

Náhodné signály II.

Jan Černocký

ÚPGM FIT VUT Brno, cernocky@fit.vutbr.cz

Časový odhad autokorelačních koeficientů

pro ergodický náhodný proces s diskrétním časem.

-

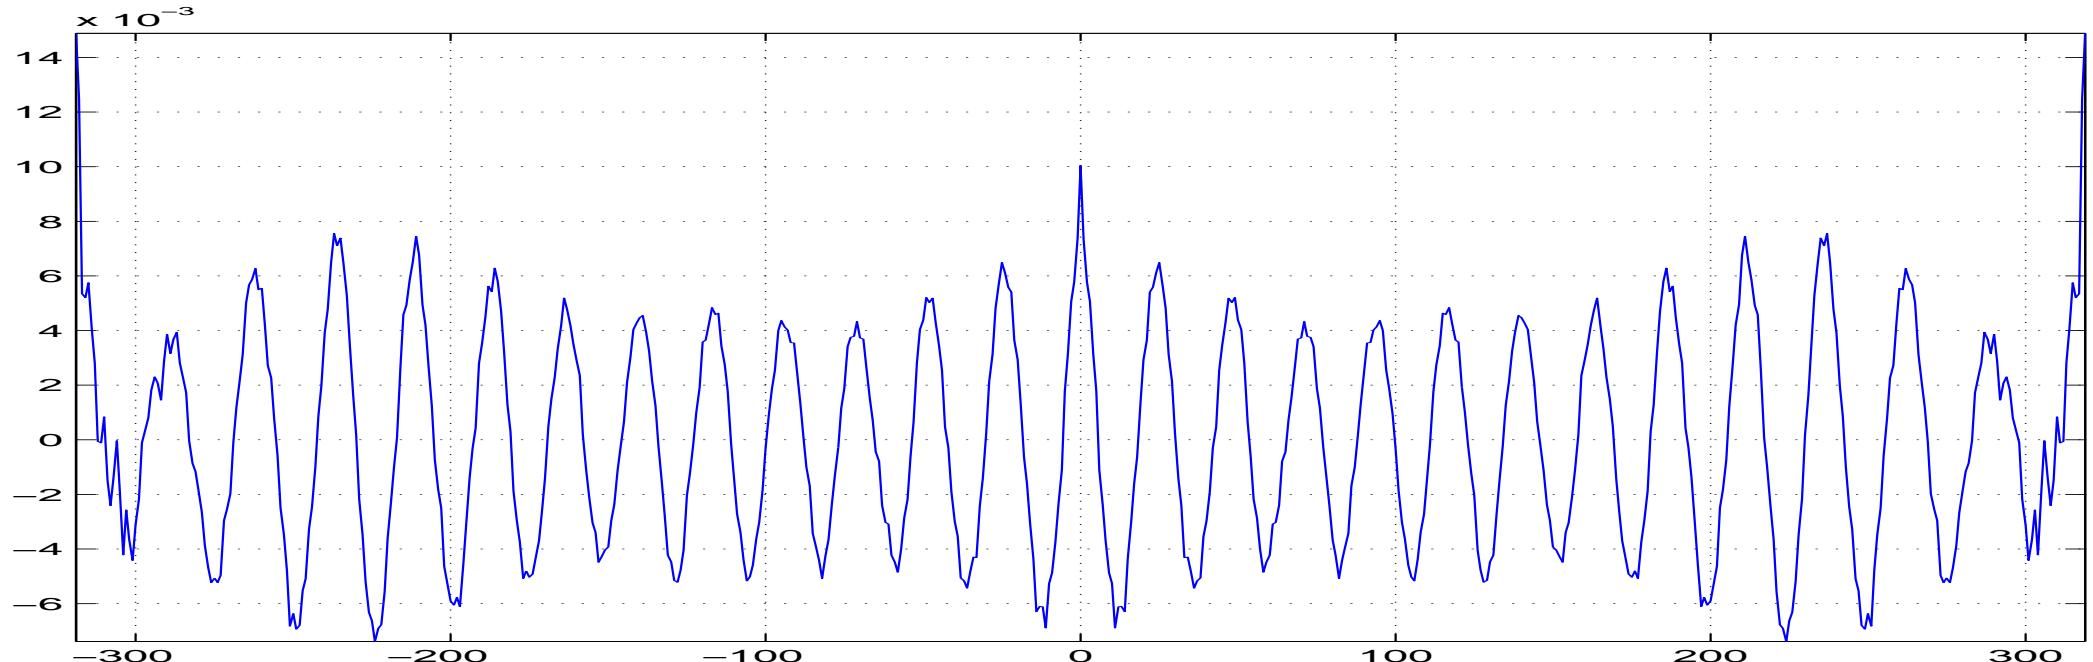
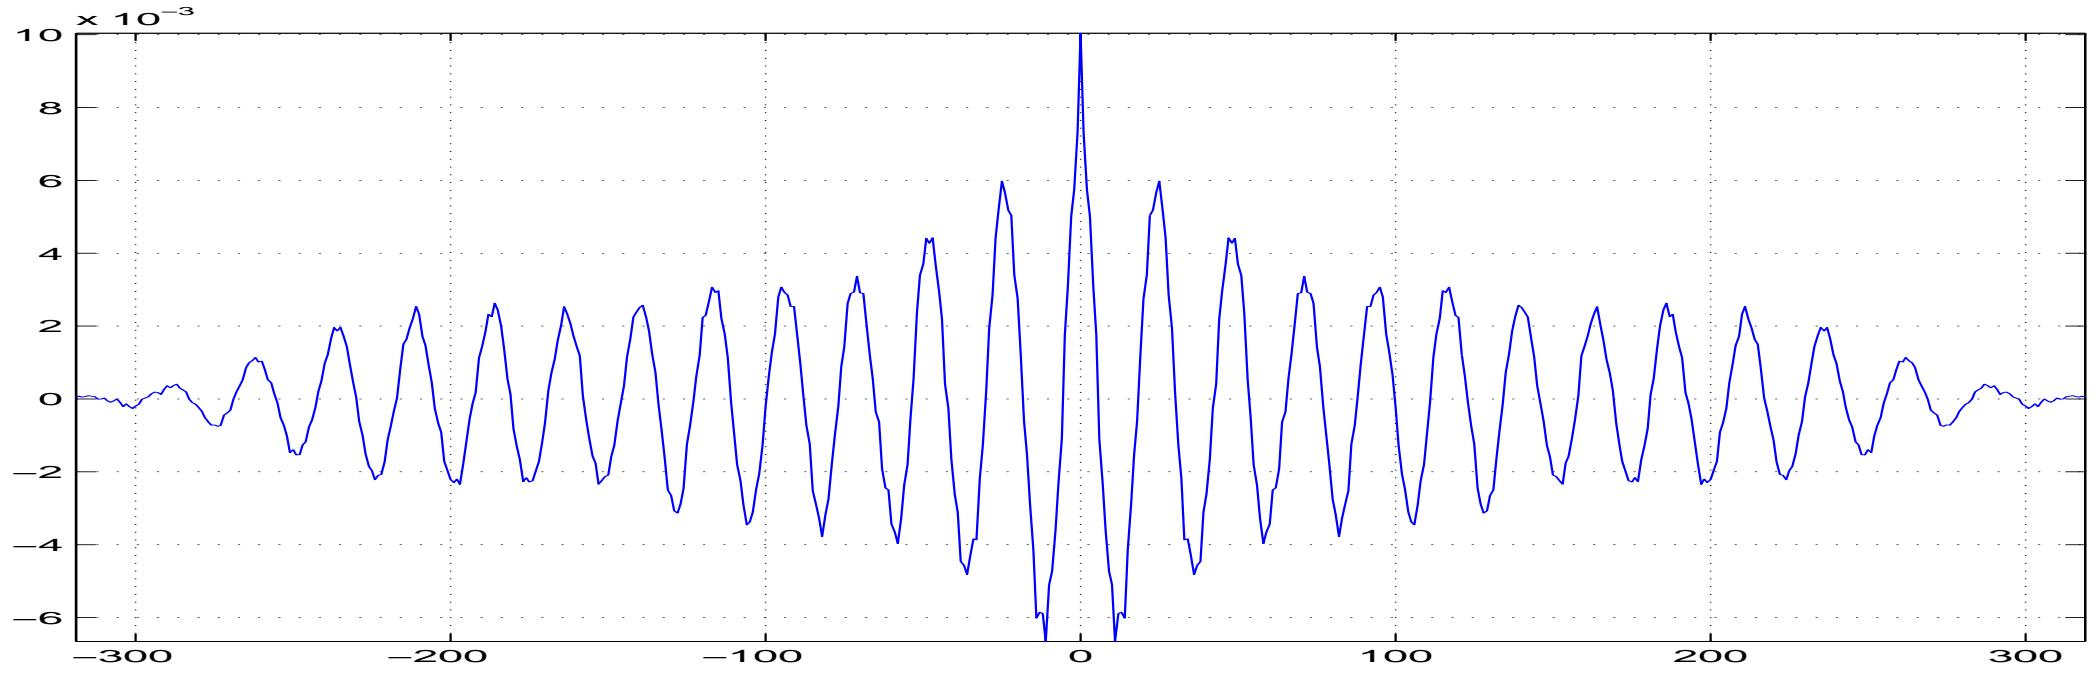
$$\hat{R}[k] = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x[n+k],$$

kde N je počet vzorků, které máme k disposici, se nazývá **vychýlený odhad** (biased estimation). Když totiž odsouváme signály od sebe, odhadujeme $R(k)$ pouze z $N - k$ vzorků. Dělíme však stále N , takže se hodnoty ke krajům budou snižovat.

-

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

je **nevychýlený odhad**, kdy se dělí skutečně použitým počtem vzorků. Krajiní koeficienty $k \rightarrow N - 1, k \rightarrow -N + 1$ jsou ale zatíženy značnou chybou (protože se k jejich odhadu používá málo vzorků!), proto dáváme přednost vychýlenému odhadu.



Spektrální hustota výkonu – spojítý čas

I u náhodných procesů nás bude zajímat chování ve frekvenční oblasti, ale:

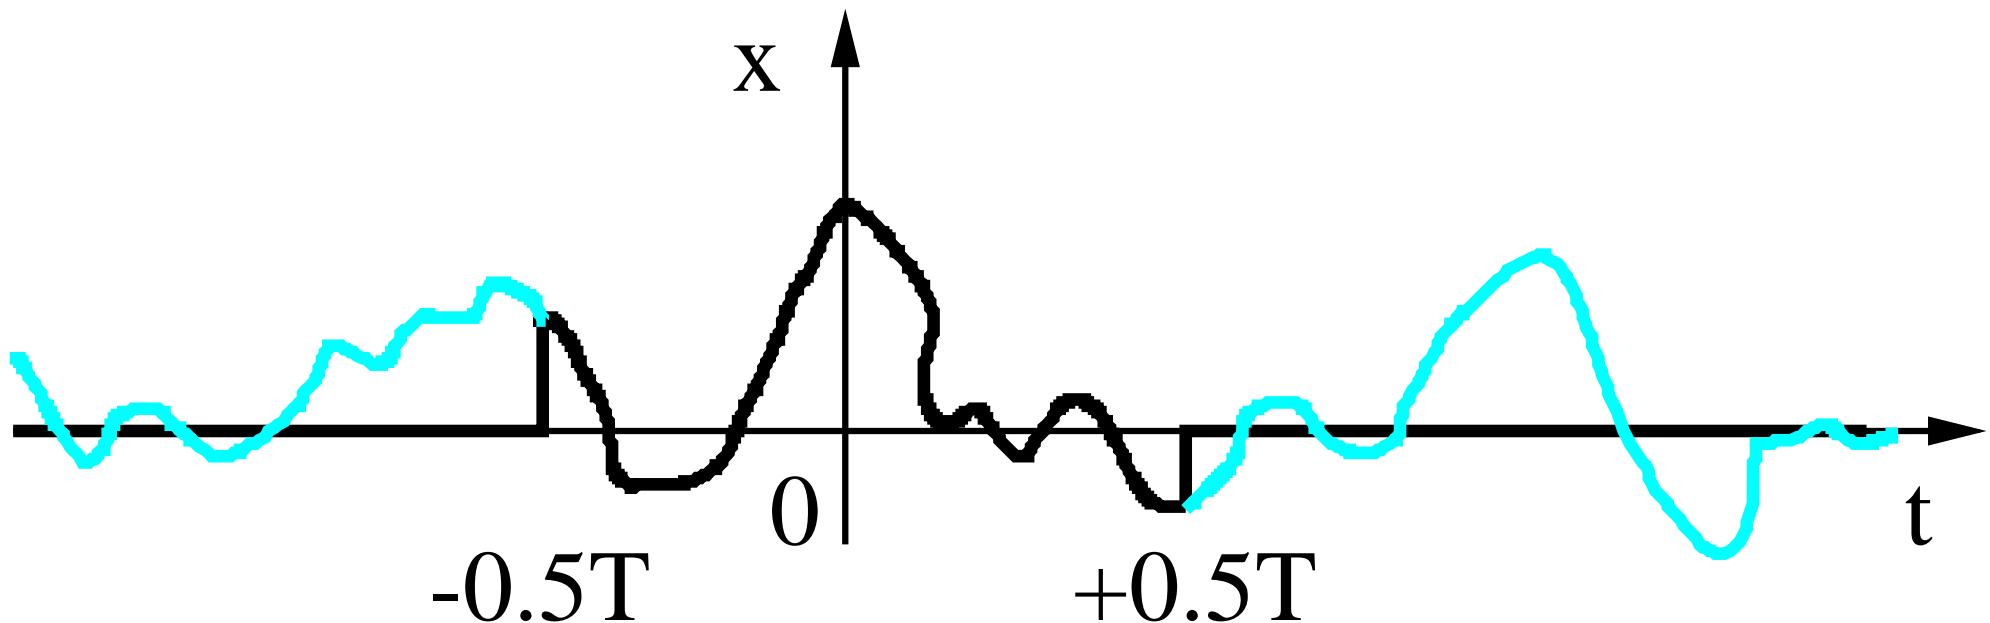
- nemůžeme použít FŘ, protože náhodné signály nejsou periodické.
- nemůžeme použít ani FT, protože náhodné signály mají nekonečnou energii (FT na tyto signály šla aplikovat, ale pouze ve speciálních případech)

Budeme uvažovat pouze ergodické náhodné signály, realizaci $x(t)$.

