

## 10.3 Wienerova filtrácia

Wienerova filtrácia je metóda najčastejšie používaná na potlačenie aditívneho šumu nezávislého na signále. Môžeme ju použiť, ak sú splnené nasledujúce 2 predpoklady:

(a)  $f(n_1, n_2)$  a  $v(n_1, n_2)$  sú lineárne nezávislé stacionárne náhodné procesy s nulovou strednou hodnotou

(b)  $P_f(\omega_1, \omega_2)$  a  $P_v(\omega_1, \omega_2)$  sú **známe** výkonové spektrálne hustoty (power spectral density, PSD) signálov  $f(n_1, n_2)$  a  $v(n_1, n_2)$


Potom **optimálny lineárny odhad minimálnej strednej kvadratickej chyby** (mean square error, MSE) odhadu originálu  $f(n_1, n_2)$  dostaneme filtráciou degradovaného obrazu  $g(n_1, n_2)$  Wienerovým filtrom s frekvenčnou charakteristikou

$$H(\omega_1, \omega_2) = \frac{P_f(\omega_1, \omega_2)}{P_f(\omega_1, \omega_2) + P_v(\omega_1, \omega_2)} \quad (10.9)$$

Vzťah (10.9) predstavuje **nekauzálny Wienerov filter na odhad funkcie**  $f(n_1, n_2)$ . Tento filter slúži na potlačenie lineárneho poškodenia obrazu (N. Wiener a A., N. Kolmogorov, 1940)

**Wienerov filter je optimálny lineárny filter z hľadiska MSE!**

- úspešnosť rekonštrukcie signálu závisí od toho, ako sa nám podarí odhadnúť výkonové spektrum originálu a šumu
- odhad výkonového spektra šumu je v typických prípadoch relatívne jednoduchý (napr. v prípade korekcie zlého zaostrenia)



**Obr. 10.5** Wienerova filtrácia

Ak  $f(n_1, n_2)$  má strednú hodnotu  $m_f$  a  $v(n_1, n_2)$  má strednú hodnotu  $m_v$ , potom

- pred filtrovaním stredné hodnoty odpočítame od degradovaného obrazu  $g(n_1, n_2)$  (Obr. 10.5):

$$g(n_1, n_2) - (m_f + m_v) \quad (10.10)$$

- následne filtrujeme Wienerovým filtrom
- $m_f$  na záver pripočítame k výslednému signálu

Predpokladáme, že:

$P_f(\omega_1, \omega_2)$  a  $P_v(\omega_1, \omega_2)$  poznáme alebo ich vieme odhadnúť.

Odhad PSD šumu je zvyčajne možný a nie je príliš zložitý.

Odhad PSD originálu  $P_f(\omega_1, \omega_2)$ :

- napríklad získaním priemeru  $|F(\omega_1, \omega_2)|^2$  pre veľa rôznych obrazov podobného obsahu.
- alebo modelovaním  $P_f(\omega_1, \omega_2)$  jednoduchou funkciou, získanou napríklad pomocou niektorého z AR (autoregresných) modelov obrazu:

$$R_f(n_1, n_2) = \rho^{\sqrt{n_1^2 + n_2^2}}$$

$$P_f(\omega_1, \omega_2) = FT[R_f(n_1, n_2)] \quad (10.11)$$

**Wienerov filter vo všeobecnosti realizujeme vo frekvenčnej oblasti.** Rekonštruovaný obraz potom dostaneme spätnou Fourierovou transformáciou:

$$p(n_1, n_2) = IDFT[G(k_1, k_2)H(k_1, k_2)] \quad (10.12)$$

kde

$G(k_1, k_2)$  je DFT signálu  $g(n_1, n_2)$

$H(k_1, k_2)$  je DFT signálu  $h(n_1, n_2)$

Veľkosť dávky DFT a inverznej DFT je  $(N + M - 1) \times (N + M - 1)$


$N \times N$  je veľkosť obrazu a  $M \times M$  je veľkosť filtra

Dížky signálov sú **konečné**  $\rightarrow$  vplyvom tzv. aliasingu **nie je**  $p(n_1, n_2)$  identické s konvolúciou  $g(n_1, n_2) * h(n_1, n_2)$  !


Sekvenčnú postupnosť **diskrétného** filtra získame napríklad vzorkovaním spojitého filtra:

$$H(k_1, k_2) = H(\omega_1, \omega_2) \Big|_{\omega_1 = 2\pi k_1 / L, \omega_2 = 2\pi k_2 / L} \quad (10.13)$$


$L \times L$  je veľkosť postupnosti DFT a IDFT



(a)



(b)



(c)

**Obr. 10.6** Ilustrácia dolnopriepustného charakteru Wienerovho filtra: **(a)**  $P_f(\omega_1, \omega_2)$  – typický priebeh PSD originálneho signálu; energia typického obrazu je sústredená v oblasti nízkych frekvencií, **(b)**  $P_v(\omega_1, \omega_2)$  – PSD náhodného bieleho šumu; náhodný šum pozadia je vo všeobecnosti širokopásmový, **(c)**  $H(\omega_1, \omega_2)$  – Wienerov filter

**Na objektívne porovnanie** dvoch obrazových signálov použijeme objektívne miery: **NMSE a normalizovanú MSE**

**NMSE rekonštruovaného obrazu vzhľadom k originálu** v percentách vypočítame ako:

$$NMSE[f(n_1, n_2), p(n_1, n_2)] = 100 \times \frac{Var[f(n_1, n_2) - p(n_1, n_2)]}{Var[f(n_1, n_2)]} [\%] \quad (10.14)$$

kde  $Var[\cdot]$  znamená rozptyl (variancia)

