

2 VYBRANÉ PRAVDĚPODOBNOTNÍ MODELY



Čas ke studiu: 60 minut



Cíl: Po prostudování této kapitoly budete umět popsat a použít pro popis technických procesů:

- Erlangovo rozdělení
- Weibullovo rozdělení
- Logaritmicko – normální rozdělení
- Vícerozměrné normální rozdělení



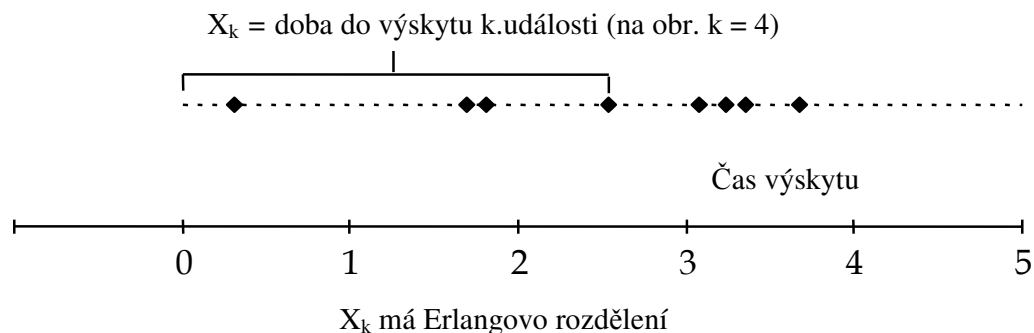
VÝKLAD

2.1 Erlangovo rozdělení

Určitým zobecněním exponenciální náhodné veličiny (doba do (první) poruchy) je náhodná veličina s Erlangovým rozdělením, která **popisuje dobu do výskytu k-té události v Poissonově procesu.**

Erlangovo rozdělení je **speciálním typem tzv. Gamma rozdělení pro k z množiny celých čísel.** (Tento vztah je vhodné znát, chceme-li k nalezení distribuční funkce, popř. hustoty pravděpodobnosti použít statistický software – některé statistické pakety mají implementováno pouze Gamma rozdělení a hodnoty Erlangova rozdělení pak získáme dosazením příslušných parametrů).

Erlangovo rozdělení má dva parametry: **k** – počet událostí (parametr tvaru, shape, α – v Gamma rozdělení), k nimž má dojít a rychlost výskytu těchto událostí λ (parametr měřítka, scale, β v Gamma rozdělení).



Má-li náhodná veličina X Erlangovo rozdělení, značíme to takto:

$$X_k \rightarrow \text{Erlang}(k, \lambda)$$

Náhodnou veličinu s Erlangovým rozdělením si můžeme představit jako součet k nezávislých exponenciálních náhodných veličin (doba do výskytu k -té události je součtem dob mezi 0-tou a 1. událostí, 1. a 2. událostí, ..., $(k-1)$. a k . událostí).

Pro Erlangovo rozdělení s parametry k a λ platí tyto vztahy:

Hustota pravděpodobnosti:

$$f(t) = \lambda \cdot e^{-\lambda t} \cdot \frac{(\lambda t)^{k-1}}{(k-1)!}; \quad t > 0$$

Distribuční funkce:

$$F(t) = 1 - e^{-\lambda t} \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!}$$


Intenzita poruch:

$$\lambda(t) = \frac{\lambda}{(k-1)! \sum_{j=0}^{k-1} \frac{1}{(k-1-j)! (\lambda t)^j}}$$

Střední hodnota: $EX_k = \frac{k}{\lambda}$

Rozptyl: $DX_k = \frac{k}{\lambda^2}$

Graf intenzity poruch Erlangova rozdělení pro $\lambda = 1$; $k = 3$; 5 ; 7



Intenzita poruch $\lambda(t)$ je v případě Erlangova rozdělení rostoucí funkce a proto je toto rozdělení vhodné pro modelování procesů stárnutí.



Průvodce studiem

Následující pasáž je určena pro zájemce o matematické pozadí používaných vztahů.