Odvození spektrální hustoty výkonu (power spectral density – PSD)

- definujeme interval o délce T , vezmeme pouze úsek od $-T/2$ do $T/2$:

$$x_T(t) = \begin{cases} x(t) & \text{pro } |t| < T/2 \\ 0 & \text{jinde} \end{cases}$$



- definujeme Fourierův obraz:

$$X_T(j\omega) = \int_{-\infty}^{+\infty} x_T(t) e^{-j\omega t} dt$$

- definujeme spektrální hustotu energie (viz přednáška o FT):

$$\int_{-\infty}^{\infty} x_T^2(t) dt = \dots = \frac{1}{2\pi} \int_{-\infty}^{\infty} X_T(j\omega) X_T(-j\omega) d\omega = \int_{-\infty}^{\infty} L_T(j\omega) d\omega$$

$L_T(\omega)$ nazýváme **(dvoustranná) spektrální hustota energie**

$$L_T(j\omega) = \frac{|X(j\omega)|^2}{2\pi}$$

- pokusíme se “natáhnout” T až do ∞ . V tomto případě by ale energie (i její hustota) rostly nad všechny meze. Definujeme tedy **(dvoustrannou) spektrální hustota výkonu** dělením T (analogie $P = E/T$):

$$G_T(j\omega) = \frac{L_T(j\omega)}{T}$$

- nyní už můžeme “natažení” provést a spočítat spektrální hustotu výkonu nejen pro úsek délky T , ale pro celý signál:

$$G(j\omega) = \lim_{T \rightarrow \infty} G_T(j\omega) = \lim_{T \rightarrow \infty} \frac{|X_T(j\omega)|^2}{2\pi T}$$

Vlastnosti $G(j\omega)$

- Pro spektrální funkci reálného signálu $X_T(j\omega)$ platí:

$$X_T(j\omega) = X_T^*(-j\omega)$$

$G(j\omega)$ je prakticky dána jejími hodnotami na druhou, bude tedy **čistě reálná a sudá**.

- Výkon náhodného procesu v intervalu $[\omega_1, \omega_2]$ můžeme spočítat jako:

$$P_{[\omega_1, \omega_2]} = \int_{\omega_1}^{\omega_2} G(j\omega) d\omega + \int_{-\omega_2}^{-\omega_1} G(j\omega) d\omega = 2 \int_{\omega_1}^{\omega_2} G(j\omega) d\omega.$$

- Pro **celkový** střední výkon náhodného signálu platí:

$$P = \int_{-\infty}^{+\infty} G(\omega) d\omega$$

- Často je ve sdělovací technice $a = 0$. Pak je střední výkon roven rozptylu: $P = D$ a efektivní hodnota $X_{ef} = \sigma$.

Wiener-Chinchinovy vztahy

Spektrální hustota výkonu je vázána FT s autokorelační funkcí $R(\tau)$ (někdy se tak dokonce definuje – je to jednodušší než limitní přechod $T \rightarrow \infty$):

$$G(j\omega) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} R(\tau) e^{-j\omega\tau} d\tau$$

$$R(\tau) = \int_{-\infty}^{+\infty} G(j\omega) e^{+j\omega\tau} d\omega$$

Spektrální hustota výkonu – diskrétní čas

PSD náhodného procesu s diskrétním časem budeme definovat přímo pomocí autokorelačních koeficientů (všimněte si terminologie: autokorelační **funkce** $R(\tau)$ pro spojitý čas, autokorelační **koeficienty** $R[k]$ pro diskrétní čas):

$$G(e^{j\omega}) = \sum_{k=-\infty}^{\infty} R[k]e^{-j\omega k}$$

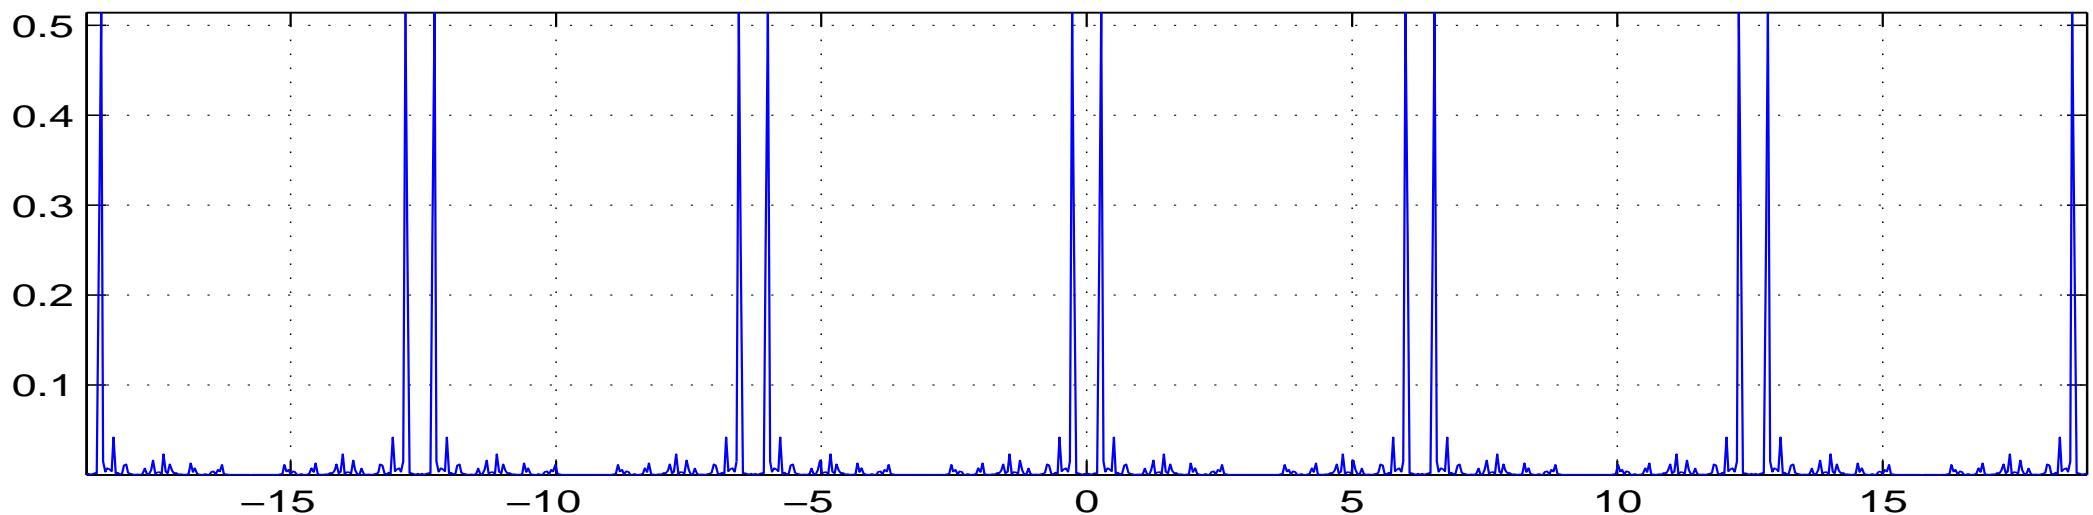
(jaká je zde ω kruhová frekvence ?). $G(e^{j\omega})$ je Fourierovou transformací s diskrétním časem (DTFT) autokorelačních koeficientů. Pokud tyto odhadneme (souborový odhad, časový odhad u ergodických), můžeme $G(e^{j\omega})$ spočítat.

Zpětný přechod od $G(e^{j\omega})$ k autokorelačním koeficientům (zpětná DTFT):

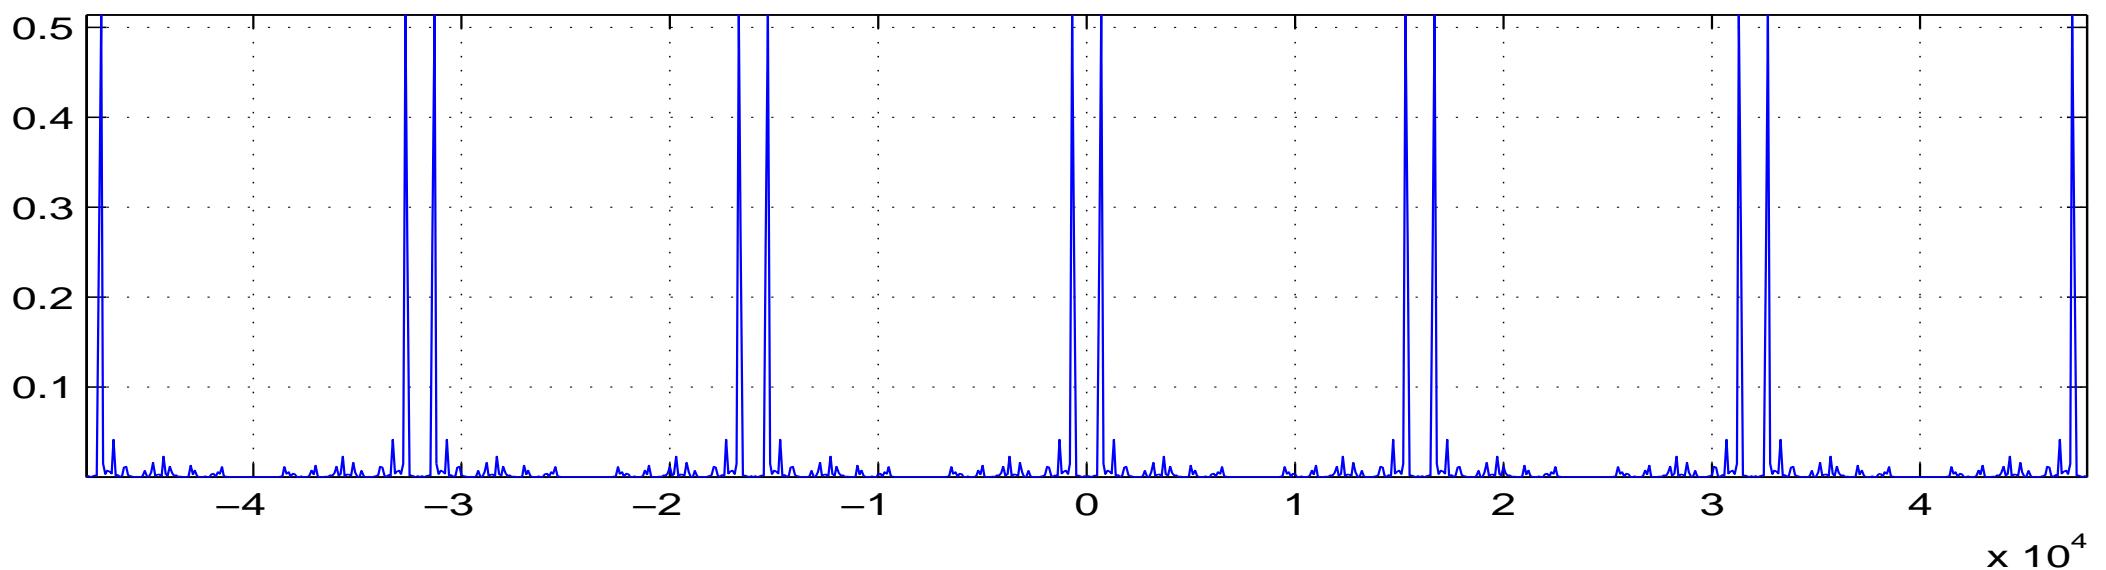
$$R[k] = \frac{1}{2\pi} \int_{-\pi}^{\pi} G(e^{j\omega})e^{+j\omega k} d\omega$$

