



# Číslíkové spracovanie signálov

## Prednáška č. 9

- **Lifting implementácia DWT**
- 2D DWT
- Vybrané oblasti využitia DWT

# DWT – Lifting implementácia

- Liftingová schéma predstavuje výhodný spôsob realizácie výpočtov v bankách filtrov.
- Jednoducho opisuje závislosti medzi párami filtrov, ktoré zdieľajú ten istý HP, resp. DP filter.
- Poskytuje postup, ako môžeme začať z triviálneho prípadu „lenivého“ waveletu a postupne vybudovať pár filtrov s požadovanými vlastnosťami. Odtiaľ pochádza aj názov „lifting“, t. j. „dvíhanie“ vlastností waveletov.
- Pomocou liftingu získané wavelety sa zvyknú nazývať aj **wavelety druhej generácie**.
- **Liftingová schéma umožňuje efektívne realizovať klasickú DWT s nasledovnými výhodami:**
  - urýchlenie implementácie (napr. v 1D prípade až dvojnásobne), označovaná ako **rýchla DWT**
  - jednoduchý návrh vlastných waveletov
  - **spätná DWT** môže byť získaná bezprostredne z priamej DWT zámenou poradia operácií a výmenou každého znamienka plus za mínus a naopak.
  - možnosť ľahko získať **celočíselnú DWT**, ktorá má jednoduchú technickú implementáciu (zaokružľovanie hodnôt) a umožňuje bezstratovú kompresiu
  - možnosť **vykonať výpočty bez použitia prídavnej pamäte**
  - Oproti klasickej konvolúcii ponúka lifting metóda **menšiu výpočtovú náročnosť**
  - Vychádza sa z impulzných charakteristík filtrov a prejde sa ku štruktúre, ktorá sa skladá iba z jednoduchých operácií - Tomuto prechodu sa hovorí **faktorizácia** a výsledkom sú **lifting koeficienty**.

# DWT – Lifting implementácia

## Časová LIFTING implementácia DWT


- Využíva biortogonálnu banku filtrov
- Impulzné charakteristiky musia spĺňať **podmienku biortogonalít** (Ortogonalne do kríža)

$$\sum_n g_0(n)h_1(n) = 0 \quad \sum_n g_1(n)h_0(n) = 0$$

# DWT – Lifting implementácia (LI)

## Časová LIFTING implementácia DWT

- Uvažujme BF pre implementáciu DWT s Haarovým waveletom
- Ďalej uvažujme, že postupnosť  $x(n) = c_j(n)$ . Túto postupnosť rozložíme na aproximačné koeficienty  $c_{j+1}(n)$  a detailové koeficienty  $d_{j+1}(n)$ .
- Jeden stupeň priamej LI DWT pozostáva z 3 krokov:
  - Rozdelenie vzoriek do dvoch vetiev
  - Predikcia (P)
  - Korekcia (K)



V bloku **prediktora (P)** sa používa **postupnosť párných vzoriek** na predikciu (predpovedanie hodnoty) postupnosti nepárnych vzoriek.

**Cieľom** je získanie čo najmenších hodnôt vzoriek na hornopriepustnom (HP) výstupe tohto stupňa.

- Odčítaním predikovanej hodnoty od aktuálnej hodnoty vzorky vedie k získaniu detailu – to ako sa od seba líšia (teda HP filter).

