

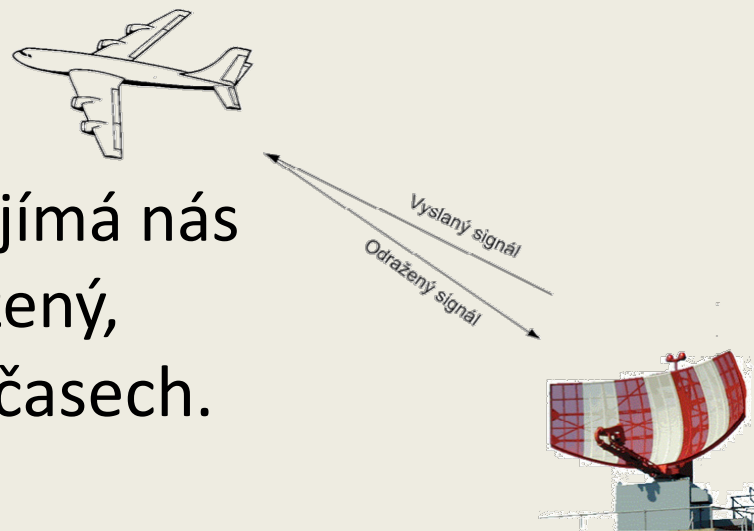
# (Auto)korelační funkce

# Náhodné procesy

- Korelace mezi náhodnými proměnnými má široké uplatnění v elektrotechnické praxi, kde se snažíme o porovnávání dvou signálů, které by měly být „stejné“.

- Příkladem může být radarová detekce nebo sonar.

- Máme nějaký vyslaný signál a zajímá nás jak detekovat (najít) signál odražený, který monitorujeme v různých časech.



- Tyto a další procesy jsou stochastické v čase. Zajímáme se o časový průběh (posloupnost) náhodných dějů.

# Náhodné procesy

- Př.: máme vysílaný signál  $x(t)$  a detekujeme odražený signál  $y(t)$ .
- V případě radaru, pro detekovaný odražený signál od letadla platí:  $y(t) = a \cdot x(t-D) + w(t)$ , kde  $a$  je faktor útlumu,  $D$  je zpoždění mezi vyslaným a přijatým signálem a  $w(t)$  je šum.
- Tedy detekovaný signál je v podstatě náhodná veličina a my hledáme korelaci s  $x(t)$ , abychom mohli určit vzdálenost letadla.
- Oba signály musí na sobě záviset, tedy musí být korelovány.

# Náhodné procesy

- Náhodný proces pak dělíme na:
  - Nestacionární
  - Stacionární
- V každém čase máme jinou náhodnou proměnnou, která je funkcí času:  $\rho(X, Y, t_1, t_2)$
- Pro stacionární náhodný proces platí, že základní charakteristiky  $E[X]$  a  $\text{Var}[X]$  nezávisí na čase a  $\rho(X, Y)$  je funkcí rozdílu času  $t_1 - t_2$ .
- Souběžný záznam několika realizací náhodné proměnné je nepraktický. Nahradím to různými čas. úseky jedné čas. realizace.
- Výpočet  $E[X]$  a  $\text{Var}[X]$  pak provedu z časových vzorků vzdálených  $\tau$ .



# (Auto)korelační funkce

- Už víme, že střední hodnota a rozptyl jsou počátečními charakteristikami (momenty) prvního řádu nebo centrální momenty druhého řádu.
- **Korelační funkce** pak je momentem druhého řádu dvojrozměrné náhodné proměnné  $\rho(X, Y)$ .
- **Autokorelační funkce** je korelační funkce náhodného procesu hodnoceného ve dvou různých časových okamžicích.
- Budeme se zajímat jen o stacionární procesy, které nejsou funkcí času  $t$  a závisí jen na „zpoždění“  $\tau$ .

# (Auto)korelační funkce

- Korelační funkce:  $R_{xy}(t, t+\tau) = E[x(t) \cdot y(t + \tau)]$ . Pro stacionární proces:

$$R_{xy}(\tau) = E\{x(t)y(t+\tau)\} = \lim_{T \rightarrow +\infty} \frac{1}{T} \int_0^T x(t)y(t+\tau) dt$$

- Autokorelační fce:  $R_{xx}(t, t+\tau) = E[x(t) \cdot x(t + \tau)]$ . Pro stacionární proces:

$$R_{xx}(\tau) = E\{x(t)x(t+\tau)\} = \lim_{T \rightarrow +\infty} \frac{1}{T} \int_0^T x(t)x(t+\tau) dt$$

