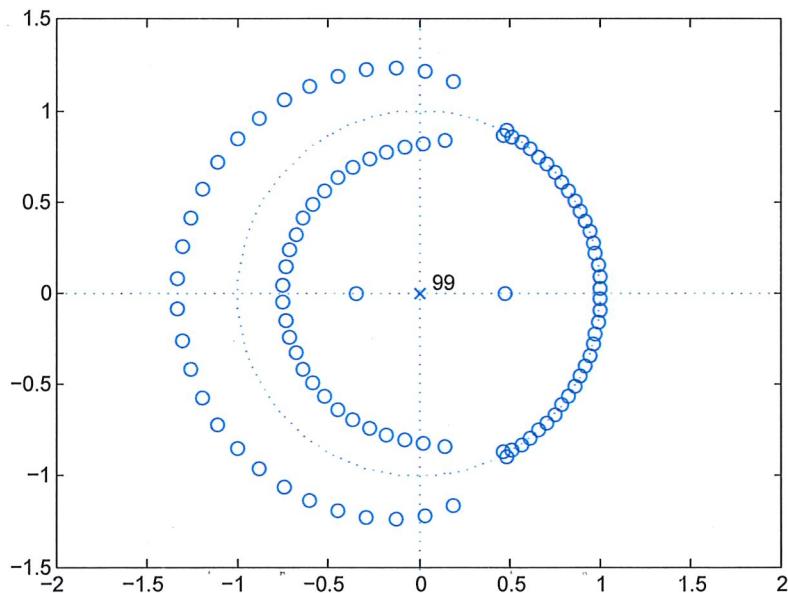


COMP.SGN.100 Signaalinkäsittelyn perusteet,
Tentti, 28.3.2023,
Sari Peltonen

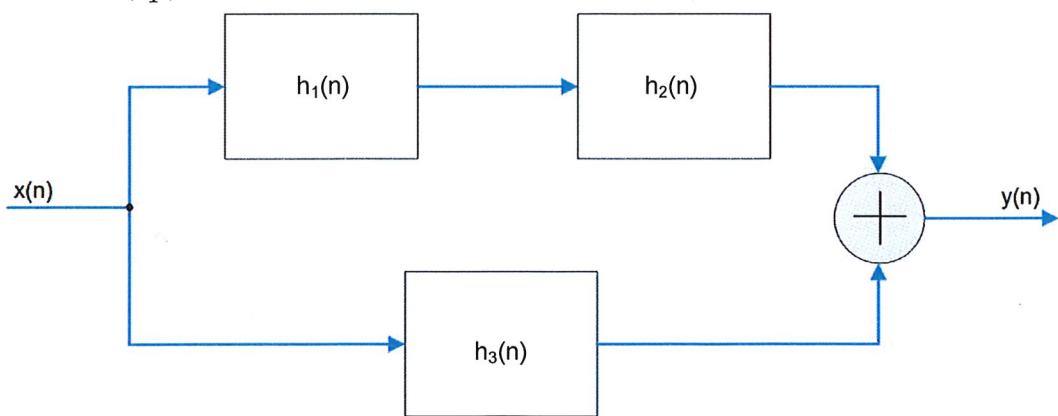
- Oma laskin sallittu.

- Tenttikysymyksiä ei tarvitse palauttaa.

1. (a) Erään suotimen napa-nollakuviot on alla olevassa kuvassa ja tiedetään että sen amplitudivaste $|H(e^{j\omega})| \in [0, 1]$. Hahmottele suotimen amplitudivasteen kuvaaja niin tarkasti kuin se näillä tiedoilla onnistuu. (2p)
 (b) Onko suodin stabiili ja millä perusteella? (2p)
 (c) Onko suodin FIR vai IIR ja millä perusteella? (2p)



2. (a) Laske vektorin $x(n) = (5, 7, -1, -1)^T$ diskreetti Fourier-muunnos. (3p)
 (b) Alla oleva järjestelmä voidaan toteuttaa yhtenä LTI-järjestelmänä. Mikä on saadun järjestelmän impulssivaste $h(n)$ ilmaistuna impulssivasteiden $h_1(n)$, $h_2(n)$ ja $h_3(n)$ avulla? (3p)



3. Oletetaan, että kausaalisen LTI-järjestelmän heräte $x(n)$ ja vaste $y(n)$ toteuttavat seuraavan differenssiyhtälön:

$$y(n) = -y(n-1) - \frac{1}{2}y(n-2) + x(n) - 2x(n-1) + 2x(n-2).$$

- (a) Määritä järjestelmän siirtofunktio $H(z)$. (2p)
 - (b) Piirrä järjestelmän napa-nollakuvio. (2p)
 - (c) Onko järjestelmä stabiili? Miksi / miksi ei? (2p)

