😊 Obs!

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

## 💡 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  $a_j \in \mathbb{R}, j \in J$  och då är också händelserna  $\{X_j \in A_j\}, j \in J$  oberoende för alla Borel mängder  $A_j$ .

## 💡 En slumpvariabelns sannolikhetsfördelning

Slumpvariabelns  $X : \Omega \rightarrow \mathbb{R}$  sannolikhetsfördelning (eller bara fördelning) är sannolikhetsfunktionen  $\Pr_X(A) = \Pr(X \in A)$  där  $A \subset \mathbb{R}$  är sådan att


$\{\omega \in \Omega : X(\omega) \in A\}$  är en händelse dvs. mängden reella tal är utfallsrummet och sannolikheterna för dess händelser definieras med funktionen  $\Pr_X$ . Om slumpvariabelns  $X$  fördelning är tex. den sk. normalfördelningen med parameterna  $\mu$  och  $\sigma^2$  så skriver man dess fördelningsfunktion som  $F_{N(\mu, \sigma^2)}$  istället för  $F_X$ .

## 💡💡 Diskreta slumpvariabler

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

$$F_X(t) = \sum_{\substack{a \leq t \\ a \in A}} f_X(a).$$

Detta innebär att  $\Pr(X = a) = f_X(a)$  då  $a \in A$  och  $\sum_{a \in A} f_X(a) = 1$  så att  $\Pr(X \notin A) = 0$  och mängden  $A$  innehåller högst numererbart många element och vi kan anta att  $f_X(t) = 0$  då  $t \notin A$ . Funktionen  $f_X$  är **frekvensfunktionen** eller **sannolikhetsfunktionen** för  $X$ .




## 💡💡 Kontinuerliga slumpvariabler

En slumpvariabel  $X$  är kontinuerlig om fördelningsfunktionen är kontinuerlig, dvs. om  $\Pr(X = a) = 0$  för alla  $a \in \mathbb{R}$ . Oftast antar man ändå att slumpvariabeln  $X$  har en **täthetsfunktion**  $f_X$  så att

$$F_X(t) = \int_{-\infty}^t f_X(s) ds.$$

Detta innebär att  $f_X(s) \geq 0$  och  $\int_{-\infty}^{\infty} f_X(s) ds = 1$ .



$$\Pr(a \leq X \leq b) = \Pr(a < X < b) = F_X(b) - F_X(a) = \int_a^b f_X(s) ds.$$

## 💡💡 Väntevärde

Om  $X$  är en diskret slumpvariabel med frekvensfunktion  $f_X$  så är dess väntevärde

$$E(X) = \sum_a a \Pr(X = a) = \sum_a a f_X(a),$$

och om  $X$  är en kontinuerlig slumpvariabel med täthetsfunktion  $f_X$  så är dess väntevärde

$$E(X) = \int_{-\infty}^{\infty} s f_X(s) ds,$$

i båda fallen förutsatt att summan eller integralen existerar (dvs.  $\sum_{a>0} a f_X(a) < \infty$  eller  $\sum_{a<0} |a| f_X(a) < \infty$  och  $\int_0^{\infty} t f_X(t) dt < \infty$  eller  $\int_{-\infty}^0 |t| f_X(t) dt < \infty$ ), i annat fall skriver man  $E(X) = \text{NaN}$  och säger att slumpvariabeln inte har något väntevärde.

## 💡💡 Väntevärdet av en funktion av en slumpvariabel

Om  $X$  är en diskret slumpvariabel och  $g$  är en mätbar funktion så är

$$E(g(X)) = \sum_a g(a) \Pr(X = a) = \sum_a g(a) f_X(a)$$

och om  $X$  är en kontinuerlig slumpvariabel med täthetsfunktion  $f_X$  så är

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

Om  $g(t) = 1$  då  $t \in A$  och  $g(t) = 0$  annars (och då skriver man ofta  $g = \mathbf{1}_A$ ) så är

$$E(g(X)) = \Pr(X \in A),$$

dvs. också sannolikheter kan skrivas som väntevärden.

