

Zapiski predavanj iz Digitalnega procesiranja signalov

Predaval: Dušan Kodek

18. januar 2000

Kazalo

0 Uvod	3
1 Teorija diskretnih, linearnih, časovno-invariantnih sistemov	3
1.1 Osnovni izrek za linearne, časovno-invariantne sisteme	4
1.2 Sistemi, ki so podani z diferenčnimi enačbami	5
1.3 Z -transformacija	6
1.4 Lastnosti Z -transformacije	6
1.5 Frekvenčni odziv diskretnega sistema	7
1.6 Fourierove "transformacije"	8
1.7 Vzorčenje	9
1.8 Izrek o jemanju vzorcev	10
1.9 Predstavitev signalov z ortogonalnimi funkcijami	11
1.10 Strukture za realizacijo diskretnih sistemov	12
2 Metode za načrtovanje digitalnih filtrov s končnim enotnim odzivom (KEO)	16
2.1 KEO digitalni filtri z linearno fazo	18
2.2 Načrtovanje z uporabo okenskih funkcij	21
2.2.1 Gibbsov pojav	21
2.2.2 Okenske funkcije	22
2.3 Načrtovanje z uporabo frekvenčnega vzorčenja	22
2.4 Načrtovanje optimalnih KEO filtrov z linearno fazo	23
2.4.1 Kriterij optimalnosti	24
2.4.2 Alternacijski izrek	24
2.4.3 Algoritem za določanje koeficientov $\alpha(k)$	25
2.4.4 Remezov algoritem	26
2.4.5 Splošen postopek načrtovanja filtrov	26
3 Metode za načrtovanje digitalnih filtrov z neskončnim enotnim odzivom (NEO filtri, IIR)	27
3.1 Načrtovanje z uporabo preslikave analognih filtrov	28
3.2 Preslikava z bilinearno transformacijo	30
3.3 Filtrske transformacije	31
3.4 Načrtovanje s Padejevo aproksimacijo	32
3.5 Načrtovanje z uporabo nelinerane optimizacije	32
3.6 Načrtovanje z uporabo lineranega programiranja (<i>simplex</i> algoritem) .	33

4 Decimacija in interpolacija	34
4.1 Decimacija	34
4.2 Interpolacija	34
5 FFT algoritem in njegova uporaba	36
5.1 Radix 2 algoritem, decimacija v času	37
5.2 Radix 4 algoritem	39
5.3 Računanje inverzne DFT	40
5.4 Računanje DFT za realna zaporedja	40
5.5 Hitro računanje konvolucije	41
5.5.1 Periodična zaporedja	41
5.5.2 Neperiodična zaporedja	42
5.5.3 Hitra konvolucija po odsekih	42
6 Križna korelacija in avtokorelacija	44
6.1 Avtokorelacija	44
6.2 Hitro računanje korelacije	44
6.2.1 Periodična zaporedja	44
6.2.2 Končno dolgi neperiodični zaporedji x, y	45
6.3 Detekcija signala v šumu	45
7 Spektralna analiza	46
7.1 Problem okna	47
7.2 Neparametrične metode za določanje spektra	48
7.3 Parametrične metode za določanje spektra	49
7.4 Primerjava LP spektra z neparametričnim spektrom	52

0 Uvod

Literatura:

- John G. Proakis, Dimitris G. Manolakis: *Digital Signal Processing: Principles, Algorithms and Applications*, 3rd edition, Prentice Hall, 1995
- L.R. Rabiner, B. Gold: *Theory and Applications of Digital Signal Processing*, Prentice Hall, Englewood Cliffs, 1975

Osnovni pojmi:

- Signal (lat. *signum*) je nekaj, kar služi za prenos informacij; optični, električni, ...
- Načini obdelave signalov:
 - analogni: občutljivi na toploto, staranje, vlogo
 - digitalni: matematična natančnost

Učni načrt:

1. Teorija diskretnih, linearnih, časovno-invariantnih sistemov
2. Digitalni filtri; dve vrsti:
 - (a) KEO (*FIR – finite impulse response*)
 - (b) NEO (*IIR – infinite impulse response*)
3. DFT in FFT algoritem
4. Spektralna analiza; spekter \equiv Fourierova analiza signalov

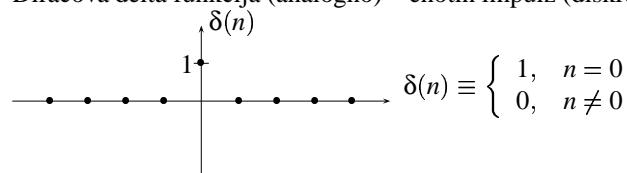
1 Teorija diskretnih, linearnih, časovno-invariantnih sistemov



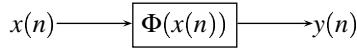
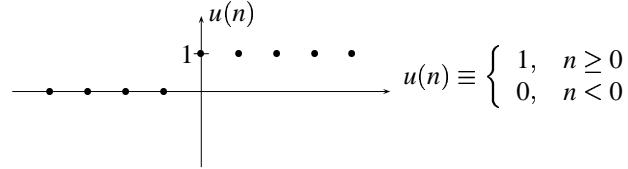
Signale predstavimo z zaporedji:

$$\begin{array}{ll} x(n), n = 0, \pm 1, \pm 2, \dots & -\text{diskretni signal} \\ x(t) & -\text{analogni signal} \end{array}$$

- Diracova delta funkcija (analogno) – enotin impulz (diskretno)



- enotina stopnica



$$y(n) = \Phi[x(n)]$$

- Linearen sistem:

$$y_1(n) \text{ odziv na } x_1(n)$$

$$y_2(n) \text{ odziv na } x_2(n)$$

$$ax_1(n) + bx_2(n) \longrightarrow ay_1(n) + by_2(n) \iff \text{sistem je linearen}$$

- Časovno invarianten sistem:

$$y(n) \text{ odziv na } x(n)$$

$$x(n-n_0) \longrightarrow y(n-n_0), n_0 \in \mathbb{Z} \iff \text{sistem je časovno invarianten}$$

Bolj splošen termin (ko n ni čas): invariantnost na pomik.

1.1 Osnovni izrek za linearne, časovno-invariantne sisteme

$$\delta(n) \longrightarrow \boxed{\quad} \longrightarrow h(n) - \text{odziv na enotin impulz}$$

$$x(n) \longrightarrow \boxed{h(n)} \longrightarrow y(n)$$

$$y(n) = \sum_{m=-\infty}^{+\infty} x(m)h(n-m) = \sum_{m=-\infty}^{+\infty} h(m)x(n-m)$$

Dokaz:

$$x(m) = x(n)\delta(n-m), \quad n = 0, \pm 1, \pm 2, \dots$$

$$x(m+1) = x(n)\delta(n-(m+1)), \quad n = 0, \pm 1, \pm 2, \dots$$

$$x(m+2) = x(n)\delta(n-(m+2)), \quad n = 0, \pm 1, \pm 2, \dots$$

$$\underline{x(m) = \sum_{n=-\infty}^{+\infty} x(n)\delta(n-m)}, \quad m = 0, \pm 1, \pm 2, \dots$$

odziv:

$$\frac{x(m)h(n-m) \quad x(m+1)h(n-(m+1)) \quad x(m+2)h(n-(m+2))}{\sum_{m=-\infty}^{+\infty} x(m)h(n-m)} \left. \right\} \text{ zaradi linearnosti in časovne inv.}$$

Q.E.D.

Lastna funkcija:

$$f(t) \xrightarrow{\quad} \boxed{\quad} \xrightarrow{\quad} a \cdot f(t - \tau) - \text{zakaj je sinusna napetost}$$

Lastnosti sistemov:

- Stabilnost sistema: na končni vhod dobimo končni izhod
Potreben in zadostni pogoj za stabilnost:

$$\sum_{n=-\infty}^{+\infty} |h(n)| < \infty$$

Dokaz:

– potrebnost:

$$\begin{aligned} \sum_{n=-\infty}^{+\infty} |h(n)| = \infty, \quad x(n) = \underbrace{\begin{cases} +1, & h(-n) \geq 0 \\ -1, & h(-n) < 0 \end{cases}}_{y(0)} \\ y(0) = \sum_{m=-\infty}^{+\infty} x(m)h(-m) = \sum_{m=-\infty}^{+\infty} |h(-m)| = \sum_{m=-\infty}^{+\infty} |h(m)| = \infty \end{aligned}$$

– zadostnost:

$$\begin{aligned} |x(n)| \leq M \\ |y(n)| = \left| \sum_{m=-\infty}^{+\infty} x(m)h(n-m) \right| \leq \sum_{m=-\infty}^{+\infty} |x(m)||h(n-m)| \leq \\ \leq M \sum_{m=-\infty}^{+\infty} |h(n-m)| < \infty \end{aligned}$$

Q.E.D.

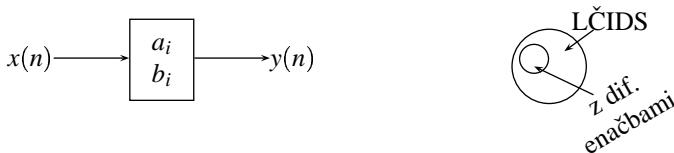
- Kavzalnost sistema: posledica ni pred vzrokom

Če je $h(n) = 0$ za $n < 0 \Rightarrow$ sistem je kavzalen
ali konstanta???

1.2 Sistemi, ki so podani z diferenčnimi enačbami

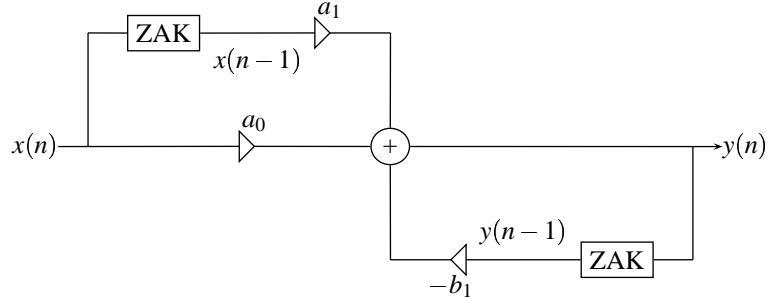
Diferenčne enačbe:

$$\begin{aligned} \sum_{i=0}^N b_i y(n-i) &= \sum_{i=0}^M a_i x(n-i) \\ y(n) &= \sum_{i=0}^M a_i x(n-i) - \sum_{i=1}^N b_i y(n-i), n \geq 0 \end{aligned}$$



1. nerekurzivne diferenčne enačbe: $b_1, b_2, \dots, b_N = 0$
2. rekurzivne diferenčne enačbe: vsaj en $b_i \neq 0$, $i = 1..N$

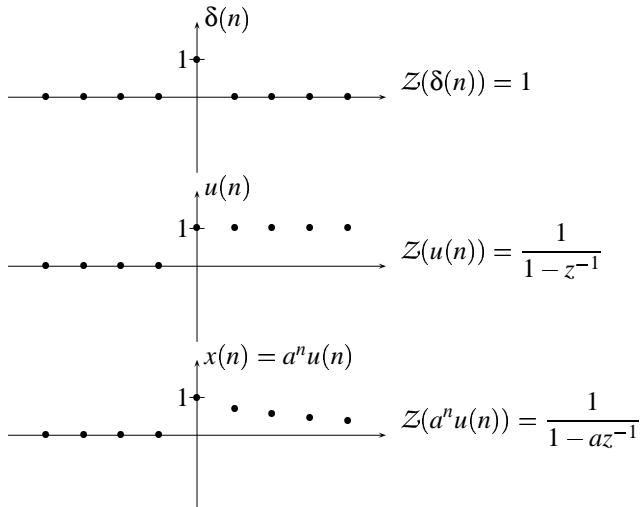
$$y(n) = a_0x(n) + a_1x(n-1) - b_1y(n-1)$$



1.3 Z-transformacija

$$X(z) = \sum_{n=-\infty}^{+\infty} x(n)z^{-n}, z \in \mathcal{C}$$

$$x(n) = \frac{1}{2\pi j} \oint_C X(z)z^{n-1} dz, j = \sqrt{-1} = i$$



1.4 Lastnosti Z-transformacije

1. linearnost:

$$X_1(z) = \sum_{n=-\infty}^{+\infty} x_1(n)z^{-n}$$

$$X_2(z) = \sum_{n=-\infty}^{+\infty} x_2(n)z^{-n}$$

$$\mathcal{Z}(ax_1 + bx_2) = aX_1(z) + bX_2(z)$$

2. premik:

$$\mathcal{Z}(x_1(n-k)) = z^{-k}X_1(z)$$

3. konvolucija:

$$\begin{aligned} y(n) &= \sum_{m=-\infty}^{+\infty} x(m)h(n-m) \\ Y(z) &= \sum_{n=-\infty}^{+\infty} \sum_{m=-\infty}^{+\infty} x(m)h(n-m)z^{-n} = \\ &= \underbrace{\sum_{m=-\infty}^{+\infty} x(m)z^{-m}}_{X(z)} \underbrace{\sum_{n=-\infty}^{+\infty} h(n-m)z^{-(n-m)}}_{H(z)} = \\ &= X(z) \cdot H(z) \\ H(z) &= \frac{Y(z)}{X(z)} \quad - \text{prevajalna funkcija} \end{aligned}$$

4. produkt:

$$y(n) = x(n)h(n)$$

$$\frac{1}{2\pi j} \oint X(u) H\left(\frac{z}{u}\right) u^{-1} du$$

1.5 Frekvenčni odziv diskretnega sistema

$$x(n) = A \cos(\omega_0 n + \Phi) \longrightarrow [h(n)] \longrightarrow y(n) = A' \cos(\omega_0 n + \Phi')$$

$$y(n) = \sum_{k=-\infty}^{+\infty} h(k)x(n-k)$$

$$x(n) = A \cos(\omega_0 n + \Phi) = \frac{A}{2} e^{j\Phi} e^{j\omega_0 n} + \frac{A}{2} e^{-j\Phi} e^{-j\omega_0 n}$$

$$y(n) = \frac{A}{2} e^{j\omega_0 n} e^{j\Phi} \sum_{k=-\infty}^{+\infty} h(k) e^{-j\omega_0 k} + \frac{A}{2} e^{-j\omega_0 n} e^{-j\Phi} \sum_{k=-\infty}^{+\infty} h(k) e^{j\omega_0 k}$$

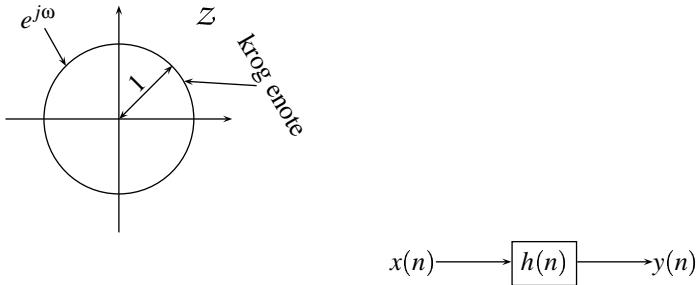
$$H(e^{j\omega}) \equiv \sum_{k=-\infty}^{+\infty} h(k) e^{j\omega k} = |H(e^{j\omega})| e^{j\Theta(e^{j\omega})} \quad - \text{frekvenčni odziv sistema}$$

Dokaz, da je sinusoidalna funkcija lastna funkcija diskretnih, linearnih, časovno-invariantnih sistemov:

$$y(n) = A |H(e^{j\omega_0})| \cos(\omega_0 n + \Phi + \Theta(e^{j\omega_0}))$$

Frekvenčni odziv: \mathcal{Z} -transformacija izračunana na krogu enote (na enotski krožnici):

$$X(z)|_{z=e^{j\omega}} = X(e^{j\omega}) = \sum_{k=-\infty}^{+\infty} x(k) e^{-j\omega k}$$



$$Y(z) = H(z)X(z)$$

$$Y(e^{j\omega}) = H(e^{j\omega})X(e^{j\omega}), \quad H(e^{j\omega}) = \frac{Y(e^{j\omega})}{X(e^{j\omega})}$$

1.6 Fourierove “transformacije”

1. zvezni signali

- periodični: $x(t) = x(t + nT)$, $n = 0, \pm 1, \pm 2, \dots$

$$\left. \begin{aligned} a_k &= \frac{1}{T} \int_0^T x(t) e^{-jk\frac{2\pi}{T}t} dt \\ x(t) &= \sum_{k=-\infty}^{+\infty} a_k e^{jk\frac{2\pi}{T}t} \end{aligned} \right\} \text{Fourierova vrsta}$$

- neperiodični:

$$\left. \begin{aligned} X(\Omega) &= \int_{-\infty}^{+\infty} x(t) e^{-j\Omega t} dt \\ x(t) &= \frac{1}{2\pi} \int_{-\infty}^{+\infty} X(\Omega) e^{j\Omega t} d\Omega \end{aligned} \right\} \begin{array}{l} \text{Fourierov integral ali} \\ \text{Fourierova transformacija} \end{array}$$

