

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%."*

💡 Sannolikhet, händelser, utfallsrum

- Mängden av alla tänkbara resultat av ett "experiment" eller ett "slumpmässigt försök" är **utfallsrummet**, ofta betecknat med Ω .
- 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 Ω 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 $\cup_{j=1}^n A_j = \Omega$, $A_j \cap A_k = \emptyset$ 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 $j \neq k$, $\Pr(B) > 0$ 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 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 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 Ω 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 Ω) 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 μ och σ^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 numrerbart 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 $\int_{-\infty}^0 |t| f(t) dt < \infty$), 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 α 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

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

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)

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

💡💡 Variansen av summan av två slumpvariabler

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

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


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

$$\begin{aligned}\text{Var}(c_1X_1 + c_2X_2) &= c_1^2\text{Var}(X_1) \\ &\quad + 2c_1c_2E((X_1 - E(X_1))(X_2 - E(X_2))) + c_2^2\text{Var}(X_2).\end{aligned}$$

💡 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.





$$x_{0.4} \in [-1, 1]$$

$$x_q = 2, \quad q \in [0.5, 0.9]$$

💡💡 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* $X \sim \text{HyperGeom}(N, r, n)$ $0 \leq n, r \leq N$:

- ◇ $\Pr(X = k) = \frac{\binom{r}{k} \binom{N-r}{n-k}}{\binom{N}{n}}$.

- ◇ *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 $\text{Geom}(p)$ -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 $-\infty < a < b < \infty$):

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

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

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

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

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

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

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

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

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 λT .*
- *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

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

💡💡 Centrala gränsvärdeessatsen

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

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

dvs.

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

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

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