## 💡💡 Varians och standardavvikelse

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

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

och dess **standardavvikelse** är on

$$D(X) = \sigma_X = \sqrt{\text{Var}(X)}.$$

(Observera att variansen aldrig är negativ!)

Fördelen med standardavvikelsen är att den har samma enhet som  $X$  och att  $D(\alpha X) = |\alpha|D(X)$  då  $\alpha$  är något reellt tal medan

$\text{Var}(\alpha X) = \alpha^2 \text{Var}(X)$  och  $\text{Var}(X)$  har enheten  $m^2$  om  $X$  tex. har enheten  $m$  (men variansen har andra stora fördelar).

## 💡💡 Väntevärdet är linjärt och monotont

Ifall  $X_1$  och  $X_2$  är två slumpvariabler (definierade i samma utfallsrum), som har ändliga väntevärden och  $c_1$  och  $c_2$  är reella tal så är

$$E(c_1 X_1 + c_2 X_2) = c_1 E(X_1) + c_2 E(X_2),$$

och om dessutom  $\Pr(X_1 \leq X_2) = 1$  så är

$$E(X_1) \leq E(X_2).$$

En följd av dethär är att (där  $\mathbf{1}$  är en slumpvariabel som får värdet 1 med sannolikheten 1)

$$\begin{aligned} \text{Var}(X) &= E((X - E(X))^2) = E(X^2 - 2XE(X) + E(X)^2) \\ &= E(X^2) - 2E(X)E(X) + E(X)^2 E(\mathbf{1}) = E(X^2) - E(X)^2. \end{aligned}$$

## 💡💡 Variansen av summan av två slumpvariabler

Ifall  $X_1$  och  $X_2$  är **oberoende** slumpvariabler (definierade i samma utfallsrum) så är

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

om  $c_1$  och  $c_2$  är reella tal och i allmänhet (förutsatt att varianserna är ändliga) gäller

$$\begin{aligned} \text{Var}(c_1 X_1 + c_2 X_2) &= c_1^2 \text{Var}(X_1) \\ &\quad + 2c_1 c_2 E((X_1 - E(X_1))(X_2 - E(X_2))) + c_2^2 \text{Var}(X_2). \end{aligned}$$

## 💡 Kvantiler

Antag att  $X$  är en slumpvariabel med fördelningsfunktion  $F_X$  och  $0 < p < 1$ .

• Om  $F_X$  har en invers funktion så är  $x_p = F_X^{-1}(p)$  slumpvariabelns  $X$  och dess fördelnings  $p$ -kvantil.

• I allmänhet är  $x_p$  en  $p$ -kvantil ifall


$$\Pr(X < x_p) \leq p \leq \Pr(X \leq x_p),$$

$$\Pr(X > x_p) \leq 1 - p \leq \Pr(X \geq x_p).$$

• **Medianen** är en 0.5-kvantil.

• Kvantilerna är inte nödvändigtvis entydiga men de existerar alltid.


• Ofta väljer man som  $p$ -kvantil mittpunkten på intervallet med alla  $p$ -kvantiler.



## 💡💡 Kvantiler, forts.

I många beräkningar i statistik bildar vi först en "testvariabel"  $U$ , vars fördelningsfunktion  $F_U$  och täthetsfunktion  $f_U$  vi känner till (åtminstone approximativt). Sedan bestämmer vi tal  $a$  och  $b$  så att  $\Pr(U < a) = p_a$  och  $\Pr(U > b) = p_b$  där vanligtvis  $p_a = p_b$  men ibland är det ena talet 0. Om fördelningsfunktionen  $F_U$  har en invers funktion så får vi

$$a = F_U^{-1}(p_a) \quad \text{och} \quad b = F_U^{-1}(1 - p_b)$$



Med hjälp av dessa tal  $a$  och  $b$  och definitionen av testvariabeln kan vi sedan räkna ut det vi verkligen är intresserade av.