4. Suunnittele ikkunamenetelmällä suodin (selvitä käsin impulssivasteen lauseke), jonka vaatimukset ovat seuraavat:

Estokaista	[0 kHz, 4 kHz]
Päästökaista	[5.5 kHz, 16 kHz]
Päästökaistan maksimivärähtely	0.1 dB
Estokaistan minimivaimennus	51 dB
Näytteenottotaaajuus	32 kHz

Käytä oheisia taulukoita hyväksesi. (6p)

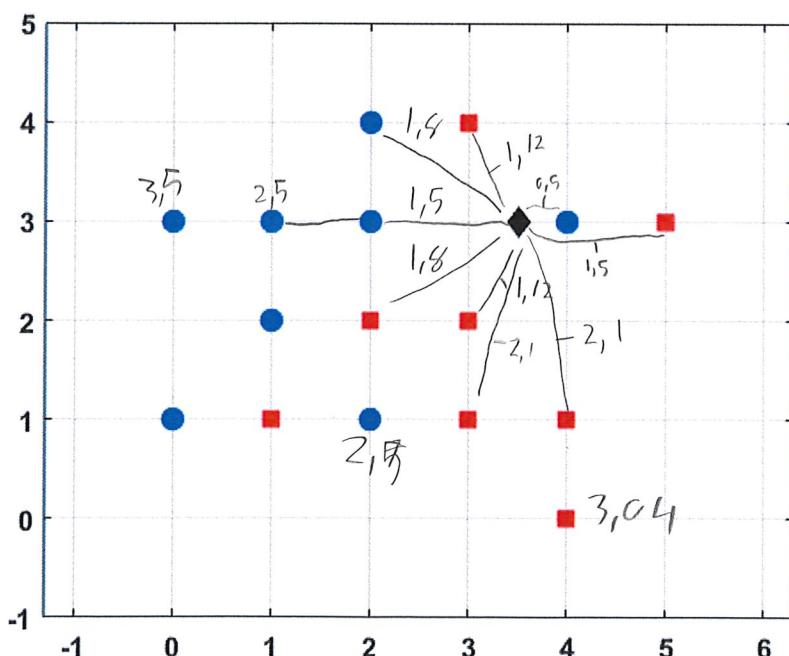
5. Alla oleva kuva esittää opetusdataa, jossa on kaksi luokkaa: "punaiset neliöt" (■) ja "siniset pallot" (●). Luokittelun käytetään k:n lähimmän naapurin (k-NN) luokittelijaa. Kumpaan luokkaan kuvaan merkity musta näyte (♦) kohdassa (3.5, 3) luokitellaan, kun käytössä on

- (a) 1-NN luokittelija,
(b) 3-NN luokittelija,
(c) 5-NN luokittelija,
(d) 7-NN luokittelija, ..

(e) 9-NN luokittelija,
(f) 11-NN luokittelija?

Perustele kukin vastauks

Perustele kukin vastauksesi. (6p)



Taulukot

Suodintyyppi	Impulssivaste kun	
	$n \neq 0$	$n = 0$
Alipäästö	$2f_c \text{sinc}(n \cdot 2\pi f_c)$	$2f_c$
Ylipäästö	$-2f_c \text{sinc}(n \cdot 2\pi f_c)$	$1 - 2f_c$
Kaistanpäästö	$2f_2 \text{sinc}(n \cdot 2\pi f_2) - 2f_1 \text{sinc}(n \cdot 2\pi f_1)$	$2(f_2 - f_1)$
Kaistanesto	$2f_1 \text{sinc}(n \cdot 2\pi f_1) - 2f_2 \text{sinc}(n \cdot 2\pi f_2)$	$1 - 2(f_2 - f_1)$

Ikkuna-funktion nimi	Siirtymäkaistan leveys (normalisoitu)	Päästökaistan värähtely (dB)	Estokaistan minimivaimennus (dB)	Ikkunan lauseke $w(n)$, kun $ n \leq (N-1)/2$
Suorakulmainen	0.9/N	0.7416	21	1
Bartlett	3.05/N	0.4752	25	$1 - \frac{2 n }{N-1}$
Hanning	3.1/N	0.0546	44	$0.5 + 0.5 \cos\left(\frac{2\pi n}{N}\right)$
Hamming	3.3/N	0.0194	53	$0.54 + 0.46 \cos\left(\frac{2\pi n}{N}\right)$
Blackman	5.5/N	0.0017	74	$0.42 + 0.5 \cos\left(\frac{2\pi n}{N}\right) + 0.08 \cos\left(\frac{4\pi n}{N}\right)$