- **Odvození distribuční funkce Erlangova rozdělení**

Mějme:

X_k ... doba do výskytu k -té události v Poissonově procesu, $X_k \rightarrow \text{Erlang}(k; \lambda)$

N_t ... počet výskytu události v časovém intervalu $(0; t)$, $N_t \rightarrow \text{Po}(\lambda t)$

Platí, že v časovém intervalu $(0; t)$ nastane alespoň k událostí, právě když doba do výskytu k -té události je menší než t .

$$(N_t \geq k) \Leftrightarrow (X_k < t)$$

Z této ekvivalence lze odvodit distribuční funkci Erlangova rozdělení.

$$F(t) = P(X_k < t) = P(N_t \geq k) = 1 - P(N_t < k) = 1 - \sum_{j=0}^{k-1} \left(e^{-\lambda t} \cdot \frac{(\lambda t)^j}{j!} \right) = 1 - e^{-\lambda t} \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!}$$

- **Odvození hustoty pravděpodobnosti**

Hustotu pravděpodobnosti získáme derivací distribuční funkce:

$$\begin{aligned} f(t) &= \frac{dF(t)}{dt} = \lambda \cdot e^{-\lambda t} \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!} + (-e^{-\lambda t}) \cdot \sum_{j=0}^{k-1} \frac{j \cdot (\lambda t)^{j-1} \cdot \lambda}{j!} = \\ &= \lambda \cdot e^{-\lambda t} \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!} - \lambda \cdot e^{-\lambda t} \cdot \sum_{j=1}^{k-1} \frac{(\lambda t)^{j-1}}{(j-1)!} = \\ &= \lambda \cdot e^{-\lambda t} \cdot \left(\sum_{j=0}^{k-2} \frac{(\lambda t)^j}{j!} + \frac{(\lambda t)^{k-1}}{(k-1)!} \right) - \lambda \cdot e^{-\lambda t} \cdot \sum_{j=0}^{k-2} \frac{(\lambda t)^j}{j!} = \\ &= \lambda \cdot e^{-\lambda t} \cdot \sum_{j=0}^{k-2} \frac{(\lambda t)^j}{j!} + \lambda \cdot e^{-\lambda t} \cdot \frac{(\lambda t)^{k-1}}{(k-1)!} - \lambda \cdot e^{-\lambda t} \cdot \sum_{j=0}^{k-2} \frac{(\lambda t)^j}{j!} = \lambda \cdot e^{-\lambda t} \cdot \frac{(\lambda t)^{k-1}}{(k-1)!} \end{aligned}$$

- **Odvození intenzity poruch**

$$\begin{aligned} \lambda(t) &= \frac{f(t)}{1-F(t)} = \frac{\lambda \cdot e^{-\lambda t} \cdot \frac{(\lambda t)^{k-1}}{(k-1)!}}{e^{-\lambda t} \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{j!}} = \frac{\lambda}{(k-1)! \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^j}{(\lambda t)^{k-1} \cdot j!}} = \frac{\lambda}{(k-1)! \cdot \sum_{j=0}^{k-1} \frac{(\lambda t)^{j-k+1}}{j!}} = \\ &= \frac{\lambda}{(k-1)! \cdot \sum_{j=0}^{k-1} \frac{1}{(\lambda t)^{k-1-j} \cdot j!}} = \frac{\lambda}{(k-1)! \cdot \sum_{j=0}^{k-1} \frac{1}{(\lambda t)^j \cdot (k-1-j)!}} \end{aligned}$$

- **Odvození střední hodnoty a rozptylu**

Mějme:

X_k ... doba do výskytu k-té události v Poissonově procesu, $X_k \rightarrow Erlang(k; \lambda)$

X ... doba do výskytu události v Poissonově procesu, $X \rightarrow E(\lambda)$

Je zřejmé, že Erlangova náhodná veličina (s parametry $k; \lambda$) je součtem k exponenciálních veličin (s parametrem λ):

$$X_k = \sum_{i=1}^k X_i$$

Z vlastností střední hodnoty víme, že střední hodnota součtu náhodných veličin je rovna součtu jejich středních hodnot:


$$EX_k = \sum_{i=1}^k EX_i = \frac{1}{\lambda} + \frac{1}{\lambda} + \dots + \frac{1}{\lambda} = \frac{k}{\lambda}$$