$$d_{j+1}(n) = b_j(n) - p_1[a_j(n) + a_j(n-1)], \quad p_1 = \frac{1}{2}$$

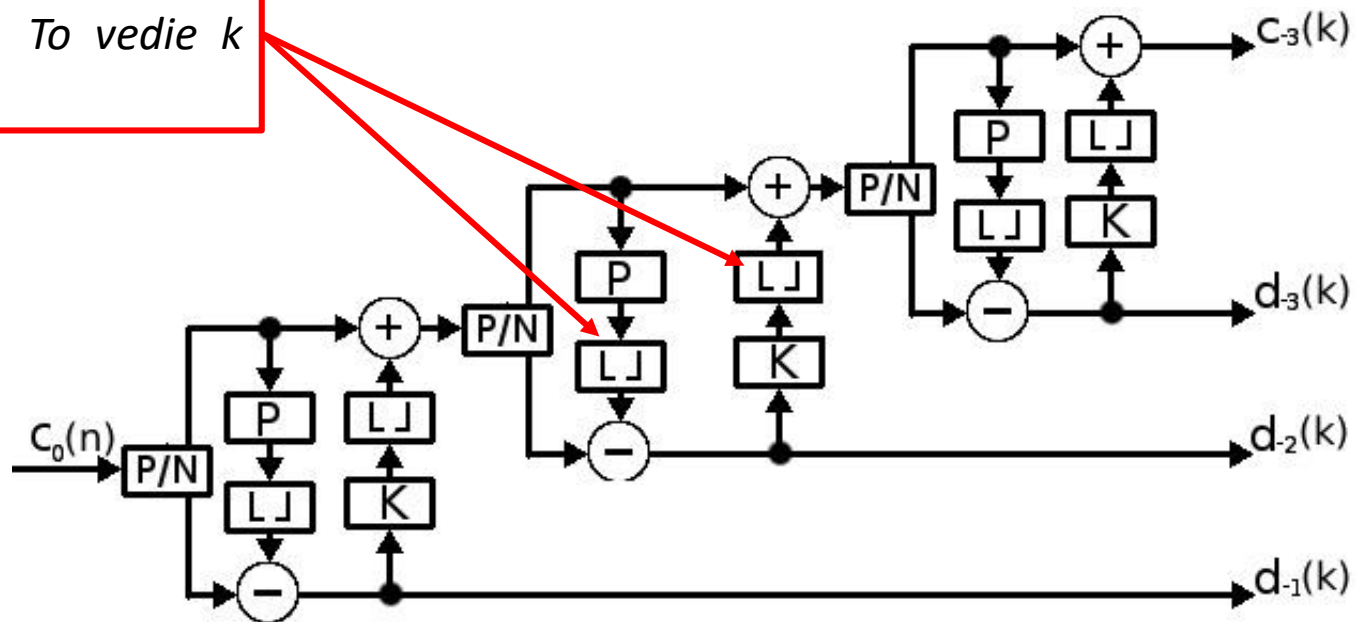
**Výstupné vzorky z bloku korektora (K)** menia hodnoty párných vzoriek na základe nepárnych tak, aby čo najvernejšie odzrkadľovali vlastnosti celej vstupnej postupnosti, t.j. aby predikcia bola účinná aj pri ďalších krokoch.

$$c_{j-1}(n) = a_j(n) + k_1[d_{j-1}(n-1) + d_{j-1}(n)], \quad k_1 = \frac{1}{4}$$

# DWT – Viacúroňová Lifting implementácia

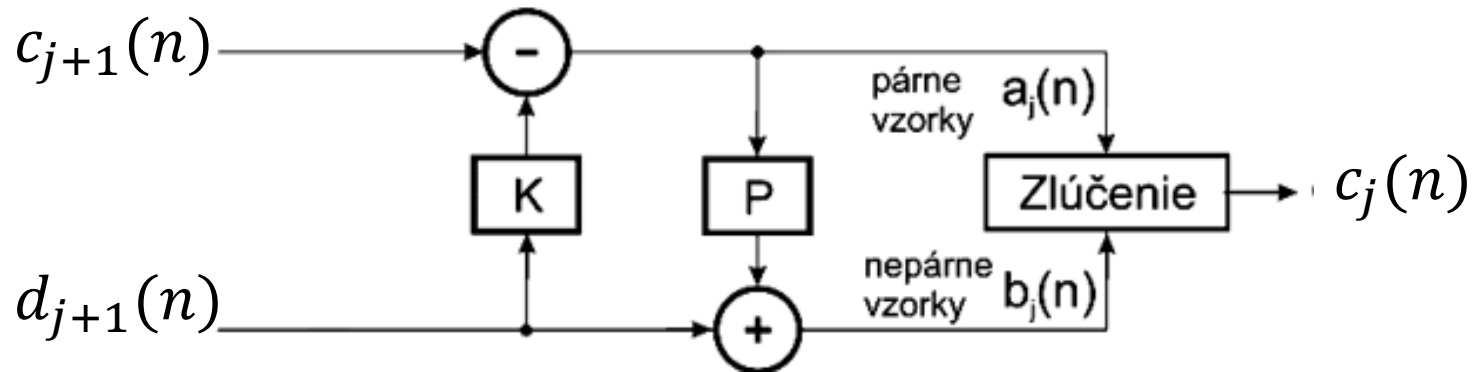
Viacúroňová LI DWT je vykonaná aplikáciou rovnakého rozkladového stupňa na aproximačné subpásma

Výstup z prediktora a korektora môže byť zaokrúhľený. To vedie k celočíselnej LI DWT



# DWT – Lifting implementácia (LI)

**Spätná LI DWT** je vykonaná aplikáciou rovnakých krokov ako pri priamej DWT ale tieto kroky sú v opačnom poradí so zámienou znamienok pri súčtových operáciách.