Pro tekoucí vodu ($R[k]$ odhadovány z jedné realizace):

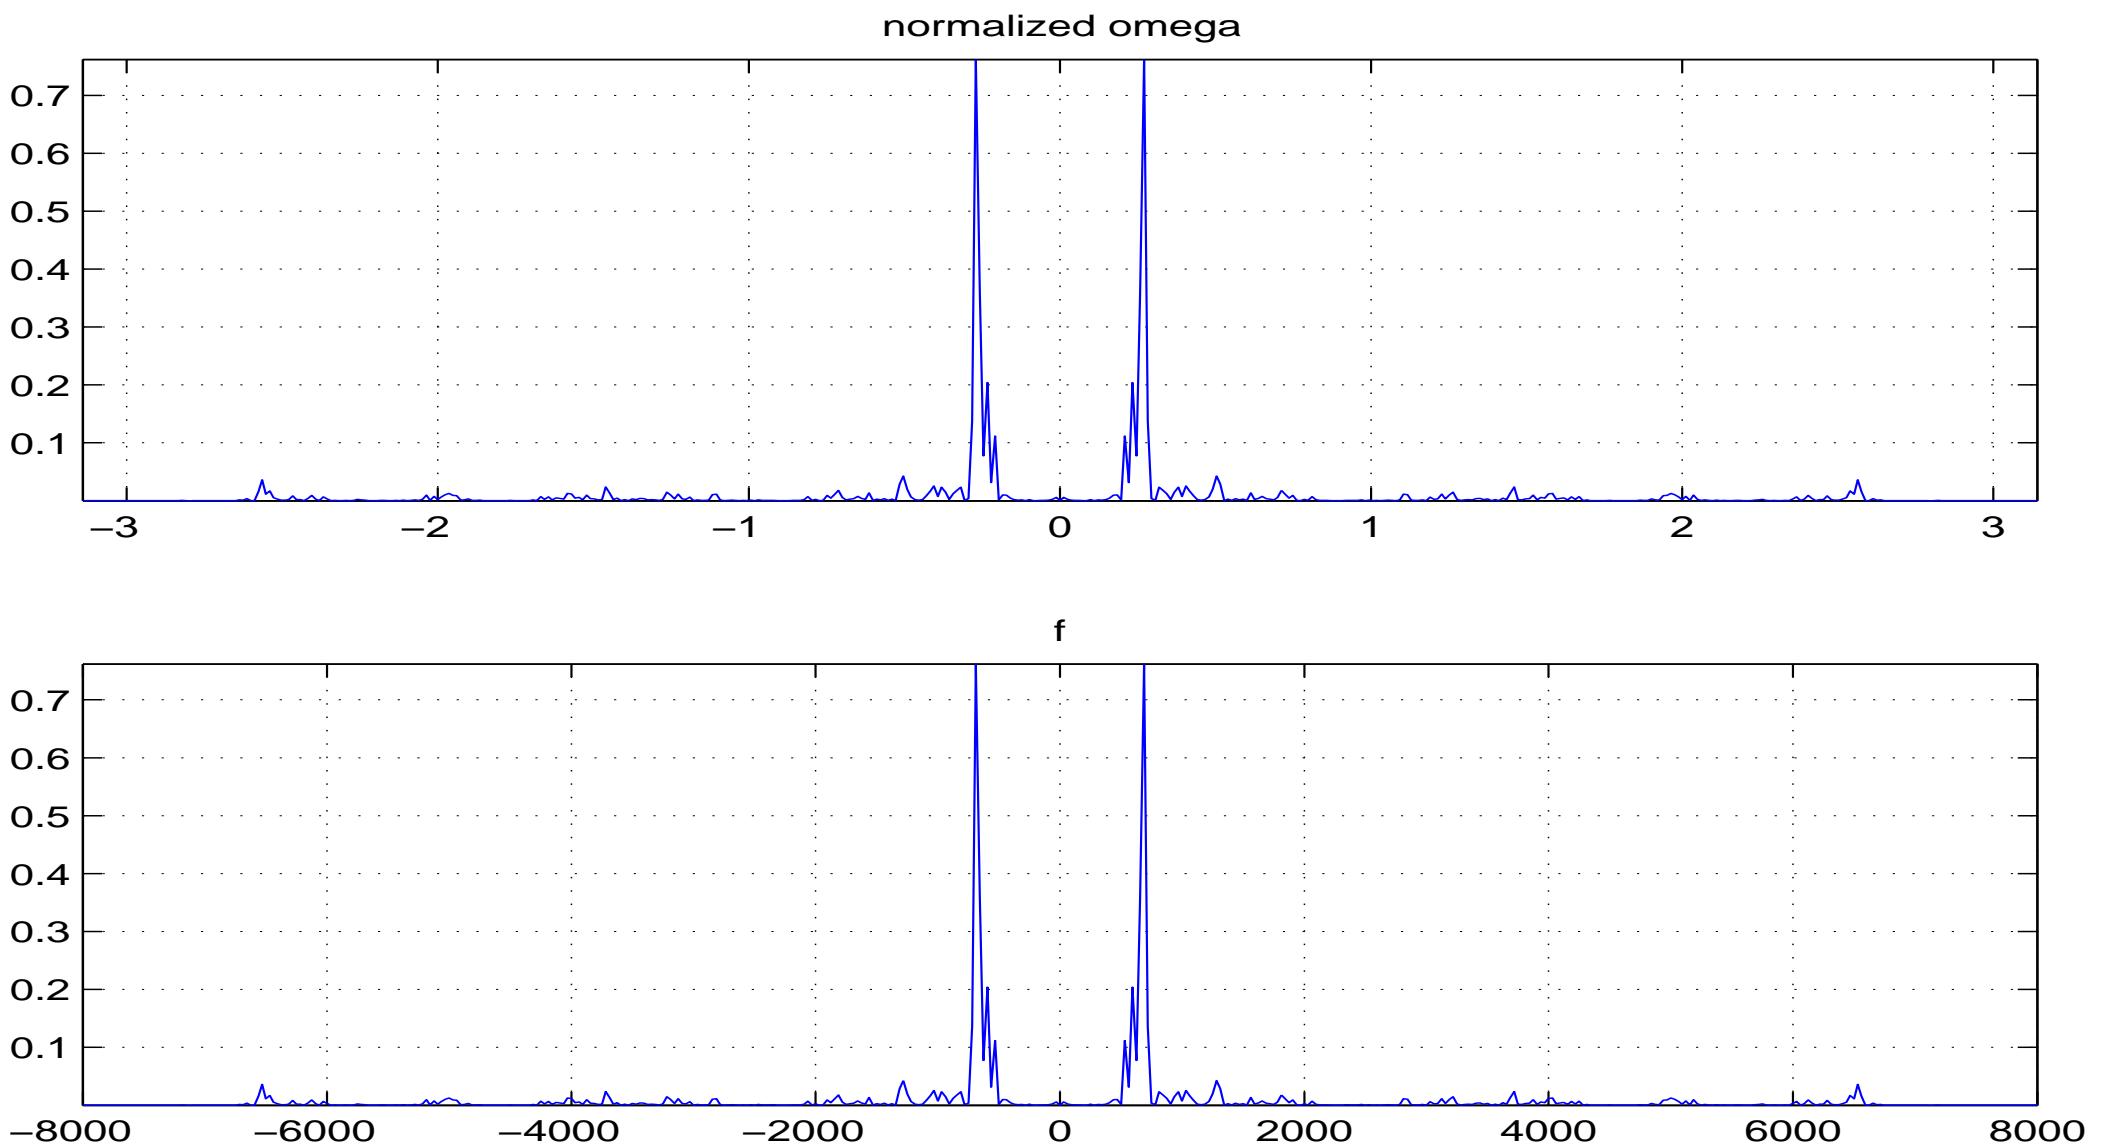
normalized omega



f



zoom od $-Fs/2$ do $Fs/2$:



⇒ tekoucí voda má silnou hodně výkonu okolo 700 Hz, že by rezonance trubky ?

vlastnosti $G(e^{j\omega})$ jsou opět dány standardními vlastnostmi obrazu DTFT:

- autokorelační koeficienty jsou reálné, proto bude pro $G(e^{j\omega})$ platit

$$G(e^{j\omega}) = G^*(e^{-j\omega}),$$

- autokorelační koeficienty jsou symetrické (sudé), proto bude $G(e^{j\omega})$ všude reálná.
- z toho vyplývá, že $G(e^{j\omega})$ bude reálná a sudá, podobně jako $G(j\omega)$.
- je periodická (s periodou 2π , 1 , F_s , $2\pi F_s$ podle frekvence, kterou si vyberete) protože signál je diskrétní.
- Výkon náhodného procesu v intervalu $[\omega_1, \omega_2]$ můžeme spočítat jako:

$$P_{[\omega_1, \omega_2]} = \frac{1}{2\pi} \int_{\omega_1}^{\omega_2} G(e^{j\omega}) d\omega + \frac{1}{2\pi} \int_{-\omega_2}^{-\omega_1} G(e^{j\omega}) d\omega = \frac{1}{\pi} \int_{\omega_1}^{\omega_2} G(e^{j\omega}) d\omega.$$

- Pro **celkový** střední výkon náhodného signálu platí:

$$P = \frac{1}{2\pi} \int_{-\pi}^{+\pi} G(e^{j\omega}) d\omega$$

to je ale hodnota zpětné DTFT pro $k = 0$:

$$R[0] = \frac{1}{2\pi} \int_{-\pi}^{\pi} G(e^{j\omega}) e^{+j\omega 0} d\omega = R[0] = \frac{1}{2\pi} \int_{-\pi}^{+\pi} G(e^{j\omega}) d\omega$$

takže jsme dostali vztah:

$$R[0] = P$$

Odhad spektrální hustoty výkonu $G(e^{j\omega})$ pomocí DFT

Máme-li k disposici realizaci náhodného procesu $x[n]$ o N vzorcích, můžeme PSD odhadnout pomocí Diskrétní Fourierovy transformace (DFT – to je ta, co se jako jediná dá slušně spočítat), pro připomenutí:

$$X[k] = \sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi}{N}kn}$$

$G(e^{j\omega})$ dostaneme pouze pro diskrétní frekvence: $\omega_k = \frac{2\pi}{N}k$:

$$\hat{G}(e^{j\omega_k}) = \frac{1}{N}|X[k]|^2.$$

Tento odhad bývá někdy velice nespolehlivý (zašuměný), proto se často využívá **Welchova metoda** – průměrování odhadu PSD přes několik časových úseků:

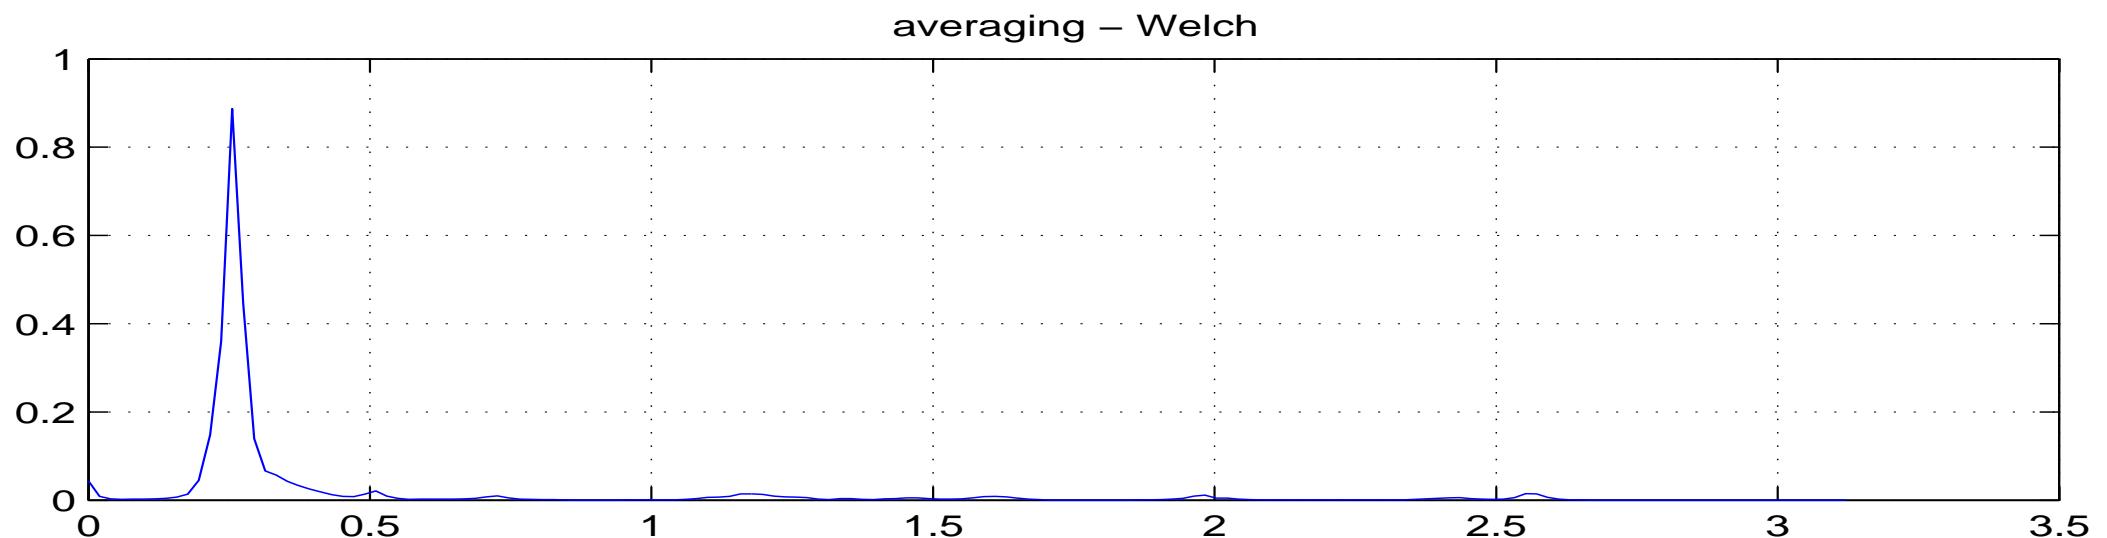
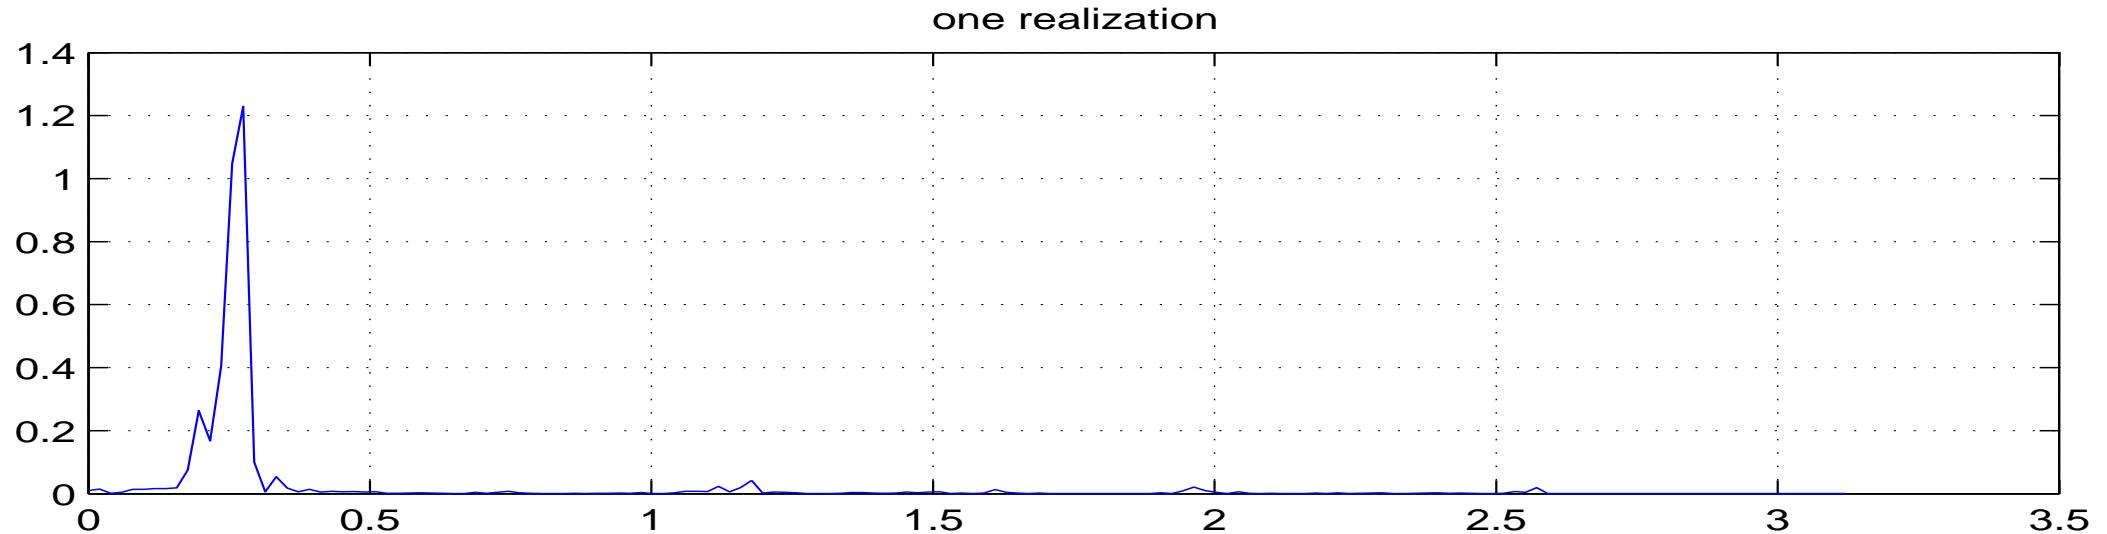
- Signál rozdělíme na M úseků po N prvcích a pro každý spočítáme DFT:

$$X_m[k] = \sum_{n=0}^{N-1} x_m[n]e^{-j\frac{2\pi}{N}kn} \quad \text{pro } 0 \leq m \leq M-1$$

- Odhad PSD spočítáme:

$$\hat{G}_W(e^{j\omega_k}) = \frac{1}{M} \sum_{m=0}^{M-1} \frac{1}{N} |X_m[k]|^2.$$

Ukázka pro odhad PSD z jednoho 320-vzorkového segmentu a z 1068 takových segmentů:



⇒ odhad získaný průměrováním je mnohem hladší.

Průchod náhodných signálů lineárními systémy

- **spojitý čas:** lineární systém má komplexní kmitočtovou charakteristiku $H(j\omega)$. Pro vstupní signál se spektrální hustotou výkonu $G_x(j\omega)$ je výstupní spektrální hustota výkonu dána:

$$G_y(j\omega) = |H(j\omega)|^2 G_x(j\omega)$$

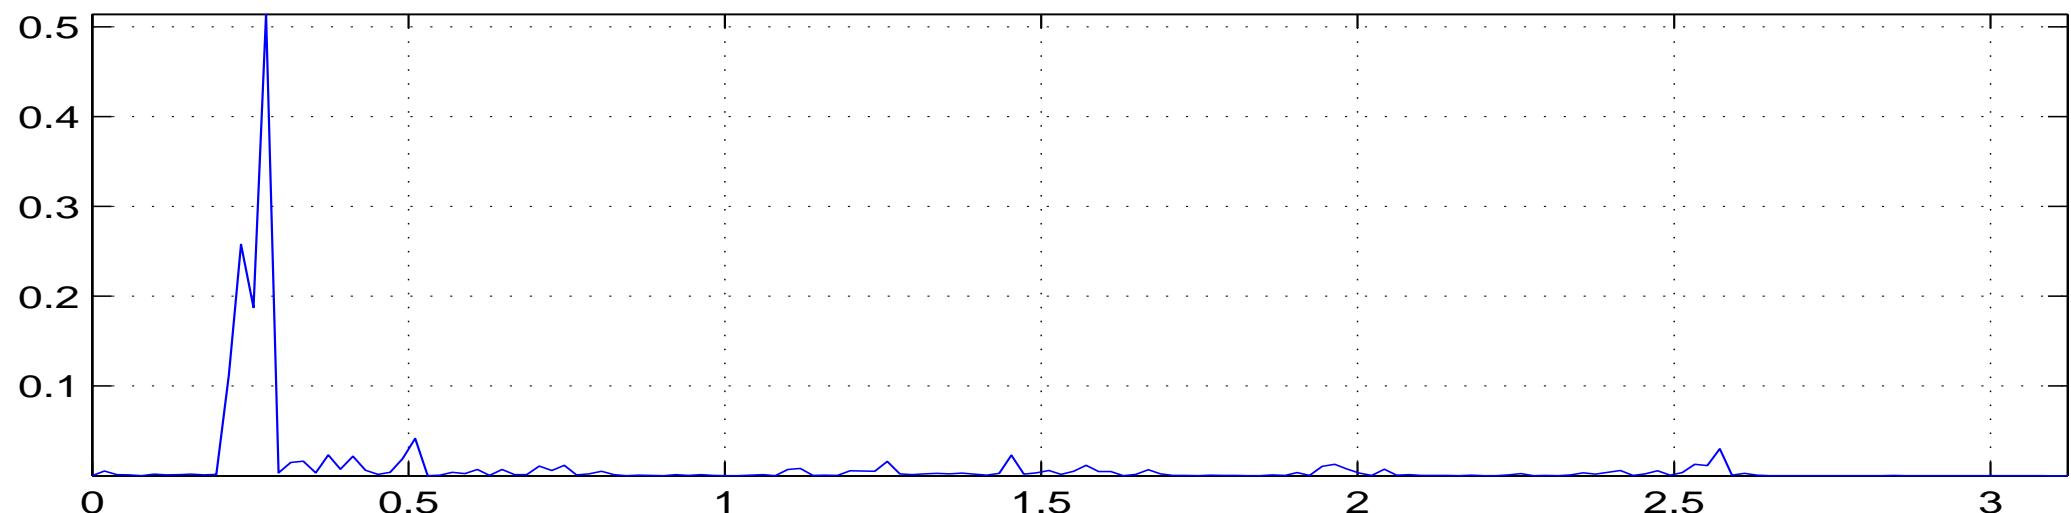
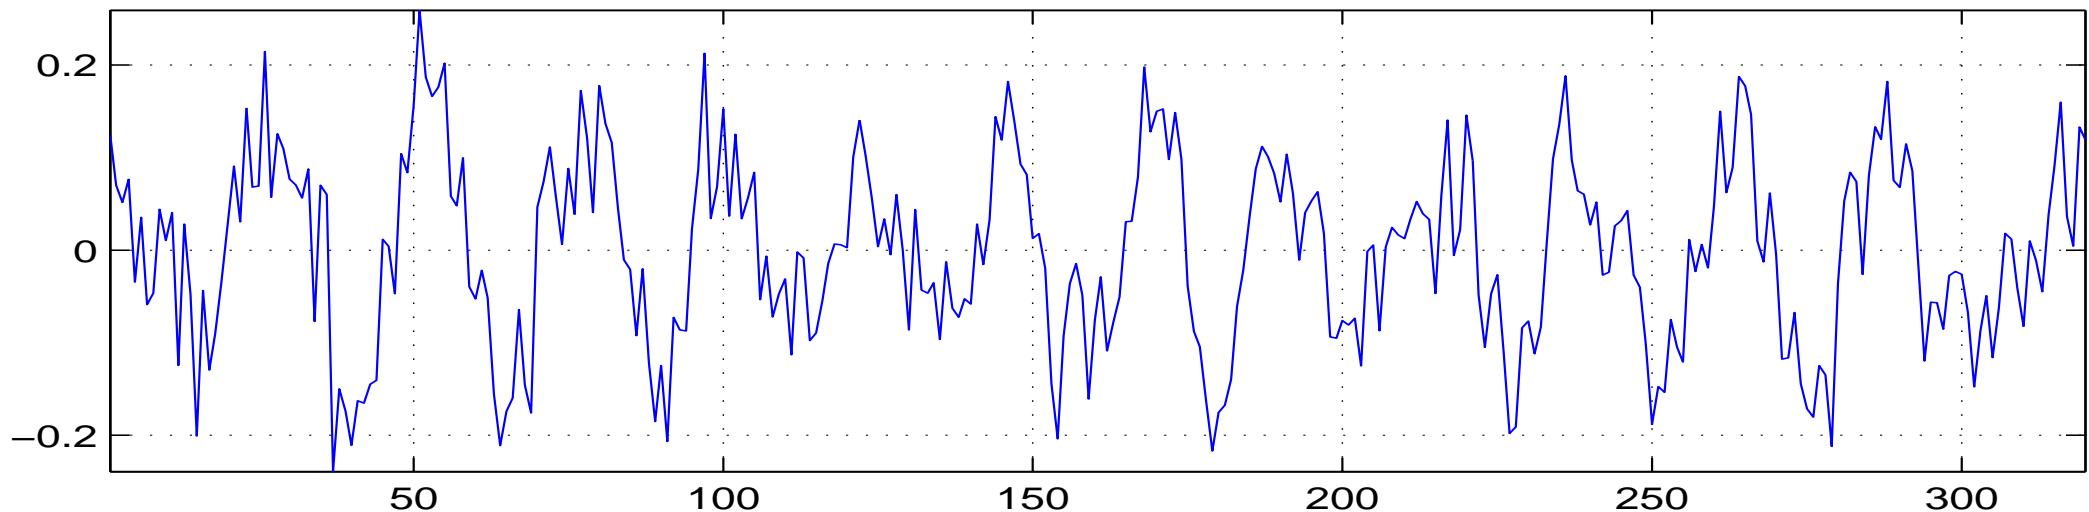
- **diskrétní čas:** lineární systém má komplexní kmitočtovou charakteristiku $H(e^{j\omega})$. Pro vstupní signál se spektrální hustotou výkonu $G_x(e^{j\omega})$ je výstupní spektrální hustota výkonu dána:

$$G_y(e^{j\omega}) = |H(e^{j\omega})|^2 G_x(e^{j\omega})$$

V obou případech násobíme vstupní PSD druhou mocninou **modulu** komplexní kmitočtové charakteristiky.