Jednotlivé exponenciální náhodné veličiny jsou nezávislé a proto také rozptyl součtu náhodných veličin je roven součtu jejich rozptylů:

$$DX_k = \sum_{i=1}^k DX_i = \frac{1}{\lambda^2} + \frac{1}{\lambda^2} + \dots + \frac{1}{\lambda^2} = \frac{k}{\lambda^2}$$

Na následujícím obrázku jsou **příklady hustoty Gamma rozdělení pro $\lambda = 1$ a různé hodnoty k** . Poznamenejme, že s rostoucím k roste rozptyl tohoto rozdělení a koeficient šikmosti se přibližuje nule (rozdělení je více symetrické).

Erlangovo rozdělení



2.2 Weibullovo rozdělení

Weibullovo rozdělení je velmi flexibilní (díky parametru β) a proto se jím zejména v teorii spolehlivosti popisují spojité náhodné veličiny definované jako **doba do poruchy** (doba bezporuchovosti). Používá se zejména při popisu komponent, které jsou **v období ranných poruch nebo v období stárnutí** (tj. tam kde se projevuje mechanické opotřebení nebo únava materiálu).

Weibullovo rozdělení má dva parametry: Θ – parametr měřítka (scale, $\Theta > 0$, závisí na materiálu, namáhání a podmínkách užívání) a β – parametr tvaru (shape, $\beta > 0$, na jeho hodnotě závisí tvar intenzity poruch a tím i vhodnost použití pro určité období doby života).

Má-li náhodná veličina X Weibullovo rozdělení, značíme to takto:

$$X \rightarrow W(\Theta, \beta)$$

Distribuční funkce:

$$F(t) = 1 - e^{-\left(\frac{t}{\Theta}\right)^\beta}; \quad t > 0; \Theta > 0; \beta > 0$$

Hustota pravděpodobnosti:

$$f(t) = \frac{\beta}{\Theta} \left(\frac{t}{\Theta}\right)^{\beta-1} e^{-\left(\frac{t}{\Theta}\right)^\beta}; \quad t > 0; \Theta > 0; \beta > 0$$

Intenzita poruch:


$$\lambda(t) = \frac{\beta}{\Theta} \left(\frac{t}{\Theta}\right)^{\beta-1}; \quad t > 0; \Theta > 0; \beta > 0$$

Ze vztahu pro intenzitu poruch Weibullova rozdělení je zřejmé, že:

$$\lambda(t) = konst. \cdot t^{\beta-1}$$

a proto tvar intenzity poruch závisí na volbě parametru β .

Některé příklady intenzity poruch Weibullova rozdělení ($\Theta=1$):



Všimněme si, že pro $\beta=1$, přejde Weibullovo rozdělení v rozdělení exponenciální (konstantní intenzita poruch) s parametrem $\lambda = \frac{1}{\Theta}$.

$$\beta=1 \Rightarrow W(\Theta;1) \rightarrow E\left(\frac{1}{\Theta}\right)$$

Z výše uvedeného grafu je rovněž zřejmé použití Weibullova rozdělení v závislosti na parametru β :

$0 < \beta < 1$	období dětských nemocí	$\lambda(t)$... klesající funkce
$\beta = 1$	období stabilního života	$\lambda(t) = konst. = \frac{1}{\Theta} = \lambda$ (exp. rozdělení)
$1 < \beta < 2$	období stárnutí	$\lambda(t)$... konkávní, rostoucí funkce
$\beta = 2$	období stárnutí	$\lambda(t)$... lineárně rostoucí funkce
$\beta > 2$	období stárnutí	$\lambda(t)$... konvexní, rostoucí funkce



CD-ROM

Na přiloženém CD-ROMu si můžete prohlédnout animace zobrazující vliv parametru tvaru Weibullova rozdělení na charakteristiky tohoto rozdělení.