2. diskretni signali

- periodični: $x(t) = x(t + nN)$, $n = 0, \pm 1, \pm 2, \dots$

$$\left. \begin{aligned} a_n &= \frac{1}{N} \sum_{n=0}^{N-1} x(k) e^{-jk\frac{2\pi}{N}n} \\ x(k) &= \sum_{n=0}^{N-1} a_n e^{jk\frac{2\pi}{N}n} \end{aligned} \right\} \text{diskretno-časovna Fourierova transf.}$$

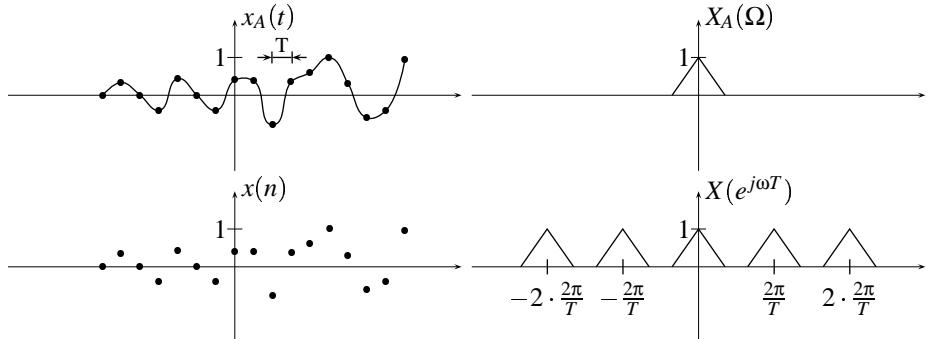
$$\left. \begin{aligned} X(n) &= \sum_{k=0}^{N-1} x(k) e^{-jk\frac{2\pi}{N}n} \\ x(k) &= \frac{1}{N} \sum_{n=0}^{N-1} X(n) e^{jk\frac{2\pi}{N}n} \end{aligned} \right\} \text{DFT – diskretna Fourierova transf.}$$

- neperiodični:

$$X(e^{j\omega}) = \sum_{k=-\infty}^{+\infty} x(k) e^{-j\omega k}$$

$$x(k) = \frac{1}{2\pi} \int_0^{2\pi} X(e^{j\omega}) e^{j\omega k} d\omega = \frac{T}{2\pi} \int_0^{\frac{2\pi}{T}} X(e^{j\omega T}) e^{j\omega T k} d\omega$$

1.7 Vzorčenje



$$\left. \begin{aligned} X_A(\Omega) &= \int_{-\infty}^{+\infty} x_A(t) e^{-j\Omega t} dt \\ x_A(t) &= \frac{1}{2\pi} \int_{-\infty}^{+\infty} X_A(\Omega) e^{j\Omega t} d\Omega \end{aligned} \right\} \text{za analogne}$$

$$\left. \begin{aligned} X(e^{j\omega T}) &= \sum_{n=-\infty}^{+\infty} x(n) e^{-j\omega T n} \\ x(n) &= \frac{T}{2\pi} \int_0^{\frac{2\pi}{T}} X(e^{j\omega T}) e^{j\omega T n} d\omega \end{aligned} \right\} \text{za diskretne}$$

$$\begin{aligned} x(n) &= x_A(nT) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X_A(\Omega) e^{j\Omega nT} d\Omega \\ &= \frac{1}{2\pi} \sum_{m=-\infty}^{+\infty} \int_{\frac{2m\pi}{T}}^{\frac{2(m+1)\pi}{T}} X_A(\Omega) e^{j\Omega nT} d\Omega \\ &= \frac{T}{2\pi} \int_0^{\frac{2\pi}{T}} \left(\frac{1}{T} \sum_{m=-\infty}^{+\infty} X_A \left(\omega + \frac{2\pi}{T} \cdot m \right) \right) e^{j\omega nT} d\omega \end{aligned}$$

$\Omega = \omega + \frac{2\pi}{T} \cdot m$

Iz primerjave sledi:
$$X(e^{j\omega T}) = \frac{1}{T} \sum_{m=-\infty}^{+\infty} X_A \left(\omega + \frac{2\pi}{T} \cdot m \right)$$

Torej: spekter vzorčenega signala je enak neskončni vsoti spektrov zamknjenih signalov.

1.8 Izrek o jemanju vzorcev

$$X_A(\Omega) = 0 \text{ za } |\Omega| > \frac{\pi}{T}$$

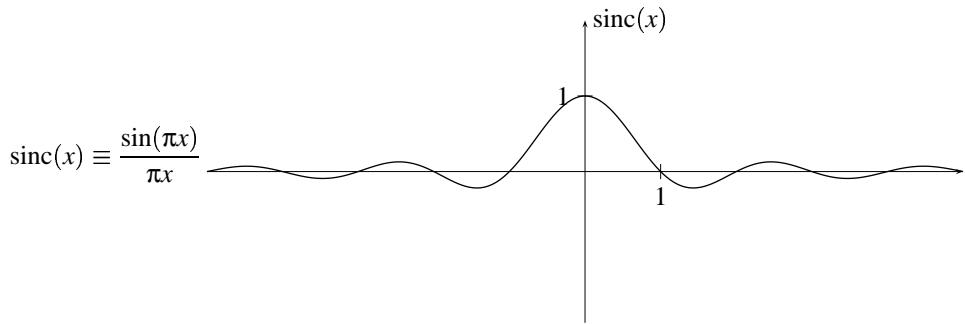
$$X(e^{j\omega T}) = \frac{1}{T} X(\omega) \text{ velja samo, če velja } -\frac{\pi}{T} \leq \omega \leq \frac{\pi}{T}$$

$$x_A(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X_A(\omega) e^{j\omega t} d\omega = \frac{1}{2\pi} \int_{-\frac{\pi}{T}}^{+\frac{\pi}{T}} X_A(\omega) e^{j\omega t} d\omega = \frac{T}{2\pi} \int_{-\frac{\pi}{T}}^{+\frac{\pi}{T}} X(e^{j\omega T}) e^{j\omega t} d\omega$$

$$X(e^{j\omega T}) = \sum_{n=-\infty}^{+\infty} x(n) e^{-j\omega T n} = \sum_{n=-\infty}^{+\infty} x_A(nT) e^{-j\omega T n}$$

$$x_A(t) = \frac{T}{2\pi} \int_{-\frac{\pi}{T}}^{+\frac{\pi}{T}} \left(\sum_{n=-\infty}^{+\infty} x(n) e^{-j\omega nT} \right) e^{j\omega t} d\omega = \sum_{n=-\infty}^{+\infty} x(n) \frac{T}{2\pi} \int_{-\frac{\pi}{T}}^{+\frac{\pi}{T}} e^{j\omega(t-nT)} d\omega, \quad x(n) = x_A(nT)$$

$x_A(t) = \sum_{n=-\infty}^{+\infty} x_A(nT) \underbrace{\frac{\sin(\frac{\pi}{T}(t-nT))}{\frac{\pi}{T}(t-nT)}}_{\text{sinc}\left(\frac{t}{T}-n\right)}$ – interpolacijska formula

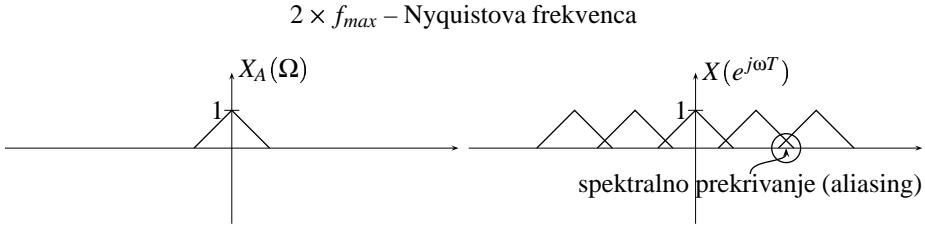


Pogoj za obratnost vzorčenja:

$$\frac{\pi}{T} \geq \text{najvišja frekvenca } (\Omega) \text{ vzorčenega signala}$$

oziroma

$$\frac{1}{T} = f_T > 2 \times \text{najvišja frekvenca vzorčenega signala}$$



Antialiasing filtri

Transformacijski par za predstavitev zveznega signala na diskreten način:

$$\boxed{x_A(t) = \sum_{n=-\infty}^{+\infty} c_n \Phi_n(t)}$$

$$c_n = x_A(nT)$$

$$\Phi_n(t) = \text{sinc}\left(\frac{t}{T} - n\right)$$

1.9 Predstavitev signalov z ortogonalnimi funkcijami

Množica funkcij $\{\Phi_k(t)\} = \{\Phi_{-\infty}(t), \dots, \Phi_{-1}(t), \Phi_0(t), \Phi_1(t), \dots, \Phi_\infty(t)\}$ je ortogonalna na intervalu t_0 do $t_0 + \tau$, če velja:

$$\int_{t_0}^{t_0+\tau} \Phi_m(t) \Phi_n(t) dt = \begin{cases} a, & m = n \\ 0, & m \neq n \end{cases}$$

$$x(t) = \sum_{k=-\infty}^{+\infty} c_k(t) \Phi_k(t)$$

$$c_k = \frac{1}{a} \int_{t_0}^{t_0+\tau} x(t) \Phi_k(t) dt$$

Dokaz:

$$\int_{t_0}^{t_0+\tau} x(t) \Phi_m(t) dt = \int_{t_0}^{t_0+\tau} \left(\sum_{k=-\infty}^{+\infty} c_k \Phi_k(t) \right) \Phi_m(t) dt = \sum_{k=-\infty}^{+\infty} c_k \int_{t_0}^{t_0+\tau} \Phi_k(t) \Phi_m(t) dt = c_m \cdot a$$

Q.E.D.

Druge družine ortogonalnih funkcij:

- Kaihunen-Loewe
- Fourier
- Walsh-Maclainard
- valčki (wavelet)
- Haav
- Legendre

Parsevalov izrek

Podaja zvezo med energijo (močjo) v časovnem in frekvenčnem prostoru in velja za vse ortogonalne funkcije.

$$x^2(t) = \sum_{k=-\infty}^{+\infty} c_k^2 \Phi_k(t) + \sum_{p=-\infty}^{+\infty} \sum_{\substack{q=-\infty \\ q \neq p}}^{+\infty} c_p c_q \Phi_p(t) \Phi_q(t)$$

$$\int_{t_0}^{t_0+\tau} x^2(t) dt = \underbrace{\sum_{k=-\infty}^{+\infty} c_k^2 \int_{t_0}^{t_0+\tau} \Phi_k^2(t) dt}_{a} + \underbrace{\sum_{p=-\infty}^{+\infty} \sum_{\substack{q=-\infty \\ q \neq p}}^{+\infty} c_p c_q \int_{t_0}^{t_0+\tau} \Phi_p(t) \Phi_q(t) dt}_{0}$$

$\frac{1}{\tau} \int_{t_0}^{t_0+\tau} x^2(t) dt = \frac{a}{\tau} \sum_{k=-\infty}^{+\infty} c_k^2$ – Parsevalov izrek

Parsevalov izrek govori o tem, kako je moč signala razporejena po koeficientih diskretnih predstavitev funkcije (oz. po spektru).

1.10 Strukture za realizacijo diskretnih sistemov

Za vsak LDČIS velja: $x(n) \rightarrow [h(n)] \rightarrow y(n)$

$$y(n) = \sum_{k=-\infty}^{+\infty} x(k) h(n-k) = \sum_{k=-\infty}^{+\infty} h(k) x(n-k)$$

$$Y(z) = H(z) \cdot X(z)$$

$$H(z) = \frac{\sum_{l=0}^M a_l z^{-l}}{1 + \sum_{l=1}^N b_l z^{-l}} = A \frac{\prod_{l=1}^M (1 - z_l z^{-1})}{\prod_{l=1}^N (1 - p_l z^{-1})}, \quad z_l, p_l \text{ – ničle, poli}$$

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{l=0}^M a_l z^{-l}}{1 + \sum_{l=1}^N b_l z^{-l}} \quad \text{– prevajalna funkcija} \quad (1)$$

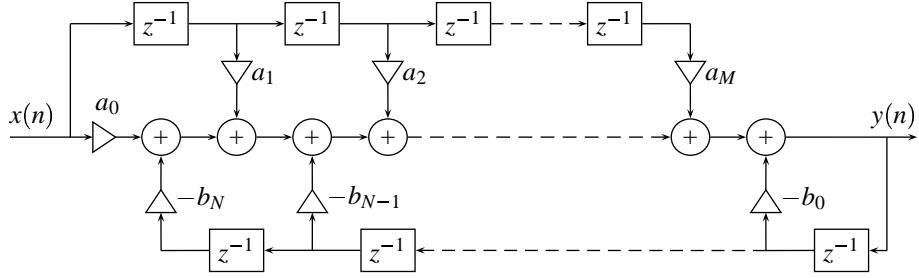
Navzkrižno pomnožimo:

$$\sum_{l=0}^M a_l z^{-l} X(z) = Y(z) \left(1 + \sum_{l=1}^N b_l z^{-l} \right)$$

$$\sum_{l=0}^M a_l x(n-l) = y(n) + \sum_{l=1}^N b_l y(n-l) \quad \text{– inverzna } Z\text{-transformacija gornje funkcije}$$

$$y(n) = \sum_{l=0}^M a_l x(n-l) - \sum_{l=1}^N b_l y(n-l) \quad \text{– diferenčna enačba za (1)}$$

Opisano je zelo enostaven postopek pretvorbe prevajalne funkcije v diferenčno enačbo. Prikaz z diagramom, direktna forma 1:



Če so vsi $b_i = 0$, potem je enačba nerekurzivna.

$$H(z) = \frac{Y(z)}{X(z)} = \underbrace{\left(\frac{1}{1 + \sum_{l=1}^N b_l z^{-l}} \right)}_{H_1(z)} \underbrace{\left(\sum_{l=0}^M a_l z^{-l} \right)}_{H_2(z)} = H_1(z) H_2(z)$$

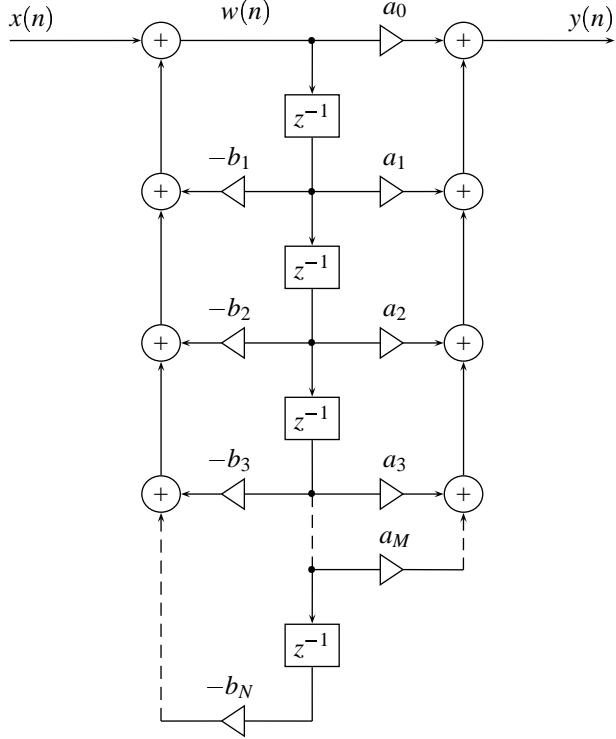
$$H_1(z) = \frac{W(z)}{X(z)} = \frac{1}{1 + \sum_{l=1}^N b_l z^{-l}}$$

$$H_2(z) = \frac{Y(z)}{W(z)} = \sum_{l=0}^M a_l z^{-l}$$

$$w(n) = x(n) - \sum_{l=1}^N b_l w(n-l)$$

$$y(n) = \sum_{l=0}^M a_l w(n-l)$$

Dobimo enostavnejšo direktno formo 2 (kanonična oblika):



Težave:

- pri kvantizaciji a_l, b_l hočemo porabiti čim manj bitov za reprezentacijo funkcije,
- že majhne napake pri koeficientih direktne forme zelo spremenijo potek prevajalne funkcije – občutljivost direktne forme na napake.

Občutljivost direktne forme na kvantizacijo koeficientov a_l, b_l :

$$\begin{aligned} a_l, b_l &\quad \text{– neskončno natančni koeficienti} \\ a_l^*, b_l^* &\quad \text{– kvantizirani koeficienti (končno število bitov)} \end{aligned}$$

$$a_l^* = a_l + \Delta a_l$$

$$b_l^* = b_l + \Delta b_l$$

$\Delta a_l, \Delta b_l$ – kvantizacijska napaka

$$P(z) = 1 + \sum_{l=1}^N b_l z^{-l} = \prod_{l=1}^N (1 - p_l z^{-l}), \quad p_l \text{ – poli}$$

$$p_l^* = p_l + \Delta p_l, \quad \Delta p_l \text{ – napaka v legi pola}$$

Če je majhna sprememba $b_l \rightarrow$ velika sprememba lege polov \rightarrow občutljivost

$$p_l = p_l(b_1, b_2, \dots, b_N)$$

$$P(z) = P(b_1, b_2, \dots, b_N) = P(p_1, p_2, \dots, p_N)$$

$$\Delta p_l = \sum_{k=1}^N \frac{\partial p_l}{\partial p_k} \Delta b_k$$

$$\frac{\partial P(z)}{\partial p_l} = \frac{\partial p_l}{\partial b_k} = \frac{\partial P(z)}{\partial b_k}$$

$$\frac{\partial p_l}{\partial b_k} = \frac{\frac{\partial P(z)}{\partial b_k}}{\frac{\partial P(z)}{\partial p_l}} = \frac{p_l^{N-k}}{\prod_{\substack{i=1 \\ i \neq l}}^N (p_l - p_i)}$$

$$\boxed{\Delta p_l = \sum_{k=1}^N \frac{p_l^{N-k}}{\prod_{\substack{i=1 \\ i \neq l}}^N (p_l - p_i)} \cdot \Delta b_k}$$

To je dokaz, da majhne spremembe b_i povzročijo velike spremembe p_l . Če sta dva (ali več) pola blizu skupaj, potem je faktor v vsoti velik.

