

# Náhodné signály

Jan Černocký

ÚPGM FIT VUT Brno, [cernocky@fit.vutbr.cz](mailto:cernocky@fit.vutbr.cz)

## Náhodné signály

- deterministické signály (můžeme je zapsat rovnicí) mají jednu zásadní nevýhodu – nesou velmi málo informace (např. kosínusovka: amplituda, frekvence, počáteční fáze).
- signály reálného světa se dají popsat deterministicky velmi těžce nebo vůbec (např. fyzikální model pro řečový signál je velmi složitý a stejně se jedná o zjednodušení).

⇒ na tyto **užitečné** signály se budeme z hlediska teorie dívat jako na **náhodné signály (procesy)** (např. řeč, cirkulace zásilek pobočkami České pošty, kurs Kč/EUR ...).

Podle charakteru časové osy dělíme na náhodné signály **se spojitým časem** (definovány pro všechna  $t$ ) a **s diskrétním časem** (jen pro diskrétní  $n$ ).

Signály nemůžeme popsat ve všech časech (to by byly deterministické), budeme spíše hledat charakteristické vlastnosti náhodných signálů, jako střední hodnota, funkce hustoty rozložení pravděpodobnosti, atd.

## Definice náhodného procesu

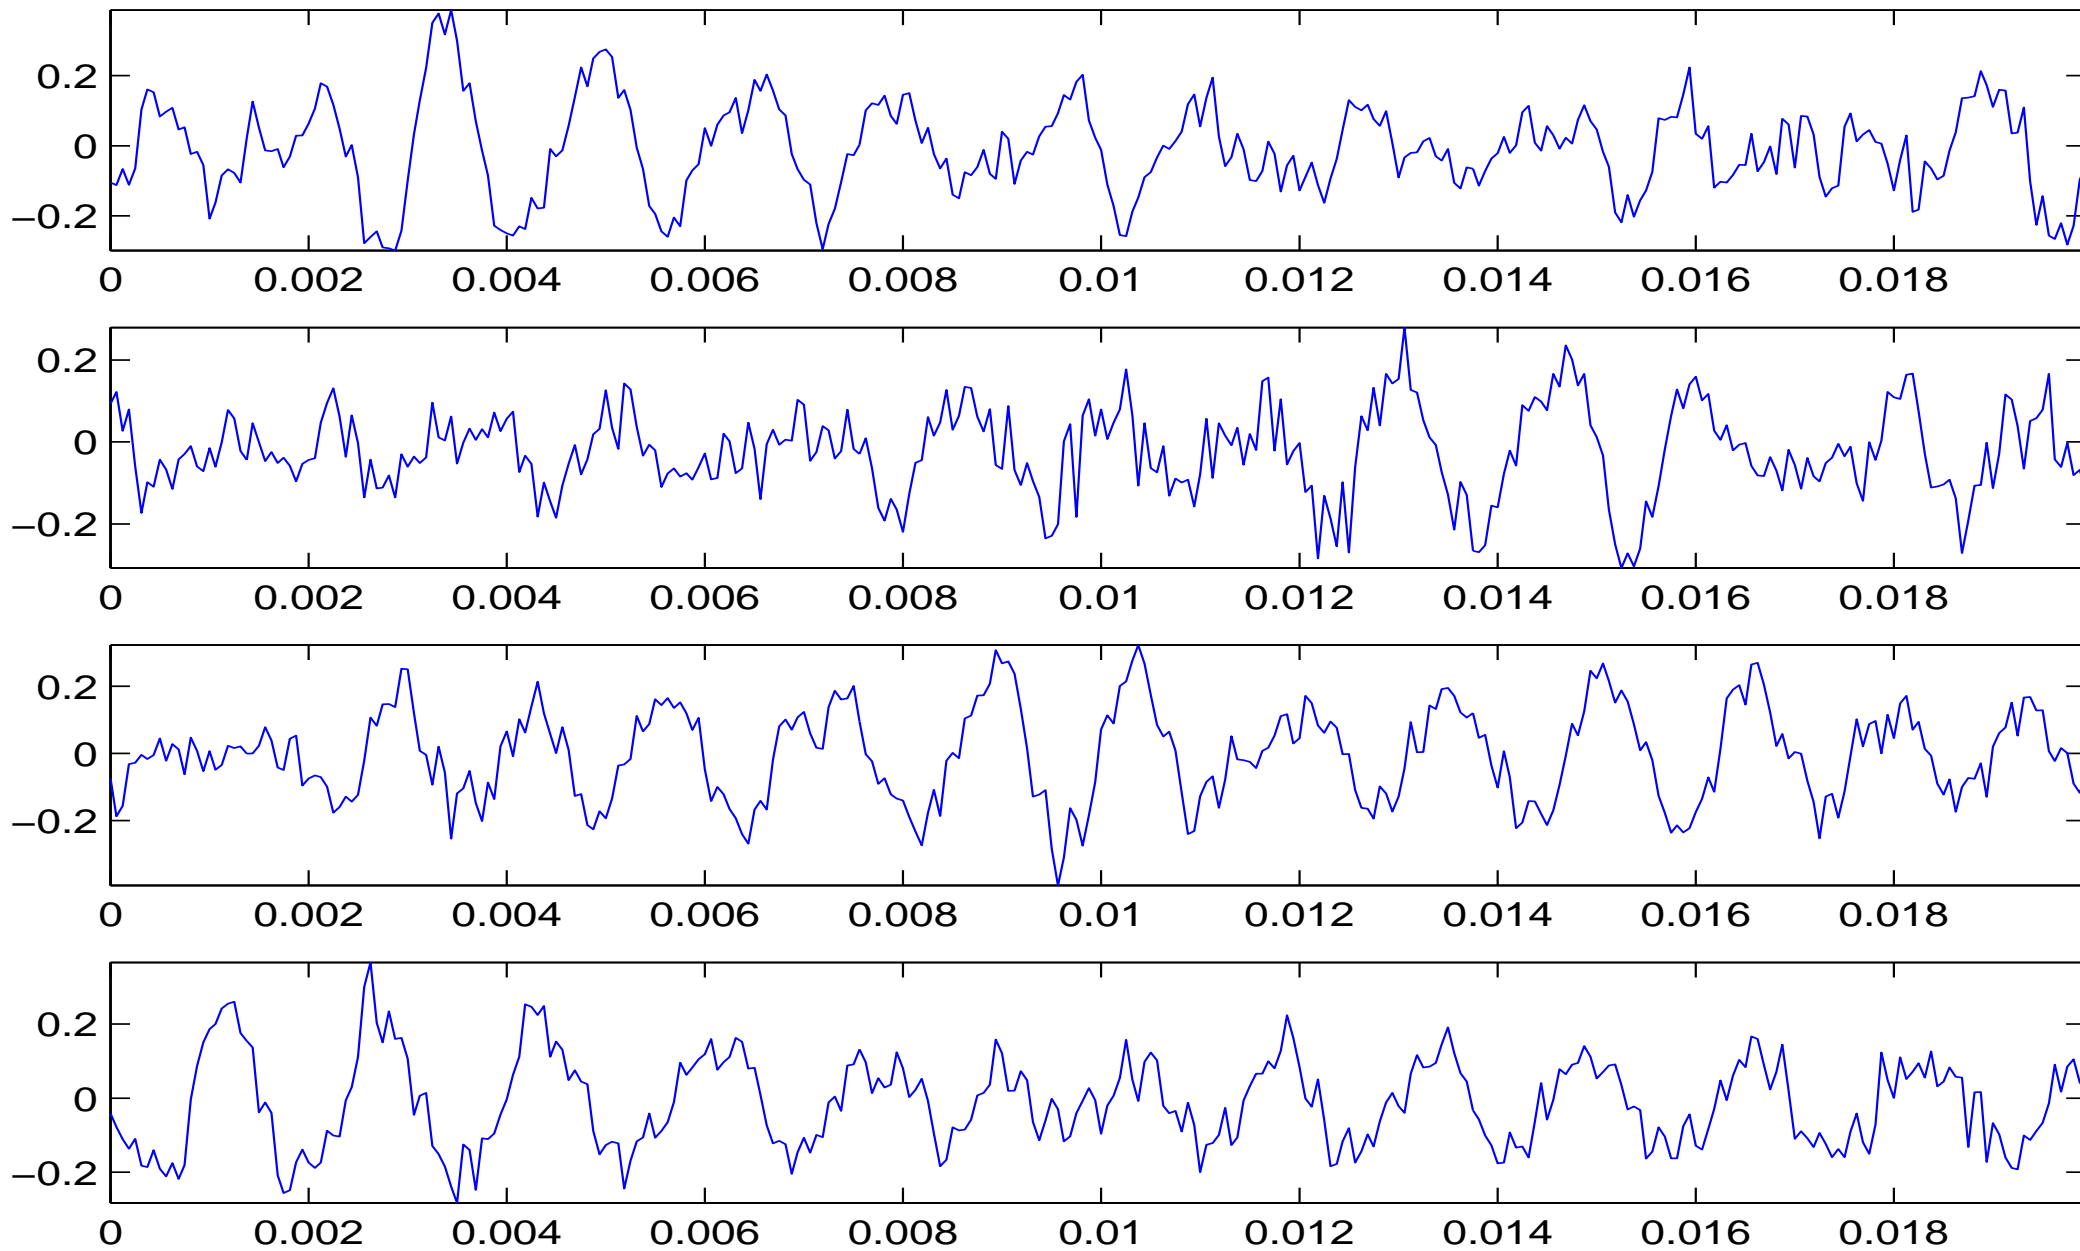
- spojité čas: systém  $\{\xi_t\}$  náhodných veličin definovaných pro všechna  $t \in \mathbb{R}$  se nazývá náhodný proces, označujeme  $\xi(t)$ .
- diskrétní čas: systém  $\{\xi_n\}$  náhodných veličin definovaných pro všechna  $n \in \mathbb{N}$  se nazývá náhodný proces, označujeme  $\xi[n]$ .