- Pro diskrétní náhodné procesy lze odvodit podobné vztahy, kdy integrál nahradíme sumou.
- Platí to pro náhodné procesy, které jsou definovaný na čase od 0 do  $\infty$ .
- Pokud u korelační funkce přehodíme pořadí náhodných procesů  $y$  a  $x$ , pak lze odvodit:

$$R_{xy}(\tau) = E\{x(t)y(t+\tau)\} = E\{y(t_1)x(t_1-\tau)\} = R_{yx}(-\tau)$$

# (Auto)korelační funkce

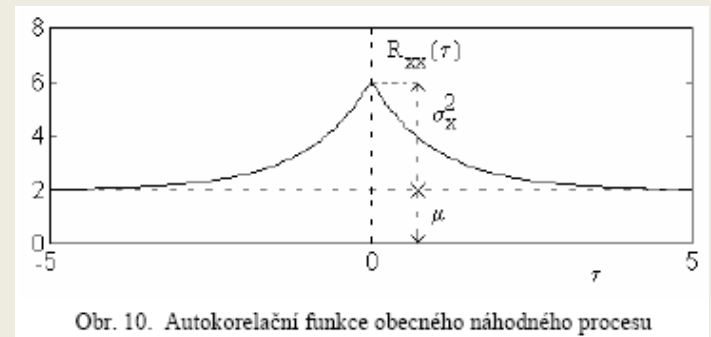
- Říkáme, že autokorelační funkce je sudá pokud platí:  $R_{xx}(\tau) = R_{xx}(-\tau)$ .
- Autokorelační funkce centrovaného  $\Delta x(t) = x(t) - E\{x(t)\}$  náhodného procesu souvisí s autokorelační funkcí necentrovaneého (obecného) procesu vztahem:
$$R_{\Delta x \Delta x}(\tau) = \lim_{T \rightarrow +\infty} \frac{1}{T} \int_0^T (x(t) - \mu)(x(t + \tau) - \mu) dt = R_{xx}(\tau) - \mu^2$$
- $R_{\Delta x \Delta x}(\tau)$  nazýváme jako **kovarianční funkce** a platí pro ni, že  $R_{\Delta x \Delta x}(0) = \sigma^2$ .

# (Auto)korelační funkce

- Pak lze dále definovat tzv. **normovanou kovarianční funkci**:

$$\rho_{\Delta x \Delta x}(\tau) = \frac{R_{\Delta x \Delta x}(\tau)}{\sigma^2}$$

- Hodnoty normované kovarianční funkce mají význam korelačních koeficientů mezi vzájemně posunutými hodnotami náhodného procesu. Pro stále větší  $\tau$  dvou vzorků náhodného procesu je jejich vzájemná souvislost stále menší a tedy i kovarianční funkce.
- Je-li vstupní náhodný proces (signál) periodická funkce, pak autokorelační funkce je také periodická.
- Typický příklad autokorelační funkce:





# Aplikace (auto)korelační funkce

- Určení časového zpoždění mezi dvěma podobnými ději
  - Známe rychlost šíření signálu  $v$  a chceme určit vzdálenost objektu  $d$  (radar, sonar, ultrazvuková diagnostika).
  - Známe vzdálenost  $d$  dvou senzorů a chceme určit rychlost tělesa  $v$ , které se pohybuje mezi senzory.
- Spočítáme autokorelační funkci mezi signálem vyslaným a přijatým nebo mezi signály ze dvou senzorů.
- Výše uvedené jsou stacionární náhodné procesy a tedy autokorelační funkce bude záviset jen na zpoždění  $\tau$ . Maximum autokorelační funkce nastává právě pro zpoždění  $\tau = T_D = d/v$ .

# Aplikace (auto)korelační funkce

- Zjištění periodicity signálů
  - Máme náhodný proces, který převedeme na signál, který může být charakterizován velmi dlouhou periodou. Pak je obtížné ve velkém množství dat najít periodicitu signálu.
- Pokud je to stacionární proces, tak autokorelační funkce musí být periodická funkce zpoždění  $\tau$ .
- Takováto autokorelační funkce bude mít silná lokální maxima pro  $\tau = 0$  a pro násobky periody náhodného signálu  $T$ .

# Aplikace (auto)korelační funkce

- Detekce periodického signálu v šumu.
  - Mohu opět určit periodu signálu
  - Mohu stanovit poměr signál/šum

$$\hat{R}_{xx}(\tau) = \frac{1}{T} \int_0^T [s(t) + n(t)][s(t + \tau) + n(t + \tau)] dt$$

$$\hat{R}_{xx}(\tau) = \hat{R}_{ss}(\tau) + \hat{R}_{sn}(\tau) + \hat{R}_{ns}(\tau) + \hat{R}_{nn}(\tau)$$

- Korelační funkce signálu a šumu a autokorelační funkce šum/šum nebudou periodické. Periodická bude jen autokorelační funkce signálu.

# Korelační funkce ve frekvenční oblasti

- (Auto)korelační funkce je charakteristika náhodného procesu v **časové doméně**. Často je užitečné definovat charakteristiky náhodných procesů ve **frekvenční doméně** – nazývané jako tzv. **spektra**.
- K převedení korelačních funkcí z časové domény do frekvenční se používají tzv. **Fourierovy transformace**.
- Je to integrální transformace převádějící časovou funkci (originál) na frekvenční funkci komplexní proměnné (obraz).