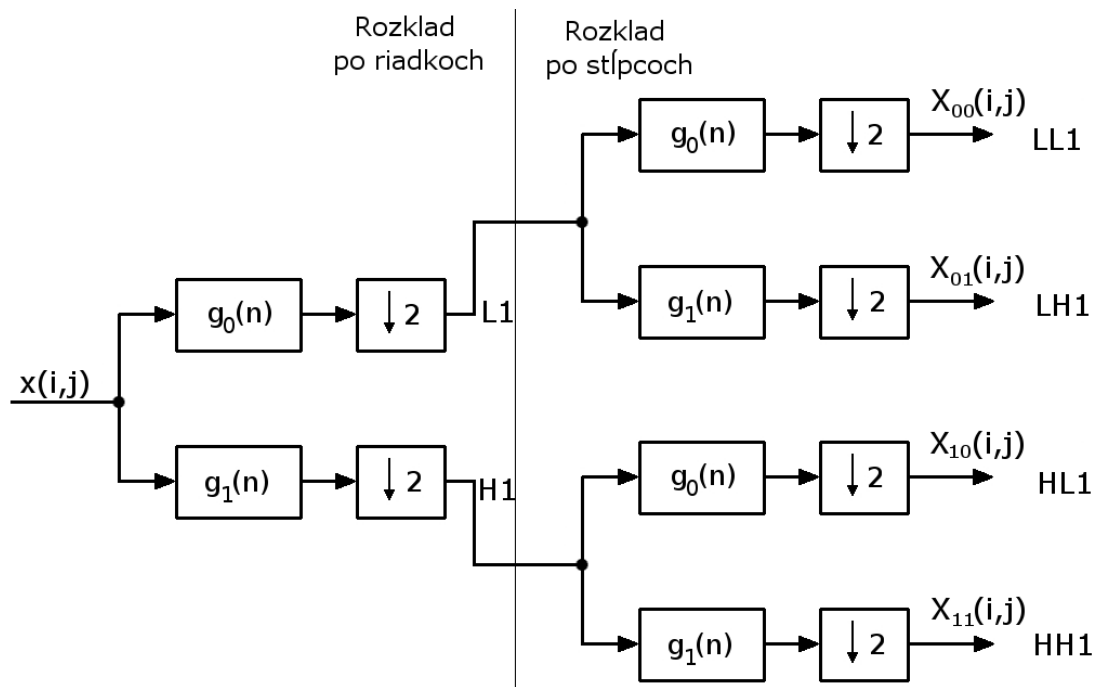
# Číslíkové spracovanie signálov

## Prednáška č. 9

- Lifting implementácia DWT
- **2D DWT**
- Vybrané oblasti využitia DWT

# 2D DWT

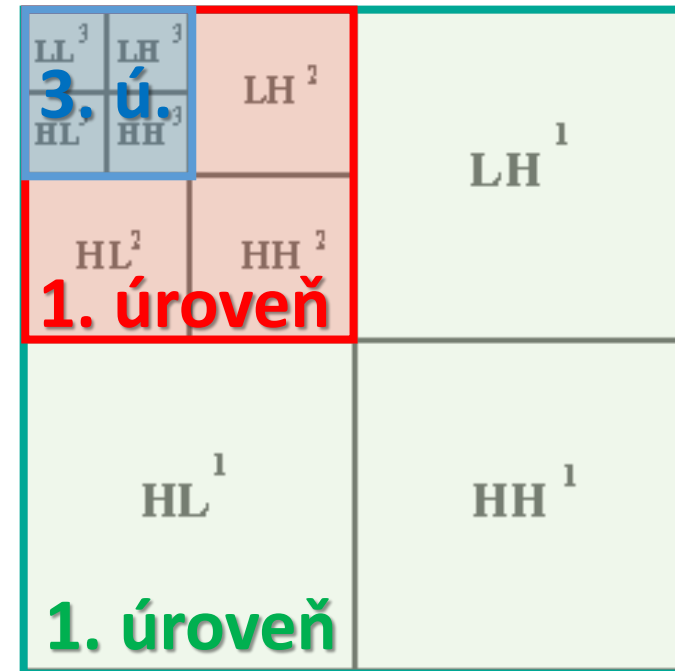

- **Dvojrozmernú DWT** je možné využiť na signály dvoch nezávislých premenných (najčastejšie obraz).
- 2D DWT obrazu je získaná aplikáciou 1D DWT na riadky obrazu a následne na stĺpce obrazu. **Hovoríme, že jadro transformácie je separovateľné.**





# 2D DWT

- Dalším rozkladem aproximační části je získána dvoj a viacúrovňová 2D DWT.