2.3 Logaritmicko-normální rozdělení

Jestliže má náhodná veličina Y , $Y = \ln X$, normální rozdělení s parametry μ a σ^2 , pak náhodná veličina X má logaritmicko-normální rozdělení se stejnými parametry, což zapisujeme:

$$X \rightarrow LN(\mu; \sigma^2)$$

Z definice je zřejmé, že náhodná veličina s logaritmicko-normálním rozdělením může nabývat pouze kladných hodnot (definiční obor $\ln x$). Proto nachází uplatnění při **popisu náhodných veličin nabývajících pouze kladných hodnot a to zejména v případech, kdy hustota pravděpodobnosti je asymetrická** (šikmost není nulová) s jedním vrcholem. Značný význam tohoto rozdělení tedy nacházíme v teorii spolehlivosti (různé parametry součástek nabývají pouze kladných hodnot – životnost, rozměry, tažnost, ...) a v ekonomii při popisu příjmů (příjmová rozdělení).

Hustota pravděpodobnosti:

$$f(x) = \begin{cases} \frac{1}{x\sigma\sqrt{2\pi}} \cdot e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}; & \text{pro } x > 0 \\ 0 & \text{pro } x \leq 0 \end{cases}$$

Distribuční funkce:

Distribuční funkci log.-normálního rozdělení nalezneme prostřednictvím distribuční funkce normovaného normálního rozdělení.

$$F(x) = \begin{cases} \Phi\left(\frac{\ln x - \mu}{\sigma}\right); & \text{pro } x > 0 \\ 0 & \text{pro } x \leq 0 \end{cases}$$

Střední hodnota: $EX = e^{\mu + \frac{\sigma^2}{2}}$

Rozptyl: $DX = e^{2\mu + 2\sigma^2}(e^{\sigma^2} - 1)$



100p%-ní kvantil: $x_p = e^{\mu + \sigma \cdot z_p}$,

kde z_p je 100p%-ní kvantil normovaného normálního rozdělení

Grafické znázornění hustoty pravděpodobnosti a distribuční funkce:

X ... příjem zaměstnanců jisté firmy

$$X \rightarrow LN(12.000; 4.000^2)$$



Při praktickém používání tohoto rozdělení postupujeme tak, že náhodnou veličinu X nejdříve převedeme na $Y = \ln X$ a potom již postupujeme stejně jako u normálního rozdělení.


Průvodce studiem

A opět zde máme pasáž pro zájemce:

- **Odvození distribuční funkce logaritmickeo-normálního rozdělení:**

Nechť:

$$Y = \ln X$$

$$X \rightarrow LN(\mu; \sigma^2) \Leftrightarrow Y \rightarrow N(\mu; \sigma^2)$$

$F_X(x)$ (resp. $F_Y(y)$) je distribuční funkce náhodné veličiny X (resp. Y)

$$\forall x > 0: F_X(x) = P(X < x) = P(e^Y < x) = P(Y < \ln x) = F_Y(\ln x) = \Phi\left(\frac{\ln x - \mu}{\sigma}\right)$$

$$\forall x \leq 0: F_X(x) = 0$$

- **Odvození hustoty pravděpodobnosti logaritmickeo-normálního rozdělení:**

$f_X(x)$... hustota pravděpodobnosti náhodné veličiny X

$$\forall x > 0: f_X(x) = \frac{dF_X(x)}{dx} = \frac{d\Phi\left(\frac{\ln x - \mu}{\sigma}\right)}{dx} = \phi\left(\frac{\ln x - \mu}{\sigma}\right) \cdot \frac{1}{x \cdot \sigma} = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{\left(\frac{\ln x - \mu}{\sigma}\right)^2}{2}}$$