- Def.:

$$F\{x(t)\} = X(\omega) = \int_{-\infty}^{+\infty} x(t) \exp(-j\omega t) dt$$

$\omega = 2\pi f$ ,  $j$  – komplexní jednotka

# Korelační funkce ve frekvenční oblasti

- Vlastnosti  $X(\omega)$ 
  - Absolutní integrovatelnost (musí existovat integrál)
  - Po částech spojitá s konečným počtem bodů nespojitosti
  - Lineární
  - Inverzní Fourierova transformace

$$F^{-1}\{X(\omega)\} = x(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X(\omega) \exp(j\omega t) d\omega$$

# Spektrální výkonová hustota

- Autokorelační funkce  $R_{xx}(\tau)$  je funkcí čas. zpoždění
- Aplikujeme na ni Fourierovu transformaci.
- Dostaneme tzv. spektrální výkonovou hustotu  $S_{xx}(\omega)$ .
- Vztahy pro přímou a zpětnou Fourierovu transformaci autokorelační funkce se nazývají **Wiener-Chinčiny vzorce**.

$$S_{xx}(\omega) = \int_{-\infty}^{+\infty} R_{xx}(\tau) \exp(-j\omega\tau) d\tau,$$
$$R_{xx}(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{xx}(\omega) \exp(j\omega\tau) d\omega$$

# Spektrální výkonová hustota

- Protože autokorelační funkce je sudá, pak spektrální výkonová hustota je také sudá funkce:  $S_{xx}(\omega) = S_{xx}(-\omega)$  a je definována pro kladné a záporné frekvence.
- Dá se ukázat, že  $R_{xx}(0)$  je rovno výkonu náhodného procesu:

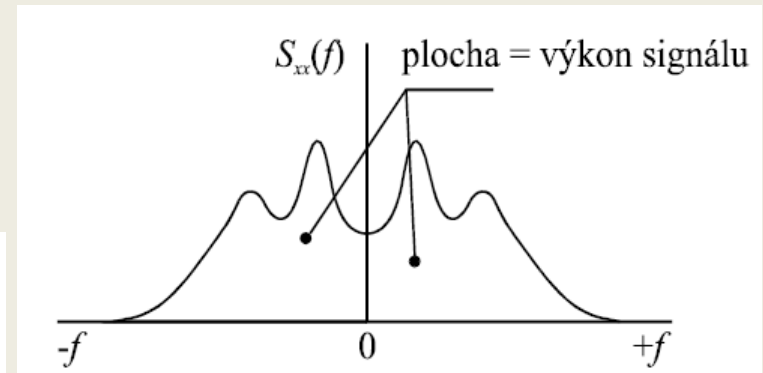
$$R_{xx}(0) = \lim_{T \rightarrow +\infty} \frac{1}{T} \int_{-T/2}^{T/2} (x(t))^2 dt = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{xx}(\omega) d\omega = \int_{-\infty}^{+\infty} S_{xx}(f) df$$

- Pozn.: pro centrované náhodné procesy je  $R_{\Delta x \Delta x}(0)$  rovno rozptylu náhodného procesu.

# Spektrální výkonová hustota

- Plocha spektra v souřadnicích frekvence  $f$  představuje výkon náhodného procesu, jak je ilustrováno na obrázku.
- Příklad: spektrální výkonová hustota bílého šumu

$$S_{ee}(\omega) = \int_{-\infty}^{+\infty} \sigma_e^2 \delta(\tau) \exp(-j\omega \tau) d\tau = \sigma_e^2 \exp(-0) = \sigma_e^2$$



- Pro spojitý čas (nekonečné  $f$ . spektrum) je  $S_{xx}(\omega)$  bílého šumu nekonečné. Při reálných měřeních je ale čas vždy diskrétní a tedy spektrum (frekvenční rozsah) omezený.



# Spektrální výkonová hustota

- Wiener-Chinčiny vztahy lze také odvodit pro dvojici náhodných procesů  $x(t)$  a  $y(t)$ .
- $S_{xy}(\omega)$  nazýváme jako **křížová výkonová hustota spektra**

$$S_{xy}(\omega) = \int_{-\infty}^{+\infty} R_{xy}(\tau) \exp(-j\omega\tau) d\tau$$

$$R_{xy}(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{xy}(\omega) \exp(j\omega\tau) d\omega$$

- Pro nezávislé centrované procesy  $x(t)$  a  $y(t)$  je  $S_{\Delta x \Delta y}(\omega) = 0$ .
- Pokud zaměníme pořadí náhodných procesů, lze dokázat platnost  $S_{xy}(\omega) = S_{yx}(-\omega)$ , podobně jako u korelační funkce.