# Číslíkové spracovanie signálov

## Prednáška č. 9

- Lifting implementácia DWT
- 2D DWT
- **Potláčanie šumu**


# Vybrané oblasti využitia DWT – Potláčanie šumu

- DWT je možné využiť pri potláčaní šumu v signáloch (obrazoch).
- Využíva sa
  - Tvrdé prahovanie
  - Mäkké prahovanie
- Princíp tvrdého prahovania spočíva v potlačení rozkladových koeficientov, ktorých absolútna hodnota je nižšia ako zvolený prah ( $\lambda$ ).

$$\tilde{x} = \begin{cases} x & \text{ak } |x| > \lambda \\ 0 & \text{inde} \end{cases}$$

- Mäkké prahovanie je definované nasledovne:


$$\tilde{x} = \begin{cases} \text{znamineko}(x) [ |x| - \lambda ] & \text{ak } |x| > \lambda \\ 0 & \text{inde} \end{cases}$$



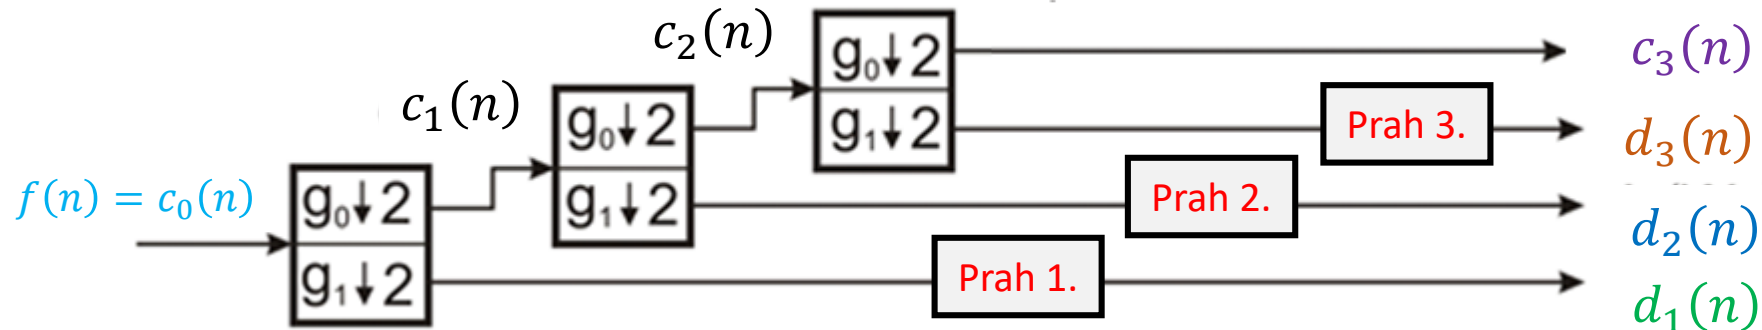
- Nevýhodou tvrdého prahovania je to, že v odšumenom signáli môžu vzniknúť prechody.
- Voľbu prahu pre úpravu koeficientov je vhodné nastaviť s ohľadom na typ šumu a teda s ohľadom na jeho smerodajnú odchýlku
- **Univerzálny prah** (pôvodne odvodený pre biely šum s Gaussovým rozložením)
$$\lambda = \sigma \sqrt{2 \log(N)}$$
- Prah je možné upravovať násobením konštantou – **empirický prah**
$$\lambda = K\sigma$$

# Vybrané oblasti využitia DWT – Potláčanie šumu

- Uvažujme zašumený signál.
- Na tento signál aplikujeme DWT
- Na detailové koeficienty aplikujeme prahovú filtráciu
- Signál sa rekonštruuje pomocou spätenej DWT



- Šum možno potláčať na viacerých úrovniach (pretože úrovne predstavujú rôzne frekvenčné pásma)