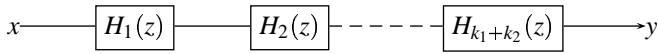
Kaskadna forma

$$H(z) = a_0 \prod_{l=1}^{k_1} H_{1l}(z) \cdot \prod_{l=1}^{k_2} H_{2l}(z)$$

$$H_{1l}(z) = \frac{1 + a_{1l}z^{-1}}{1 + b_{1l}z^{-1}}$$

$$H_{2l}(z) = \frac{1 + a_{1l}z^{-1} + a_{2l}z^{-2}}{1 + b_{1l}z^{-1} + b_{2l}z^{-2}}$$

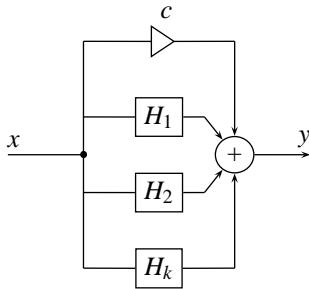
Realizacija:



Skupna občutljivost na kvantizacijske napake je bistveno manjša, ker so le-te omejene na posamezne H -je.

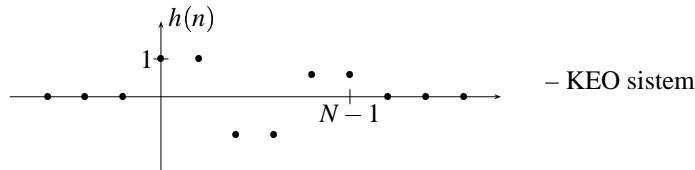
Paralelna forma

$$H(z) = c + \sum_{l=1}^k H_l(z)$$



2 Metode za načrtovanje digitalnih filtrov s končnim enotinim odzivom (KEO)

Če $h(n) = 0, n \geq N$, potem pravimo, da ima $h(n)$ končno dolžino.



Negativni indeksi so nič zaradi kavzalnosti sistema! Pri nerekurzivnih funkcijah imamo KEO sistem.

Lastnosti:

1. $H(z)$ nima polov (razen pri $z = 0$)

$$H(z) = \sum_{k=0}^{N-1} h(k)z^{-k}$$

2. sistem je vedno stabilen:

$$\sum_{k=0}^{N-1} |h(k)| = \text{končno}$$

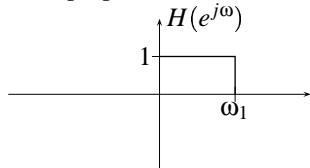
Kaj je to načrtovanje digitalnega filtra?

1. podan imamo želeni frekvenčni potek $H_d(e^{j\omega})$
2. podano imamo dolžino N
3. iščemo tak odziv na enotin impulz $h(n)$, da bo razlika $H(e^{j\omega}) - H_d(e^{j\omega})$ čim manjša (z večanjem N manjšamo le-to)

Koeficienti KEO filtra: $h(0), h(1), \dots, h(N-1)$.

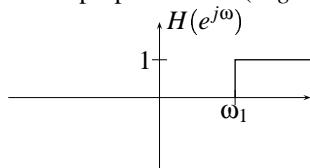
Štiri osnovne vrste filtrov (poleg teh štirih še veliko drugih):

- nizkopropustni filter (*Low-Pass*) LP

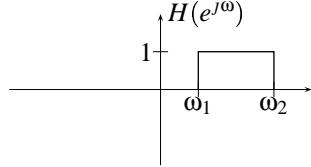


Primer: antialiasing filtri.

- visokopropustni filter (*High-Pass*) HP

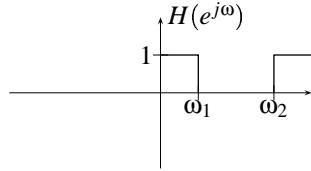


- pasovnopropustni filter (*Band-Pass*) BP

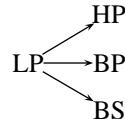


Primer: radio in televizija; širina pasu za radio: AM: 4.5 kHz, FM: 50 KHz (EU), 100 kHz (USA).

- pasovnozaporni filter (*Band-Stop*) BS



Obstajajo transformacije za preslikavo:



$H_d(e^{j\omega})$ je odsekoma konstantna funkcija.

Za KEO digitalne filtre velja $h(k) = 0$ za $k \geq N$, N = dolžina filtra. KEO filter je vedno stabilen, ker $\sum_{k=0}^{\infty} |h(k)|$ = končen.

$$H(e^{j\omega}) = \sum_{k=0}^{N-1} h(k)e^{-j\omega k} = |H(e^{j\omega})| \cdot e^{j\Theta(e^{j\omega})}$$

frekvenčni odziv amplitudni odziv fazni odziv (zakasnitev)

$$x(k) \longrightarrow [h(k)] \longrightarrow y(k), x(k) = A \cos(\omega k)$$

$$\begin{aligned} y(k) &= A \cdot |H(e^{j\omega})| \cdot \cos(\omega k + \Theta(e^{j\omega})) \\ &= A \cdot |H(e^{j\omega})| \cdot \cos\left(\omega\left(k + \underbrace{\frac{\Theta(e^{j\omega})}{\omega}}_{\Delta k}\right)\right) \end{aligned}$$

$$-\frac{\Theta(e^{j\omega})}{\omega} = \text{zakasnitev}$$

Linearna faza: $\Theta(\omega) = \alpha - \beta\omega$

$$\frac{\Theta(\omega)}{\omega} = \frac{\alpha}{\omega} - \beta$$

1. Filtri z linearno fazo

2. Filtri z nelinearno fazo



2.1 KEO digitalni filtri z linearno fazo

$$H(e^{j\omega}) = \sum_{k=0}^{N-1} h(k)e^{-j\omega k} \stackrel{\text{def}}{=} G(e^{j\omega})e^{j(\alpha-\beta\omega)}$$

realna funkcija (lahko tudi negativna)

Za realne $h(k)$:

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

konjugirano kompleksen

$$\begin{aligned}|H(e^{j\omega})| &= |H(e^{-j\omega})| \\ |G(e^{j\omega})| &= |G(e^{-j\omega})|\end{aligned}$$

Iz tega sledi, da je funkcija $G(e^{j\omega})$:

1. ali soda,
2. ali liha.

Primer:

$$1. G(e^{j\omega}) = G(e^{-j\omega}) \quad \text{soda funkcija}$$

$$H^*(e^{j\omega}) = G(e^{j\omega}) \cdot e^{-j(\alpha-\beta\omega)}$$

$$H(e^{-j\omega}) = G(e^{-j\omega}) \cdot e^{j(\alpha+\beta\omega)}$$

Zaradi $H^*(e^{j\omega}) = H(e^{-j\omega})$ sledi

$$\underbrace{G(e^{j\omega})}_{\text{isto}} e^{-j(\alpha-\beta\omega)} = \underbrace{G(e^{-j\omega})}_{\text{isto}} e^{j(\alpha+\beta\omega)}$$

$$e^{-j(\alpha-\beta\omega)} = e^{j(\alpha+\beta\omega)}$$

$$e^{-j\alpha} \cdot e^{j\beta\omega} = e^{j\alpha} \cdot e^{j\beta\omega}$$

$$\boxed{\alpha = 0}$$

$$2. G(e^{j\omega}) = -G(e^{-j\omega}) \quad \text{liha funkcija}$$

$$e^{-j\alpha} = -e^{j\alpha}$$

$$\boxed{\alpha = \frac{\pi}{2}}$$

Kakšen je β ?

- Za sodo funkcijo $G(e^{j\omega})$, $\alpha = 0$

$$\left\{ \begin{array}{l} G(e^{j\omega}) = H^*(e^{j\omega}) \cdot e^{j\beta\omega} \quad \text{- po definiciji} \\ G(e^{-j\omega}) = H(e^{-j\omega}) \cdot e^{-j\beta\omega} \end{array} \right.$$

$\rightarrow H(e^{j\beta\omega})e^{j\beta\omega} = H(e^{-j\omega})e^{-j\beta\omega}$

$$\left(\sum_{k=0}^{N-1} h(k) e^{-j\omega k} \right) e^{j\beta\omega} = \left(\sum_{k=0}^{N-1} h(k) e^{j\alpha k} \right) e^{-j\beta\omega} =$$

$$= e^{j(N-1-2\beta)\omega} \left(\sum_{k=0}^{N-1} h(N-1-k) e^{-j\omega k} \right) e^{j\beta\omega}$$

$$\boxed{\beta = \frac{N-1}{2}} \quad \boxed{\alpha = 0}$$

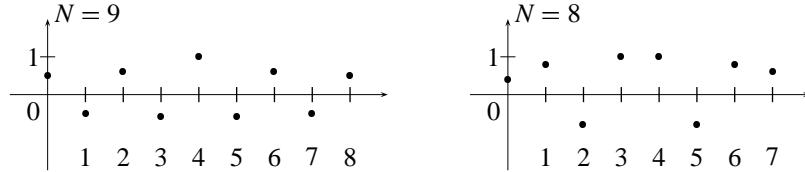
$$\boxed{h(k) = h(N-1-k)} \quad \text{– pozitivna simetrija}$$

- Za liho funkcijo $G(e^{j\omega}) = -G(e^{-j\omega})$

$$\boxed{\beta = \frac{N-1}{2}} \quad \boxed{\alpha = \frac{\pi}{2}}$$

$$\boxed{h(k) = -h(N-1-k)} \quad \text{– negativna simetrija}$$

Posledica linearne faze: pozitivna ali negativna simetrija $h(k)$



Sledi: polovica $h(k)$ je vnaprej določena, prostostna stopnja se zmanjša.
4 osnovni tipi KEO filterov z linearno fazo:

1. pozitivna simetrija ($G(e^{j\omega}) = G(-e^{j\omega})$), N = liho število

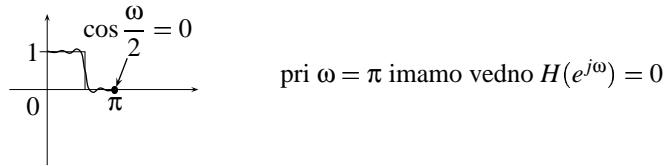
$$\begin{aligned} H(e^{j\omega}) &= e^{-j\omega \frac{N-1}{2}} \left(h\left(\frac{N-1}{2}\right) + \sum_{k=1}^{\frac{N-1}{2}} 2h\left(\frac{N-1}{2} - k\right) \cos(\omega k) \right) = \\ &= e^{-j\omega \frac{N-1}{2}} \underbrace{\sum_{k=0}^{\frac{N-1}{2}} a(k) \cos(\omega k)}_{\text{kosinusni polinom}} \\ a(0) &= h\left(\frac{N-1}{2}\right) \\ a(k) &= 2h\left(\frac{N-1}{2} - k\right), \quad k = 1, 2, \dots, \frac{N-1}{2} \end{aligned}$$

Kosinusni polinom:

$$\cos(\omega k) = \sum_{l=1}^k \alpha_l \cos^l \omega = \sum_{l=1}^k \alpha_l x^l$$

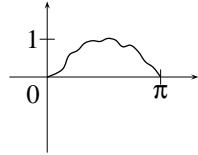
2. pozitivna simetrija, $N =$ sodo število

$$\begin{aligned} H(e^{j\omega}) &= e^{-j\omega \frac{N-1}{2}} \sum_{k=0}^{\frac{N-1}{2}-1} 2h\left(\frac{N}{2} - 1 - k\right) \cdot \cos\left(\omega\left(k + \frac{1}{2}\right)\right) = \\ &= e^{-j\omega \frac{N-1}{2}} \cos\frac{\omega}{2} \sum_{k=0}^{\frac{N}{2}-1} b(k) \cos(\omega k) \end{aligned}$$



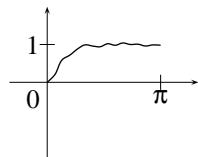
3. negativna simetrija, $N =$ liho število ($\alpha = \frac{\pi}{2}$)

$$\begin{aligned} H(e^{j\omega}) &= e^{-j\omega \frac{N-1}{2}} e^{j\frac{\pi}{2}} \left(e^{-j\frac{\pi}{2}} \underbrace{h\left(\frac{N-1}{2}\right)}_{0, \text{sicer } G(e^{j\omega}) \text{ ni liha}} + \sum_{k=1}^{\frac{N-1}{2}} 2h\left(\frac{N-1}{2}\right) \sin(\omega k) \right) = \\ &= e^{-j\omega \frac{N-1}{2}} e^{j\frac{\pi}{2}} \sin \omega \sum_{k=0}^{\frac{N-3}{2}} c(k) \cos(\omega k) \end{aligned}$$



4. negativna simetrija, $N =$ sodo število

$$\begin{aligned} H(e^{j\omega}) &= e^{-j\omega \frac{N-1}{2}} e^{j\frac{\pi}{2}} \left(\sum_{k=0}^{\frac{N}{2}-1} 2h\left(\frac{N}{2} - 1 - k\right) \sin \omega \left(k + \frac{1}{2}\right) \right) = \\ &= e^{-j\omega \frac{N-1}{2}} e^{j\frac{\pi}{2}} \sin \frac{\omega}{2} \sum_{k=0}^{\frac{N}{2}-1} d(k) \cos(\omega k) \end{aligned}$$



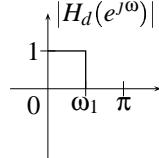
$Q(\omega)$	$P(\omega)$
1,	
$\cos\frac{\omega}{2},$	
$\sin\omega,$	$\sum_{k=0}^n d(k) \cos(\omega k)$
$\sin\frac{\omega}{2}$	

2.2 Načrtovanje z uporabo okenskih funkcij

$H_d(e^{j\omega})$ želeni frekvenčni potek

$$H_d(e^{j\omega}) = \sum_{k=-\infty}^{+\infty} h_d(k) e^{-j\omega k}$$

$$h_d(k) = \frac{1}{2\pi} \int_0^{2\pi} H_d(e^{j\omega}) e^{j\omega k} d\omega$$



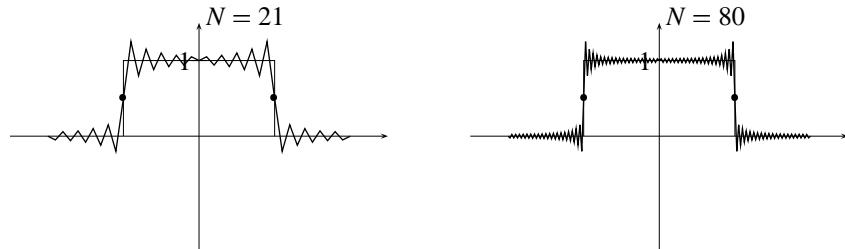
Problem: $h_d(k)$ je neskončno dolg, če vsebuje $H_d(e^{j\omega})$ nezveznosti. Rešitev:

$$h(k) = \begin{cases} h_d(k) & k = 0, 1, \dots, N-1 \\ 0 & \text{drugod} \end{cases} \quad (2)$$

filter s končnim enotnim odzivom

2.2.1 Gibbsov pojav

1898, Albert Michelson s harmoničnim analizatorjem ugotovil posledice enačbe (2):



Gibbsov pojav: v točkah nezveznosti je vedno (za vsak končen N) 9% odstopanja (funkcija gre skozi sredino stopnice).

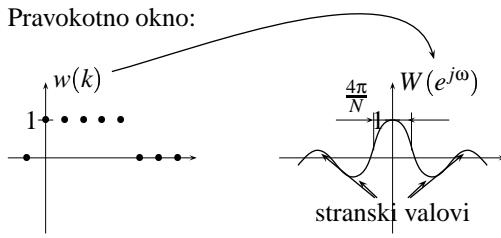
Kako razložimo?

$$h(k) = h_d(k) \cdot w(k)$$

$$w(k) = \begin{cases} 1 & k = 0, 1, \dots, N-1 \\ 0 & \text{drugod} \end{cases} \quad - \text{pravokotno okno}$$

$$H(e^{j\omega}) = \frac{1}{2\pi} \int_0^{2\pi} H_d(e^{j\Theta}) W(e^{j(\omega-\Theta)}) d\Theta \quad - \text{konvolucijski integral}$$

$$W(e^{j\omega}) = \sum_{k=-\infty}^{+\infty} w(k) e^{-j\omega k} = e^{-j\omega \frac{N-1}{2}} \underbrace{\frac{\sin \frac{\omega N}{2}}{\sin \frac{\omega}{2}}}_{\text{digitalni sinc}}$$

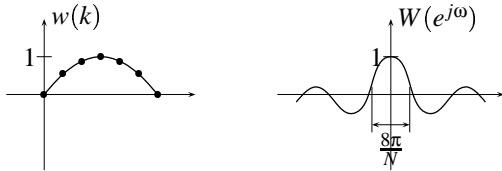


Stranski valovi povzročijo Gibsov pojav. Funkcija brez valov je δ , vendar jo povzroči neskončno pravokotno okno. Torej iščemo funkcije s čim manjšimi valovi.