# Počítání s více náhodnými proměnnými

# Součet diskrétních $X$ a $Y$

- Bude nás zajímat, jak bude vypadat pravděpodobnostní distribuce náhodné proměnné, která vznikne matematickou operací (sčítání, rozdíl, násobení, dělení) více náhodných proměnných, které mají definovanou svou vlastní pravděpodobnostní distribuci.
- Budeme hledat, jakou má distribuci diskrétní náhodná proměnná  $Z = X + Y$ .
- Náhodná proměnná  $Z$  bude nabývat hodnot  $a_i + b_j = c$ . Pravděpodobnostní funkce bude:

$$p_Z(c) = \sum_{(i,j):a_i+b_j=c} P(X = a_i, Y = b_j), \quad p_Z(c) = \sum_j P(X = c - b_j, Y = b_j)$$

# Součet diskrétních $X$ a $Y$

- Tedy můžeme definovat pravidlo pro výpočet pravděpodobnostní funkce pro náhodnou proměnnou vzniklou součtem  $X$  a  $Y$ .

ADDING TWO INDEPENDENT DISCRETE RANDOM VARIABLES. Let  $X$  and  $Y$  be two independent discrete random variables, with probability mass functions  $p_X$  and  $p_Y$ . Then the probability mass function  $p_Z$  of  $Z = X + Y$  satisfies

$$p_Z(c) = \sum_j p_X(c - b_j) p_Y(b_j),$$

where the sum runs over all possible values  $b_j$  of  $Y$ .

# Součet diskrétních X a Y

- Příklad: mějme X a Y a každá má pravděpodobnostní distribuci  $\text{Geo}(p)$ . Hledáme distribuci proměnné  $Z = X + Y$ . Podle pravidla musí platit:

$$P(X + Y = k) = p_Z(k) = \sum_{\ell=1}^{\infty} p_X(k - \ell)p_Y(\ell).$$

- Protože  $p_X(a) = 0$  pro  $a \leq 0$ , potom v sumaci členy s  $\ell \geq k$  zmizí. Dostaneme tedy:

$$\begin{aligned} P(X + Y = k) &= \sum_{\ell=1}^{k-1} p_X(k - \ell) \cdot p_Y(\ell) = \sum_{\ell=1}^{k-1} (1 - p)^{k-\ell-1} p \cdot (1 - p)^{\ell-1} p \\ &= \sum_{\ell=1}^{k-1} p^2 (1 - p)^{k-2} = (k - 1)p^2 (1 - p)^{k-2}. \end{aligned}$$

- Všimněte si, že pravděpodobnostní distribuce pro  $X + Y$  už není geometrická.

# Součet diskrétních $X$ a $Y$

- PŘ.: Necht' máme náhodnou proměnnou  $X$  a  $Y$  každou popsanou distribucí  $\text{Bin}(n,p)$  a  $\text{Bin}(m,p)$ .
- První distribuce popisuje  $n$  nezávislých pokusů s pravděpodobností  $p$ .
- Druhá distribuce popisuje  $m$  nezávislých pokusů s pravděpodobností  $p$ .
- Tedy pravděpodobnostní distribuce náhodné proměnné  $Z = X + Y$  mi popisuje  $n + m$  pokusů s pravděpodobností úspěchu  $p$ . Musí tedy mít tvar  $\text{Bin}(n+m,p)$ .
- Důkaz: Každá  $\text{Bin}(n,p)$  a  $\text{Bin}(m,p)$  náhodná proměnná má stejnou distribuci jako součet  $n$  nezávislých resp.  $m$  nezávislých  $\text{Ber}(p)$  distribuovaných náhodných proměnných. Jinými slovy náhodná proměnná  $Z = X + Y$  má tedy stejnou distribuci jakou součet  $n + m$  nezávislých  $\text{Ber}(p)$  náhodných proměnných a tedy  $Z$  má náhodnou distribuci  $\text{Bin}(n+m,p)$ .

# Součet spojitých X a Y

- Budeme mít dvě spojitě náhodné proměnné X a Y. Bude nás zajímat jak bude vypadat hustota pravděpodobnosti náhodné proměnné  $Z = X + Y$ .
- Dá se ukázat, že distribuční funkce náhodné proměnné Z bude dána vztahem:

$$F_Z(a) = P(Z \leq a) = P(X + Y \leq a) = \iint_{(x,y):x+y \leq a} f(x,y) dx dy.$$

- Je to vlastně dvojité integrování přes x a pak přes y. Obě proměnné běží přes interval od  $-\infty, \infty$  a zároveň  $x+y \leq a$  (ekvivalentně  $x \leq a-y$ ). Pak:

$$F_Z(a) = \int_{-\infty}^{\infty} \left( \int_{-\infty}^{a-y} f(x,y) dx \right) dy.$$

# Součet spojitých X a Y

- Pokud jsou X a Y nezávislé náhodné proměnné pak lze distribuční funkci vyjádřit pomocí marginálních hustot pravděpodobnosti a poslední integrál přepsat na:

$$\int_{-\infty}^{\infty} \left( \int_{-\infty}^{a-y} f_X(x) dx \right) f_Y(y) dy,$$

- Nakonec pro  $-\infty < a < \infty$  dostaneme:

$$F_Z(a) = \int_{-\infty}^{\infty} F_X(a - y) f_Y(y) dy$$



# Součet spojitých $X$ a $Y$

- Derivací  $F_Z$  dostaneme vztah pro hustotu pravděpodobnosti.