# Číslicové spracovanie signálov

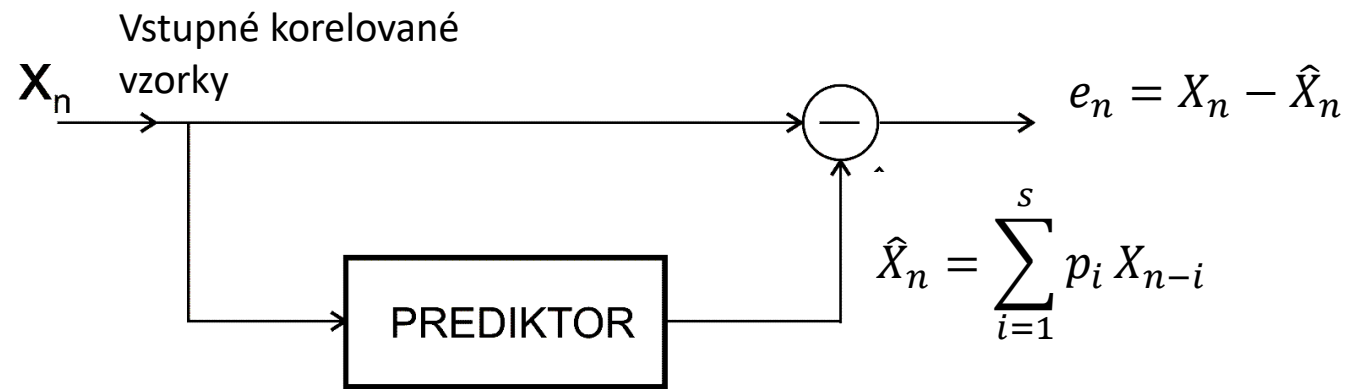

## Prednáška č. 10

- **Predikcia signálov**
- Estimácia signálov

# Predikcia signálov

**Predikcia** (predpoved') vzoriek signálu súvisí s predikčnými metódami kompresie údajov.

- odstraňuje štatistickú **redundanciu (nadbytočnosť)** reprezentovanú korelovanosťou (väzbou) medzi vzorkami
- **predikcia nie je vhodná pre nekorelované vzorky!**



$p_i$  – predikčné koeficienty,  $s$  – rád prediktora, tj. počet predchádzajúcich vzoriek použitých na predikciu



# Číslicové spracovanie signálov

## Prednáška č. 10

- Predikcia signálov
- **Estimácia signálov**

# Estimácia signálov

Pri spracovaní **zašumených signálov** môžeme vykonávať estimáciu (odhad) vzoriek užitočného signálu (filtrácia) alebo aspoň niektorých jeho parametrov.

Rozlišujeme:

- **Lineárnu**
- **nelineárnu estimáciu**

Iné rozdelenie:

- **rekurzívna** (so spätnou väzbou)
- **nerekurzívna** (bez spätnej väzby)

Obmedzíme sa preto len na výklad lineárnej estimácie, a to: Estimácia – buď **parametra** alebo **vzoriek signálu**



# Nerekurzívna lineárna estimácia parametrov

**Nerekurzívna (bez spätnej väzby) estimácia** sa realizuje pomocou lineárnej kombinácie určitého počtu vzoriek zašumeného signálu.

Konkrétne estimujme amplitúdu (parameter) *jednosmerného náhodného signálu* (opísaný náhodnou premennou  $A$ ) pohlteneho v šume. Predpokladajme, že dĺžka signálu je  $s$  vzoriek. Za predpokladu aditívneho šumu **vzorky zašumeného signálu sú**

$$X_n = A + V_n$$


kde  $V_n$  sú **vzorky šumu**.

Estimácia jednosmerného signálu bude nasledovná:

$$\hat{A} = \frac{1}{s} \sum_{i=1}^s X_i$$

• Chyba estimácie je:

$$e = A - \hat{A} = A - \frac{1}{s} \sum_{i=1}^s X_i$$



**Stredná kvadratická chyba estimácie je daná ako:**

$$\sigma_e^2 = E(e^2) = E\left(\frac{1}{s} \sum_{i=1}^s V_i\right)^2 = \frac{\sigma_v^2}{s}$$

**Zo vzťahu vyplýva, že s nárastom počtu vzoriek ( $s$ ) bude chyba menšia a estimácia presnejšia.**

# Nerekurzívna lineárna estimácia parametrov

Estimácia jednosmerného signálu pomocou aritmetického priemeru nie je optimálna vzhľadom na minimalizáciu strednej kvadratickej hodnoty chyby.

$$\hat{A} = \frac{1}{N} \sum_{i=1}^N X_i$$

- Preto sa využíva nasledovný vzťah:

$$\hat{A} = \frac{1}{s} \sum_{i=1}^s d_i X_i$$


$d_i$  sú **estimačné koeficienty**, ktoré určíme tak, aby  $\sigma_e^2$  bolo *minimálne*.