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

$$\forall x \leq 0: f_X(x) = 0$$

- **Odvození vztahu pro výpočet 100p%-ního kvantilu:**

$$P(X < x_p) = p$$

$$F(x_p) = p$$

$$\Phi\left(\frac{\ln x_p - \mu}{\sigma}\right) = p$$

$$\frac{\ln x_p - \mu}{\sigma} = z_p \quad (\Phi(z_p) = p)$$

$$\ln x_p = \sigma \cdot z_p + \mu$$

$$x_p = e^{(\mu + \sigma \cdot z_p)}$$



Řešený příklad

Nechť X je náhodná veličina s logaritmickeo-normálním rozdělením s parametry: $\mu=2$; $\sigma^2=9$. Určete:

- pravděpodobnost, že náhodná veličina X je z intervalu $(0;30)$
- medián daného rozdělení
- střední hodnotu a rozptyl náhodné veličiny X

$$X \rightarrow LN(2;9)$$

ada) Pravděpodobnost, že náhodná veličina X je z intervalu $(0;30)$, můžeme určovat rovněž jako pravděpodobnost, že náhodná veličina X je menší než 30, neboť log.-normální náhodná veličina může nabývat pouze kladných hodnot.

Připomeňme si postup při určování distribuční funkce log.-normální náhodné veličiny:

$$F(x) = \begin{cases} \Phi\left(\frac{\ln x - \mu}{\sigma}\right); & \text{pro } x > 0 \\ 0 & \text{pro } x \leq 0 \end{cases}$$

A nyní již přejdeme k určení hledané pravděpodobnosti:

$$\underline{\underline{P(0 < X < 30) = F(30) - F(0) = \Phi\left(\frac{\ln 30 - 2}{\sqrt{9}}\right) - 0 = \Phi(0,47) = 0,681}}$$

nebo

$$\underline{\underline{P(0 < X < 30) = P(X < 30) = F(30) = \Phi\left(\frac{\ln 30 - 2}{\sqrt{9}}\right) = \Phi(0,47) = 0,681}}$$

adb) Pro určení mediánu můžeme použít vztah pro 100p%-ní kvantil, který byl odvozen v Průvodci studiem:

$$x_p = e^{\mu + \sigma \cdot z_p}$$

$$z_{0,5} = 0 \quad \Rightarrow \quad \underline{\underline{x_{0,5} = e^{2 + \sqrt{9} \cdot 0} = e^2 \cong 7,4}}$$

adc) Střední hodnotu a rozptyl určíme na základě výše uvedených vztahů:

$$EX = e^{\mu + \frac{\sigma^2}{2}} \Rightarrow \underline{\underline{EX = e^{2 + \frac{9}{2}} = e^{\frac{13}{2}} \cong 665,1}}$$

$$DX = e^{2\mu + \sigma^2} (e^{\sigma^2} - 1) \Rightarrow \underline{\underline{DX = e^{2 \cdot 2 + 9} (e^9 - 1) \cong 3,6 \cdot 10^9}}$$

2.4 Vícerozměrné normální rozdělení

Uvažujme náhodný vektor \underline{X} . ($\underline{X} = (X_1, X_2, \dots, X_n)^T$). Vektor \underline{X} má n-rozměrné normální rozdělení pravděpodobnosti s parametry $\underline{\mu}$ a Σ , jestliže jeho hustota pravděpodobnosti je:

$$f(x_1, x_2, \dots, x_n) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \cdot e^{-\frac{1}{2}(\underline{x} - \underline{\mu})^T \Sigma^{-1} (\underline{x} - \underline{\mu})}$$

$$-\infty < x_j < \infty, j = 1, \dots, n,$$

kde: $\underline{\mu} = (\mu_1, \dots, \mu_n)^T$ je vektor n reálných čísel

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1n} \\ \vdots & \vdots & \vdots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nn} \end{pmatrix} \text{ je kovarianční matice } (\sigma_{ij} = \text{cov}(X_i, X_j))$$

(symetrická pozitivně definitní matice typu (n;n))

$|\Sigma|$ je determinant kovarianční matice Σ , $|\Sigma| \neq 0$

Σ^{-1} je inverzní matice k matici Σ

(protože matice Σ je pozitivně definitní, je $|\Sigma| > 0$ a inverzní matice Σ^{-1} existuje)