ADDING TWO INDEPENDENT CONTINUOUS RANDOM VARIABLES. Let  $X$  and  $Y$  be two independent continuous random variables, with probability density functions  $f_X$  and  $f_Y$ . Then the probability density function  $f_Z$  of  $Z = X + Y$  is given by

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(z - y) f_Y(y) dy$$

for  $-\infty < z < \infty$ .

- Je tedy zřejmé, že obecně součet dvou náhodných proměnných se stejnou distribucí nebude mít stejnou distribuci.

# Součet spojitých X a Y

- Platí pro součet dvou nezávislých náhodných proměnných X a Y se standardním normálním rozdělením, že náhodná proměnná  $Z = X + Y$  bude mít také standardní normální rozdělení pravděpodobnosti?

$$\begin{aligned} f_{X+Y}(z) &= \int_{-\infty}^{\infty} f_X(z-y)f_Y(y) dy \\ &= \int_{-\infty}^{\infty} \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(z-y)^2} \right) \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2} \right) dy \\ &= \int_{-\infty}^{\infty} \left( \frac{1}{\sqrt{2\pi}} \right)^2 e^{-\frac{1}{2}(2y^2-2yz+z^2)} dy. \end{aligned}$$

- Odečteme z exponentu  $1/2z^2$  a závorku upravíme.

# Součet spojitých X a Y

$$2y^2 - 2yz + \frac{1}{2}z^2 = \left[ \sqrt{2} \left( y - \frac{z}{2} \right) \right]^2$$

- Zavedeme novou proměnnou:

$$t = \sqrt{2} \left( y - \frac{z}{2} \right)$$

$$\begin{aligned} f_{X+Y}(z) &= \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{4}z^2} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(2y^2 - 2yz + \frac{1}{2}z^2)} dy \\ &= \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{4}z^2} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}[\sqrt{2}(y - z/2)]^2} dy \\ &= \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{4}z^2} \frac{1}{\sqrt{2}} \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}t^2} dt \\ &= \frac{1}{\sqrt{4\pi}} e^{-\frac{1}{4}z^2} \int_{-\infty}^{\infty} \phi(t) dt. \end{aligned}$$

- Pozor změna proměnné, musím si spočítat  $dt!!!$

$$f_{X+Y}(z) = \frac{1}{\sqrt{4\pi}} e^{-\frac{1}{4}z^2},$$

# Součet spojitých $X$ a $Y$

- Dostali jsme hustotu pravděpodobnosti normální standardní distribuce  $N(0,2)$ :

$$f_{X+Y}(z) = \frac{1}{\sqrt{4\pi}} e^{-\frac{1}{4}z^2},$$

- Obecné pravidlo:

THE SUM OF INDEPENDENT NORMAL RANDOM VARIABLES. If  $X$  and  $Y$  are independent random variables with a normal distribution, then  $X + Y$  also has a normal distribution.

- Dá se ukázat, že nezávislost  $X$  a  $Y$  není nutná podmínka a platí to i pro závislé  $X$  a  $Y$ .

# Násobení spojitých X a Y

- Bude nás zajímat jak bude vypadat pravděpodobnostní distribuce nové náhodné proměnné  $Z = X \cdot Y$ . Kde X a Y jsou **nezávislé** náhodné proměnné.
- Je to podobná úloha, kterou jsme řešili na str. 37 přednášky 2. Poznali jsme, jak spočítat střední hodnotu náhodné proměnné  $Z = X \cdot X$  (pozn.: uvědomte si, že náhodné proměnné X a X jsou vzájemně závislé a tedy **nelze** psát  $E[Z] = E[X] \cdot E[X] = E[X]^2$ . Pokud by byly X a X nezávislé tak by rovnost platila, ale v konkrétním příkladu čtverců jsou velikosti stran vzájemně závislé).
- Dá se ukázat, že hustota pravděpodobnosti náhodné proměnné Z je dána netriviálním vztahem:

$$f_Z(z) = \frac{d}{dz} F_Z(z) = \frac{d}{dz} \frac{z(1 + 2 \ln 10 - \ln z)}{100} = \frac{\ln 100 - \ln z}{100}$$

# Násobení spojitých $X$ a $Y$

- Nalezení hustoty pravděpodobnosti náhodné proměnné  $Z = X \cdot Y$  lze zobecnit:

PRODUCT OF INDEPENDENT CONTINUOUS RANDOM VARIABLES. Let  $X$  and  $Y$  be two independent continuous random variables with probability densities  $f_X$  and  $f_Y$ . Then the probability density function  $f_Z$  of  $Z = XY$  is given by

$$f_Z(z) = \int_{-\infty}^{\infty} f_Y\left(\frac{z}{x}\right) f_X(x) \frac{1}{|x|} dx$$

for  $-\infty < z < \infty$ .