## Množina realizací náhodného procesu





možnou reprezentací náhodného procesu je nekonečně mnoho jeho různých průběhů – **realizací**. Omezíme se na konečný počet  $\Omega$  a každou realizaci označíme  $\xi_\omega(t)$ , případně  $\xi_\omega[n]$ . Pokud budeme na souboru realizací náhodného procesu odhadovat nějaké jeho parametry, bude se jednat o **souborové odhady**.

**Příklad:** náhodný proces je zvukový signál vody tekoucí vodovodní trubkou doma u Černockých. Bylo nahráno 1068 realizací po 20 ms. Pro výklad spojitych náhodných procesů si je budeme představovat jako spojitě signály  $\xi_\omega(t)$ , pro výklad diskrétních náhodných procesů jako  $\xi_\omega[n]$ .

$\xi_\omega(t)$  pro  $\omega = 1, 200, 500, 1000$



$\xi_\omega[n]$  pro  $\omega = 1, 200, 500, 1000$



## Distribuční funkce

je definována pro jednu náhodnou veličinu: náhodný proces pro určitý čas  $t$  nebo  $n$  je takovou náhodnou veličinou. Definice:

$$F(x, t) = \mathcal{P}\{\xi(t) < x\},$$


$$F(x, n) = \mathcal{P}\{\xi[n] < x\},$$


kde  $\mathcal{P}\{\xi(t) < x\}$  nebo  $\mathcal{P}\{\xi[n] < x\}$  je pravděpodobnost toho, že náhodná proměnná zde nabude hodnoty menší než  $x$ . Uvědomme si prosím, že  $x$  není nic náhodného, je to pomocná proměnná, kterou nasadíme na nějakou hodnotu a pro tuto hodnotu sledujeme pravděpodobnost.