Ifall  $U$  som här är kontinuerlig så är  $\Pr(U < a) = \Pr(U \leq a)$  och  $\Pr(a \leq U \leq b) = \Pr(a < U < b) = 1 - p_a - p_b$ .

## 💡💡 Några viktiga diskreta slumpvariabler och deras fördelningar

- **Jämn diskret fördelning:**  $\Pr(X = x_i) = \frac{1}{n}$ ,  $i = 1, 2, \dots, n$  och man antar att  $x_i \neq x_j$  då  $i \neq j$ .
- **Bernoullifördelning**  $X \sim \text{Bernoulli}(p)$ ,  $0 \leq p \leq 1$ :
  - ◇  $\Pr(X = 1) = p$ ,  $\Pr(X = 0) = (1 - p)$  dvs.  $X(\omega) = 1$  då  $\omega \in A \subset \Omega$  och  $X(\omega) = 0$  då  $\omega \in \Omega \setminus A$  där  $\Pr(A) = p$ .
  - ◇  $E(X) = p$  och  $\text{Var}(X) = p(1 - p)$ .
- **Binomialfördelning**  $X \sim \text{Bin}(n, p)$ ,  $n \geq 0$ ,  $0 \leq p \leq 1$ :
  - ◇  $\Pr(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}$ ,  $k = 0, 1, \dots, n$ .
  - ◇  $X$  är summan av  $n$  oberoende Bernoulli( $p$ )-fördelade slumpvariabler, dvs. experimentet upprepas  $n$  gånger med oberoende resultat och händelsen  $A$ , med sannolikheten  $p$  inträffar  $X$  gånger.
  - ◇  $E(X) = np$  och  $\text{Var}(X) = np(1 - p)$ .
- **Poisson-fördelning**  $X \sim \text{Poisson}(\lambda)$ ,  $\lambda \geq 0$ :
  - ◇  $\Pr(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}$ ,  $k = 0, 1, 2, \dots$
  - ◇ Fås som gränsvärde av binomialfördelningen då  $n \rightarrow \infty$  och  $np \rightarrow \lambda$ .
  - ◇  $E(X) = \text{Var}(X) = \lambda$ .

## 💡💡 Några viktiga diskreta slumpvariabler och deras fördelningar, forts.

- **Hypergeometrisk fördelning**  $X \sim \text{HyperGeom}(N, r, n)$   $0 \leq n, r \leq N$ :
  - ◇  $\Pr(X = k) = \frac{\binom{k}{r} \binom{N-k}{n-k}}{\binom{N}{n}}$ .
  - ◇ Om man plockar  $n$  kulor ur en urna som innehåller  $r$  vita och  $N - r$  svarta kulor så är  $X$  antalet vita kulor man plockat.
  - ◇  $E(X) = \frac{nr}{N}$ ,  $\text{Var}(X) = \frac{nr}{N} \cdot \frac{N-r}{N} \cdot \frac{N-n}{N-1}$ .
- **Geometrisk fördelning**  $X \sim \text{Geom}(p)$ :
  - ◇  $\Pr(X = k) = (1 - p)^{k-1} p$ ,  $k \geq 1$ .
  - ◇ Ett experiment upprepas tills händelsen  $A$  med sannolikheten  $p$  har inträffat och  $X$  är antalet upprepningar.
  - ◇  $E(X) = \frac{1}{p}$  och  $\text{Var}(X) = \frac{1-p}{p^2}$ .
- **Negativ binomialfördelning**  $X \sim \text{NegBin}(p, r)$ ,  $0 < p \leq 1$ ,  $r \geq 1$ :
  - ◇ Ett experiment upprepas tills händelsen  $A$  med sannolikheten  $p$  har inträffat  $r$  gånger och  $X$  är antalet upprepningar, dvs.  $X$  är summan av  $r$  oberoende Geom( $p$ )-fördelade slumpvariabler.
  - ◇  $\Pr(X = n) = \binom{n-1}{r-1} p^r (1 - p)^{n-r}$ .
  - ◇  $E(X) = \frac{r}{p}$ , och  $\text{Var}(X) = \frac{r(1-p)}{p^2}$ .