# Podíl spojitých $X$ a $Y$

- Bude nás zajímat jak bude vypadat hustota pravděpodobnosti náhodné proměnné  $Z = X/Y$ .
- Pokud jsou  $X$  a  $Y$  nezávislé, tak také  $X$  a  $1/Y$  musí být nezávislé.
- Pak můžeme použít pravidlo pro hledání hustoty pravděpodobnosti součinu dvou nezávislých náhodných proměnných a dostaneme:

QUOTIENT OF INDEPENDENT CONTINUOUS RANDOM VARIABLES. Let  $X$  and  $Y$  be two independent continuous random variables with probability densities  $f_X$  and  $f_Y$ . Then the probability density function  $f_Z$  of  $Z = X/Y$  is given by

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(zx) f_Y(x) |x| dx$$

for  $-\infty < z < \infty$ .

# Cauchyho distribuce

- Příklad: necht'  $X$  a  $Y$  jsou nezávislé náhodné proměnné mající každá standardní normální distribuci pravděpodobnosti. Jaká bude distribuce pravděpodobnosti náhodné proměnné  $Z = X/Y$ ? Dá se ukázat, že to bude tzv. standardní Cauchyho distribuce:

$$\begin{aligned} f_Z(z) &= \int_{-\infty}^{\infty} |x| \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}z^2x^2} \right) \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \right) dx \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} |x| e^{-\frac{1}{2}(z^2+1)x^2} dx = 2 \cdot \frac{1}{2\pi} \int_0^{\infty} x e^{-\frac{1}{2}(z^2+1)x^2} dx \\ &= \frac{1}{\pi} \left[ \frac{-1}{z^2+1} e^{-\frac{1}{2}(z^2+1)x^2} \right]_0^{\infty} = \frac{1}{\pi(z^2+1)}. \end{aligned}$$



# Cauchyho distribuce

- Obecně Cauchyho pravděpodobnostní distribuce je definována:

DEFINITION. A continuous random variable has a *Cauchy distribution* with parameters  $\alpha$  and  $\beta > 0$  if its probability density function  $f$  is given by

$$f(x) = \frac{\beta}{\pi (\beta^2 + (x - \alpha)^2)} \quad \text{for } -\infty < x < \infty.$$

We denote this distribution by  $Cau(\alpha, \beta)$ .

- Je speciální tím, že nemá střední hodnotu a své uplatnění nalézá v částicové fyzice.

# Zákon velkých čísel

# Motivace

- Ze zkušenosti víme, že pokud opakujeme nějaký experiment založený na měření nějakého přírodního jevu (např. interferometrické měření rychlosti světla), tak po vykonání mnoha identických opakování měření dostaneme pokaždé trošku jiný výsledek.
- V praxi provedeme měření mnohokrát a najdeme aritmetický průměr všech takto získaných výsledků experimentů.
- Ve skutečnosti máme sadu  $n$  nezávislých náhodných proměnných, u kterých neznáme jejich pravděpodobnostní distribuce.
- Zákon velkých čísel pak dává do souvislosti skutečnost, že čím více opakování nezávislých experimentů provedeme, tak s větší pravděpodobností spočítaný arit. průměr se bude blížit střední hodnotě náhodné proměnné.

# Průměr vs. střední hodnota

- Mějme sekvenci náhodných proměnných  $X_1, X_2, X_3, \dots, X_n$ . Každé  $X_i$  představuje  $i$ -té opakování stejného experimentu (např. měření nějaké fyzikální veličiny). Experimentální podmínky každého měření musí být identické a výsledek každého měření nesmí nijak ovlivnit výsledek následných měření. Potom náhodné proměnné  $X_i$  jsou nezávislé. Zároveň všechny  $X_i$  mají stejnou pravděpodobnostní distribuci.
- Nechť každá  $X_i$  má distribuční funkci  $F$ , střední hodnotu  $\mu$  a směrodatnou odchylku  $\sigma$ .
- Potom a. průměr prvních  $n$  náhodných proměnných je:  $\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}$
- Z podmínky linearitě střední hodnoty plyne:

$$E[\bar{X}_n] = \frac{1}{n}E[X_1 + X_2 + \dots + X_n] = \frac{1}{n}(\mu + \mu + \dots + \mu) = \mu$$

# Průměr vs. střední hodnota

- Podle pravidla výpočtu rozptylu součtu  $n$  náhodných proměnných plyne:

$$\text{Var}(\bar{X}_n) = \frac{1}{n^2} \text{Var}(X_1 + X_2 + \dots + X_n) = \frac{1}{n^2} (\sigma^2 + \sigma^2 + \dots + \sigma^2) = \frac{\sigma^2}{n}$$

EXPECTATION AND VARIANCE OF AN AVERAGE. If  $\bar{X}_n$  is the average of  $n$  independent random variables with the same expectation  $\mu$  and variance  $\sigma^2$ , then

$$E[\bar{X}_n] = \mu \quad \text{and} \quad \text{Var}(\bar{X}_n) = \frac{\sigma^2}{n}.$$