**NMSE degradovaného obrazu vzhľadom k originálu** v percentách vypočítame ako:

$$NMSE[f(n_1, n_2), g(n_1, n_2)] = 100 \times \frac{Var[f(n_1, n_2) - g(n_1, n_2)]}{Var[f(n_1, n_2)]} [\%] \quad (10.15)$$

**Zisk v odstupe signálu od šumu** (signal-to-noise ratio, SNR) pri rekonštrukcii obrazu je potom definovaný

$$SNR_{zisk} = 10 \log_{10} \frac{NMSE[f(n_1, n_2), g(n_1, n_2)]}{NMSE[f(n_1, n_2), p(n_1, n_2)]} [dB] \quad (10.16)$$

pričom samotný **odstup signálu od šumu** (SNR) môžeme určiť pomocou vzťahu

$$SNR = 10 \log_{10} \frac{Var[f(n_1, n_2)]}{Var[v(n_1, n_2)]} [dB] \quad (10.17)$$

- ak máme 2 obrazy s **tým istým typom degradácie**, vo všeobecnosti sa nám javí **obraz s nižšou NMSE bližší originálu** ako obraz s vyššou NMSE.
- čím nižšia je hodnota NMSE, tým je rekonštruovaný obraz bližší originálu, no NMSE je stále len jednou z možných mier podobnosti
- pri rôznych typoch degradácie **nemusí platiť**, že nižšia hodnota NMSE automaticky znamená väčšiu **subjektívnu** zhodu s originálom

NMSE ani SNR sa vo všeobecnosti nedajú používať na porovnávanie rôznych algoritmov.



(a)



(b)



(c)



(d)

**Obr. 10.7** Wienerova filtrácia: (a) originál, (b) obraz poškodený aditívnym šumom, (b) SNR 7 dB, NMSE 19.91%, (c) rekonštruovaný obraz, pričom bol známy len degradovaný obraz, NMSE=3,75%, (d) rekonštruovaný obraz, pričom bol známy aj originál, NMSE=16%

Pozn.:

Objektívne hodnotenie NMSE nezodpovedá subjektívnemu hodnoteniu kvality. Objektívne je lepšie (c) ale subjektívne (d)

## Modifikácie Wienerovej filtrácie

- Wienerova filtrácia je založená na minimalizácii MSE medzi originálom a rekonštruovaným obrazom.
- Objektívne kritériá (ako je aj MSE) málo hovoria o subjektívnom hodnotení kvality obrazu pozorovateľom.

Boli vytvorené viaceré modifikácie Wienerovej filtrácie založené na ľudskom vnímaní.

**Výkonová filtrácia** – metóda filtrácie výkonového spektra. V tejto metóde používame nasledovnú frekvenčnú charakteristiku filtra

$$H(\omega_1, \omega_2) = \left( \frac{P_f(\omega_1, \omega_2)}{P_f(\omega_1, \omega_2) + P_v(\omega_1, \omega_2)} \right)^{1/2} \quad (10.18)$$

$H(\omega_1, \omega_2)$  – druhá odmocnina frekvenčnej charakteristiky Wienerovho filtra.

Ak  $f(n_1, n_2)$  a  $v(n_1, n_2)$  sú lineárne nezávislé vzorky stacionárneho náhodného procesu, potom rekonštruovaný obraz má výkonové spektrum zhodné s výkonovým spektrom originálu:

$$\begin{aligned} P_p(\omega_1, \omega_2) &= |H(\omega_1, \omega_2)|^2 \cdot P_g(\omega_1, \omega_2) \\ &= |H(\omega_1, \omega_2)|^2 \cdot (P_f(\omega_1, \omega_2) + P_v(\omega_1, \omega_2)) \end{aligned} \quad (10.19)$$

Dosadením (10.18) do (10.19) dostaneme:

$$P_p(\omega_1, \omega_2) = P_f(\omega_1, \omega_2) \quad (10.20)$$

## Všeobecný tvar modifikácií Wienerovho filtra:

$$H(\omega_1, \omega_2) = \left( \frac{P_f(\omega_1, \omega_2)}{P_f(\omega_1, \omega_2) + \alpha \cdot P_v(\omega_1, \omega_2)} \right)^\beta \quad (10.21)$$

kde  $\alpha$  a  $\beta$  sú konštanty:

- Štandardný Wienerov filter :  $\alpha = \beta = 1$
- Výkonová filtrácia: pre  $\alpha = 1$  a  $\beta = 0,5$
- Parametrický Wienerov filter:  $\beta = 1$  a  $\alpha$  – parameter

## Wienerov filter – zhrnutie

- Wienerove filtre sú typicky **dolnopriepustného charakteru s nulovou fázou** – ovplyvňujú len magnitúdovú frekvenčnú charakteristiku signálu a neovplyvňujú fázovú frekvenčnú charakteristiku
- V každom prípade **predpokladáme, že PSD šumu a originálu sú známe, resp. ich vieme určiť**.
- Filtre sú najčastejšie implementované pomocou DFT a IDFT.
- Redukujú šum, ale tiež čiastočne **zahmlievajú obraz**.
- **Wienerov filter** minimalizuje MSE medzi rekonštruovaným obrazom a originálom (rôzne „ad hoc“ modifikácie Wienerovho filtra sa snažia vystihnúť vnímanie kvality obrazu ľudským zrakom; MSE nekorešponduje s hodnotením HVS)