Má-li náhodná veličina n -rozměrné normální rozdělení pravděpodobnosti s parametry μ a Σ , značíme to takto:

$$X \rightarrow N_n(\mu, \Sigma)$$

□ Dvourozměrné normální rozdělení

Speciálním případem n -rozměrného normálního rozdělení je dvourozměrné normální rozdělení. Kovarianční matice Σ má v tomto případě tvar:

$$\Sigma = \begin{pmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{pmatrix}$$

Všimněte si, že podmínka nenulového determinantu kovarianční matice ($|\Sigma| \neq 0$) je splněna pro $|\rho| < 1$.

Hustota pravděpodobnosti náhodného vektoru \underline{X} ($\underline{X}=(X_1, X_2)^T$) s dvourozměrným normálním rozdělením je dána vztahem:

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right]}$$

Věta:

Nechť $f(x_1, x_2)$ je hustota náhodného vektoru $\underline{X}=(X_1, X_2)^T$ s dvourozměrným normálním rozdělením $N_2(\mu, \Sigma)$, kde $\mu = (\mu_1, \mu_2)$ je vektor středních hodnot a Σ je kovarianční matice náhodného vektoru \underline{X} . Pak náhodné veličiny X_1 a X_2 mají normální rozdělení $N(\mu_1, \sigma_1^2)$ a $N(\mu_2, \sigma_2^2)$. Hustoty f_{X_1}, f_{X_2} nezávisí na korelačním koeficientu ρ .



Průvodce studiem

Pro zájemce o hlubší pochopení studované látky uvádíme důkaz předcházející věty:

Hustota pravděpodobnosti náhodného vektoru \underline{X} ($\underline{X}=(X_1, X_2)^T$) s dvourozměrným normálním rozdělením je dána vztahem:

$$f(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right]}$$

Marginální hustoty nalezneme takto:

$$\begin{aligned}
 f_{X_1}(x_1) &= \int_{-\infty}^{\infty} f(x_1, x_2) dx_2 = \\
 &= \int_{-\infty}^{\infty} \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right]} dx_2 = \\
 &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\left(\frac{x_2-\mu_2}{\sigma_2}\right) + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right]} dx_2
 \end{aligned}$$

Zavedeme si substituci: $y = \left(\frac{x_2 - \mu_2}{\sigma_2}\right)$

Pak: $dy = \frac{1}{\sigma_2} dx_2$

$$\begin{aligned}
 f_{X_1}(x_1) &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} \sigma_2 \cdot e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)y + y^2\right]} dy = \\
 &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)y + y^2\right]} dy = \\
 &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)y + y^2 + \rho^2\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - \rho^2\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2\right]} dy = \\
 &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[\rho^2\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)y + y^2 + (1-\rho^2)\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2\right]} dy = \\
 &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[\rho^2\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)y + y^2\right]} \cdot e^{-\frac{1}{2(1-\rho^2)}\left[(1-\rho^2)\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2\right]} dy = \\
 &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[y - \rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\right]^2} \cdot dy =
 \end{aligned}$$

Nyní zavedeme substituci: $z = y - \rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right)$

Pak: $dz = dy$

$$\begin{aligned} f_{X_1}(x_1) &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}\left[y-\rho\left(\frac{x_1-\mu_1}{\sigma_1}\right)\right]^2} \cdot dy = \\ &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}z^2} \cdot dz \end{aligned}$$

A nakonec zavedeme ještě jednu substituci: $t = \frac{1}{\sqrt{1-\rho^2}} z$

Pak: $dt = \frac{1}{\sqrt{1-\rho^2}} dz$

$$\begin{aligned} f_{X_1}(x_1) &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} e^{-\frac{1}{2(1-\rho^2)}z^2} \cdot dz = \\ &= \frac{1}{2\pi\sigma_1\sqrt{1-\rho^2}} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} \sqrt{1-\rho^2} \cdot e^{-\frac{1}{2}t^2} \cdot dt = \frac{1}{2\pi\sigma_1} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \int_{-\infty}^{\infty} e^{-\frac{1}{2}t^2} \cdot dt = \\ &= \frac{1}{2\pi\sigma_1} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \cdot \sqrt{2\pi} = \frac{1}{\sqrt{2\pi}\sigma_1} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \end{aligned}$$