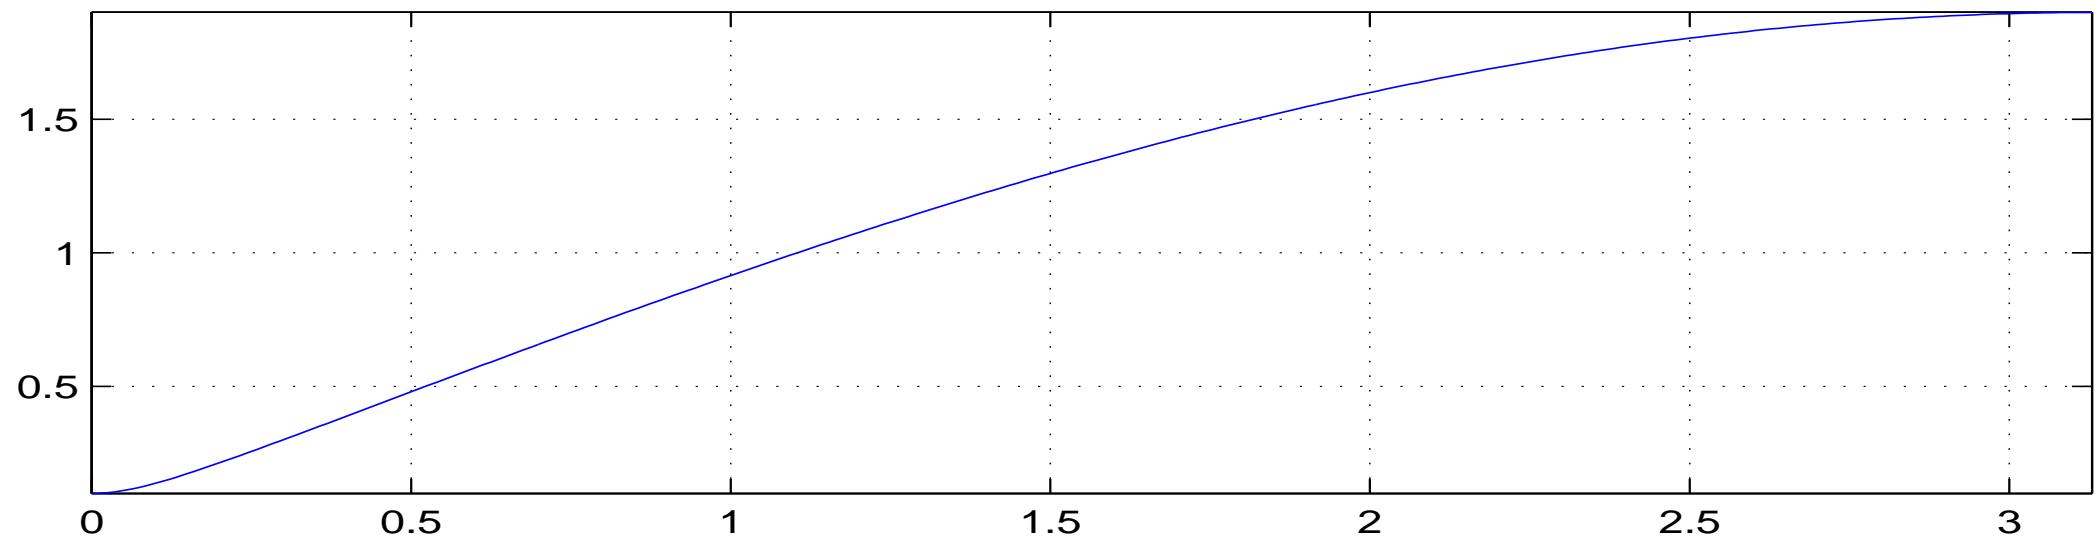
Tvar funkce hustoty rozdělení pravděpodobnosti se průchodem lineárním systémem **nemění** – mění se jen parametry.

Příklad: filtrování jedné realizace tečení vody filtrem $H(z) = 1 - 0.9z^{-1}$. Vstupní signál a jeho PSD:

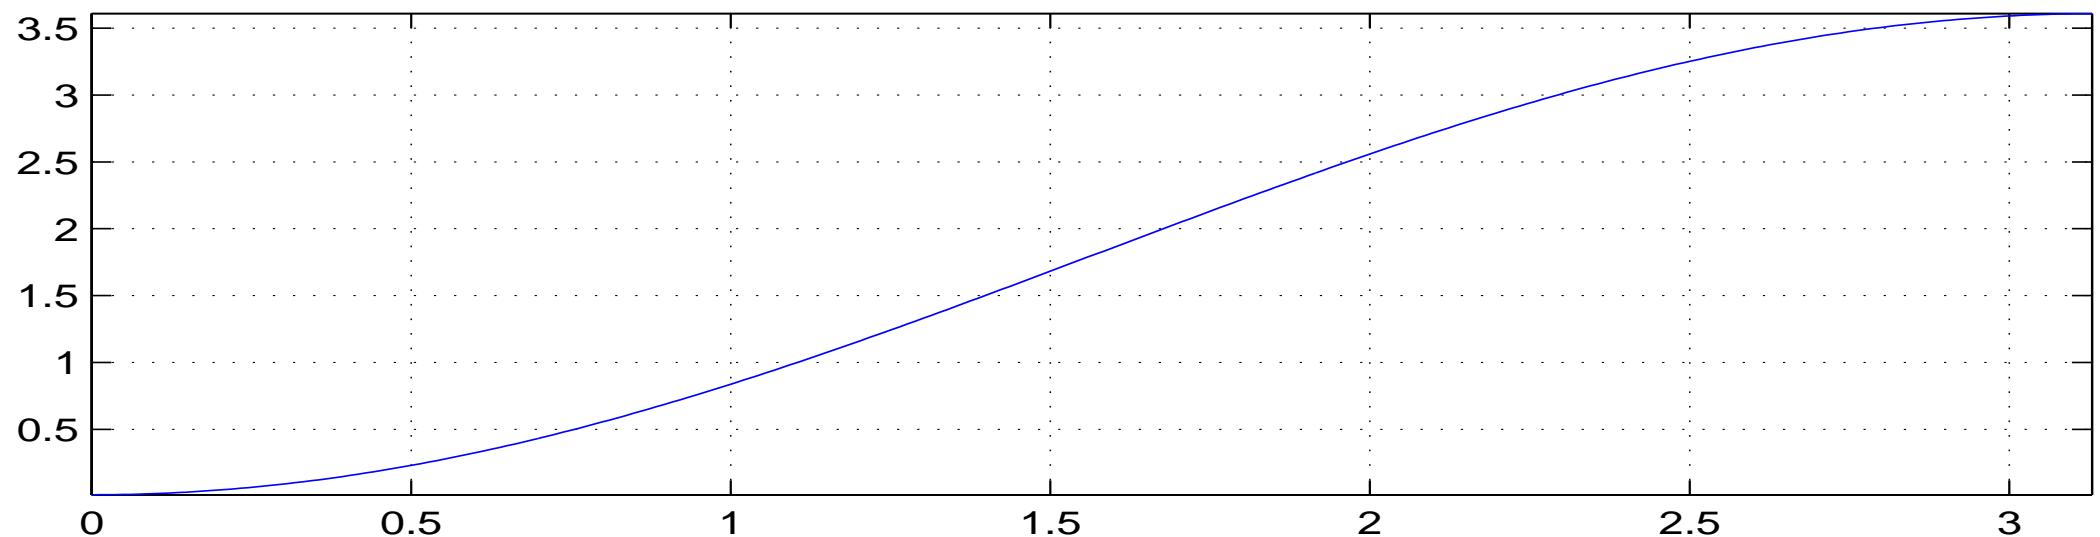


Modul komplexní kmitočtové charakteristiky a jeho druhá mocnina:

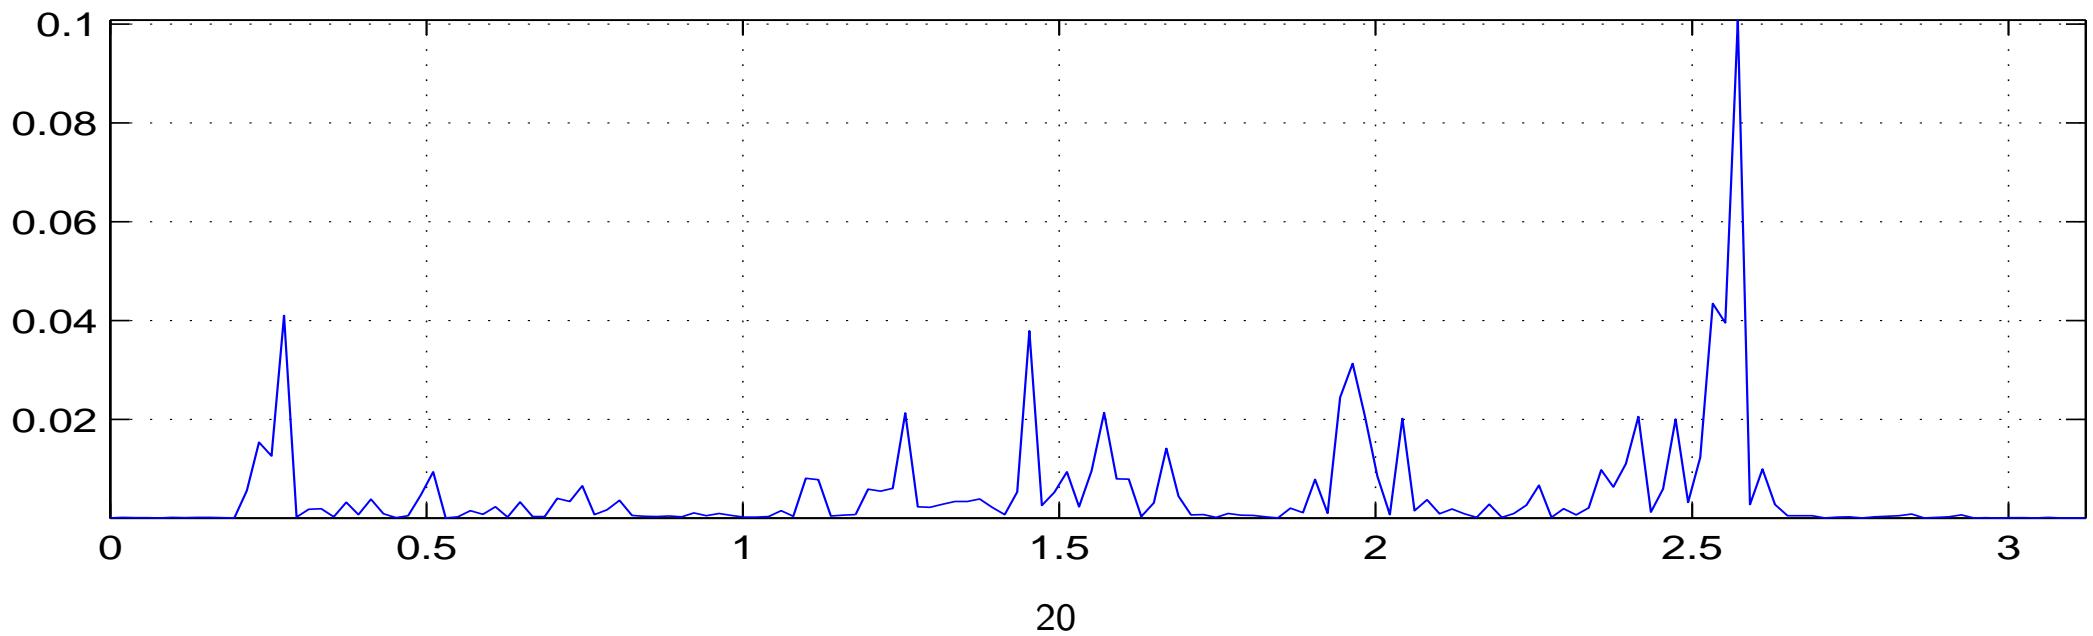
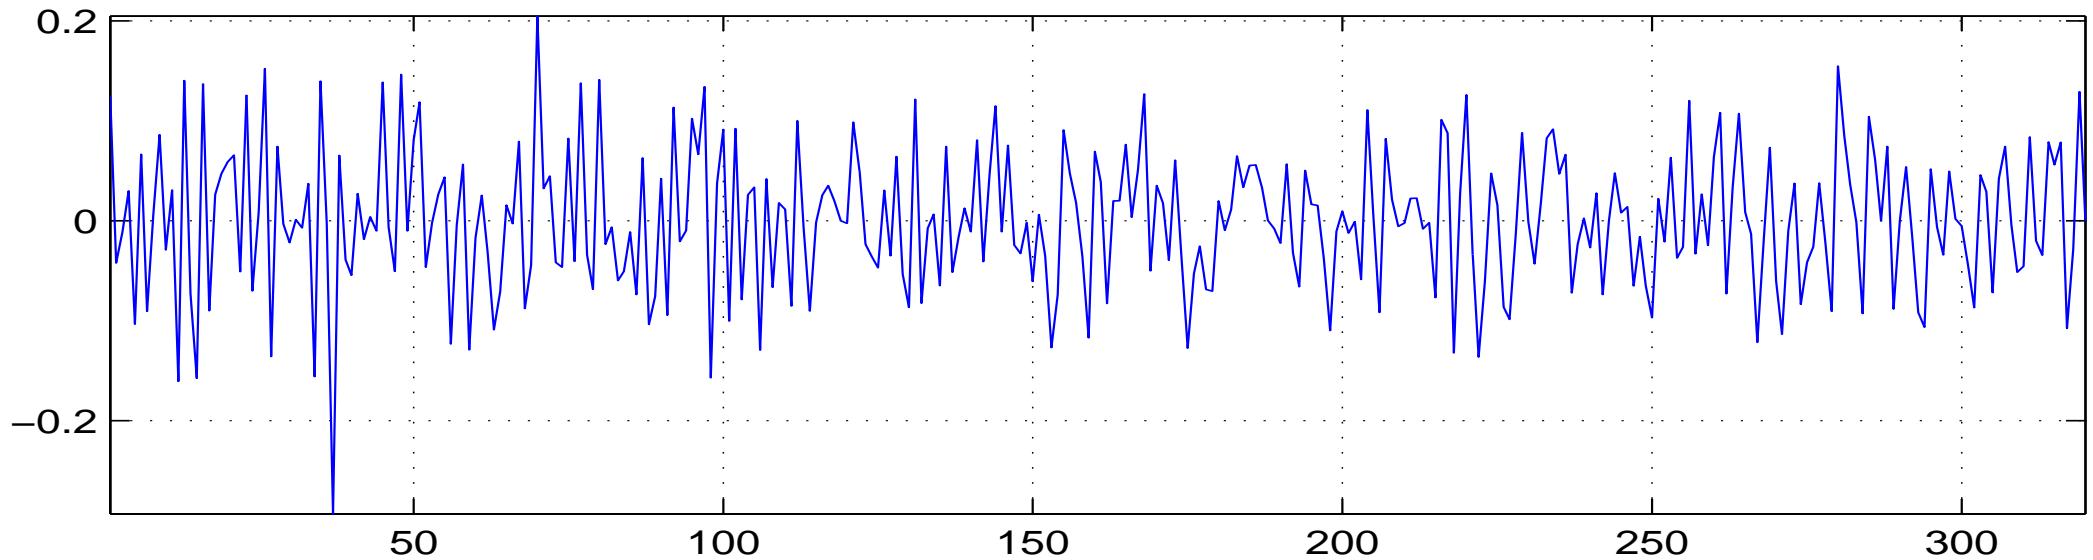
$|H|$



$|H|^2$



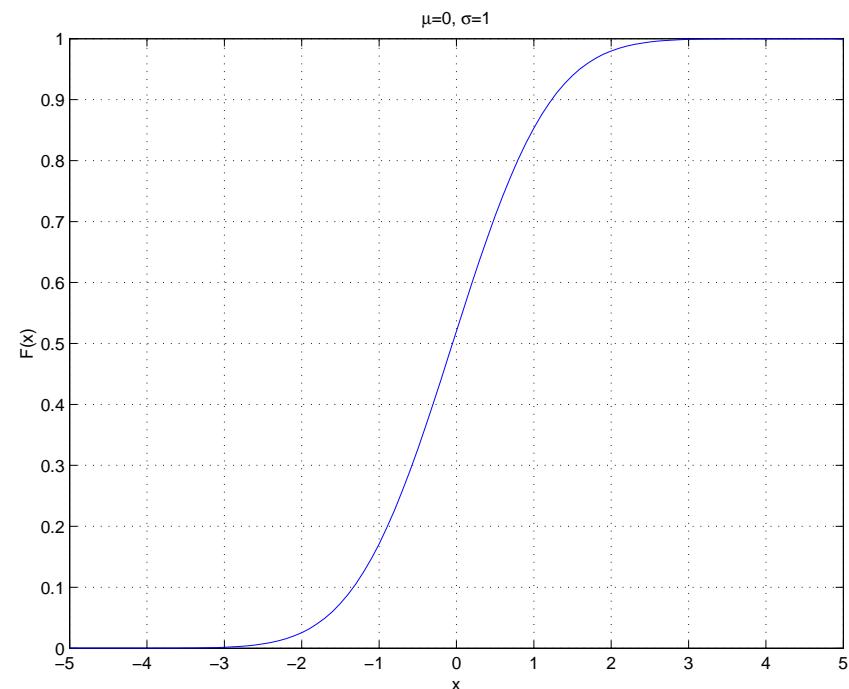
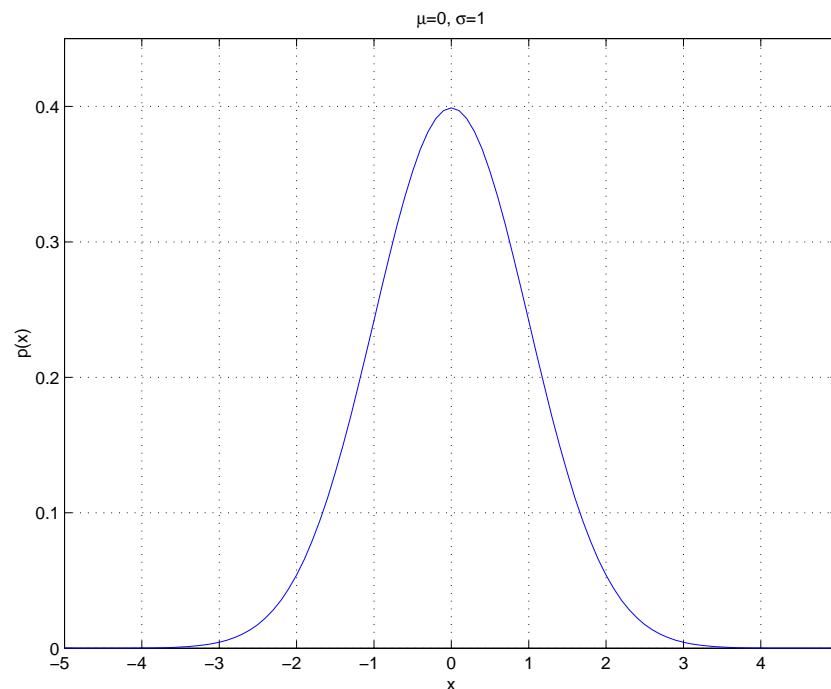
Výstupní signál a jeho PSD:



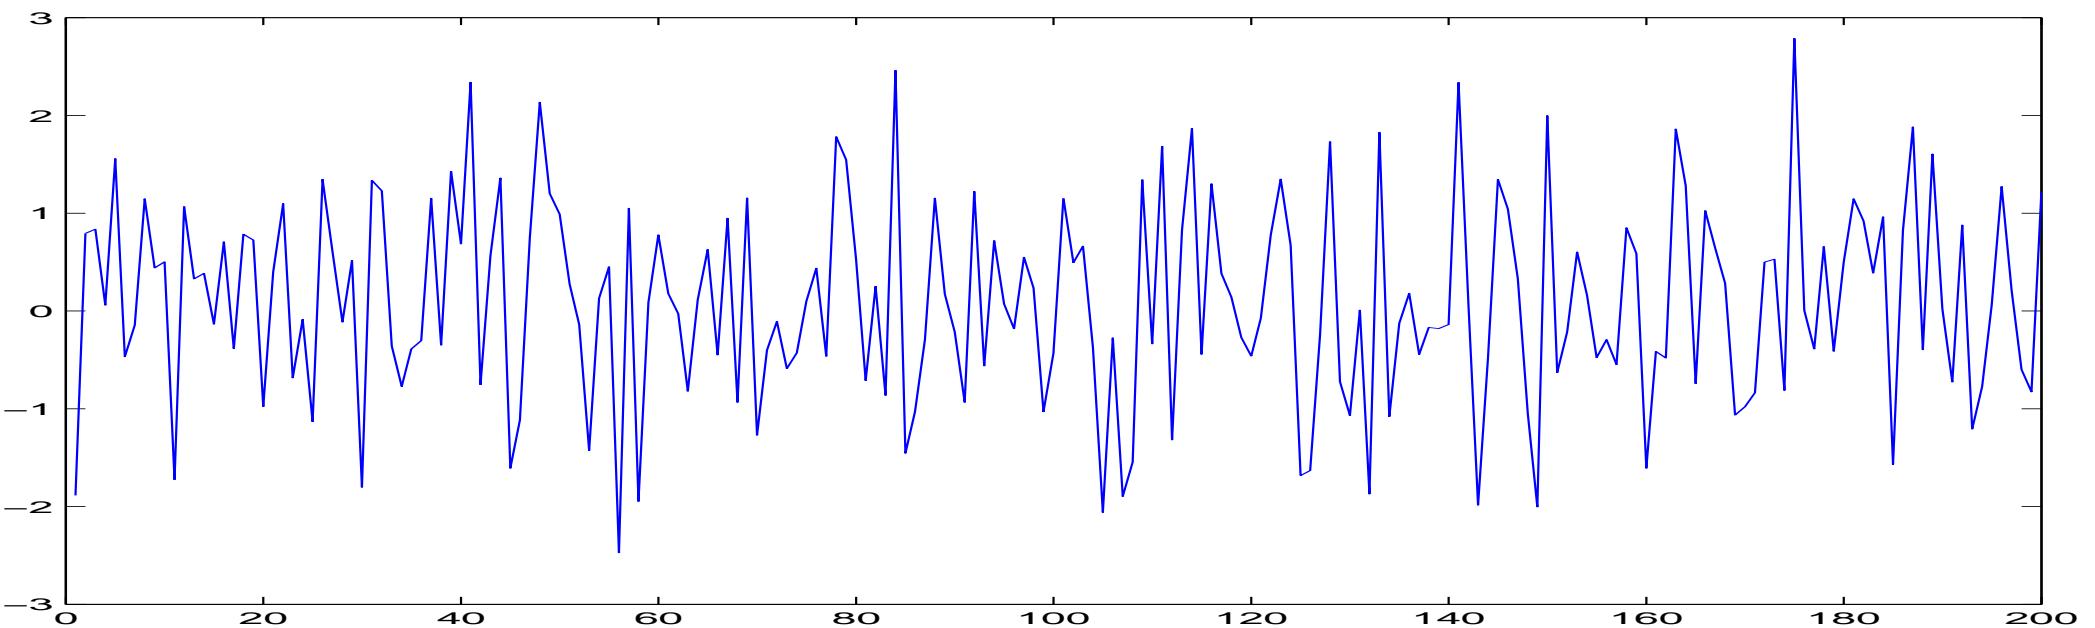
Příklad náhodného procesu – Gaussovský bílý šum