## 💡💡 Några viktiga kontinuerliga slumpvariabler och deras fördelningar

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

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

$$E(X) = \frac{1}{2}(a + b) \quad \text{och} \quad \text{Var}(X) = \frac{1}{12}(b - a)^2.$$

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

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

$$E(X) = \mu, \quad \text{Var}(X) = \sigma^2, \quad \text{och} \quad F_{N(\mu, \sigma^2)}(t) = F_{N(0,1)}\left(\frac{t-\mu}{\sigma}\right).$$

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

$$f_X(t) = \begin{cases} \lambda e^{-\lambda t}, & t \geq 0, \\ 0, & t < 0, \end{cases} \quad F_X(t) = 1 - e^{-\lambda t}, \quad t \geq 0.$$

$$E(X) = \frac{1}{\lambda} \quad \text{och} \quad \text{Var}(X) = \frac{1}{\lambda^2}.$$

Observera att som parameter ofta används väntevärdet  $\mu = \frac{1}{\lambda}$ .

## 💡 Sambandet mellan Poisson- och exponentialfördelningen

- Kunder anländer till en servicepunkt med oberoende och  $\text{Exp}(\lambda)$ -fördelade intervall om och endast om antalet kunder som kommer inom ett intervall med längden  $T$  är en slumpvariabel som har en  $\text{Poisson}(\lambda T)$ -fördelning och antalet kunder som anländer inom disjunkta tidsintervall är oberoende.
- I detta fall är väntevärdet längden av tidsintervallet mellan två ankomsttider  $\frac{1}{\lambda}$  och väntevärdet av antalet kunder som anländer inom ett tidsintervall med längden  $T$  är  $\lambda T$ .
- Om  $\dots < T_{-1} < T_0 < T_1 < T_2 < \dots$  så gäller
  - ◊  $U_{(a,b]} = |\{j : T_j \in (a, b]\}|$  är  $\text{Poisson}(\lambda(b-a))$ -fördelad då  $a < b$  och  $U_{(a_1,b_1]}$  och  $U_{(a_2,b_2]}$  är oberoende om  $(a_1, b_1] \cap (a_2, b_2] = \emptyset$  om och endast om
    - ◊  $T_{j+1} - T_j$  oberoende och  $\text{Exp}(\lambda)$ -fördelade för alla  $j$ .

## 💡 Summan av två oberoende slumpvariabler mm.

- Antag att  $X$  och  $Y$  är två oberoende slumpvariabler så att  $X$  har täthetsfunktionen  $f_X$  och  $Y$  har fördelningsfunktionen  $F_Y$ . (Motsvarande resultat gäller också då  $X$  är diskret.)

- Om  $a \leq b$  och  $A(s) \leq B(s)$  för alla  $s \in \mathbb{R}$  så är

$$\begin{aligned} \Pr(X \in (a, b], Y \in (A(X), B(X)]) &= \int_a^b f_X(s) \Pr(Y \in (A(s), B(s))) ds \\ &= \int_a^b f_X(s) (F_Y(B(s)) - F_Y(A(s))) ds. \end{aligned}$$

- Slumpvariabelns  $X + Y$  fördelningsfunktion är

$$\begin{aligned} F_{X+Y}(t) &= \Pr(X + Y \leq t) = \Pr(X \in (-\infty, \infty), Y \leq t - X) \\ &= \int_{-\infty}^{\infty} f_X(s) \Pr(Y \leq t - s) ds = \int_{-\infty}^{\infty} f_X(s) F_Y(t - s) ds. \end{aligned}$$

- Om  $Y$  har täthetsfunktionen  $f_Y$  så har  $X + Y$  täthetsfunktionen

$$f_{X+Y}(t) = \int_{-\infty}^{\infty} f_X(s) f_Y(t - s) ds.$$

## 💡 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

$$\frac{\frac{1}{n} \sum_{j=1}^n X_j - \mu}{\sqrt{\frac{\sigma^2}{n}}} = \frac{\sum_{j=1}^n X_j - n\mu}{\sqrt{n\sigma^2}} \sim_a N(0, 1) \quad \text{då } n \rightarrow \infty,$$

dvs.