Vidíme, že jde o hustotu náhodné veličiny s normálním rozdělením $N(\mu_1, \sigma_1^2)$. Obdobně bychom ukázali, že marginální hustota f_{X_2} náhodné veličiny X_2 odpovídá normálnímu rozdělení $N(\mu_2, \sigma_2^2)$.

Je-li $\rho = 0$, pak:

$$\begin{aligned} f(x_1, x_2) &= \frac{1}{2\pi\sigma_1\sigma_2} \cdot e^{-\frac{1}{2}\left[\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2 + \left(\frac{x_2-\mu_2}{\sigma_2}\right)^2\right]} = \frac{1}{2\pi\sigma_1\sigma_2} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \cdot e^{-\frac{1}{2}\left(\frac{x_2-\mu_2}{\sigma_2}\right)^2} = \\ &= \frac{1}{\sqrt{2\pi}\sigma_1} \cdot e^{-\frac{1}{2}\left(\frac{x_1-\mu_1}{\sigma_1}\right)^2} \cdot \frac{1}{\sqrt{2\pi}\sigma_2} \cdot e^{-\frac{1}{2}\left(\frac{x_2-\mu_2}{\sigma_2}\right)^2} = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \end{aligned}$$

a náhodné veličiny X_1, X_2 jsou tedy nezávislé.



Řešený příklad

Nechť náhodný vektor $\underline{X}=(X_1, X_2)^T$ má dvourozměrné normální rozdělení s parametry: $\mu_1 = 2, \mu_2 = (-1), \sigma_1^2 = 4, \sigma_2^2 = 16, \rho = (-0,8)$. Stanovte pravděpodobnosti:

- a) $P(1 < X_1 < 4)$
- b) $P(3 < X_2 < 6)$

Již výše jsme si ukázali, že náhodné veličiny X_1 a X_2 mají normální rozdělení $N(\mu_1, \sigma_1^2)$ a $N(\mu_2, \sigma_2^2)$.

$$X_1 \rightarrow N(2;4) \quad X_2 \rightarrow N(-1;16)$$

ada)

$$\begin{aligned} \underline{P(1 < X_1 < 4)} &= F(4) - F(1) = \Phi\left(\frac{4-2}{\sqrt{4}}\right) - \Phi\left(\frac{1-2}{\sqrt{4}}\right) = \Phi(1) - \Phi(-0,5) = \Phi(1) - (1 - \Phi(0,5)) \\ &= 0,841 - (1 - 0,691) = \underline{\underline{0,532}} \end{aligned}$$

adb)

$$\begin{aligned} \underline{P(3 < X_2 < 6)} &= F(6) - F(3) = \Phi\left(\frac{6-(-1)}{\sqrt{16}}\right) - \Phi\left(\frac{3-(-1)}{\sqrt{16}}\right) = \Phi(1,75) - \Phi(1) = 0,960 - 0,8 \\ &= \underline{\underline{0,119}} \end{aligned}$$

$$DX = e^{2\mu + \sigma^2} (e^{\sigma^2} - 1) \Rightarrow \underline{\underline{DX}} = e^{2 \cdot 2 + 4} (e^4 - 1) \cong \underline{\underline{3,6 \cdot 10^9}}$$



Otázky 2.

1. Popište náhodnou veličinu mající Erlangovo rozdělení
2. Popište náhodnou veličinu mající Weibulovo rozdělení
3. V čem spočívá flexibilita Weibullova rozdělení? (užití pro různá období intenzity poruch)
4. Popište náhodnou veličinu mající Logaritmicke – normální rozdělení
5. Popište náhodný vektor mající Vícerozměrné normální rozdělení