2.2.2 Okenske funkcije

1. von Hannovo okno:

$$w(k) = 0.5 - 0.5 \cdot \cos\left(\frac{2\pi k}{N-1}\right)$$



Valovi so manjši, vendar je okno širše.

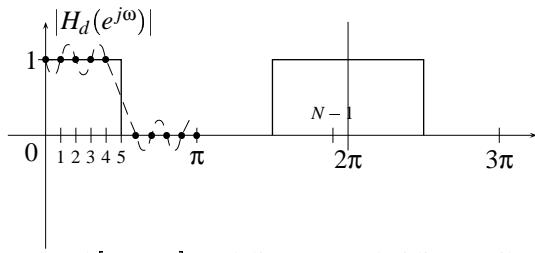
2. Hammingovo okno:

$$w(k) = 0.54 - 0.46 \cdot \cos\left(\frac{2\pi k}{N-1}\right)$$

Podobno je von Hannovemu oknu.

3. Kaiserjeva okna (optimalna): v stranskih valovih imajo najmanj energije.
4. Dulph-Čebiševovo okno
5. Bartlettovo okno
6. Trikotno okno

2.3 Načrtovanje z uporabo frekvenčnega vzorčenja



Interval $[0 \dots 2\pi]$ razdelimo na N ekvidistančnih točk.

$$H_d(e^{j\omega_k}), \quad \omega_k = \frac{2\pi}{N} \cdot k, \quad k = 0, 1, \dots, N-1$$

$$H_d(e^{j\omega}) = \sum_{n=0}^{N-1} h(n) e^{-j\omega n}$$

Zanimajo nas točke $\omega = \omega_k$:

$$H_d(e^{j\frac{2\pi}{N}k}) = \sum_{n=0}^{N-1} h(n) e^{-\frac{2\pi jnk}{N}} \quad \leftarrow \text{DFT: } H_d(k) = \sum_{n=0}^{N-1} h(n) e^{-\frac{2\pi jnk}{N}}$$

$$h(n) = \frac{1}{N} \sum_{k=0}^{N-1} H_d(k) e^{\frac{2\pi jkn}{N}} \quad \leftarrow \text{inverzna DFT (IDFT)}$$

$$\begin{aligned} H(z) &= \sum_{n=0}^{N-1} h(n) z^{-n} = \sum_{n=0}^{N-1} \left(\frac{1}{N} \sum_{k=0}^{N-1} H_d(k) e^{\frac{2\pi jkn}{N}} \right) z^{-n} = \\ &= \sum_{k=0}^{N-1} \frac{H_d(k)}{N} \sum_{n=0}^{N-1} \left(e^{\frac{2\pi jk}{N}} \cdot z^{-1} \right)^n = \\ &= \sum_{k=0}^{N-1} \frac{H_d(k)}{N} \cdot \underbrace{\frac{1 - e^{2\pi jk}}{1 - e^{\frac{2\pi jk}{N}} \cdot z^{-1}}}_{=1} = \\ &= \frac{1 - z^{-N}}{N} \sum_{k=0}^{N-1} \frac{H_d(k)}{1 - z^{-1} e^{\frac{2\pi jk}{N}}} \end{aligned}$$

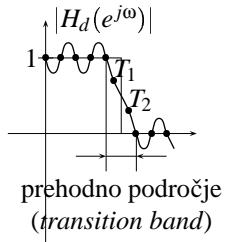
$$H(e^{j\omega}) = H(z)|_{z=e^{j\omega}}$$

$$H(e^{j\omega}) = e^{\frac{-j\omega(N-1)}{2}} \sum_{k=0}^{N-1} H_d(e^{j\omega_k}) e^{j2\pi k \frac{N-1}{2N}} \cdot \underbrace{\frac{\sin(N(\frac{\omega}{2} - \frac{\pi k}{N}))}{N \cdot \sin(\frac{\omega}{2} - \frac{\pi k}{N})}}_{\text{digitalni sinc: } \frac{\sin(Nx)}{N \sin x}}$$

Pri linearni fazi:

$$H_d(e^{j\omega_k}) = |H_d(e^{j\omega_k})| e^{-j2\pi k \frac{N-1}{2N}}$$

$$H(e^{j\omega}) = e^{\frac{-j\omega(N-1)}{2}} \sum_{k=0}^{N-1} |H_d(e^{j\omega_k})| \underbrace{\frac{\sin(N(\frac{\omega}{2} - \frac{\pi k}{N}))}{N \cdot \sin(\frac{\omega}{2} - \frac{\pi k}{N})}}_{\text{povzroča "valove" } \rightarrow \text{slab filter}}$$



T_1, T_2 sta frekvenci v prehodnem področju.

Ideja metode: položaj $H(e^{j\omega})$ za $\omega = \omega_{T_1}, \omega_{T_2}$ ni pomemben. Imamo: 1,2 ali 3 točke, v katerih $|H(e^{j\omega})|$ lahko spremenjamo. Pametna izbira $|H(e^{j\omega})|_{\omega=\omega_{T_1}, \omega_{T_2}, \omega_{T_3}}$ močno zmanjša valove.

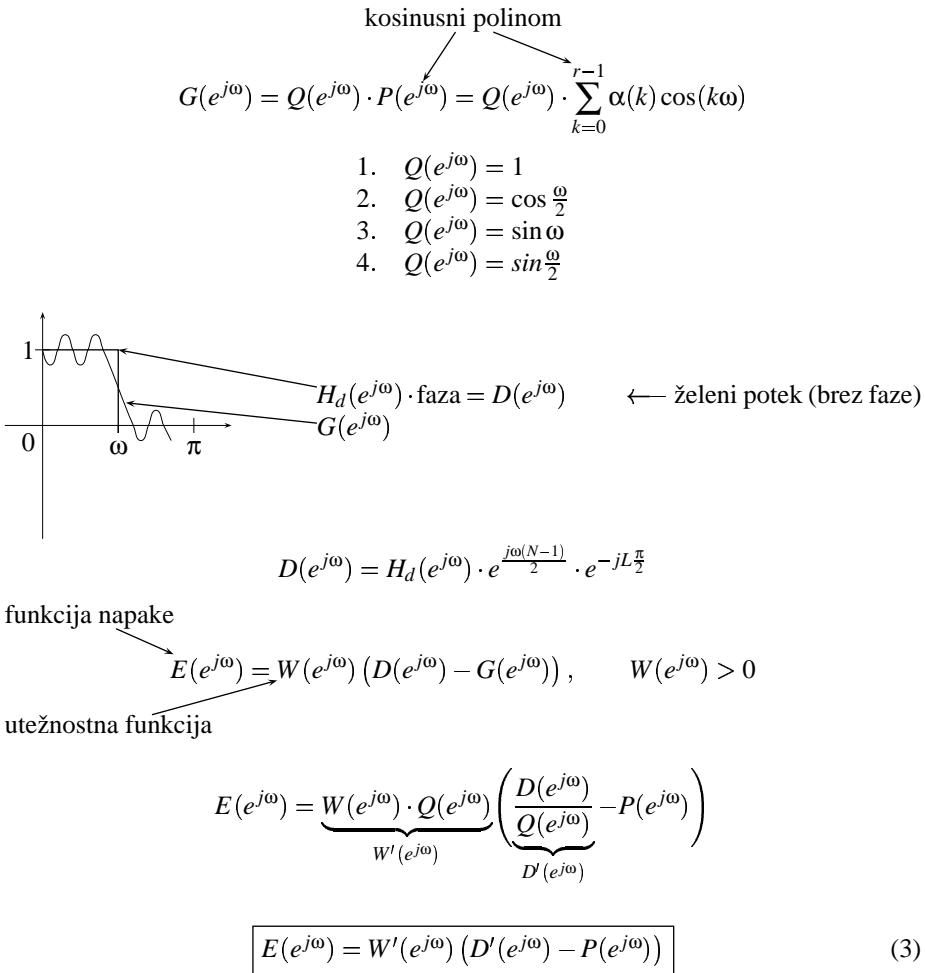
Kje dobimo pametno izbiro? Obstajajo tabele.

2.4 Načrtovanje optimalnih KEO filtrov z linearno fazo

$$H(e^{j\omega}) = e^{\frac{-j\omega(N-1)}{2}} e^{jL\frac{\pi}{2}} G(e^{j\omega})$$

$L = 0$ pri pozitivni simetriji

$L = 1$ pri negativni simetriji



Enačba (3) je poenotenje štirih tipov filtrov na isti aproksimacijski problem.

2.4.1 Kriterij optimalnosti

aproksimacijski problem

$$\|E(e^{j\omega})\|_\infty = \min_{\{\alpha\}} \left(\max_{\omega \in \Omega} |W'(e^{j\omega}) (D'(e^{j\omega}) - P(e^{j\omega}))| \right), \quad \Omega \subseteq (0, \pi)$$

– Čebiševa norma (mat.), minimax (teh.), L_∞ norma, enakomerna aproksimacija

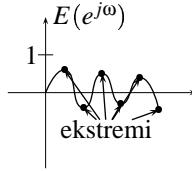
2.4.2 Alternacijski izrek

Naj bo $P(e^{j\omega})$ kosinusni polinom:

$$P(e^{j\omega}) = \sum_{k=0}^{r-1} \alpha(k) \cos(k \cdot \omega)$$

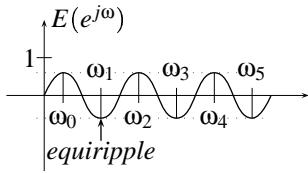
Potreben in zadosten pogoj za optimalno aproksimacijo je, da ima funkcija napake $E(e^{j\omega})$:

1. najmanj $r + 1$ ekstremov:



2. če so $0 \leq \omega_0 < \omega_1 < \omega_2 < \dots < \omega_r \leq \pi$ točke, v katerih je ekstrem (ekstremalne frekvence), potem velja:

$$E(e^{j\omega_i}) = -E(e^{j\omega_{i+1}}), \quad i = 0, 1, \dots, r-1$$



$$|E_{\max}| = |E(e^{j\omega_i})|, \quad i = 0, 1, \dots, r-1$$

Funkcija napake:

$$E(e^{j\omega}) = W'(e^{j\omega}) (D'(e^{j\omega}) - P(e^{j\omega})), \quad P(e^{j\omega}) = \sum_{k=0}^{r-1} \alpha(k) \cos(k\omega)$$

2.4.3 Algoritem za določanje koeficientov $\alpha(k)$

Remezov algoritmom; leta 1972 sta ga uporabila Parks & McClellan

1. Predpostavimo, da poznamo ekstremalne frekvence $\omega_0, \omega_1, \dots, \omega_r$. Potem velja sistem enačb:

$$W'(e^{j\omega_k}) (D'(e^{j\omega_k}) - P(e^{j\omega_k})) = (-1)^k \delta, \quad k = 0, 1, \dots, r$$

(drugače zapisan alternacijski izrek)

$$D'(e^{j\omega_k}) = \frac{(-1)^k}{W'(e^{j\omega_k})} \cdot \delta + \sum_{i=0}^{r-1} \alpha(i) \cos(i\omega_k), \quad k = 0, 1, \dots, r$$

$$\begin{bmatrix} 1 & \cos \omega_0 & \cos(2\omega_0) & \cdots & \cos((r-1)\omega_0) & \frac{1}{W'(e^{j\omega_0})} \\ 1 & \cos \omega_1 & \cos(2\omega_1) & \cdots & \cos((r-1)\omega_1) & \frac{-1}{W'(e^{j\omega_1})} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & \cos \omega_r & \cos(2\omega_r) & \cdots & \cos((r-1)\omega_r) & \frac{(-1)^r}{W'(e^{j\omega_r})} \end{bmatrix} \begin{bmatrix} \alpha(0) \\ \alpha(1) \\ \vdots \\ \alpha(r-1) \\ \delta \end{bmatrix} = \begin{bmatrix} D'(e^{j\omega_0}) \\ D'(e^{j\omega_1}) \\ \vdots \\ D'(e^{j\omega_r}) \end{bmatrix}$$

Če poznamo $\omega_0, \omega_1, \dots, \omega_r$, lahko izračunamo $\alpha(0), \alpha(1), \dots, \alpha(r-1)$ in δ . Problem: ne poznamo jih. Uporabimo trik:

2. δ je mogoče izračunati, ker imamo Van der Modejevo determinanto:

$$\begin{vmatrix} 1 & x_0 & x_0^2 & x_0^3 & \cdots \\ 1 & x_1 & x_1^2 & x_1^3 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{vmatrix}$$

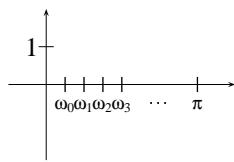
$$\delta = \frac{\gamma_0 D'(e^{j\omega_0}) + \gamma_1 D'(e^{j\omega_1}) + \cdots + \gamma_r D'(e^{j\omega_r})}{\frac{\gamma_0}{W'(e^{j\omega_0})} - \frac{\gamma_1}{W'(e^{j\omega_1})} + \cdots + \frac{(-1)^r \gamma_r}{W'(e^{j\omega_r})}}, \quad \gamma_k = \frac{1}{\prod_{\substack{n=0 \\ n \neq k}}^r (\cos \omega_k - \cos \omega_n)}$$

3. Uporabimo interpolacijski polinom, ki gre skozi točke

$$D'(e^{j\omega_k}) - \frac{(-1)^k \delta}{W'(e^{j\omega_k})}$$

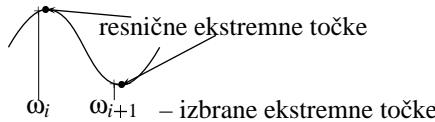
2.4.4 Remezov algoritem

1. Izberemo ekstremalne frekvence $\omega_0, \omega_1, \dots, \omega_r$. Najboljša izbira je ekvidistančna.



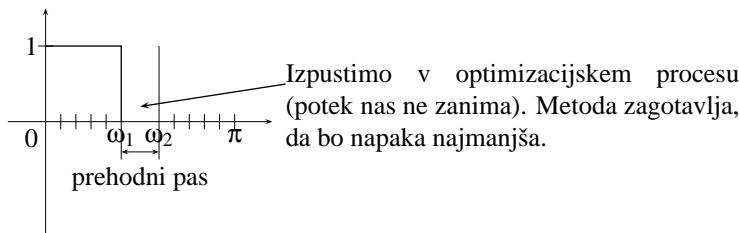
2. Izračunamo δ .

3. Potegnemo interpolacijski polinom skozi δ



4. Poiščemo resnične ekstremalne frekvence $\omega'_0, \omega'_1, \dots, \omega'_r$ (iz polinoma).

5. Če so resnične ekstremalne frekvence enake prejšnjim, imamo rešitev; sicer vzmemo $\omega_k = \omega'_k$ in se vrnemo na korak 2.



$$\Omega = (0, \omega_1) \cup (\omega_2, \pi)$$

Izberemo gosto diskretno množico točk (tipično $10 \cdot r$).

2.4.5 Splošen postopek načrtovanja filtrov

1. Potrebujemo $D(\omega)$ (želeni potek), po potrebi tudi $W(\omega)$ (utežnostna funkcija).
2. Izberemo dolžino filtra N (stopnja polinoma).
3. Izračunamo koeficiente filtra (npr. optimalne).
4. Preverimo napako (razlika med želenim $D(\omega)$ in resničnim $G(\omega)$).
5. Po potrebi popravimo N in ponovimo postopek od 3. koraka naprej.