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

## 💡 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  $\Omega$  är ett utfallsrum på vilket en sannolikhetsfunktion är definierad så är  $(X, Y) : \Omega \rightarrow \mathbb{R}^2$  en tvådimensionell slumpvariabel med fördelningsfunktion  $F_{XY}(s, t) = \Pr(X \leq s, Y \leq t)$  förutsatt att

$\{\omega \in \Omega : X(\omega) \leq s, Y(\omega) \leq t\}$  är en mängd för vilken sannolikheten är definierad.

- En tvådimensionell slumpvariabel  $(X, Y)$  är diskret och den har frekvensfunktionen  $f_{XY}(a, b)$  ifall  $f_{XY}(a, b) \geq 0$  för alla  $a$  och  $b$ ,  $\sum_a \sum_b f_{XY}(a, b) = 1$  och  $\Pr(X = a, Y = b) = f_{XY}(a, b)$  för alla  $a$  och  $b$ .



- En tvådimensionell slumpvariabel  $(X, Y)$  är kontinuerlig och har täthetsfunktion  $f_{XY}(s, t)$  ifall  $f_{XY}(s, t) \geq 0$  för alla  $s$  och  $t$ ,  $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{XY}(s, t) ds dt = 1$  och  $F_{XY}(s, t) = \int_{-\infty}^s \int_{-\infty}^t f_{XY}(u, v) du dv$  för alla  $s$  och  $t$ .



## 😊 Marginalfördelningar

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

$$f_X(a) = \Pr(X = a) = \sum_b f_{XY}(a, b) \quad \text{och}$$

$$f_Y(b) = \Pr(Y = b) = \sum_a f_{XY}(a, b).$$

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

$$f_X(s) = \int_{-\infty}^{\infty} f_{XY}(s, t) dt \quad \text{och} \quad f_Y(t) = \int_{-\infty}^{\infty} f_{XY}(s, t) ds.$$

## 😊 Väntevärden

Om  $(X, Y)$  är en tvådimensionell slumpvariabel och  $h(x, y)$  är en mätbar funktion så är

$$E(h(X, Y)) = \sum_a \sum_b h(a, b) f_{XY}(a, b),$$

då  $(X, Y)$  är en diskret slumpvariabel och summan existerar och

$$E(h(X, Y)) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} h(s, t) f_{XY}(s, t) ds dt,$$

då  $(X, Y)$  är en kontinuerlig slumpvariabel med täthetsfunktion och integral existerar.

## 💡 Oberoende slumpvariabler

- Om  $(X, Y)$  är en tvådimensionell slumpvariabel (diskret eller kontinuerlig 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** då  $\text{Var}(X) < \infty$  och  $\text{Var}(Y) < \infty$ :

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

- **Korrelation eller korrelationskoefficient:**

$$\text{Cor}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}, \quad -1 \leq \text{Cor}(X, Y) \leq 1$$

då  $0 < \text{Var}(X) < \infty$  och  $0 < \text{Var}(Y) < \infty$ .

- Om  $X$  och  $Y$  är oberoende är  $\text{Cor}(X, Y) = 0$  men om korrelationen är 0 så är  $X$  och  $Y$  inte nödvändigtvis oberoende, om inte  $(X, Y)$  är normalfördelad.