**Souborový odhad distribuční funkce:** posadíme se do určitého času  $t$  nebo  $n$ , vezmeme  $\Omega$  realizací, které máme k dispozici a pro  $x$  odhadujeme:

$$\hat{F}(x, t) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}(t) < x, \quad 0 \text{ jinak}}{\Omega}$$

$$\hat{F}(x, n) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}[n] < x, \quad 0 \text{ jinak}}{\Omega}$$







## Funkce hustoty rozdělení pravděpodobnosti

je opět definována pro jednu náhodnou veličinu (náhodný proces pro určitý čas  $t$  nebo  $n$  je takovou náhodnou veličinou). Definice:

$$p(x, t) = \frac{\delta F(x, t)}{\delta x}$$

$$p(x, n) = \frac{\delta F(x, n)}{\delta x}$$

**Souborový odhad funkce hustoty rozdělení pravděpodobnosti:** Funkci můžeme získat numerickým derivováním z odhadnuté  $\hat{F}(x, t)$  nebo  $\hat{F}(x, n)$  nebo ji odhadnout pomocí **histogramu**:


- posadíme se do určitého  $t$  nebo  $n$
- Musíme si zvolit  $L$  hodnot  $x$  od  $x_{min}$  do  $x_{max}$ , nejlépe s pravidelným krokem

$$\Delta = \frac{x_{max} - x_{min}}{L - 1}:$$

$$x_1 = x_{min}, \quad x_2 = x_{min} + \Delta, \quad x_3 = x_{min} + 2\Delta \quad \dots$$

$$\dots \quad x_{L-1} = x_{min} + (L - 2)\Delta, \quad x_L = x_{min} + (L - 1)\Delta = x_{max}$$





dostaneme tak  $L$  "chlívků" o šířce  $\Delta$ , pro  $x_i$  je daný chlívěk  $ch_i$  od  $x_i - \frac{\Delta}{2}$  do  $x_i + \frac{\Delta}{2}$ . Levý okraj spodního chlívku (1) natáhneme až do  $-\infty$ , pravý okraj horního ( $L$ ) do  $+\infty$ .







- odhad pro  $x_i$  počítáme jako

$$\hat{p}(x_i, t) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}(t) \in ch_i, \quad 0 \text{ jinak}}{\Omega \Delta}$$

$$\hat{p}(x_i, n) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}[n] \in ch_i, \quad 0 \text{ jinak}}{\Omega \Delta}$$





## $F(x, t)$ , $p(x, t)$ a pravděpodobnosti

pokud máme za úkol vypočítat pravděpodobnost toho, že se hodnota procesu v čase  $t$  nebo  $n$  vyskytne v intervalu  $[a, b]$ , máme tyto možnosti (budeme ukazovat jen na spojitém čase, vzorečky pro diskrétní jsou naprosto stejné):



- vypočítat tuto pravděpodobnost z distribuční funkce, pokud si uvědomíme její definici:

$$F(x, t) = \mathcal{P}\{\xi(t) < x\}, \text{ pak}$$

$$\mathcal{P}\{a < \xi(t) < b\} = F(b, t) - F(a, t)$$

- vypočítat ji z funkce hustoty rozdělení pravděpodobnosti. Už jsme si zvykli, že pokud je někde hustota, bude se integrovat:

$$\mathcal{P}\{a < \xi(t) < b\} = \int_a^b p(x, t) dx$$



Z těchto vzorečků vyplývají důležité vlastnosti distribuční funkce a funkce hustoty rozdělení pravděpodobnosti:

- hodnoty náhodného procesu budou těžko menší než  $-\infty$ , proto  $F(-\infty, t) = \mathcal{P}\{\xi(t) < -\infty\} = 0$ .
- hodnoty náhodného procesu zřejmě všechny menší než  $\infty$ , proto  $F(+\infty, t) = \mathcal{P}\{\xi(t) < +\infty\} = 1$ .
- funkce hustoty rozdělení pravděpodobnosti je dána jako derivace distribuční funkce, naopak platí integrál:

$$F(x, t) = \int_{-\infty}^x p(g, t) dg$$


jelikož  $F(+\infty, t) = 1$ , musí být

$$\int_{-\infty}^{+\infty} p(x, t) dx = 1$$

- hodnota funkce hustoty rozdělení pravděpodobnosti pro určité  $x$  **není pravděpodobnost !!!** (častý chyták statistiků).

## Ilustrace $F(x, t)$ , $p(x, t)$ – bečka piva...

na kolejích se od  $x = 18.00$  do  $22.00$  pije bečka piva. Definujeme funkci  $p(x)$  jako okamžitou spotřebu piva (picí funkce) a  $F(x)$  jako funkci vypitého piva ( $x$  je v tomto příkladu výjimečně čas):



Chování je podobné funkci hustoty rozdělení pravděpodobnosti a distribuční funkci, pouze za 1 dosad'te "1 bečka":

- $F(x)$  je nulová v čase  $-\infty$  (je nulová dokonce až do  $18.00$ ), protože pivo nebylo.



- $F(x)$  je 1 bečka v čase  $+\infty$  (dokonce už ve 22.00), protože pivo je vypité a víc ho nebude.
- množství vypitého piva v čase  $x$ :  $F(x) = \int_{-\infty}^x p(g)dg$ .
- celkové množství vypitého piva:  $F(+\infty) = \int_{-\infty}^{+\infty} p(x)dx = 1$  bečka.
- množství vypitého piva od času  $x_1$  do času  $x_2$  je možné spočítat jako rozdíl dvou bodů  $F(x)$  nebo integrací  $p(x)$ .
- hodnotě  $p(x)$  (např.  $p(19.00)$ ) nemůžeme říkat množství piva – za nekonečně krátký časový interval ho do nikoho nevtekla ani kapka.

## Momenty

na rozdíl od funkcí jsou momenty **čísla**, která charakterizují náhodný proces v daném čase  $t$  nebo  $n$ :

**střední hodnota** nebo též “Expectation” (očekávání), první moment:

$$a(t) = E\{\xi(t)\} = \int_{-\infty}^{+\infty} xp(x, t)dx$$



$$a[n] = E\{\xi[n]\} = \int_{-\infty}^{+\infty} xp(x, n)dx$$

**souborový odhad střední hodnoty** je pro každý čas  $t$  nebo  $n$  dán jako průměr vzorků přes všechny realizace:

$$\hat{a}(t) = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}(t)$$

$$\hat{a}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}[n]$$

Pro naše signály:



## rozptyl (disperze), směrodatná odchylka

$$D(t) = E\{[\xi(t) - a(t)]^2\} = \int_{-\infty}^{+\infty} [x - a(t)]^2 p(x, t) dx$$

$$D[n] = E\{[\xi[n] - a[n]]^2\} = \int_{-\infty}^{+\infty} [x - a[n]]^2 p(x, n) dx$$

směrodatná odchylka (std - standard deviation) je odmocninou rozptylu:



$$\sigma(t) = \sqrt{D(t)} \quad \sigma[n] = \sqrt{D[n]}$$

**souborový odhad rozptylu a směrodatné odchylky** je pro každý čas  $t$  nebo  $n$  dán:

$$\hat{D}(t) = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} [\xi_{\omega}(t) - \hat{a}(t)]^2, \quad \hat{\sigma}(t) = \sqrt{\hat{D}(t)}$$

$$\hat{D}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} [\xi_{\omega}[n] - \hat{a}[n]]^2, \quad \hat{\sigma}[n] = \sqrt{\hat{D}[n]}$$