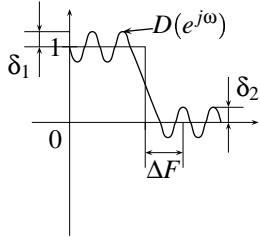
Približna formula za N :

$$D_\infty(\delta_1, \delta_2) = (N-1)\Delta F + f(\delta_1, \delta_2)\Delta F^2$$

$$f(\delta_1, \delta_2) = b_1 + b_2(\log_{10} \delta_1 - \log_{10} \delta_2)$$

$$D_\infty(\delta_1, \delta_2) = (a_1 \log_{10}^2 \delta_1 + a_2 \log_{10} \delta_1 + a_3) \log_{10} \delta_2 + (a_4 \log_{10}^2 \delta_1 + a_5 \log_{10} \delta_1 + a_6)$$

$$\left. \begin{array}{c} a_1, \dots, a_6 \\ b_1, b_2 \end{array} \right\} \text{v knjigi}$$



3 Metode za načrtovanje digitalnih filtrov z neskončnim enotnim odzivom (NEO filtri, IIR)

$$H(z) = \frac{\sum_{l=0}^M a_l z^{-l}}{1 + \sum_{l=1}^N b_l z^{-l}}$$

Če niso vsi $b_l = 0 \Rightarrow$ neskončni enotni odziv $h(n)$

Pogoj za linearno fazo: $h(n) = \pm h(N-n)$

$$\begin{aligned} H(z) &= \sum_{n=0}^{N-1} h(n)z^{-n} = \\ &= h(0) + h(1)z^{-1} + \dots + h(2)z^{-(N-3)} + h(1)z^{(N-2)} + h(0)z^{-(N-1)} = \\ &= z^{-\frac{N-1}{2}} \underbrace{\left(h(0)(z^{\frac{N-1}{2}} + z^{-\frac{N-1}{2}}) + h(1)(z^{\frac{N-3}{2}} + z^{-\frac{N-3}{2}}) + \dots \right)}_{\text{enako}} \\ H(z^{-1}) &= z^{\frac{M-1}{2}} \overbrace{\left(h(0)(z^{\frac{N-1}{2}} + z^{-\frac{N-1}{2}}) + h(1)(z^{\frac{N-3}{2}} + z^{-\frac{N-3}{2}}) + \dots \right)} \\ H(z^{-1}) &= z^{(N-1)} H(z) \quad \text{pozitivna simetrija} \\ H(z^{-1}) &= -z^{(N-1)} H(z) \quad \text{negativna simetrija} \end{aligned}$$

Vzemimo, da je $z_i = r_i e^{j\Theta_i}$ pol od $H(z) \Rightarrow z_i^{-1}$ je tudi pol: $\frac{1}{z_i} = \frac{1}{r_i} e^{-j\Theta_i}$.

Če je $r_i < 0 \Rightarrow \frac{1}{r_i} > 1$.

Če imamo pole (razen pri 0), je sistem pri linearni fazi vedno **nestabilen**. Optimiziramo:

1. Močnostni odziv

$$|H(e^{j\omega})|^2 = |H(z)H(z^{-1})| \Big|_{z=e^{j\omega}}$$

2. Fazni odziv, v dveh oblikah:

(a)

$$H(e^{j\omega}) = |H(e^{j\omega}| e^{j\beta(e^{j\omega})}$$

$$H(e^{-j\omega}) = |H(e^{j\omega})| e^{-j\beta(e^{j\omega})}$$

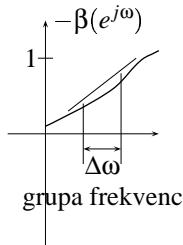
$$\beta(e^{j\omega}) = \frac{1}{2j} \ln \left(\frac{H(z)}{H(z^{-1})} \right) \quad - \text{fazni odziv pri } z = e^{j\omega}$$

(b) grupna zakasnitev

$$\tau_g(e^{j\omega}) = -\frac{d\beta(e^{j\omega})}{d\omega} = -jz \frac{d\beta}{dz} \Big|_{z=e^{j\omega}}$$

slednje pride iz

$$\frac{d\beta(e^{j\omega})}{d\omega} = \frac{d\beta(e^{j\omega})}{d(e^{j\omega})} \cdot j \cdot e^{j\omega}$$



$$\tau_g(e^{j\omega}) = -\operatorname{Re} \left(z \frac{\frac{dH(z)}{dz}}{H(z)} \right)_{z=e^{j\omega}}$$

1. močnostni odziv – najbolj pogost (90%)
2. močnostni odziv +β
3. močnostni odziv +τ_g

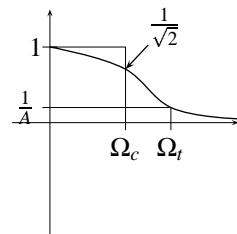
3.1 Načrtovanje z uporabo preslikave analognih filtrov

Tri najpogostejše vrste analognih filtrov:

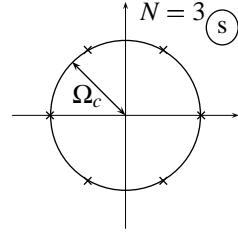
1. Butterworthovi filtri

$$|H_a(s)|^2 = \frac{1}{1 + \left(\frac{s}{j\Omega_c}\right)^{2N}}$$

$$N = \frac{\log_{10}(A^2 - 1)}{2 \log_{10} \frac{\Omega_t}{\Omega_c}}$$



- ima samo pole (nima ničel)
- monotono padajoča funkcija
- poli so na krožnici s polmerom Ω_c



$$H(s) = \frac{\sum_{l=0}^M a_l s^{-l}}{1 + \sum_{l=1}^N b_l s^{-l}} \quad - \text{splošen analogen filter, } s = \text{Laplaceov operator}$$

2. Čebiševi filtri

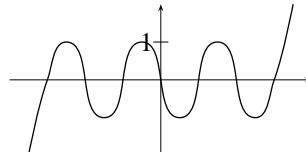
Tip 1

$$|H_a(s)|^2 = \frac{1}{1 + \varepsilon^2 T_N\left(\frac{s}{j\Omega_c}\right)}$$

$$T_N(x) = \begin{cases} \cos(N \cdot \arccos x) & \text{za } |x| \leq 1 \\ \cosh(N \cdot \operatorname{Arch} x) & \text{za } |x| > 1 \end{cases}$$

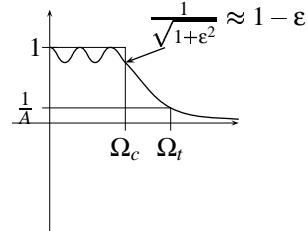
Čebiševi polinomi:

$$\begin{aligned} T_0(x) &= 1 \\ T_1(x) &= x \\ \dots \\ T_{N+1}(x) &= 2xT_N(x) - T_{N-1}(x) \end{aligned}$$

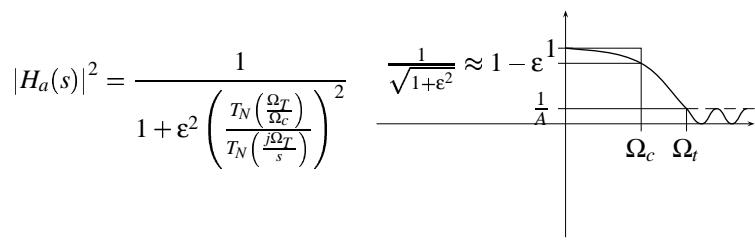


$$g = \sqrt{\frac{A^2 - 1}{\varepsilon^2}}$$

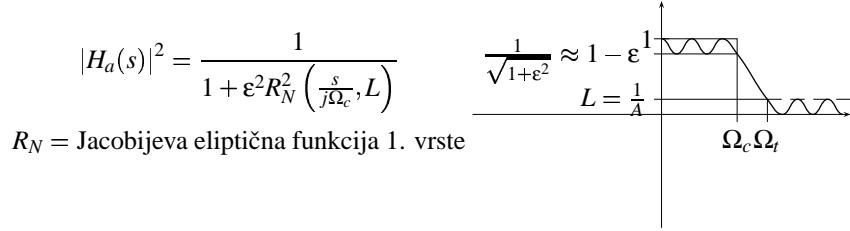
$$N = \frac{\log_{10} \left(g + \sqrt{g^2 - 1} \right)}{\log_{10} \left(\frac{\Omega_t}{\Omega_c} + \sqrt{\left(\frac{\Omega_t}{\Omega_c} \right)^2 - 1} \right)}$$



Tip 2 (inverzni Čebišev filter)



3. Cauerjevi ali eliptični filtri

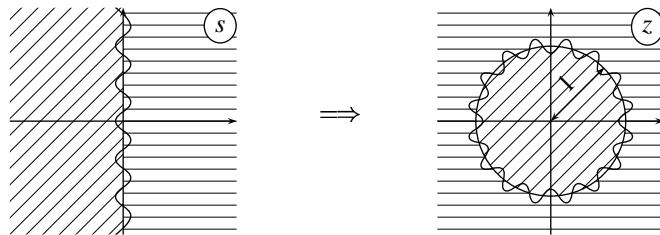


Ta filter je vedno boljši od Čebiševih filtrov in veliko boljši od Butterworthovih filtrov.

3.2 Preslikava z bilinearno transformacijo

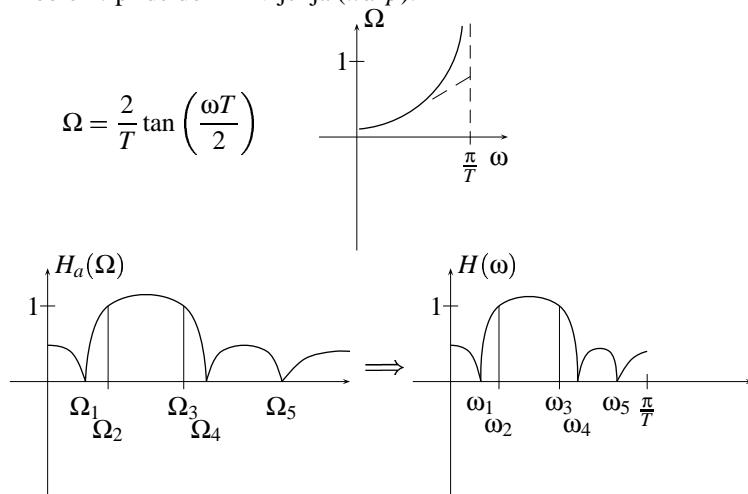
$$s = \frac{2}{T} \cdot \frac{1 - z^{-1}}{1 + z^{-1}}, \quad z = \frac{\frac{2}{T} + s}{\frac{2}{T} - s}$$

$$H(z) = H(s) \Big|_{s=\frac{2}{T} \cdot \frac{1-z^{-1}}{1+z^{-1}}}$$



Transformacija zagotavlja (ohranja) stabilnost.

Problem: pride do izkrivljenja (*warp*):



Rešitev: predizkrivljanje (*pre-warping*)

S pomočjo $\Omega = \frac{2}{T} \tan\left(\frac{\omega T}{2}\right)$ preslikamo $\omega_1, \omega_2, \dots$ v $\Omega_1, \Omega_2, \dots$

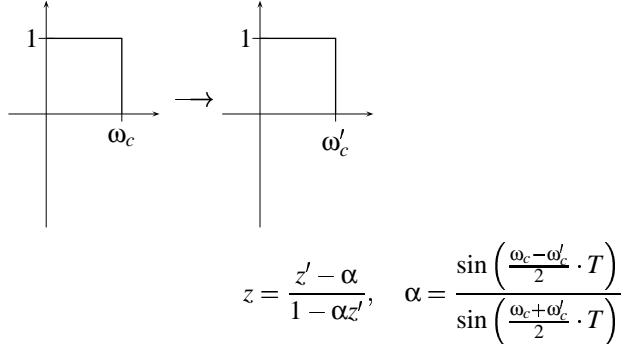
To je uspešno samo, če je želen potek odsekoma konstantna funkcija.

3.3 Filtrske transformacije

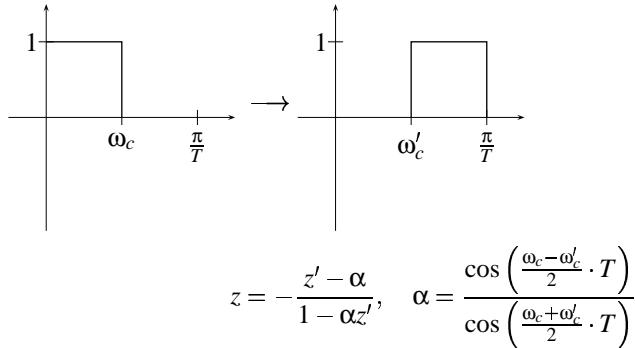
$$H(z') = H(z) \Big|_{z=f(z')}$$

$f(z')$ je filtrska transformacija (Constantinidesove transformacije).

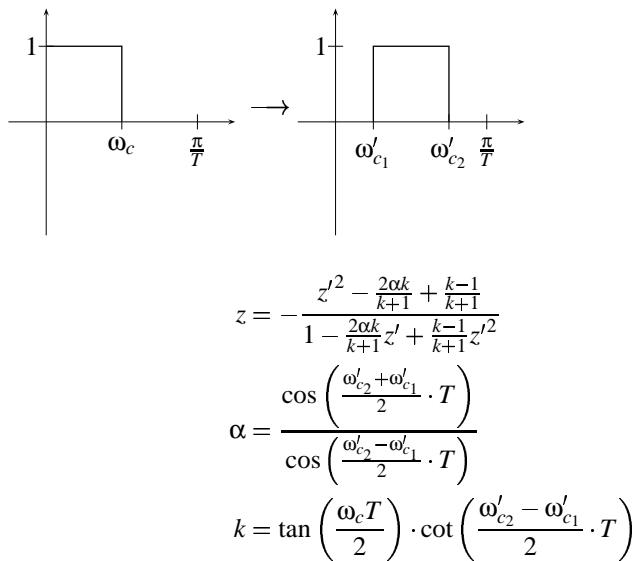
1. LP \rightarrow LP



2. LP \rightarrow HP



3. LP \rightarrow BP



3.4 Načrtovanje s Padejevo aproksimacijo

- aproksimacija racionalne funkcije s potenčno funkcijo

$$H(z) = \frac{\sum_{l=0}^M a_l z^{-l}}{1 + \sum_{l=1}^N b_l z^{-l}} = \sum_{k=0}^{\infty} h(k) z^{-k}$$

- iz želenega frekvenčnega poteka $H_d(e^{j\omega})$ lahko vedno izračunamo $h_d(k)$
-

$$P = N + M + 1, \quad h(k) = h_d(k) \text{ za } k = 0, 1, \dots, P - 1 \quad \leftarrow P \text{ enačb} \\ h(k) \neq h_d(k) \text{ za } k \geq P$$

$$y(n) = \sum_{l=0}^M a_l x(n-l) - \sum_{l=1}^N b_l y(n-l)$$

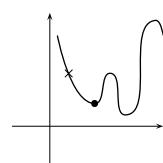
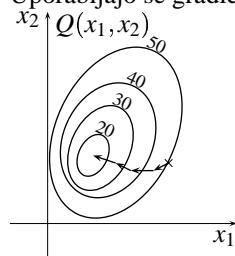
$$\begin{aligned} h(0) &= a_0 \\ h(1) &= -b_1 h(0) + a_1 \\ h(2) &= -b_1 h(1) - b_2 h(0) + a_2 \\ &\vdots \\ h(M) &= -b_1 h(M-1) - b_2 h(M-2) - \dots - b_N h(M-N) + a_M \\ h(M+1) &= -b_1 h(M) - b_2 h(M-1) - \dots - b_N h(M+1-N) \\ &\vdots \\ h(M+N+1) &= -b_1 h(M+N) - b_2 h(M+N-1) - \dots - b_N h(M+1) \end{aligned}$$

$$\left. \begin{array}{l} N \text{ neznank } b_1, b_2, \dots, b_N \\ M \text{ enačb} \end{array} \right\} \text{izračunamo } b_l$$

nato izračunamo še a_l

3.5 Načrtovanje z uporabo nelinerane optimizacije

Uporabljajo se gradientne metode; primer: Fletcher-Powell.



$$\text{grad } Q = \left(\frac{\partial Q}{\partial x_1}, \frac{\partial Q}{\partial x_2} \right)$$

$$H(z) = A \prod_{k=1}^K \frac{1 + a_k z^{-1} + b_k z^{-2}}{1 + c_k z^{-1} + d_k z^{-2}}$$

$$Q(\vec{\Theta}) = \sum_{l=1}^M (|H_d(e^{j\omega_l})| - |H(e^{j\omega_l})|)^{2p}$$

$$p \rightarrow \infty : \max_{l=1,2,\dots,M} ||H_d(e^{j\omega_l})| - |H(e^{j\omega_l})|| \leftarrow L_\infty \text{ norma}$$

Padejeva aproksimacija da začetno točko.