V Matlabu funkce `randn` – jednotlivé vzorky na sobě nezávisí, funkce hustoty rozdělení pravděpodobnosti je dána Gaussovým rozložením:

$$p(x) = \mathcal{N}(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{[x-\mu]^2}{2\sigma^2}}$$

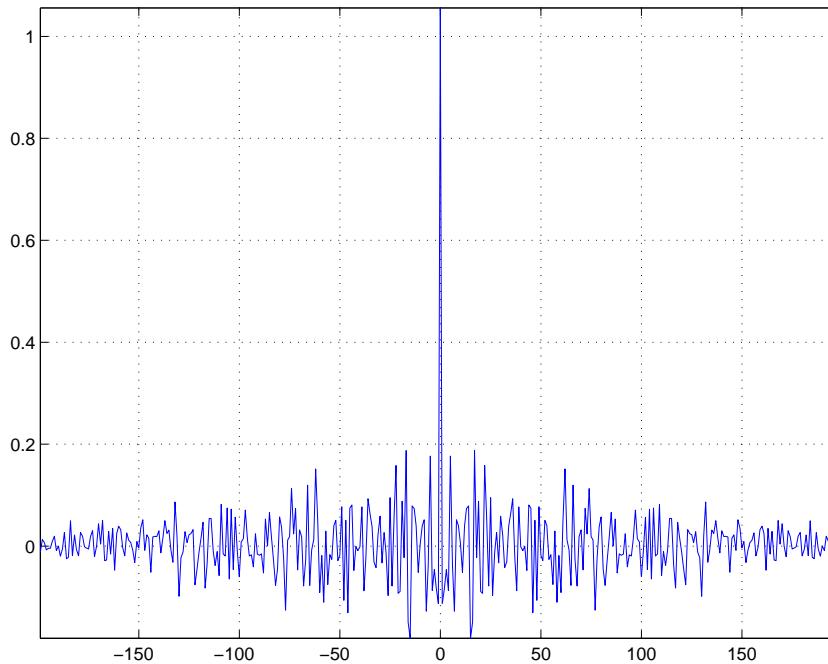


Generování v Matlabu: `x = sigma*randn(1,N) + mu`



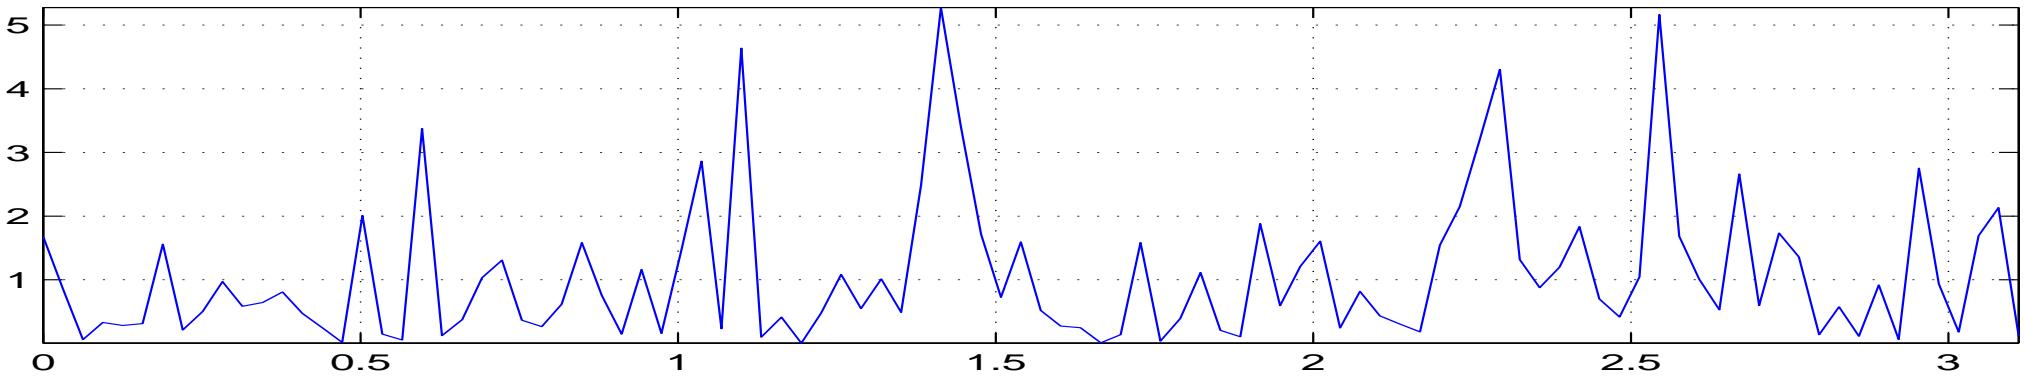
Autokorelační koeficienty:

$$R[0] = \mu^2 + D, \quad R[k] = \mu^2 \text{ pro } k \neq 0$$

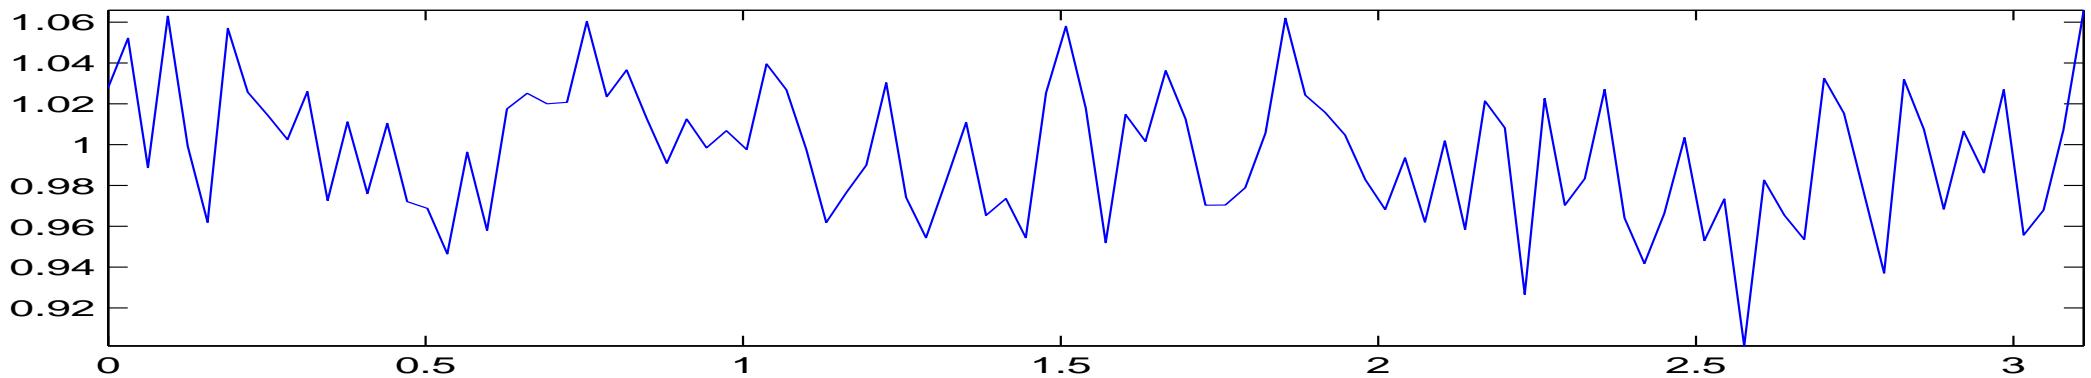


Spektrální hustota výkonu je u bílého šumu **konstantní** (proto bílý):

$$G(e^{j\omega}) = R[0]$$



averaging – Welch

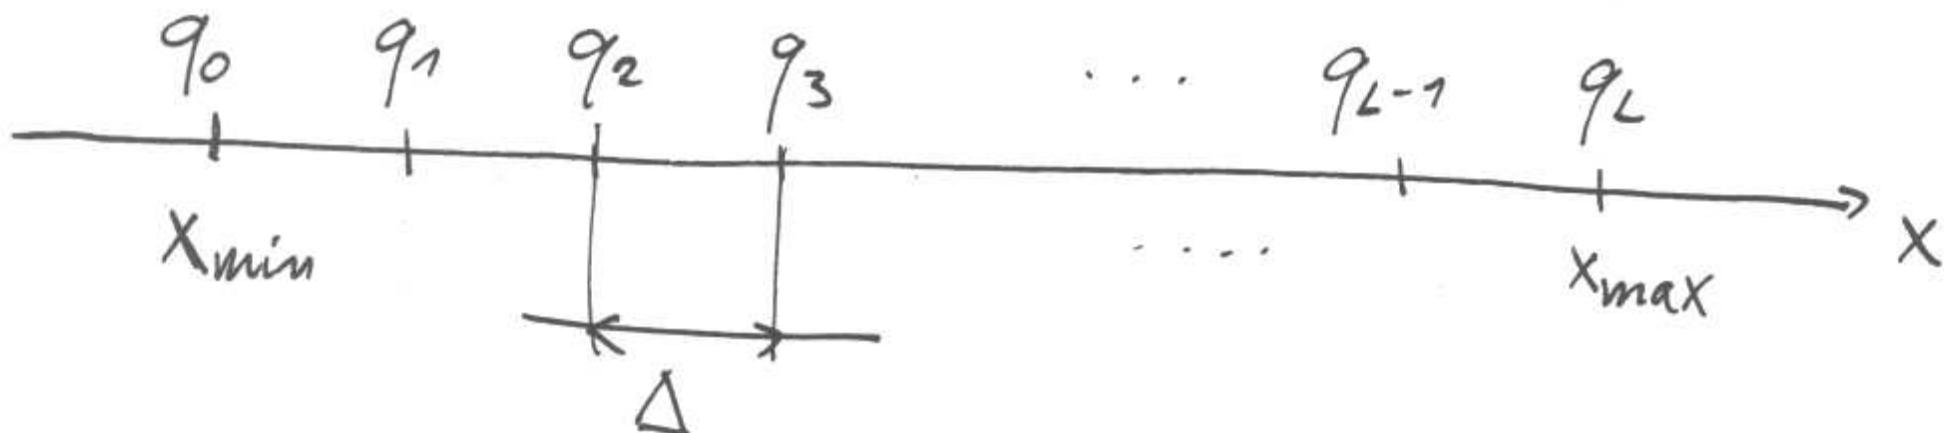


Pro spojitý čas nejde čistě bílý šum vygenerovat: pokud by $G(j\omega)$ byla nenulová pro všechny ω , měl by nekonečný výkon...

Kvantování

Representace vzorků diskrétního signálu $x[n]$ není možná s libovolnou přesností
⇒ **kvantování**. Nejčastěji **zaokrouhlujeme** na fixní počet L **kvantovacích hladin**, které jsou očíslované od 0 do $L - 1$. Pokud máme na kvantování k disposici b bitů, $L = 2^b$.

Uniformní kvantování má rovnoměrné rozložení kvantovacích hladin $q_0 \dots q_{L-1}$ od minimální hodnoty signálu x_{min} do maximální hodnoty x_{max} :



Kvantovací krok Δ je dán:

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

pro velká L můžeme použít přibližný vztah:

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

Kvantování: pro hodnotu $x[n]$ je index nejlepší kvantovací hladiny dán:

$$i[n] = \arg \min_{l=0 \dots L-1} |x[n] - q_l|,$$

a kvantovaný signál je:

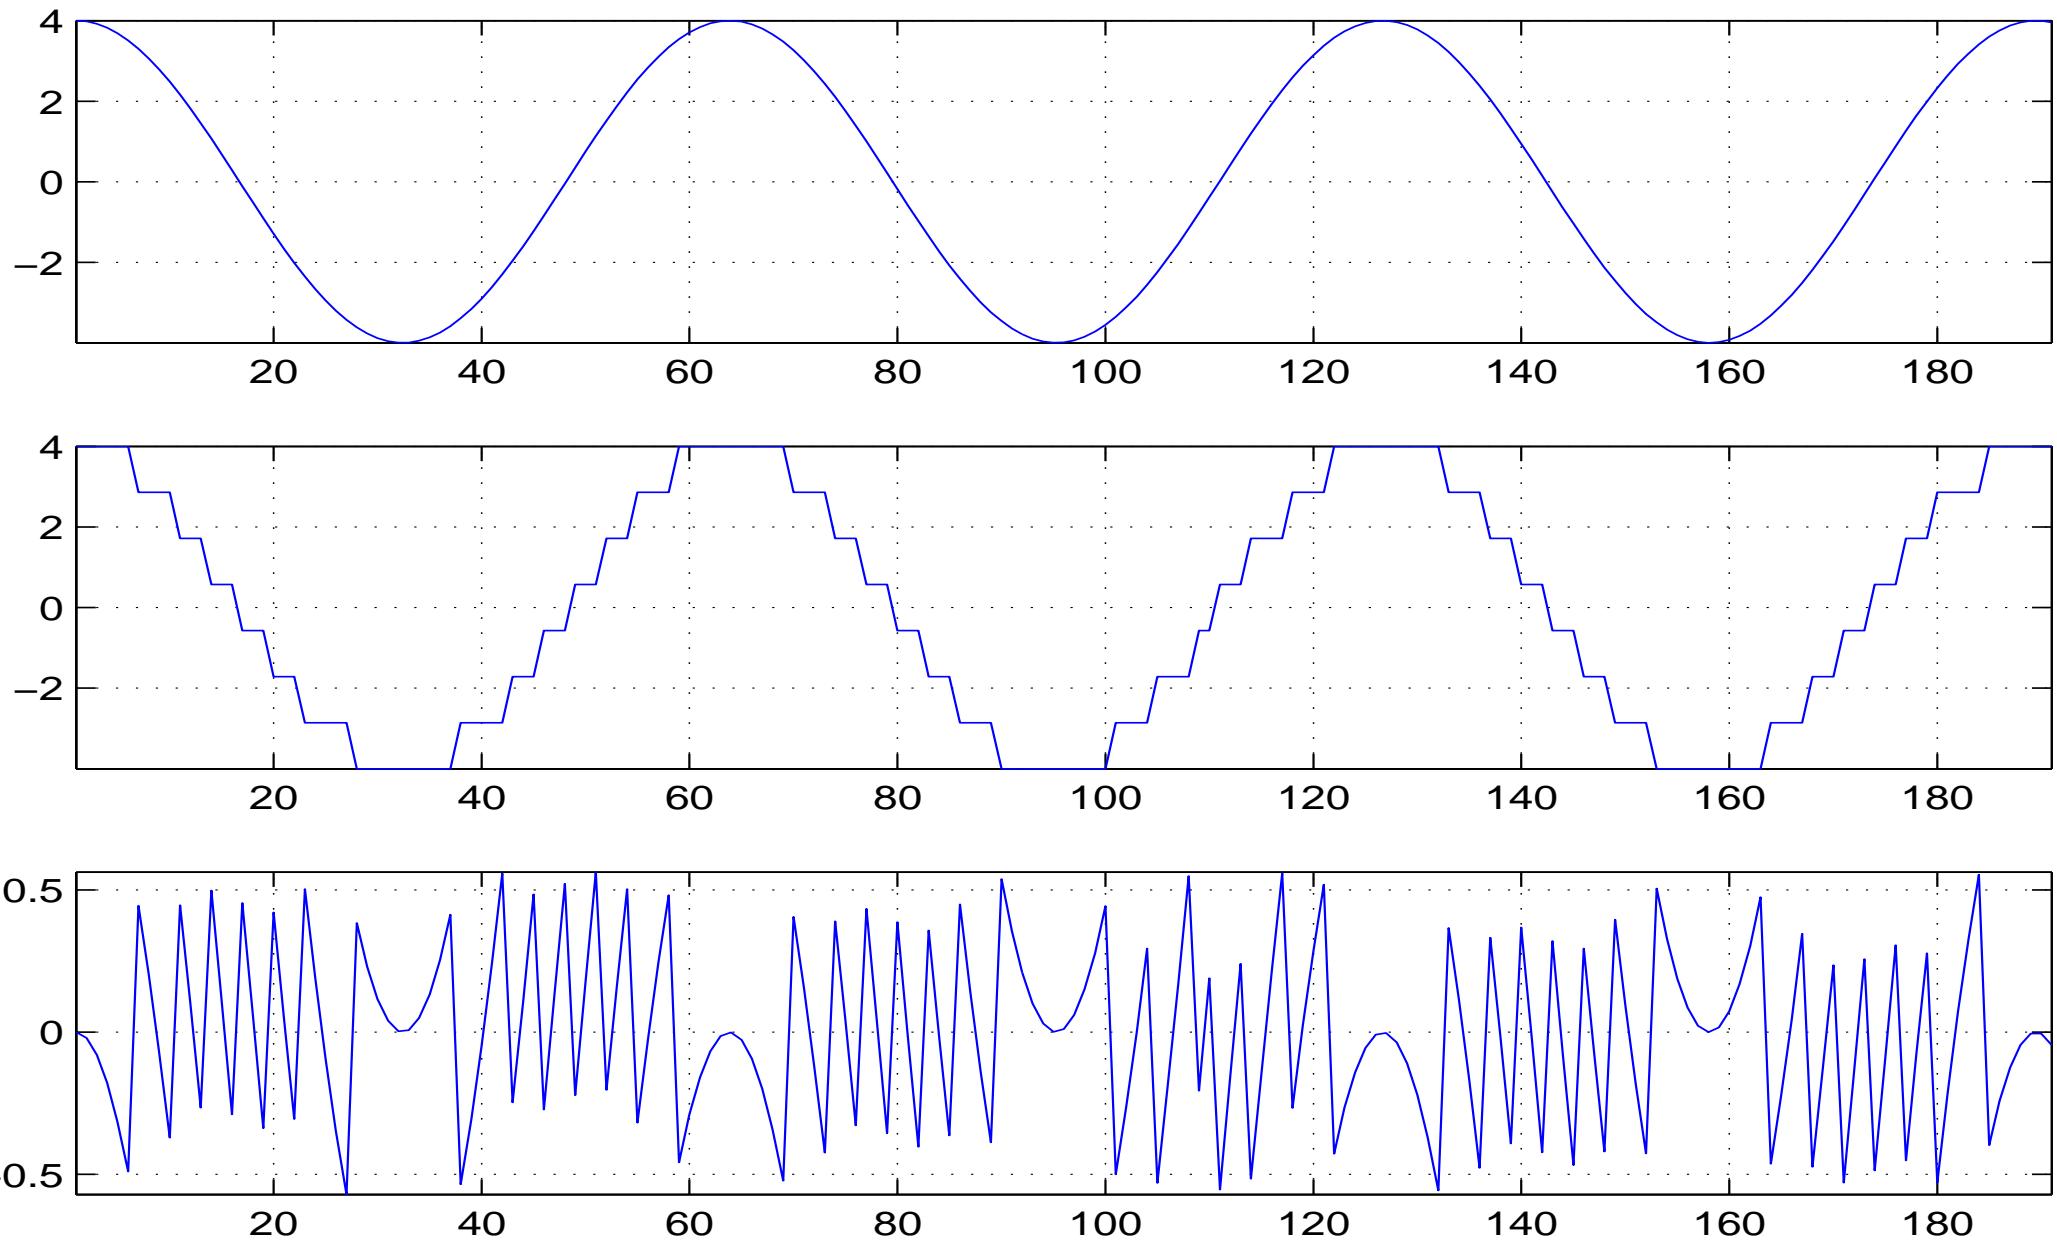
$$x_q[n] = q_{i[n]}.$$

Chyba kvantování:

$$e[n] = x[n] - x_q[n].$$

může být také považována za **signál**.

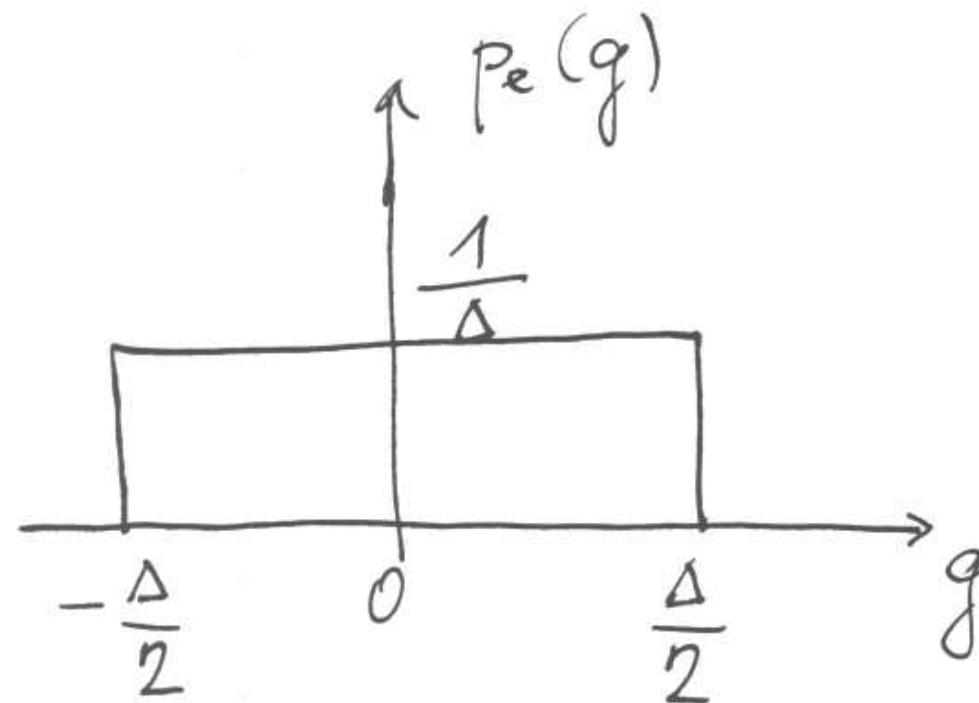
Ilustrace na kvantování kosinusovky $x[n] = 4 \cos(0.1n)$, $L = 8$:



Abychom zjistili, jak je signál kvantováním narušen, bude dobré spočítat **výkon chybového signálu** P_e a srovnat jej s výkonom užitečného signálu P_s : **poměr signálu k šumu – signal-to-noise ratio (SNR)**:

$$SNR = 10 \log_{10} \frac{P_s}{P_e} \quad [\text{dB}].$$

Pro výpočet výkonu chybového signálu využijeme teorie **náhodných procesů**: neznáme hodnoty $e[n]$, ale víme, že budou v intervalu $[-\frac{\Delta}{2}, +\frac{\Delta}{2}]$ a že budou rovnoměrně rozložené. Funkce hustoty rozdělení pravděpodobnosti pro $e[n]$ bude:



... výška $\frac{1}{\Delta}$ vychází z toho, že plocha:

$$\int_{-\frac{\Delta}{2}}^{\frac{\Delta}{2}} p_e(g) dg \stackrel{!}{=} 1.$$

Tento proces má nulovou střední hodnotu (snadno bychom zjistili, že $\int_{-\frac{\Delta}{2}}^{\frac{\Delta}{2}} g p_e(g) dg = 0$), výkon bude tedy roven **rozptylu**:

$$P_e = D_e = \int_{-\infty}^{\infty} g^2 p_e(g) dg = \int_{-\frac{\Delta}{2}}^{\frac{\Delta}{2}} g^2 p_e(g) dg = \frac{1}{\Delta} \left[\frac{g^3}{3} \right]_{-\frac{\Delta}{2}}^{\frac{\Delta}{2}} = \frac{1}{3\Delta} \left(\frac{\Delta^3}{8} + \frac{\Delta^3}{8} \right) = \frac{\Delta^2}{12}$$

Výpočet SNR pro kosinusovku

amplituda A , kosinusovka má výkon $P_s = \frac{A^2}{2}$

$x_{min} = -A$, $x_{max} = A$, takže

$$\Delta = \frac{2A}{L} \quad P_e = \frac{\Delta^2}{12} = \frac{4A^2}{12L^2} = \frac{A^2}{3L^2}.$$

Poměr signálu k šumu:

$$SNR = 10 \log_{10} \frac{P_s}{P_e} = 10 \log_{10} \frac{\frac{A^2}{2}}{\frac{A^2}{3L^2}} = 10 \log_{10} \frac{3L^2}{2}.$$

Pokud máme k disposici b bitů a počet kvantovacích hladin $L = 2^b$:

$$SNR = 10 \log_{10} \frac{3}{2} (2^b)^2 = 10 \log_{10} \frac{3}{2} + 10 \log_{10} 2^{2b} = 1.76 + 20b \log_{10} 2 = 1.76 + 6b \text{ dB.}$$

Konstanta 1.76 závisí na charakteru signálu (cos, šum), ale platí, že **přidání/ubrání jednoho bitu zlepšuje/zhoršuje SNR o 6 dB.**

Příklad: kosinusovky s $A = 4$ kvantované na $L = 8$ hladinách:

$$SNR_{teor} = 1.76 + 3 \times 6 = 19.76 \text{ dB}$$

$$SNR_{exp} = 10 \log_{10} \frac{\frac{1}{N} \sum_{n=0}^{N-1} s^2[n]}{\frac{1}{N} \sum_{n=0}^{N-1} e^2[n]} = 19.36 \text{ dB}$$

Matlab: `snr = 10*log10 (sum(x.^2) / sum(e.^2))`

... celkem to vychází.