## 💡 Betingade fördelningar

- Ifall  $(X, Y)$  är en diskret tvådimensionell slumpvariabel med frekvensfunktion  $f_{XY}(a, b)$  eller en kontinuerlig tvådimensionell slumpvariabel med täthetsfunktion  $f_{XY}(s, t)$  så är

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

den betingade frekvensfunktionen respektive täthetsfunktionen för  $Y$  givet  $X = a$ .

- $E(Y|X = a) = \begin{cases} \sum_b b f_{Y|X}(b|a) & \text{eller} \\ \int_{-\infty}^{\infty} t f_{Y|X}(t|a) dt \end{cases}$
- $E(Y|X)$  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  $(X, Y)$  är normalfördelad om varje linjärkombination  $\alpha X + \beta Y$  är normalfördelad.
- Om  $(X, Y)$  är normalfördelad så är också  $X$  och  $Y$  normalfördelade, dvs.  $X \sim N(\mu_X, \sigma_X^2)$  och  $Y \sim N(\mu_Y, \sigma_Y^2)$ .
- Om  $(X, Y)$  är normalfördelad och  $\text{Cov}(X, Y) = 0$  (så att också  $\rho_{XY} = \text{Cor}(X, Y) = 0$ ) så är  $X$  och  $Y$  oberoende.
- Om  $(X, Y)$  är normalfördelad,  $\sigma_X^2 > 0$ ,  $\sigma_Y^2 > 0$  och  $\rho_{XY} \neq \pm 1$  så är

$$f_{Y|X}(t|s) = \frac{1}{\sqrt{2\pi\sigma_Y\sqrt{1-\rho_{XY}^2}}} e^{-\frac{1}{2}\left(\frac{t-\mu_Y-\rho_{XY}\frac{\sigma_Y}{\sigma_X}(s-\mu_X)}{\sigma_Y\sqrt{1-\rho_{XY}^2}}\right)^2} \text{ dvs.}$$

$$(Y|X = s) \sim N\left(\mu_Y + \rho_{XY}\frac{\sigma_Y}{\sigma_X}(s - \mu_X), (1 - \rho_{XY}^2)\sigma_Y^2\right),$$

och motsvarande resultat gäller för  $(X|Y = t)$ .

- Ifall  $(X, Y)$  är normalfördelad,  $\sigma_X^2 > 0$ ,  $\sigma_Y^2 > 0$  och  $\rho_{XY} \neq \pm 1$  så har  $(X, Y)$  täthetsfunktionen

$$f_{XY}(t, u) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{XY}^2}} e^{-\frac{1}{2(1-\rho_{XY}^2)}\left(\frac{(t-\mu_X)^2}{\sigma_X^2} + \frac{(u-\mu_Y)^2}{\sigma_Y^2} - \frac{2\rho_{XY}(t-\mu_X)(u-\mu_Y)}{\sigma_X\sigma_Y}\right)}$$

## 💡 Obs!

- Om  $(X, Y)$  är en slumpvariabel så att  $X$  är normalfördelad och  $Y$  är normalfördelad så är inte slumpvariabeln  $(X, Y)$  nödvändigtvis normalfördelad.
- Om  $X$  och  $Y$  är oberoende normalfördelade slumpvariabler så är  $(X, Y)$  normalfördelad.
- Om  $X_j \sim N(\mu_j, \sigma_j^2)$ ,  $j = 1, \dots, n$  är oberoende så är  $\sum_{j=1}^n c_j X_j \sim N\left(\sum_{j=1}^n c_j \mu_j, \sum_{j=1}^n c_j^2 \sigma_j^2\right)$ .

## 😊 "Tillbaka till väntevärdet"

Om  $(X, Y)$  är normalfördelad så att  $X$  och  $Y$  har samma fördelning  $N(\mu, \sigma^2)$  och korrelationskoefficienten  $\rho_{XY} = \text{Cor}(X, Y) \neq \pm 1$  så gäller

$$|E(Y|X = s) - \mu| = |\rho_{XY}| |s - \mu| < |s - \mu|.$$