3.6 Načrtovanje z uporabo lineranega programiranja (*simplex algoritmom*)

$$H(z) = \frac{\sum_{l=0}^M a_l z^{-l}}{1 + \sum_{l=1}^N b_l z^{-l}} = \frac{\sum_{l=0}^M a_l z^{-l}}{\sum_{l=0}^N b_l z^{-l}}, \quad b_0 = 1$$

$$|H(e^{j\omega})|^2 = H(z)H(z^{-1}) \Big|_{z=e^{j\omega}} = \frac{c_0 + 2 \sum_{l=1}^M c_l \cos \omega l}{d_0 + 2 \sum_{l=1}^N d_l \cos \omega l}$$

$$c_l = \sum_{k=0}^{M-l} a_k a_{k+l}, \quad d_l = \sum_{k=0}^{M-l} b_k b_{k+l}$$

pogoja:

pogoj:

$$\left| |H(e^{j\omega})|^2 - |H_d(e^{j\omega})|^2 \right| < \delta \Rightarrow \begin{cases} \left| |H(e^{j\omega})|^2 - |H_d(e^{j\omega})|^2 \right| - \delta \leq 0 \\ - \left| |H(e^{j\omega})|^2 + |H_d(e^{j\omega})|^2 \right| - \delta \leq 0 \end{cases}$$

problem: minimiziraj δ

problem: minimiziraj δ

$$\frac{c_0 + 2 \sum_{l=1}^M c_l \cos \omega l}{d_0 + 2 \sum_{l=1}^N d_l \cos \omega l} - |H_d(e^{j\omega})|^2 - \delta \leq 0 \quad \text{ne gre, ker se pojavijo produkti } \delta \cdot d$$

Drugače: δ spremenimo v konstanto, vpeljemo ε in prevedemo na linearni problem.

problem: minimiziraj ε

pogoj:

$$\left| \frac{c_0 + 2 \sum_{l=1}^M c_l \cos \omega l}{d_0 + 2 \sum_{l=1}^N d_l \cos \omega l} - |H_d(e^{j\omega})|^2 \right| \leq \delta - \frac{\varepsilon}{d_0 + 2 \sum_{l=1}^N d_l \cos \omega l}$$

Izberemo δ ; če je $\varepsilon > 0$, potem rešitev za dani δ obstaja. Ponavljamo, dokler ni $\varepsilon \approx 0$, kjer imamo optimalno rešitev.

Minimiziramo ε pri pogojih:

$$\begin{aligned} \varepsilon + c_0 + 2 \sum_{l=1}^M c_l \cos \omega l - \left(d_0 + 2 \sum_{l=1}^N d_l \cos \omega l \right) \left(|H_d(e^{j\omega})|^2 + \delta \right) &\leq 0 \\ \varepsilon - c_0 - 2 \sum_{l=1}^M c_l \cos \omega l + \left(d_0 + 2 \sum_{l=1}^N d_l \cos \omega l \right) \left(|H_d(e^{j\omega})|^2 - \delta \right) &\leq 0 \\ -c_0 - 2 \sum_{l=1}^M c_l \cos \omega l \leq 0 \\ -d_0 - 2 \sum_{l=1}^N d_l \cos \omega l \leq 0 \end{aligned} \quad \left\{ \begin{array}{l} \text{izhaja iz } |H(e^{j\omega})|^2 = \frac{c_0 + 2 \sum_{l=1}^M c_l \cos \omega l}{d_0 + 2 \sum_{l=1}^N d_l \cos \omega l} \end{array} \right.$$

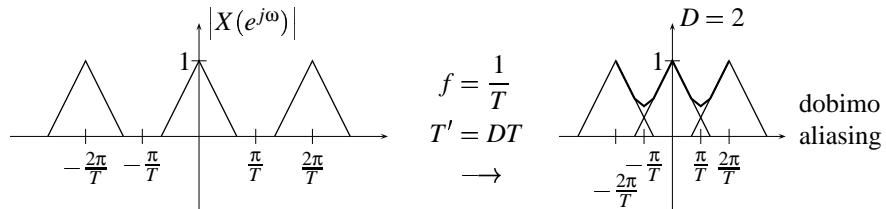
4 Decimacija in interpolacija

- decimacija (redčenje) je zmanjševanje vzorčevalne frekvence
- interpolacija je povečevanje vzorčevalne frekvence

4.1 Decimacija

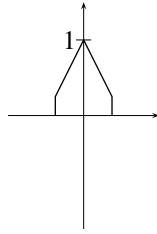
$x(n)$ – signal; frekvenco vzorčenja želimo zmanjšati za faktor D , $D \in \mathbb{N}$.

$$v(n) = x(Dn)$$

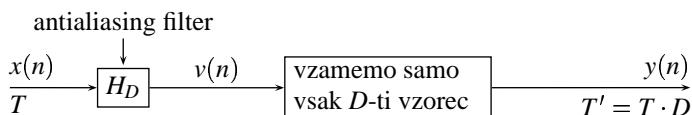


Izhodišče: spekter ostane nespremenjen. Potrebujemo (antialiasing) decimacijski filter:

$$H_D(e^{j\omega}) = \begin{cases} 1, & |\omega| \leq \frac{\pi}{DT} \\ 0, & \text{drugod} \end{cases}$$



Recept:



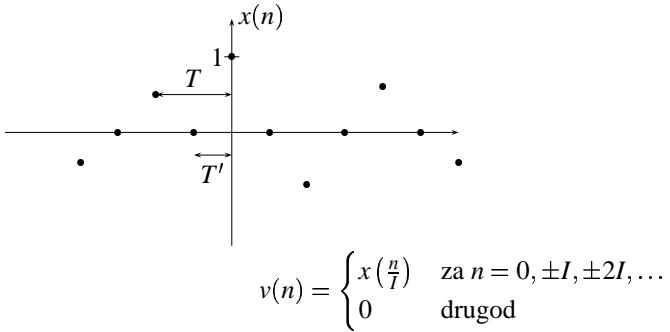
$$y(m) = v(mD) = \sum_{k=0}^{\infty} h_D(k)x(mD - k)$$

$$v(n) = \sum_{k=0}^{\infty} h_D(k)x(n - k)$$

4.2 Interpolacija

$x(n)$ – signal; frekvenco vzorčenja želimo povečati za faktor I , $I \in \mathbb{N}$.

$$f = \frac{1}{T}, \quad T' = \frac{T}{I}$$

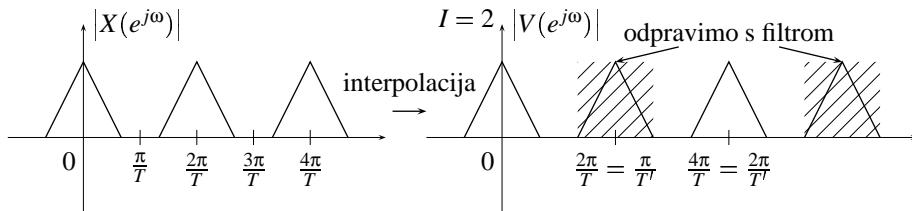


Izhodišče: spekter ostane nespremenjen, signal mora biti tak, kot bi bil, če bi prvotni analogni signal vzorčili s T' .

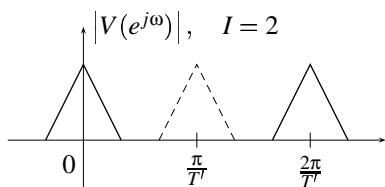
$$V(z) = \sum_{n=-\infty}^{+\infty} v(n)z^{-n} = \sum_{n=-\infty}^{+\infty} x(n)z^{-nI} = X(z^I)$$

$$T' = \frac{T}{I}$$

$$V(e^{j\omega}) = X(e^{j\omega I}) \Rightarrow V(e^{j\omega T'}) = X(e^{j\omega T' \cdot I}) = X(e^{j\omega T})$$

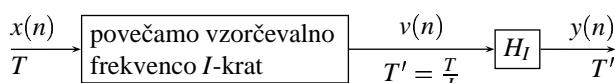


Če takoj vzorčimo analogni signal z novo frekvenco (brez interpolacije), dobimo:



Potrebujemo interpolacijski filter:

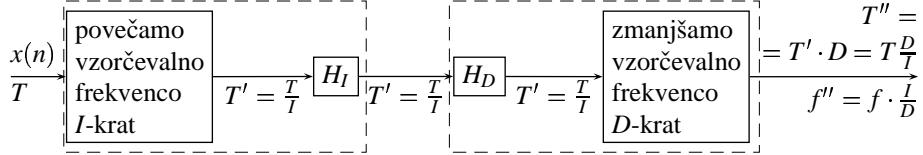
$$H_I(e^{j\omega}) = \begin{cases} I, & |\omega| \leq \frac{\pi}{IT'} \\ 0, & \text{drugod} \end{cases}$$



$$y(n) = \sum_{k=0}^{\infty} h_I(k)v(n-k) = \sum_{k=-\infty}^{+\infty} h_I(n-k)v(k) = \sum_{k=-\infty}^{+\infty} h_I(n-kI)x(k)$$

Boljše je vzeti KEO filter, ker zmanjšamo število računskih operacij.

S kombinacijo decimacije in interpolacije lahko spremenimo vzorčevalno frekvenco za poljuben racionalni faktor $\frac{I}{D}$:



H_I in H_D združimo v en filter:

$$H = \begin{cases} I, & |\omega| \leq (\frac{\pi}{D}, \frac{\pi}{I}) \\ 0, & \text{drugod} \end{cases}$$

5 FFT algorititem in njegova uporaba

- Leta 1965 FFT ponovno odkrijeta Cooley in Tukey.
- FFT (*Fast Fourier Transform*) je algoritem za računanje DFT (diskretna Fourierjeva transformacija).

$$x_p(k + mN) = x_p(k), \quad m = 0, \pm 1, \pm 2, \dots$$

$$X_p(k) \stackrel{\text{def}}{=} \sum_{n=0}^{N-1} x_p(n) e^{-2\pi j k \frac{n}{N}}, \quad k = 0, 1, \dots, N-1$$

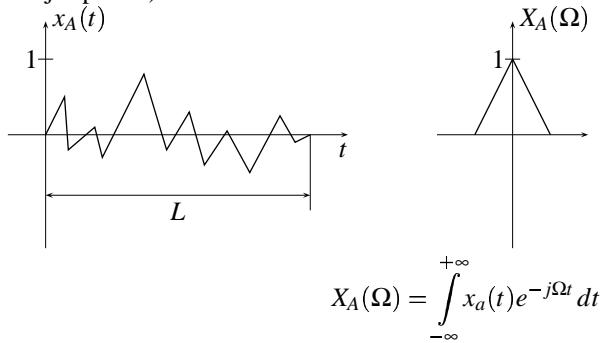
$$x_p(n) = \frac{1}{N} \sum_{k=0}^{N-1} X_p(k) e^{2\pi j k \frac{n}{N}}, \quad n = 0, 1, \dots, N-1$$

primitivni N -ti koren od 1: $w_N = e^{-\frac{2\pi j}{N}}$, $w_N^r \neq 1$ za $0 < r < N$

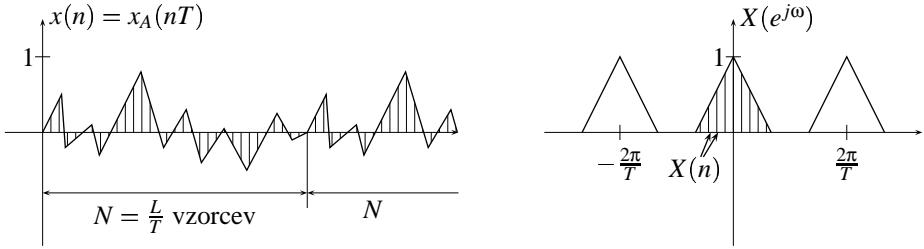
$$\sum_{k=0}^{N-1} w_N^{km} w_N^{-kl} = \begin{cases} N, & n - l = 0 \pmod{N} \\ 0, & \text{drugod} \end{cases}$$

Zahtevnost DFT: N^2 operacij.

Zveza med DFT in Fourierovim integralom (oz. kdaj smemo DFT uporabiti za računanje spektra):



Predpostavka: ni aliasinga.



$$X(e^{j\omega}) = \sum_{n=0}^{N-1} x(n)e^{-j\omega n}$$

ploščina = 1

$$X_A(\Omega) = \int_0^L x_A(t) e^{-j\Omega t} dt = \sum_{k=0}^{N-1} \int_{kT}^{(k+1)T} x_A(t) e^{-j\Omega t} dt = \sum_{k=0}^{N-1} x_A(kT) e^{-j\Omega kT}$$

$$\text{DFT: } X(n) = \sum_{k=0}^{N-1} x(k) e^{-2\pi j k \frac{n}{N}}, \quad x(k) = x_A(kT)$$

$$X(n) = X_A(\Omega) \Big|_{\Omega=\frac{2\pi}{T}, \frac{n}{N}}$$

FFT algoritmi: $N^2 \rightarrow N \log N$, dobro se dajo paralelizirati

- decimacija v času
- decimacija v frekvenci
- radix 2, 4, 8 in praštevilski ($N = 2^n, 4^n, 8^n, p$)
- Winograd FFT algoritem – najboljši možen

5.1 Radix 2 algoritem, decimacija v času

$N = 2^n$, razdelimo na sode ter lihe indekse, upoštevajoč $w_N^2 = w_{N/2}$:

$$\begin{aligned} X(l) &= \sum_{r=0}^{\frac{N}{2}-1} x(2r) w_N^{2rl} + \sum_{r=0}^{\frac{N}{2}-1} x(2r+1) w_N^{(2r+1)l} = \\ &= \sum_{r=0}^{\frac{N}{2}-1} x(2r) w_{N/2}^{rl} + w_N^l \sum_{r=0}^{\frac{N}{2}-1} x(2r+1) w_{N/2}^{rl} \end{aligned}$$

Dobimo par enačb, imenovan metuljček:

$$X(l) = G(l) + w_N^l F(l), \quad l = 0, 1, \dots, \frac{N}{2} - 1$$

$$X\left(l + \frac{N}{2}\right) = G(l) - w_N^l F(l), \quad l = 0, 1, \dots, \frac{N}{2} - 1$$

$F(L)$, $G(l)$ – DFT dolžine $\frac{N}{2}$; število operacij: $2\left(\frac{N}{2}\right)^2 + \frac{N}{2}$

$$G(l) = \sum_{r=0}^{\frac{N}{2}-1} x(2r) w_{N/2}^{rl} = \underbrace{\sum_{r=0}^{\frac{N}{4}-1} x(4r) w_{N/4}^{rl}}_{A(l)} + w_{N/2}^l \underbrace{\sum_{r=0}^{\frac{N}{4}-1} x(4r+2) w_{N/4}^{rl}}_{B(l)} = A(l) + w_{N/2}^l B(l)$$

$$G(l) = A(l) + w_{N/2}^l B(l), \quad l = 0, 1, \dots, \frac{N}{4} - 1$$

$$G\left(l + \frac{N}{4}\right) = A(l) - w_{N/2}^l B(l), \quad l = 0, 1, \dots, \frac{N}{4} - 1$$

$$F(l) = \sum_{r=0}^{\frac{N}{2}-1} x(2r+1) w_{N/2}^{rl} = \sum_{r=0}^{\frac{N}{4}-1} x(4r+1) w_{N/4}^{rl} + w_{N/2}^l \sum_{r=0}^{\frac{N}{4}-1} x(4r+3) w_{N/4}^{rl} =$$

$$= C(l) + w_{N/2}^l D(l)$$

$$F(l) = C(l) + w_{N/2}^l D(l), \quad l = 0, 1, \dots, \frac{N}{4} - 1$$

$$F\left(l + \frac{N}{4}\right) = C(l) - w_{N/2}^l D(l), \quad l = 0, 1, \dots, \frac{N}{4} - 1$$

Število operacij: $2\left(2 \cdot \left(\frac{N}{4}\right)^2 + \frac{N}{4}\right) + \frac{N}{2} = 4 \cdot \left(\frac{N}{4}\right)^2 + \frac{N}{2} + \frac{N}{2}$.

Splošna formula za število operacij: $\frac{N}{2} \log_2 N$.

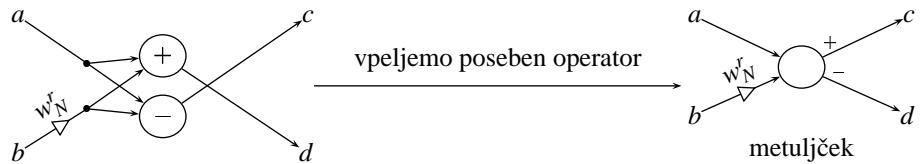
Od kod ime metuljček:

metuljček je par enačb

$$c = a + w_N^r b$$

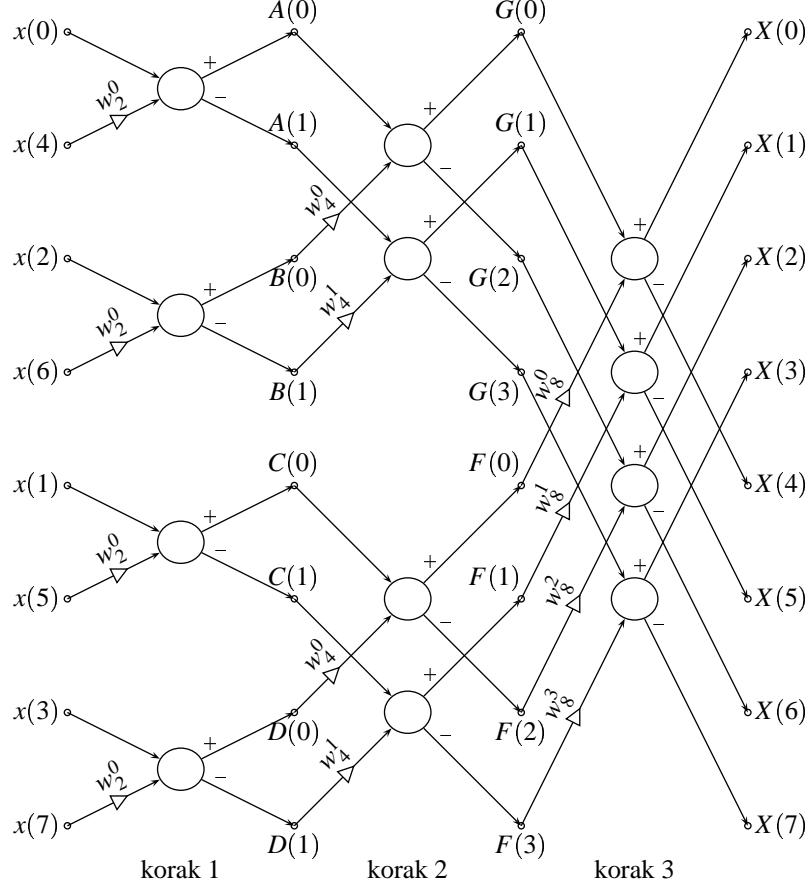
$$d = a - w_N^r b$$

vhodni podatki: a, b



Uporablja se bit-reverzno mešanje indeksov (velja samo za radix-2 algoritmom): index $x(i)$; $i = b_{n-1}b_{n-2}\dots b_1b_0 \rightarrow i = b_0b_1\dots b_{n-2}b_{n-1}$

Primer za $N = 8 = 2^3$:



n korakov, v vsakem koraku $\frac{N}{2}$ metuljčkov.

