

# 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%."*

### 1 Sannolikheter

### 2 Slumpvariabler

- Centrala gränsvärdesatsen

### 3 Tvådimensionella slumpvariabler och fördelningar

### 💡 Sannolikhet, händelser, utfallsrum

- *Mängden av alla tänkbara resultat av ett "experiment" är **utfallsrummet**, ofta betecknat med  $\Omega$ .*
- *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  $\Omega$  innehåller ändligt många element är det naturligt att alla delmängder av  $\Omega$  är händelser men i allmänhet är detta inte alltid möjligt eller ens önskvärt och då är  $\Pr$  en funktion definierad i en  $\sigma$ -algebra  $\mathcal{A}$  i  $\Omega$ , 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  $\Omega$  till  $B$  och räkna om sannolikheterna för händelserna  $A \cap B$  som är delmängder av det nya utfallsrummet.

### 😊 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  $j \neq k$  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  $\Omega$  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

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

### 💡💡 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

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

### 💡 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.

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.

### 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  $\{\omega \in \Omega : X(\omega) \leq x\}$  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  $\Omega$ ) 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  $a_j \in \mathbb{R}, j \in J$ .

### 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  $\int_{-\infty}^{\infty} f(t) dt = 1$ .

### 💡 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 numererbart många element liksom oftast också utfallsrummet  $\Omega$ . Funktionen  $f$  är **frekvensfunktionen** eller **sannolikhetsfunktionen** för  $X$ .

### 💡 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 slumpvariabel 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  $E(X) = NaN$ ).

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

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

### 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  $\lambda$ .
- **Two 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  $\mu$  och variansen  $\sigma^2$ .

- **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  $\Omega$  är ett utfallsrum på vilket en sannolikhetsfunktion är definierad så är  $(X, Y) : \Omega \rightarrow \mathbb{R}^2$  en tvådimensionell slumpvariabel med fördelningsfunktion  $F_{XY}(x, y) = \Pr(X \leq x, Y \leq y)$  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  $X = x$ .

- $E(Y|X = x) = \begin{cases} \sum_y y f_{Y|X}(y|x) \\ \int_{-\infty}^{\infty} y f_{Y|X}(y|x) dy \end{cases}$  eller
- $E(Y|X)$  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

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

där  $\boldsymbol{\Sigma} = \begin{bmatrix} \sigma_X^2 & \rho\sigma_X\sigma_Y \\ \rho\sigma_X\sigma_Y & \sigma_Y^2 \end{bmatrix}$ , så att  $\boldsymbol{\Sigma}^{-1} = \frac{1}{1-\rho^2} \begin{bmatrix} \frac{1}{\sigma_X^2} & -\frac{\rho}{\sigma_X\sigma_Y} \\ -\frac{\rho}{\sigma_X\sigma_Y} & \frac{1}{\sigma_Y^2} \end{bmatrix}$  och  $\det(\boldsymbol{\Sigma}) = \sigma_X^2\sigma_Y^2(1-\rho^2)$ .