Dá sa ukázať, že ak

$$d_1 = d_2 = \dots = d_s = \frac{1}{s + b}$$

potom je stredná kvadratická chyba daná nasledovne:

$$\sigma_e^2 = E \left[ (A - \hat{A})^2 \right] = \frac{\sigma_v^2}{s + b}$$



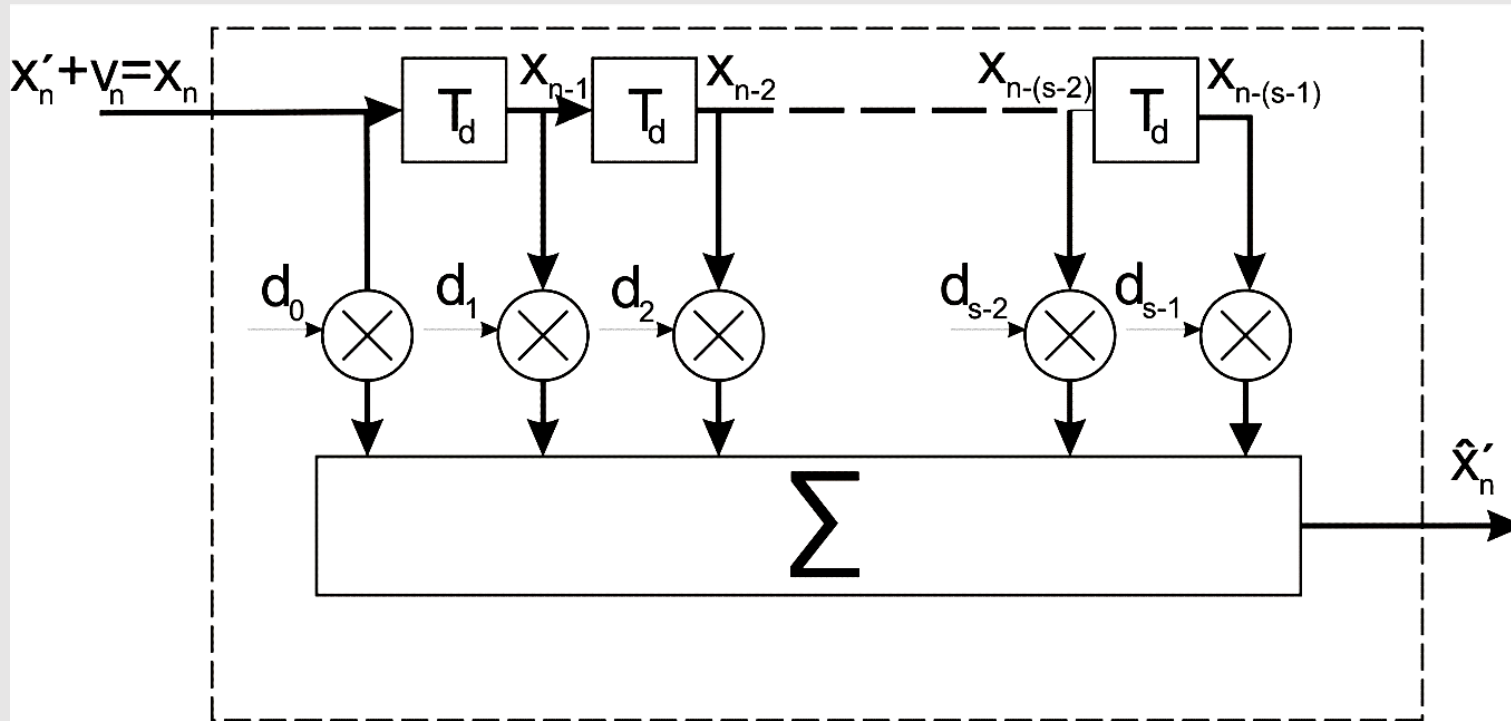
**Je zrejmé, že**

$$\frac{\sigma_v^2}{s + b} < \frac{\sigma_v^2}{s}$$

v prípade **optimálnej nerekurzívnej lineárnej estimácie** sa chyba zmenšuje aj vplyvom „b“ v menovateli.

# Nerekurzívna lineárna estimácia diskrétnych signálov

Pri tejto estimácii sa užitočná hodnota (vzorka)  $\hat{x}'_i$  spracovávanej **zašumenej vzorky**  $x_i = x'_i + v_i$  estimuje pomocou lineárnej kombinácie **tejto vzorky** a niekoľkých predchádzajúcich vzoriek zašumeného signálu:



$$\hat{X}'_n = \sum_{i=0}^{s-1} d_i X_{n-i}$$

Bloková schéma **nerekurzívneho lineárneho estimátora** (tj. **Wienerov filter**)  
s-tého rádu (k estimácii sa používa „s“ zašumených vzoriek)

# Rekurzívna lineárna estimácia parametrov

*Princíp rekurzívnej lineárnej estimácie spočíva v rekonštrukcii (oprave) minulých estimácií pomocou spracovávaných (prítomných) vzoriek zašumeného signálu.* Tým sa značne redukuje zložitosť a čas výpočtu