Pro naše signály:



## Korelační funkce

Udává podobnost mezi hodnotami náhodného procesu v časech  $t_1$  (nebo  $n_1$ ) a  $t_2$  (nebo  $n_2$ ):

$$R(t_1, t_2) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1 x_2 p(x_1, x_2, t_1, t_2) dx_1 dx_2,$$

$$R(n_1, n_2) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1 x_2 p(x_1, x_2, n_1, n_2) dx_1 dx_2,$$

kde  $p(x_1, x_2, t_1, t_2)$ , resp.  $p(x_1, x_2, n_1, n_2)$  je dvourozměrná funkce hustoty rozdělení pravděpodobnosti mezi časy  $t_1$  a  $t_2$ , resp.  $n_1$  a  $n_2$ . Teoreticky ji vypočítáme z dvourozměrné distribuční funkce:

$$F(x_1, x_2, t_1, t_2) = \mathcal{P}\{\xi(t_1) < x_1 \text{ a } \xi(t_2) < x_2\},$$

$$F(x_1, x_2, n_1, n_2) = \mathcal{P}\{\xi[n_1] < x_1 \text{ a } \xi[n_2] < x_2\}$$


pomocí derivace podle  $x_1$  a  $x_2$ :

$$p(x_1, x_2, t_1, t_2) = \frac{\delta^2 F(x_1, x_2, t_1, t_2)}{\delta x_1 \delta x_2}$$

$$p(x_1, x_2, n_1, n_2) = \frac{\delta^2 F(x_1, x_2, n_1, n_2)}{\delta x_1 \delta x_2}$$

Nás bude ale spíše zajímat souborový odhad, který zařídíme pomocí dvourozměrného histogramu:

- podobně jako u standardního histogramu vytvoříme “chlívky”, tentokrát ale budou dvourozměrné (čtverečky):  $ch_{ij}$  je pro první rozměr od  $x_i - \frac{\Delta}{2}$  do  $x_i + \frac{\Delta}{2}$  a pro druhý rozměr od  $x_j - \frac{\Delta}{2}$  do  $x_j + \frac{\Delta}{2}$ .






- hodnota 2D histogramu pro chlívěk  $ch_{ij}$  určený hodnotami  $x_i$  a  $x_j$  bude:

$$\hat{p}(x_i, x_j, t_1, t_2) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}(t_1), \xi_{\omega}(t_2) \in ch_{ij}, \quad 0 \text{ jinak}}{\Omega \Delta^2}$$

$$\hat{p}(x_i, x_j, n_1, n_2) = \frac{\sum_{\omega=1}^{\Omega} 1 \text{ pokud } \xi_{\omega}[n_1], \xi_{\omega}[n_2] \in ch_{ij}, \quad 0 \text{ jinak}}{\Omega \Delta^2}$$

Pro naše signály (uvádíme jen diskrétní časy, stejně jste už přišli na to, že ty se spojitým časem jsou úplně stejné...):  $n_1 = 0, n_2 = 0, 1, 5, 11$ .





Pro  $n_1 = 0$ ,  $n_2 = 0, 1, 5, 11$  nám po numerické integraci vyšly následující autokorelační koeficienty

- $R(0, 0) = 0.0188$ : ve stejném bodě je sám sobě proces vždy nejvíce podobný. . .
- $R(0, 1) = 0.0151$ : posuneme-li se do vedlejšího vzorku, je stále ještě dost podobný času  $n_1 = 0$ .
- $R(0, 5) = 0.0030$ : časy  $n_1 = 0$  a  $n_2 = 5$  si nejsou vůbec podobné.
- $R(0, 11) = -0.0133$ : v časech  $n_1 = 0$  a  $n_2 = 11$  si je proces podobný, ale s opačným znaménkem ! Je pravděpodobné, že když bude hodnota  $\xi[n_1]$  kladná, bude  $\xi[n_2]$  záporná, a naopak.