5.2 Radix 4 algoritam

Približno 30% prihranek pri prehodu iz radix 2 na radix 4 algoritom.
 $N = 4^n$, razdelimo člene glede na ostanek pri deljenju s 4:

$$\begin{aligned}
 X(l) &= \sum_{r=0}^{\frac{N}{4}-1} x(4r)w_{N/4}^{rl} + w_N^l \sum_{r=0}^{\frac{N}{4}-1} x(4r+1)w_{N/4}^{rl} + \\
 &\quad + w_N^{2l} \sum_{r=0}^{\frac{N}{4}-1} x(4r+2)w_{N/4}^{rl} + w_N^{3l} \sum_{r=0}^{\frac{N}{4}-1} x(4r+3)w_{N/4}^{rl} = \\
 &= A(l) + w_N^l B(l) + w_N^{2l} C(l) + w_N^{3l} D(l)
 \end{aligned}$$

Upoštevamo zvezne:

$$w_N^{N/4} = -j, \quad w_N^{N/2} = -1, \quad w_N^{3N/4} = j$$

$$\begin{aligned}
X(l) &= A(l) + w_N^l B(l) + w_N^{2l} C(l) + w_N^{3l} D(l) \\
X\left(l + \frac{N}{4}\right) &= A(l) - jw_N^l B(l) - w_N^{2l} C(l) + jw_N^{3l} D(l) \\
X\left(l + \frac{N}{2}\right) &= A(l) - w_N^l B(l) + w_N^{2l} C(l) - w_N^{3l} D(l) \\
X\left(l + \frac{3N}{4}\right) &= A(l) + jw_N^l B(l) - w_N^{2l} C(l) - jw_N^{3l} D(l)
\end{aligned}$$

Zahtevnost algoritma: $3 \cdot \frac{N}{4} \log_4 N = \frac{3}{8} N \log_2 N$

5.3 Računanje inverzne DFT

$$\begin{aligned}
x(k) &= \frac{1}{N} \sum_{l=0}^{N-1} X(l) w_N^{-lk} \\
Nx^*(k) &= \sum_{l=0}^{N-1} X^*(l) w_N^{lk}
\end{aligned}$$

Trik:

$$x(k) = \frac{1}{N} \left(\sum_{l=0}^{N-1} X^*(l) w_N^{lk} \right)^*$$

5.4 Računanje DFT za realna zaporedja

$x(k)$ – realno zaporedje dolžine $2N$; tvorimo kompleksno zaporedje dolžine N :

$$\begin{aligned}
y(k) &= x(2k) + jx(2k+1) = \underbrace{y_1(k)}_{\text{sodi}} + j\underbrace{y_2(k)}_{\text{lihi}}, \quad k = 0, 1, \dots, N-1 \\
Y(l) &= \sum_{k=0}^{N-1} y(k) w_N^{kl} = \sum_{k=0}^{N-1} (y_1(k) + jy_2(k)) w_N^{kl} = Y_1(l) + jY_2(l) \\
Y^*(N-l) &= \sum_{k=0}^{N-1} y^*(k) w_N^{-(N-l)k} = \sum_{k=0}^{N-1} (y_1(k) - jy_2(k)) w_N^{kl} = Y_1(l) + jY_2(l) \\
Y_1(l) &= \frac{1}{2} (Y^*(N-l) + Y(l)) \\
Y_2(l) &= \frac{j}{2} (Y^*(N-l) - Y(l))
\end{aligned}$$

DFT od realnega zaporedja $x(k)$ dolžine $2N$:

$$\begin{aligned}
X(l) &= \sum_{k=0}^{2N-1} x(k) w_{2N}^{kl} = \sum_{k=0}^{N-1} x(2k) w_{2N}^{2lk} + \sum_{k=0}^{N-1} x(2k+1) w_{2N}^{2k+1} = \\
&\quad \text{velja: } w_{2N}^2 = w_N \\
&= \sum_{k=0}^{N-1} x(2k) w_N^{kl} + w_{2N}^l \sum_{k=0}^{N-1} x(2k+1) w_N^{kl} = Y_1(l) + w_{2N}^l Y_2(l)
\end{aligned}$$

$$X(l) = \frac{1}{2} \left(Y^*(N-l) + Y(l) + jw_{2N}^l (Y^*(N-l) - Y(l)) \right), \quad l = 0, 1, \dots, N-1$$

$$X(l+N) = \frac{1}{2} \left(Y^*(N-l) + Y(l) - jw_N^l (Y^*(N-l) - Y(l)) \right), \quad l = 0, 1, \dots, N-1$$

Prihranek: namesto DFT dolžine $2N$ potrebujemo DFT dolžine N ter N množenj. Za kompleksno zaporedje dolžine $2N$:

$$\frac{2N}{2} \log_2(2N) = N(1 + \log_2 N),$$

z upoštevanjem realnosti:

$$\frac{N}{2} \log_2 N + N$$

5.5 Hitro računanje konvolucije

5.5.1 Periodična zaporedja

Dani sta zaporedji x_p, h_p

$$y_p(n) \stackrel{\text{def}}{=} \sum_{l=0}^{N-1} x_p(l)h_p(n-l) = \sum_{l=0}^{N-1} h_p(l)x_p(n-l)$$

Dokaz za zadnjo enačbo izpelji sam.

$$Y_p(l) = H_p(l)X_p(l), \quad l = 0, 1, \dots, N-1$$

$$H_p(l) = \sum_{k=0}^{N-1} h_p(k)w_N^{kl}$$

$$X_p(l) = \sum_{k=0}^{N-1} x_p(k)w_N^{kl}$$

DFT konvolucije = produkt DFT-jev

Hitro računanje konvolucije:

1. izračunamo DFT od x_p in h_p : $2 \times \frac{N}{2} \log_2 N$ množenj
2. pomnožimo transforma $H_p \cdot X_p$: N množenj
3. izračunamo inverzno DFT od $H_p X_p$: $\frac{N}{2} \log_2 N$ množenj

Zahtevnost:

$$3 \cdot \frac{N}{2} \log_2 N + N$$

5.5.2 Neperiodična zaporedja

$x(n)$ je zaporedje dolžine N_1 : $x(n) = 0$ za $n \begin{cases} \geq N_1 \\ < 0 \end{cases}$

$h(n)$ je zaporedje dolžine N_2 : $h(n) = 0$ za $n \begin{cases} \geq N_2 \\ < 0 \end{cases}$

$$y(n) = \sum_{l=0}^{\infty} h(l)x(n-l) = \sum_{l=0}^{\infty} h(l)x(n-l)$$

$y(n)$ je zaporedje dolžine $N_1 + N_2 - 1$: $y(n) = 0$ za $n \begin{cases} n \geq N_1 + N_2 - 1 \\ < 0 \end{cases}$

Pri periodični konvoluciji imajo vsa tri zaporedja (x, h, y) enako periodo.

$$x_p(n) = \begin{cases} x(n) & \text{za } n = 0, 1, \dots, N_1 - 1 \\ 0 & \text{za } n = N_1, N_1 + 1, \dots, N_1 + N_2 - 2 \end{cases} \quad \begin{array}{l} \text{periodično zaporedje} \\ \text{s periodo } N_1 + N_2 - 1 \end{array}$$

$$h_p(n) = \begin{cases} h(n) & \text{za } n = 0, 1, \dots, N_2 - 1 \\ 0 & \text{za } n = N_2, N_2 + 1, \dots, N_2 + N_1 - 2 \end{cases} \quad \begin{array}{l} \text{periodično zaporedje} \\ \text{s periodo } N_1 + N_2 + 1 \end{array}$$

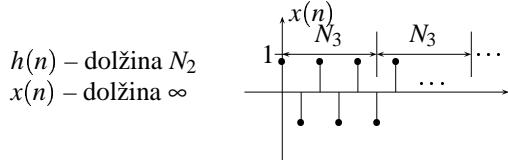
$$y_p(n) = \sum_{l=0}^{N_1+N_2-2} h_p(l)x_p(n-l) = \sum_{l=0}^n h(l)x(n-l) = y(n), \quad n = 0, 1, \dots, N_1 + N_2 - 2$$

Algoritem:

- izberemo število L ($L = 2^n$) tako, da je $L \geq N_1 + N_2 - 1$
- če je $x(n)$ neskončno dolgo zaporedje, potem uporabimo trik: hitro konvolucijo po odsekih

5.5.3 Hitra konvolucija po odsekih

$$x(n) \longrightarrow [h(n)] \longrightarrow y(n) = \sum_{l=0}^{\infty} h(l)x(n-l) = \sum_{l=0}^{N_2-1} h(l)x(n-l)$$



trik: izberemo število N_3

$$x(n) = \sum_{k=0}^{\infty} x_k(n), \quad x_k(n) \stackrel{\text{def}}{=} \begin{cases} x(n) & kN_3 \leq n \leq (k+1)N_3 - 1 \\ 0 & \text{drugod} \end{cases}$$

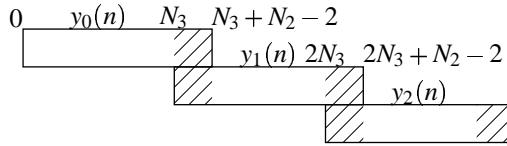
$$\begin{aligned}
y(n) &= \sum_{l=0}^{\infty} h(l)x(n-l) = \sum_{l=0}^n h(l)x(n-l) = \sum_{l=0}^n h(l) \sum_{k=0}^{\text{infity}} x_k(n-l) = \\
&= \sum_{k=0}^{\infty} \underbrace{\sum_{l=0}^n h(l)x_k(n-l)}_{y_k(n)} = \sum_{k=0}^{\infty} y_k(n)
\end{aligned}$$

odsek konvolucije

$$y_k(n) = \sum_{l=0}^n h(l) \underbrace{x_k(n-l)}_{N_2}, \quad N_2 + N_3 - 1$$

$$\left\{
\begin{array}{l}
y_0(n) \neq 0 \text{ za } n = 0, 1, \dots, N_3 + N_2 - 2 \\
y_1(n) \neq 0 \text{ za } n = N_3, N_3 + 1, \dots, 2N_3 + N_2 - 2 \\
y_2(n) \neq 0 \text{ za } n = 2N_3, 2N_3 + 1, \dots, 3N_3 + N_2 - 2
\end{array}
\right.$$

prekrivanje pri indeksih $N_3, N_3 + 1, \dots, N_3 + N_2 - 2$
 prekrivanje pri indeksih $2N_3, 2N_3 + 1, \dots, 2N_3 + N_2 - 2$



Algoritem OVERLAP-ADD:

1. Izberemo N_3 ($L = N_3 + N_2 - 1 = 2^n$)
2. Tvorimo $h_p(n)$ dolžine L (dodamo $N_3 - 1$ ničel)
3. Izračunamo DFT od $h_p(n) \rightarrow H_p(l)$
4. $k = 0$
5. Tvorimo $x_{kp}(n)$ dolžine L (dodamo $N_2 - 1$ ničel k $x_k(n)$)
6. Izračunamo DFT od $x_{kp}(n) \rightarrow X_{kp}(l)$
7. $Y_{kp}(l) = H_p \cdot X_{kp}(l), l = 0, 1, \dots, L - 1$
8. Izračunamo inverzno DFT – dobimo $y_k(n)$ za $n = kN_3, kN_3 + 1, \dots, kN_3 + N_2 - 1$
9. Tvorimo $y(n)$:
 - (a) $k = 0: y(n) = y_k(n)$ za $n = 0, 1, \dots, N_3 + N_2 - 2$
 - (b)

$$\begin{aligned}
k \geq 1 : & y(n) = y_k(n) + y(n) && \text{za } n = kN_3, kN_3 + 1, \dots, kN_3 + N_2 - 2 \\
& y(n) = y_k(n) && \text{za } n = kN_3 + N_2 - 1, kN_3 + N_2, \dots, (k+1)N_3 + N_2 - 2
\end{aligned}$$

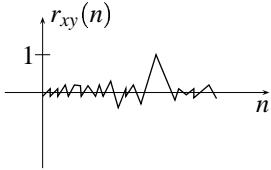
10. $k = k + 1$

Večji $L \rightarrow$ večja hitrost.

6 Križna korelacija in avtokorelacija

$$r_{xy}(n) \stackrel{\text{def}}{=} \sum_{l=-\infty}^{+\infty} x(l)y(l+n) = \sum_{l=-\infty}^{+\infty} x(l-n)y(l), \quad n = 0, \pm 1, \pm 2, \dots$$

$$r_{xy}(n) = r_{yx}(-n) \quad \leftarrow \text{ni komutativno!}$$



6.1 Avtokorelacija

$$r_{xx}(n) \stackrel{\text{def}}{=} \sum_{l=-\infty}^{+\infty} x(l)x(l+n)$$

$$r_{xx}(n) = r_{xx}(-n)$$

$$r_{xx}(0) \geq r_{xx}(n), \quad \text{za } n \neq 0$$

6.2 Hitro računanje korelacije

6.2.1 Periodična zaporedja

$x_p(n), y_p(n)$:

$$r_{pxy}(n) \stackrel{\text{def}}{=} \sum_{l=0}^{N-1} x_p(l)y_p(l+n), \quad n = 0, 1, \dots, N-1$$

$$R_{pxy}(k) = \sum_{n=0}^{N-1} r_{pxy}(n)w_N^{kn} = \sum_{n=0}^{N-1} \sum_{l=0}^{N-1} x_p(l)y_p(l+n)w_N^{kn} =$$

$$= \sum_{l=0}^{N-1} x_p(l)w_N^{-kl} \sum_{n=0}^{N-1} y_p(l+n)w_N^{k(l+n)}$$

$$\sum_{n=0}^{N-1} y_p(\underbrace{l+n}_{=u})w_N^{k(l+n)} = \sum_{n=l}^{N-1+l} y_p(n)w_N^{kn} = \sum_{u=l}^{N-1} y_p(u)w_N^{kn} + \sum_{u=N}^{N-1+l} y_p(u)w_N^{kn} =$$

$$u' = u - N$$

$$= \sum_{u=l}^{N-1} y_p(u)w_N^{kn} + \sum_{u'=0}^{l-1} y_p(u')w_N^{ku'} = \sum_{u=0}^{N-1} y_p(u)w_N^{ku}$$

$$R_{pxy} = \sum_{l=0}^{N-1} x_p(l)w_N^{-kl} \sum_{u=0}^{N-1} y_p(u)w_N^{ku} = X_p(-k)Y_p(k)$$

$$R_{pxy}(k) = X_p(-k)Y_p(k) = X_p(N-k)Y_p(k)$$

Za realna zaporedja: $R_{pxy}(k) = X_p^*(k)Y_p(k)$, ker: $X_p(-k) = X_p^*(k)$ za realna zaporedja $x(n)$.