Joitakin mahdollisesti hyödyllisiä Wikipedia-sivuja

Suppose two classes of observations have means $\vec{\mu}_0, \vec{\mu}_1$ and covariances Σ_0, Σ_1 . Then the linear combination of features $\vec{w} \cdot \vec{x}$ will have means $\vec{w} \cdot \vec{\mu}_i$ and variances $\vec{w}^T \Sigma_i \vec{w}$ for $i = 0, 1$. Fisher defined the separation between these two distributions to be the ratio of the variance between the classes to the variance within the classes:

$$S = \frac{\sigma_{\text{between}}^2}{\sigma_{\text{within}}^2} = \frac{(\vec{w} \cdot \vec{\mu}_1 - \vec{w} \cdot \vec{\mu}_0)^2}{\vec{w}^T \Sigma_1 \vec{w} + \vec{w}^T \Sigma_0 \vec{w}} = \frac{(\vec{w} \cdot (\vec{\mu}_1 - \vec{\mu}_0))^2}{\vec{w}^T (\Sigma_0 + \Sigma_1) \vec{w}}$$

This measure is, in some sense, a measure of the signal-to-noise ratio for the class labelling. It can be shown that the maximum separation occurs when

$$\vec{w} \propto (\Sigma_0 + \Sigma_1)^{-1} (\vec{\mu}_1 - \vec{\mu}_0)$$

When the assumptions of LDA are satisfied, the above equation is equivalent to LDA.

Be sure to note that the vector \vec{w} is the normal to the discriminant hyperplane. As an example, in a two dimensional problem, the line that best divides the two groups is perpendicular to \vec{w} .

Generally, the data points to be discriminated are projected onto \vec{w} , then the threshold that best separates the data is chosen from analysis of the one-dimensional distribution. There is no general rule for the threshold. However, if projections of points from both classes exhibit approximately the same distributions, a good choice would be the hyperplane between projections of the two means, $\vec{w} \cdot \vec{\mu}_0$ and $\vec{w} \cdot \vec{\mu}_1$. In this case the parameter c in threshold condition $\vec{w} \cdot \vec{x} > c$ can be found explicitly:

$$c = \vec{w} \cdot \frac{1}{2} (\vec{\mu}_0 + \vec{\mu}_1) = \frac{1}{2} \vec{\mu}_1^T \Sigma_1^{-1} \vec{\mu}_1 - \frac{1}{2} \vec{\mu}_0^T \Sigma_0^{-1} \vec{\mu}_0.$$

Inversion of 2×2 matrices [edit]

The cofactor equation listed above yields the following result for 2×2 matrices. Inversion of these matrices can be done as follows:^[6]

$$\mathbf{A}^{-1} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}^{-1} = \frac{1}{\det \mathbf{A}} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix} = \frac{1}{ad - bc} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix}.$$

A more condensed form of the difference equation is:

$$y[n] = \frac{1}{a_0} \left(\sum_{i=0}^P b_i x[n-i] - \sum_{j=1}^Q a_j y[n-j] \right)$$

which, when rearranged, becomes:

$$\sum_{j=0}^Q a_j y[n-j] = \sum_{i=0}^P b_i x[n-i]$$

To find the transfer function of the filter, we first take the Z-transform of each side of the above equation, where we use the time-shift property to obtain:

$$\sum_{j=0}^Q a_j z^{-j} Y(z) = \sum_{i=0}^P b_i z^{-i} X(z)$$

We define the transfer function to be:

$$\begin{aligned} H(z) &= \frac{Y(z)}{X(z)} \\ &= \frac{\sum_{i=0}^P b_i z^{-i}}{\sum_{j=0}^Q a_j z^{-j}} \end{aligned}$$

Considering that in most IIR filter designs coefficient a_0 is 1, the IIR filter transfer function takes the more traditional form:

$$H(z) = \frac{\sum_{i=0}^P b_i z^{-i}}{1 + \sum_{j=1}^Q a_j z^{-j}}$$

Techniques [edit]

Conceptual approaches to sample-rate conversion include: converting to an analog continuous signal, then re-sampling at the new rate, or calculating the values of the new samples directly from the old samples. The latter approach is more satisfactory, since it introduces less noise and distortion.^[3] Two possible implementation methods are as follows:

1. If the ratio of the two sample rates is (or can be approximated by)^{[nb 1][4]} a fixed rational number L/M : generate an intermediate signal by inserting $L - 1$ 0s between each of the original samples. Low-pass filter this signal at half of the lower of the two rates. Select every M -th sample from the filtered output, to obtain the result.^[5]
2. Treat the samples as geometric points and create any needed new points by interpolation. Choosing an interpolation method is a trade-off between implementation complexity and conversion quality (according to application requirements). Commonly used are: ZOH (for film/video frames), cubic (for image processing) and windowed sinc function (for audio).

Kaavoja

$$ax^2 + bx + c = 0 \Leftrightarrow x = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

$$\begin{cases} X(n) = X_0(n) + w_N^{-n} X_1(n), & \text{kun } n = 0, 1, 2, \dots, N/2 - 1 \\ X(n) = X_0(n - N/2) + w_N^{-n} X_1(n - N/2), & \text{kun } n = N/2, N/2 + 1, \dots, N - 1 \end{cases}$$