# Korelační funkce

pro  $n_1 = 0, n_2 = n_1 + k$  pro  $k = 0 \dots 40$ , srovnání s  $n_1 = 100, n_2 = n_1 + k$  pro  $k = 0 \dots 40$ :



## STACIONARITA NÁHODNÉHO PROCESU

lidově řečeno, chování stacionárního náhodného procesu se nemění v čase. Statistické veličiny nejsou závislé na aktuálním  $t$  nebo  $n$ . Korelační funkce není závislá na přesné poloze  $t_1, t_2$  nebo  $n_1, n_2$ , ale pouze na jejich rozdílu:  $\tau = t_2 - t_1$ ,  $k = n_2 - n_1$ . Pro stacionární systémy se spojitým časem:

$$F(x, t) \rightarrow F(x) \quad p(x, t) \rightarrow p(x)$$

$$a(t) \rightarrow a \quad D(t) \rightarrow D \quad \sigma(t) \rightarrow \sigma$$

$$p(x_1, x_2, t_1, t_2) \rightarrow p(x_1, x_2, \tau) \quad R(t_1, t_2) \rightarrow R(\tau)$$

Podobně pro diskrétní čas:

$$F(x, n) \rightarrow F(x) \quad p(x, n) \rightarrow p(x)$$


$$a[n] \rightarrow a \quad D[n] \rightarrow D \quad \sigma[n] \rightarrow \sigma$$

$$p(x_1, x_2, n_1, n_2) \rightarrow p(x_1, x_2, k) \quad R(n_1, n_2) \rightarrow R(k)$$

V příkladu s tekoucí vodou jsme zřejmě měli stacionární signál, protože:

- střední hodnota byla pro všechny časy podobná (pokud bychom měli k dispozici více realizací, byla by ještě “stejnější”).
- směrodatná odchylka také (dtto).
- korelační funkce pro  $n_1 = 0, n_2 = n_1 + k$  a pro  $n_1 = 100, n_2 = n_1 + k$  vypadala podobně.

Stacionární vs. nestacionární signál:





## ERGODICITA NÁHODNÉHO PROCESU

nutnost mít k dispozici mnoho realizací k jakémukoliv odhadu je trochu svazující. U ergodických náhodných procesů můžeme parametry odhadnout z jediné realizace.



Příklad stacionárního a ergodického a stacionárního, ale neergodického procesu:



Všechny **souborové odhady** můžeme nahradit **časovými odhady**, máme k dispozici interval o délce  $T$  (pro spojité procesy) případně o počtu vzorků  $N$  (pro diskrétní). Jedinou realizaci, kterou máme k dispozici, nazveme klasicky  $x(t)$ , resp.  $x[n]$ :

- pomocí histogramů můžeme stejným způsobem jako u souborových odhadů odhadnout distribuční funkci a funkci hustoty rozdělení pravděpodobnosti.
- střední hodnota, rozptyl, směrodatná odchylka:

$$\hat{a} = \frac{1}{T} \int_0^T x(t) dt \quad \hat{D} = \frac{1}{T} \int_0^T [x(t) - \hat{a}]^2 dt \quad \hat{\sigma} = \sqrt{\hat{D}}$$

$$\hat{a} = \frac{1}{N} \sum_{n=0}^{N-1} x[n] \quad \hat{D} = \frac{1}{N} \sum_{n=0}^{N-1} [x[n] - \hat{a}]^2 \quad \hat{\sigma} = \sqrt{\hat{D}}$$

- korelační funkce

$$\hat{R}(\tau) = \frac{1}{T} \int_0^T x(t)x(t + \tau) dt$$

$$\hat{R}(k) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[n + k]$$