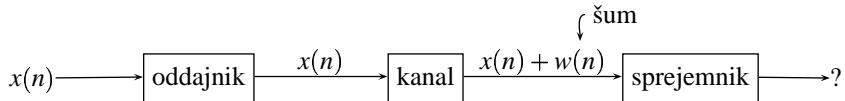
Hitro računanje:

- izračunamo DFT od x_p, y_p
- izračunamo $R_{pxy}(k) = X_p^*(k)Y_p(k)$
- izračunamo IDFT od $R_{pxy}(k) \rightarrow r_{pxy}(n), n = 0, 1, \dots, N-1$

6.2.2 Končno dolgi neperiodični zaporedji x, y

$$\begin{aligned}
 & x(n) \text{ dolžina } N_1 \\
 & y(n) \text{ dolžina } N_2 \\
 & r_{xy}(n) \text{ dolžina } N_1 + N_2 - 1 \quad \leftarrow \\
 & r_{xy}(n) = \sum_{l=-\infty}^{+\infty} x(l)y(l+n) = \sum_{l=0}^{N_2-1-n} x(l)y(l+n) \\
 & r_{xy}(n) = 0 \text{ za } \begin{cases} l+n < 0 & \Rightarrow n < -(N_1-1) \\ l+n > N_2-1 & \Rightarrow n > (N_2-1) \end{cases} \\
 & r_{xy}(n) \neq 0 \text{ v } N_1-1+N_2-1+1 = N_1+N_2-1 \text{ točkah}
 \end{aligned}$$

6.3 Detekcija signala v šumu

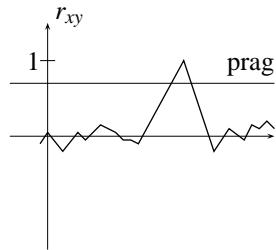


$$y(n) = x(n) + w(n)$$

$$r_{xy}(n) = \frac{1}{K} \sum_{l=0}^{K-1} x(l)y(l+n) = \frac{1}{K} \sum_{l=0}^{K-1} x(l)(x(l+n) + w(l+n)) = r_{xx}(n) + r_{xw}(n) \approx r_{xx}(n)$$

Ker: $r_{xw}(n) \approx 0$; velja, če $x(n)$ in $w(n)$ nista korelirana (aditivni šum).

$$K \gg n$$



$$\begin{aligned}
 r_{yy}(n) &= \frac{1}{K} \sum_{l=0}^{K-1} y(l)y(l+n) = \frac{1}{K} \sum_{l=0}^{K-1} (x(l) + w(l))(x(l+n) + w(l+n)) = \\
 &= r_{xx}(n) + r_{xw}(n) + r_{wx}(n) + r_{ww}(n)
 \end{aligned}$$

vrhovi pri $n = 0, n = N, n = 2N, \dots$

7 Spektralna analiza

- Določanje močnostnega spektra

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

$$\int_{-\infty}^{+\infty} |x_a(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{+\infty} |X_a(\omega)|^2 d\omega \quad - \text{Parsevalov izrek}$$

- Spekter je Fourierov (harmonični) spekter, obstajajo tudi drugi spektri
- Nedeterministični signali: poznamo samo avtokorelacijo r_{xx} , x_a pa ne:

$$r_{xx}(\tau) = \int_{-\infty}^{+\infty} x_a^*(t) x_a(t + \tau) dt$$

$$\begin{aligned} \int_{-\infty}^{+\infty} r_{xx}(\tau) e^{-j\omega\tau} d\tau &= \int_{-\infty}^{+\infty} \left(\int_{-\infty}^{+\infty} x_a^*(t) x_a(t + \tau) dt \right) e^{j\omega\tau} d\tau = \\ &= \int_{-\infty}^{+\infty} x_a^*(t) \left(\int_{-\infty}^{+\infty} x_a(t + \tau) e^{-j\omega(t+\tau)} d\tau \right) e^{j\omega t} dt = \\ &= \int_{-\infty}^{+\infty} x_a^*(t) X_a(\omega) e^{j\omega t} dt = X_a^*(\omega) X_a(\omega) = |X_a(\omega)|^2 \end{aligned}$$

Izhodišče: $x_a(t)$ ali $r_{xx}(\tau)$.

Zaradi enostavnosti vzamemo $x_a(t)$.

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

$X_a(\omega)$ bomo določali na digitalni način.

$$x(n) \stackrel{\text{def}}{=} X_a(nT), \quad n = 0, \pm 1, \pm 2, \dots$$

Če ni aliasinga (najmanj 2× višja frekvenca vzorčenja od največje frekvence signala)(antialiasing filter):

$$X(\omega T) = \sum_{n=-\infty}^{+\infty} x(n) e^{-j\omega T n} = \frac{q}{T} X_a(\omega), \quad |\omega| \leq \frac{\pi}{T}$$

$$X_a(\omega) = T \cdot X(\omega T), \quad |\omega| \leq \frac{\pi}{T}$$

Spekter lahko izračunamo na digitalen način, če ni aliasinga.

$$X(\omega) = \sum_{n=-\infty}^{+\infty} x(n)e^{-j\omega n}$$

Problem: n od $-\infty$ do $+\infty$.

Rešitev: namesto neskončnega signala uporabimo končen del signala.

$$\begin{aligned} x_w(n) &= x(n)w(n), \quad w(n) = \begin{cases} 1 & 0 \leq n \leq N-1 \\ 0 & \text{drugod} \end{cases} \quad \leftarrow \text{pravokotno okno} \\ X_w(\omega) &= \frac{1}{2\pi} \int_0^{2\pi} X(\Theta)W(\omega - \Theta) d\Theta \\ W(\omega) &= \sum_{n=0}^{N-1} w(n)e^{-j\omega n} \end{aligned}$$

Namesto $X(\omega)$ izračunamo $X_w(\omega)$.

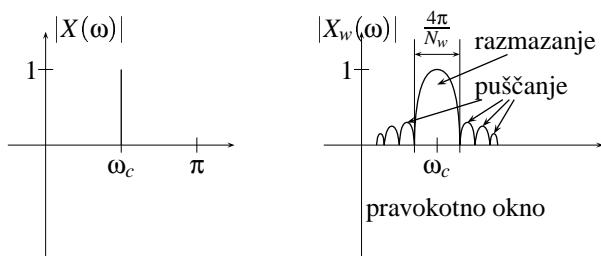
Vprašanje: $X_w(\omega) \approx X(\omega)$? \leftarrow Problem okna (*windowing problem*).

7.1 Problem okna

$$\begin{aligned} X(\omega) &= \sum_{n=-\infty}^{+\infty} x(n)e^{-j\omega n} \\ x_w(n) &= x(n)w(n) \quad \text{okno dolžine } N_w \\ X_w(\omega) &= \frac{1}{2\pi} \int_0^{2\pi} X(\Theta)W(\omega - \Theta) d\Theta \\ W(\omega) &= \sum_{n=0}^{N_w-1} w(n)e^{-j\omega n} \\ \text{Pravokotno okno: } |W(\omega)| &= \left| \frac{\sin \frac{\omega N_w}{2}}{\sin \frac{\omega}{2}} \right| \end{aligned}$$

1. razmazanje (*spreading*)

2. puščanje (*leaking*)



Druga okna: Hann, Hamming, ...: zmanjša se puščanje, ampak se poveča razmazanje.

7.2 Neparametrične metode za določanje spektra

Uporaba Fourierove transformacije

računamo z DFT in FFT algoritmom

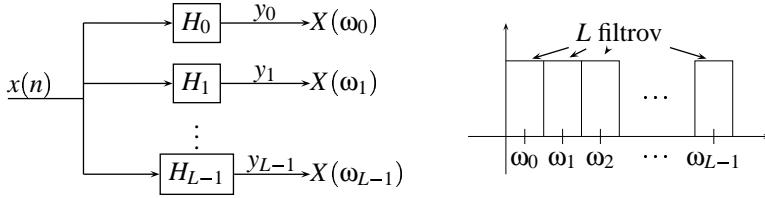
$$X_w(\omega) = \sum_{n=-\infty}^{+\infty} x(n)w(n)e^{-j\omega n} = \sum_{n=0}^{N_w-1} x(n)w(n)e^{-j\omega n}, \quad X_w(k) = \sum_{n=0}^{N_w-1} x(n)w(n)e^{-j\frac{2\pi nk}{N_w}}$$

Predpostavka: $X(\omega) \approx X_w(\omega)$

Pri analognih (zveznih) signalih je še ena predpostavka:

$$X_a(\omega_k) \approx TX(k), \quad \omega_k = \frac{2\pi}{N_w} \cdot \frac{k}{T}, \quad k = 0, 1, \dots, N_w - 1 \quad \leftarrow \text{velja, če ni aliasinga}$$

Namesto DFT lahko uporabimo množico filtrov:



Kakšna je zveza med na ta način izmerjenim spektrom in tistim z DFT?

DFT:

$$X_w(k) = \sum_{l=0}^{N_w-1} x(l)w(l)e^{-\frac{2\pi jkl}{N_w}}$$

Filtti: $x(n) \rightarrow [H_k] \rightarrow y_k(n)$ (KEO filtri dolžine N_w)

$$y_k(n) = \sum_{l=0}^{N_w-1} x(l)h_k(n-l)$$

$$n = N_w - 1 : \quad y_k(N_w - 1) = \sum_{l=0}^{N_w-1} x(l)h_k(N_w - 1 - l)$$

Da je enako: mora biti $h_k(N_w - 1 - l) = w(l)e^{-\frac{2\pi jkl}{N_w}}$

$$H_k(\omega) = \sum_{n=0}^{N_w-1} h_k(n)e^{-j\omega n}$$

$$h_k(n) = w(N_w - 1 - n)e^{\frac{2\pi jk(n+1)}{N_w}}$$

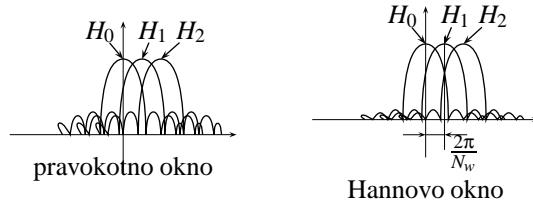
$$\begin{aligned} H_k(\omega) &= \sum_{n=0}^{N_w-1} h_k(n)e^{-j\omega n} = \sum_{n=0}^{N_w-1} w(N_w - 1 - n)e^{-jn(\omega - \frac{2\pi}{N_w} \cdot k)} e^{2\pi j \frac{k}{N_w}} = \\ &= e^{-j(N_w-1)\omega} \sum_{n=0}^{N_w-1} w(n)e^{-jn(\frac{2\pi k}{N_w} - \omega)} \end{aligned}$$

$$W(\omega) = \sum_{n=0}^{N_w-1} w(n) e^{-j\omega n}$$

$$H_k(\omega) = e^{-j(N_w-1)\omega} W\left(\frac{2\pi k}{N_w} - \omega\right)$$

Pri realnih oknih $w(n)$: $|W(\omega)| = |W(-\omega)|$

$$|H_k(\omega)| = \left| W\left(\omega - \frac{2\pi}{N_w} \cdot k\right) \right|$$



Ugotovitev: DFT je množica KEO filtrov, katerih frekvenčni odziv je enak odzivu okna ($W(\omega)$).

razmazanje \leftarrow širina filtra

puščanje \leftarrow slab filter, s prisluhom

7.3 Parametrične metode za določanje spektra

Model procesa, ki generira signal:

$$u(n) \xrightarrow{H(z)} x(n)$$

$$X(\omega) = H(\omega) \cdot U(\omega)$$

- če poznamo parametre od $H(z) \Rightarrow$ poznamo spekter
- določevanje parametrov \Leftrightarrow določevanje spektra

$$H(z) = \frac{\sum_{l=0}^q a_l z^{-l}}{1 + \sum_{l=1}^p b_l z^{-l}}$$

$$x(n) = \sum_{l=0}^q a_l u(n-l) - \sum_{l=1}^p b_l x(n-l)$$

1. pri danem zaporedju $x(n)$, $n = 0, 1, \dots, N_w - 1$ izračunamo parametre a_l, b_l
2. iz parametrov a_l, b_l izračunamo $H(\omega)$ in naredimo predpostavko $X(\omega) = H(\omega) (\cdot c) \leftarrow$ konstanta

Poseben primer modela je model s samimi poli:

$$H(z) = \frac{a_0}{1 - \sum_{l=1}^p b_l z^{-l}}$$

Druga imena za ta model:

1. linearna predikcija

2. avtoregresivni model

Ta model ustreza enačbi

$$x(n) = \underbrace{\sum_{l=1}^p b_l x(n-l)}_{\tilde{x}(n)} + a_0 u(n)$$

$$\tilde{x}(n) = \sum_{l=1}^p b_l x(n-l)$$

linearna predikcija ali avtoregresijska metoda

$$x(n) = \tilde{x}(n) + \underbrace{a_0 u(n)}_{\text{lahko damo 0}}$$

$$e(n) = x(n) - \tilde{x}(n) \quad - \text{napaka}$$

$$E = \sum_{n=0}^{L-1} e^2(n), \quad \min_{\{b_1, b_2, \dots, b_p\}} E; \quad \text{optimizacijski postopek:}$$

$$E = \sum_{n=0}^{L-1} (x(n) - \tilde{x}(n))^2 = \sum_{n=0}^{L-1} \left(x(n) - \sum_{l=1}^p b_l x(n-l) \right)^2$$

$$\frac{\partial E}{\partial b_l} = 0, \quad l = 1, 2, \dots, p$$

$$\text{p enačb: } \sum_{n=0}^{L-1} x(n)x(n-l) = \sum_{i=1}^p b_i \sum_{n=0}^{L-1} x(n-1)x(n-l), \quad l = 1, 2, \dots, p$$

Vprašanje: koliko je L ?

1. avtokorelacijska metoda (LP (linearno-prediktivni) oz. AR (avtoregresijski) spektor)

- postopamo podobno, kot pri neparametrični metodi
- $x(n) = \begin{cases} 0 & \text{za } n \geq N_w \text{ in } n < 0 \text{ (okno dolžine } N_w) \\ \neq 0 & \text{za } 0 < n \leq N_w - 1 \end{cases}$
- $e(n) \neq 0 \text{ za } n = 0, 1, \dots, N_w - 1, N_w, \dots, N_w + p - 1 \Rightarrow L = N_w + p$
- potrebno je uporabiti okensko funkcijo (Hann, Hamming,...)

$$\sum_{n=0}^{N_w+p-1} x(n)x(n-l) = \sum_{i=1}^p b_i \sum_{n=0}^{N_w+p-1} x(n-i)x(n-l), \quad l = 1, 2, \dots, p$$

$$\begin{aligned}
r_{xx}(l) &= \sum_{n=-\infty}^{+\infty} x(n)x(n+l) = \sum_{n=0}^{N_w-1-l} x(n)x(n+l) = \sum_{n=0}^{N_w-1} x(n)x(n-l) = \\
&= \sum_{n=0}^{N_w+p-1} x(n)x(n-l) \\
r_{xx}(|i-l|) &= \sum_{n=-\infty}^{+\infty} x(n-i)x(n-l) = \sum_{n=0}^{N_w+p-1} x(n-i)x(n-l)
\end{aligned}$$

$$r_{xx}(l) = \sum_{i=1}^p b_i r_{xx}(|i-l|), \quad l = 1, 2, \dots, p$$

\leftarrow Toeplitz matrika

Obstaja zelo enostaven algoritem za računanje b_1, b_2, \dots, b_p

2. kovariančna metoda (velja za LP oz. AR spekter) – bolj zapletena od prejšnje

- ne predpostavljam, da je $x(n) = 0$ izven okna!
- množenje z okensko funkcijo ni potrebno

N_w vzorcev od $x(n)$

$$L = N_w$$

- pri računanju so potrebne vrednosti $x(n)$ za $n = -p, -p+1, \dots, 0, 1, \dots, N_w-1$

$$\Phi(i, l) = \sum_{n=0}^{N_w-1} x(n-i)x(n-l) = \sum_{n=-i}^{N_w-i-1} x(n)x(n+i-l) = \sum_{n=-l}^{N_w-l-1} x(N)x(n+l-i)$$

$$\Phi(0, l) = \sum_{i=1}^p b_i \Phi(i, l), \quad l = 1, 2, \dots, p$$

simetrična matrika (ni Toeplitzova)

$$E = \sum_{n=0}^{L-1} e^2(n) = a_0 \sum_{n=0}^{L-1} u^2(n) \Rightarrow \boxed{a_0 = \sqrt{E}}$$

Vedno lahko izberemo vzbujanje, da velja: $\sum_{n=0}^{L-1} u^2(n) = 1$

$$X(\omega) = H(\omega)U(\omega)$$

$$U(\omega) = 1$$

$$X(\omega) = H(\omega)$$

7.4 Primerjava LP spektra z neparametričnim spektrom

$$E = \sum_{n=0}^{L-1} e(n)^2 = \sum_{n=0}^{L-1} \left(x(n) - \sum_{l=1}^p b_l x(n-l) \right)^2$$

Parsevalov izrek

$$E = \frac{1}{2\pi} \int_0^{2\pi} |X_w(\omega)|^2 \left| 1 - \sum_{l=1}^p b_l e^{-j\omega l} \right|^2 d\omega$$

$$X_w(\omega) = \sum_{n=0}^{L-1} x(n) e^{-j\omega n}$$

Pomeni okno dolžine L

$$|H(\omega)|^2 = \frac{a_0^2}{\left| 1 - \sum_{l=1}^p b_l e^{-j\omega l} \right|^2}$$

$$E = \frac{a_0}{2\pi} \int_0^{2\pi} \frac{|X_w(\omega)|^2}{|H(\omega)|^2} d\omega \quad p \rightarrow \infty : H(\omega) \rightarrow X_w(\omega)$$

$H(\omega)$ dobimo z minimizacijo E .

Z minimizacijo E povzročimo, da sta X_w in H zelo podobna v “vrhovih” spektra, manj podobna sta v “dolinah” spektra.