Vychádzajúc zo vzťahu pre optimálnu nerekurzívnu lineárnu estimáciu  $s+1$  rádu, ktorej zodpovedá stredná kvadratická chyba

$$\hat{A}_{s+1} = \sum_{i=1}^{s+1} d_i X_i \quad \sigma_e^2(s+1) = \frac{\sigma_v^2}{(s+1)+b} \quad \text{pričom } d_i = \frac{1}{(s+1)+b}$$

sa dá dokázať, že estimáciu  $\hat{A}_{s+1}$  je možné vypočítať rekurzívne z predchádzajúceho odhadu  $\hat{A}_s$  a aktuálnej zašumenej vzorky  $x_{s+1}$ .

$$\hat{A}_{s+1} = \frac{g_{s+1}}{g_s} \hat{A}_s + g_{s+1} X_{s+1} = h_{s+1} \hat{A}_s + g_{s+1} X_{s+1}$$

Kde pre  $g_s$  a  $g_{s+1}$  platí:

$$g_s = \frac{\sigma_e^2(s)}{\sigma_v^2}$$

$$g_{s+1} = \frac{g_s}{g_s + 1}$$

# Rekurzívna lineárna estimácia parametrov

$$\hat{A}_{s+1} = h_{s+1}\hat{A}_s + g_{s+1}X_{s+1}$$

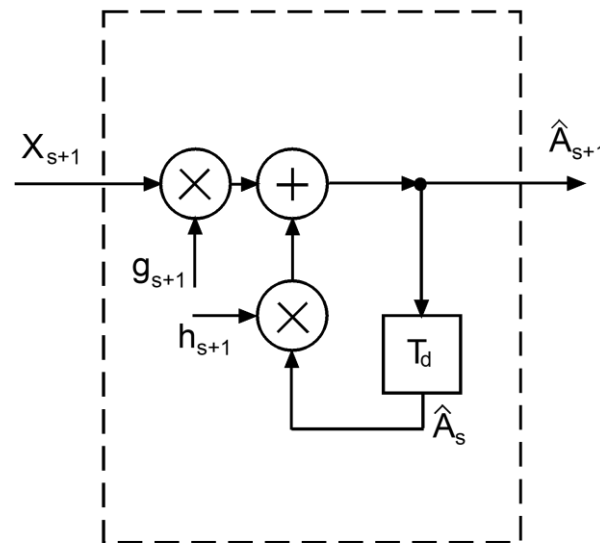
$$g_s = \frac{\sigma_e^2(s)}{\sigma_v^2}$$

$$g_{s+1} = \frac{g_s}{g_s + 1}$$

$$h_{s+1} = \frac{g_s + 1}{g_s}$$

z rov. vyplýva, že **estimačná amplitúda  $\hat{A}_{s+1}$**  sa získa **korekciou predchádzajúcej estimácie  $\hat{A}_s$**  a **rekonštrukciou prítomnej zašumenej vzorky  $X_{s+1}$**  pomocou **korekčného člena**.

- Normovaná stredná kvadratická estimačná chyba  $g_{s+1}$  sa znižuje s narastajúcim rádom „s“, pričom sa  $\hat{A}_{s+1}$  bude stabilizovať na určitej hodnote.
- Bloková schéma rekurzívneho lineárneho estimátora amplitúdy A je nasledovná:



# Rekurzívna lineárna estimácia parametrov

Rekurzívny algoritmus estimácie parametra môžeme výhodne použiť aj pri estimácii diskretných signálov. V tomto prípade sa bude jednať o **Kalmanovú filtráciu**.

Uvažujme stacionárny diskretný signál s nulovou strednou hodnotou, pričom tento budeme modelovať pomocou **autoregresívneho procesu prvého rádu**

$$X'_n = c X'_{n-1} + W_n$$

kde  $c$  je časová konštanta a  $W_n$  sú vzorky bieleho šumu v tomto procese

Ďalej predpokladajme zašumenie stacionárneho diskretného signálu, ktorý modelujeme s autoregresívnym procesom prvého rádu pomocou *aditívneho bieleho šumu*  $V_n$ , teda

$$X_n = X'_n + V_n$$

tento biely šum ( $V_n$ ) musíme odlišovať od bieleho šumu v modeli pre  $X'_n - (W_n)$