# Průměr vs. střední hodnota

- Tedy střední hodnota a. průměru  $n$  výsledků nezávislých měření  $X_i$  je rovna střední hodnotě jednotlivého náhodného experimentu.
- Na druhou stranu směrodatná odchylka průměru je menší o  $\sqrt{n}$ . Tedy vícenásobné opakování měření mi bude dávat pořád stejnou střední hodnotu, ale rozptyl naměřených hodnot mi bude s počtem měření konvergovat k nule.
- Tedy čím více nezávislých měření provedu, pak s odmocninou z počtu měření se mi bude zmenšovat interval (směrodatná odchylka), ve kterém se mohou vyskytovat naměřené náhodné proměnné.
- Je zřejmé, že součet náhodných proměnných každé s identickou pravděpodobnostní distribucí mi musí dát novou distribuční funkci.
- Bude nás zajímat jak bude vypadat hustota pravděpodobnosti náhodné proměnné  $\bar{X}_n$ . Jako příklad uveďme  $\text{Gam}(2,1)$  rozdělení s hustotou pravděpodobnosti:

$$f(x) = xe^{-x} \quad \text{for } x \geq 0$$

# Průměr vs. střední hodnota

- Gam(2,1) je distribuce, jejíž každá náhodná proměnná je dána součtem dvou nezávislých Exp(1) náhodných proměnných.

$$\begin{aligned} f_{Z_2}(z) &= f_{T_1+T_2}(z) = \int_{-\infty}^{\infty} f_{T_1}(z-y) f_{T_2}(y) dy \\ &= \int_0^z \lambda e^{-\lambda(z-y)} \cdot \lambda e^{-\lambda y} dy \\ &= \lambda^2 e^{-\lambda z} \int_0^z dy = \lambda^2 z e^{-\lambda z}. \end{aligned}$$

DEFINITION. A continuous random variable  $X$  has a *gamma distribution* with parameters  $\alpha > 0$  and  $\lambda > 0$  if its probability density function  $f$  is given by  $f(x) = 0$  for  $x < 0$  and

$$f(x) = \frac{\lambda (\lambda x)^{\alpha-1} e^{-\lambda x}}{\Gamma(\alpha)} \quad \text{for } x \geq 0,$$

where the quantity  $\Gamma(\alpha)$  is a normalizing constant such that  $f$  integrates to 1. We denote this distribution by  $Gam(\alpha, \lambda)$ .

# Průměr vs. střední hodnota

- Tedy náhodná proměnná  $S_n = X_1 + X_2 + X_3 + \dots + X_n$  je dána součtem  $2n$  nezávislých  $\text{Exp}(1)$  náhodných proměnných a má distribuci  $\text{Gam}(2n, 1)$  s hustou pravděpodobnosti:

$$f_{S_n}(x) = \frac{x^{2n-1} e^{-x}}{(2n-1)!} \quad \text{for } x \geq 0.$$


- Budeme hledat hustotu pravděpodobnosti náhodné proměnné  $\bar{X}_n = S_n/n$ . Aplikací pravidla o transformaci náhodné proměnné dostaneme:

$$f_{\bar{X}_n}(x) = n f_{S_n}(nx) = \frac{n (nx)^{2n-1} e^{-nx}}{(2n-1)!} \quad \text{for } x \geq 0$$



# Průměr vs. střední hodnota

- Takto jsme explicitně získaly hustotu pravděpodobnosti náhodné proměnné  $\overline{X}_n$ .
- Počet opakování měření  $n$  je parametr hustoty pravděpodobnosti.
- Pro rostoucí  $n$  se mi hustota pravděpodobnosti mění. Stává se stále užší kolem střední hodnoty, která je pro  $\text{Gam}(2,1)$  rovna 2.
- Pro  $n \rightarrow \infty$  se mi hustota pravděpodobnosti náhodné proměnné  $\overline{X}_n$  změní na konstantu  $\mu$ .



# Čebyševova nerovnost

- Tento teorém mi kvantifikuje jak moc se mi „zúží“ hustota pravděpodobnosti, při nezávislém opakování stejného náhodného experimentu.
- Ke kvantifikaci použijeme podmínku, jaká je pravděpodobnost, že náhodná proměnná  $Y$  bude ležet mimo interval  $(E[Y]-a, E[Y]+a)$ .