Rekurzívna lineárna estimácia diskretného signálu je opísaná rovnicou

$$\hat{X}'_n = h_n \hat{X}'_{n-1} + g_n X_n$$

# Rekurzívna lineárna estimácia parametrov

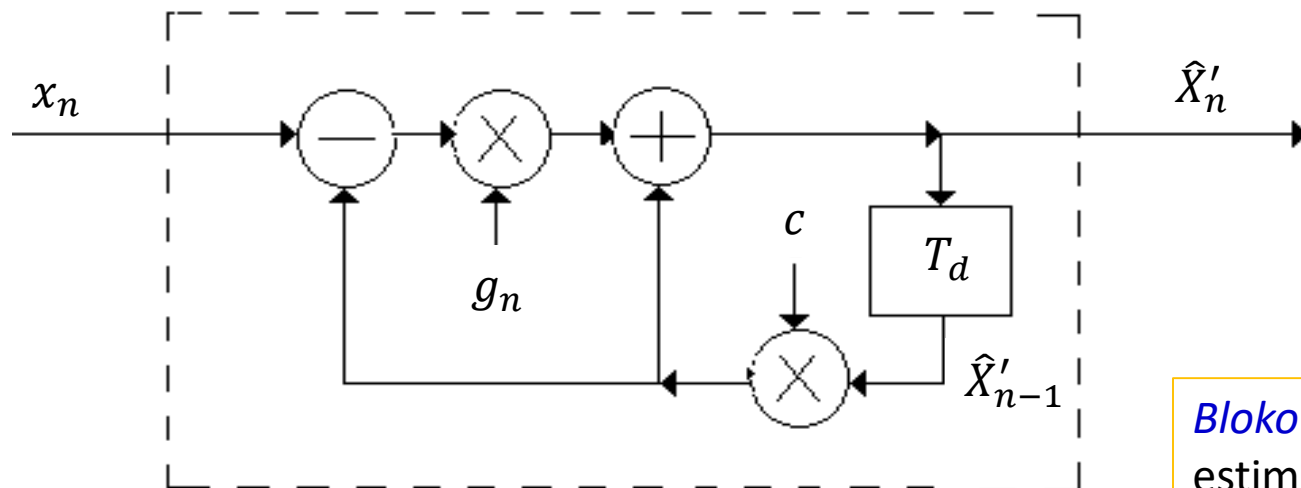
Rekurzívna lineárna estimácia diskrétného signálu je opísaná rovnicou, z ktorej vidno, že estimačná vzorka užitočného signálu  $\hat{X}'_n$  sa vypočíta pomocou predchádzajúcej estimácie užitočnej vzorky  $\hat{X}'_{n-1}$  a spracovávanej (prítomnej) zašumenej vzorky  $X_n$ .

$$\hat{X}'_n = h_n \hat{X}'_{n-1} + g_n X_n = c \hat{X}'_{n-1} + g_n (X_n - c \hat{X}'_{n-1})$$

$$h_n = c(1 - g_n)$$

reprezentuje *predikciu* vzorky užitočného signálu pomocou predchádzajúcich vzoriek signálu.

reprezentuje *korekciu*, ktorú vypočítame súčinom koeficientu  $g_n$  s rozdielom spracovávanej zašumenej vzorky  $X_n$  a predikčnej vzorky  $X_n$ .



*Bloková schéma* rekurzívneho lineárneho estimátora (**Kalmanovho filtra**)

# Rekurzívna lineárna estimácia parametrov

Rekurzívna lineárna estimácia diskrétného signálu je opísaná rovnicou, z ktorej vidno, že estimačná vzorka užitočného signálu  $\hat{X}'_n$  sa vypočíta pomocou predchádzajúcej estimácie užitočnej vzorky  $\hat{X}'_{n-1}$  a spracovávanej (prítomnej) zašumenej vzorky  $X_n$ .

$$\hat{X}'_n = h_n \hat{X}'_{n-1} + g_n X_n = c \hat{X}'_{n-1} + g_n (X_n - c \hat{X}'_{n-1}) \quad \leftarrow h_n = c(1 - g_n)$$

reprezentuje *predikciu* vzorky užitočného signálu pomocou predchádzajúcich vzoriek signálu.

reprezentuje *korekciu*, ktorú vypočítame súčinom koeficientu  $g_n$  s rozdielom spracovávanej zašumenej vzorky  $X_n$  a predikčnej vzorky  $X_n$ .

V procese *optimalizácie* rekurzívnej lineárnej estimácie **minimalizujeme strednú kvadratickú estimačnú chybu**

$$\sigma_e^2(n) = E \left[ (X'_n - \hat{X}'_n)^2 \right]$$

Výsledkom tohto sú časovo premenné koeficienty  $h_n$  a  $g_n$ .