CHEBYSHEV'S INEQUALITY. For an arbitrary random variable  $Y$  and any  $a > 0$ :

$$P(|Y - E[Y]| \geq a) \leq \frac{1}{a^2} \text{Var}(Y).$$

# Čebyševova nerovnost

- Důkaz: necht'  $f_Y$  je hustota pravděpodobnosti náhodné proměnné  $Y$  a  $\mu$  je totožné s  $E[Y]$ . Pak:

$$\begin{aligned}\text{Var}(Y) &= \int_{-\infty}^{\infty} (y - \mu)^2 f_Y(y) dy \geq \int_{|y-\mu| \geq a} (y - \mu)^2 f_Y(y) dy \\ &\geq \int_{|y-\mu| \geq a} a^2 f_Y(y) dy = a^2 \text{P}(|Y - \mu| \geq a).\end{aligned}$$

- Když obě strany podělíme  $a^2$  dostaneme Čebyševovu nerovnost.
- Označme  $\text{Var}(Y)$  jako  $\sigma^2$ . Pravděpodobnost, že  $Y$  leží v intervalu širokém  $k \cdot \sigma$  kolem  $\mu$ , kde  $k$  je malé celé číslo, je rovna:  $\text{P}(|Y - \mu| < k\sigma) = 1 - \text{P}(|Y - \mu| \geq k\sigma)$  Pokud  $a = k\sigma$ , pak z Čebyševovy nerovnosti máme:

$$\text{P}(|Y - \mu| < k\sigma) \geq 1 - \frac{\text{Var}(Y)}{k^2 \sigma^2} = 1 - \frac{1}{k^2}.$$

# Čebyševova nerovnost

- Pro rostoucí  $k = 2, 3, 4, \dots, n$  pravá strana poslední rovnice konverguje k jedničce.
- Na základě Čebyševovy nerovnosti můžeme vyslovit silnější tvrzení:

THE “ $\mu \pm \text{A FEW } \sigma$ ” RULE. Most of the probability mass of a random variable is within a few standard deviations from its expectation.

- Jinými slovy většina plochy hustoty pravděpodobnosti leží v intervalu omezeném nižší mezí v nerovnici:  $P(|Y - \mu| < k\sigma)$

# Zákon velkých čísel

- Mějme posloupnost  $n$  nezávislých náhodných proměnných s identickou pravděpodobnostní distribucí, se střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ .
- Budeme aplikovat Čebyševovu nerovnost na a. průměr  $\bar{X}_n$ ,  $E[\bar{X}_n] = \mu$ ,  $\text{Var}(\bar{X}_n) = \sigma^2/n$  a  $\varepsilon > 0$ , pak: 
$$P(|\bar{X}_n - \mu| > \varepsilon) = P(|\bar{X}_n - E[\bar{X}_n]| > \varepsilon) \leq \frac{1}{\varepsilon^2} \text{Var}(\bar{X}_n) = \frac{\sigma^2}{n\varepsilon^2}.$$
- Pravá strana rovnice konverguje k nule pro  $n$  rostoucí do nekonečna a  $\varepsilon$  může být jakékoliv.

# Zákon velkých čísel

- Pak dostáváme zákon velkých čísel:


THE LAW OF LARGE NUMBERS. If  $\bar{X}_n$  is the average of  $n$  independent random variables with expectation  $\mu$  and variance  $\sigma^2$ , then for any  $\varepsilon > 0$ :

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| > \varepsilon) = 0.$$

- Interpretace zákona velkých čísel na příkladu.
- Provádějme nějaký složitý experiment, kdy měříme nějakou fyzikální veličinu. Po mnoha opakováních vidíme, že měřená hodnota se pohybuje v blízkosti „správné“ hodnoty, kterou očekáváme.
- Předpokládejme, že naše měření má hypoteticky Gam(2,1) distribuci. To co mi chceme získat našim  $n$ -krát opakovaným měřením, je vlastně střední hodnota Gam(2,1) na základě průměru výsledků náhodných experimentů.

# Zákon velkých čísel

- Takovýto experiment, lze nasimulovat.
- Uděláme 500 měření a pro každé  $n$  spočítáme průměr prvních  $n$  naměřených hodnot a vyneseme do grafu jako funkci  $n$ .
- Víme, že  $E[\text{Gam}(2,1)] = 2$ .
- Z grafu je patrné, že už po 200 opakováních je průměr velmi blízko k  $\mu$ .
- Když budeme pokračovat dále, tak „průměry“ budou oscilovat ve stále menším intervalu kolem  $\mu$ .
- Ale to nevylučuje, že po 1000 opakováních mi „průměr“ nevyskočí na třeba 2,3.
- Zákon velkých čísel mi jen říká, že pravděpodobnost, že průměr mnoha měření se bude blížit střední hodnotě, se bude blížit limitně jedné. Ale to neznamená, že nemusím mít smůlu a zrovna naměřit špatné hodnoty.



# Zákon velkých čísel

- Platí zákon velkých čísel i pro sekvenci náhodných proměnných, jejichž pravděpodobnostní distribuce nemá střední hodnotu nebo je nekonečně velká?
- Cauchyho distribuce nemá střední hodnotu – viz strana 33.
- Provedeme simulaci jako v předchozím příkladě.
- Vidíme, že průměry mají tendenci konvergovat k bodu symetrie Cauchyho distribuce, ale je to jenom iluze.
- Každou chvíli další hodnota  $X_i$  padne daleko od čísla 2. Pokud bychom provedli simulaci pro ještě větší  $n$ , tak výsledek by byl stejný. Nelze pozorovat žádnou konvergenci.
- Tedy zde zákon velkých čísel neplatí.

