


**6. JELDİGİTALİZÁLÁS ÉS JELREKONSTRUKCIÓ: KVANTÁLÁS, KÓDOLÁS 2**

<b>6.3. Differenciális, prediktív kvantálás, kódolás</b>	<b>2</b>
6.3.1. A differenciális kvantálás alapelve	2
6.3.2. A lineáris predikció	3
6.3.3. A predikciós nyereség elvi határa	4
6.3.4. A differencia képző és rekonstruáló lineáris hálózatok	6
6.3.5. A differencia képzés és kvantálás	8
<b>6.4. Részsávú, kódolás</b>	<b>11</b>
6.4.1. A részsávú kódolók felépítése, analízise	11
6.4.2. Az optimális bitallokáció	13
<b>6.5. Transzformációs, kódolás</b>	<b>15</b>
6.5.1. A transzformációs kódolók felépítése, analízise	15
6.5.2. Az optimális transzformációs kódolás: KLT	16
6.5.3. Szuboptimális transzformációk	17
6.5.4. Kéjjelek transzformációs kódolása	18

## 6. Jeldigitalizálás és jelrekonstrukció: kvantálás, kódolás

### 6.3. Differenciális, prediktív kvantálás, kódolás

#### 6.3.1. A differenciális kvantálás alapelve



ahol  $\hat{\xi}_n$  a  $\xi_n$ -nek valamilyen becslése, jóslása (predikció).

$\delta_n$  a különbségi (predikciós hiba-) jel,  $Q$  pedig ehhez a különbségi jelhez illesztett kvantáló, melynek jel-zaj viszonya az előző pontok szerint optimalizált  $SNR_Q$  jel-zaj viszony érték. A kvantált differenciális jel:

$$\delta'_n = \delta_n + \varepsilon_n$$

ahol  $\varepsilon_n$  a kvantálási hiba.

Az eredő rendszer jel-zaj viszonyára írhatjuk:

$$SNR = \frac{E\{\xi_n^2\}}{E\{\varepsilon_q^2\}} = \frac{E\{\xi_n^2\}}{E\{\delta_n^2\}} \frac{E\{\delta_n^2\}}{E\{\varepsilon_q^2\}} = G_p \cdot SNR_Q,$$

ahol  $G_p$  az u. n. *predikciós nyereség*,

$$G_p = \frac{E\{\xi_n^2\}}{E\{\delta_n^2\}}$$

amely megmutatja, hogy a bejövő jel teljesítményéhez képest mekkora a hibajel teljesítménye.  $SNR_Q$  pedig a sémán  $Q$ -val jelölt kvantáló jel-zaj viszonya. Az eredmény tehát:

$$\boxed{SNR = G_p \cdot SNR_Q}$$

azaz a differenciális kvantálás elvét alkalmazva a nem differenciális kvantáláshoz képest a predikciós nyereséggel megnövelt jel-zaj viszony érhető el.

### 6.3.2. A lineáris predikció

A predikciós nyereség maximalizálásához a  $\delta_n = \xi_n - \hat{\xi}_n$  differenciális jel  $P_\delta = E\left\{\left|\xi_n - \hat{\xi}_n\right|^2\right\}$  teljesítményét kell minimalizálni.

A  $\hat{\xi}_n$  predikció legyen a forrás korábbi  $N$  mintájának valamilyen függvénye:

$$\hat{\xi}_n = S(\xi_{n-1}, \dots, \xi_{n-N}),$$

ahol  $S$  egy  $N$ -ed fokú predikció.

A továbbiakban lineáris predikcióval fogunk foglalkozni, a mikor  $\hat{\xi}_n = S(\xi_{n-1}, \dots, \xi_{n-N})$  lineáris függvény, azaz

$$\hat{\xi}_n = a_1 \xi_{n-1} + a_2 \xi_{n-2} + \dots + a_N \xi_{n-N}.$$

Az  $a_i$   $i=1,2,\dots,N$  együtthatókat az  $N$ -ed fokú predikciós együtthatóknak nevezzük.

Ekkor a lineáris predikció alapfeladata: határozzuk meg a predikciós együtthatók azon értékét, melyeknél a differenciális jel teljesítménye minimális:

$$\min_{a_1, \dots, a_N} E\left\{\left|\xi_n - \hat{\xi}_n\right|^2\right\}.$$

A továbbiakban legyen:

$$\underline{a} = [a_1, \dots, a_N]^T \text{ és } \underline{\xi}_{n-1} = [\xi_{n-1}, \dots, \xi_{n-N}]^T$$

Ekkor a predikciós egyenlet vektoros formában:

$$\hat{\xi}_n = \underline{a}^T \underline{\xi}_{n-1}.$$

A minimalizálandó kifejezés:

$$E\left\{\left|\xi_n - \hat{\xi}_n\right|^2\right\} = P_\delta = E\left\{\xi_n^2 - 2\xi_n \underline{a}^T \underline{\xi}_{n-1} + \underline{a}^T \underline{\xi}_{n-1} \underline{a}^T \underline{\xi}_{n-1}\right\} = E\left\{\xi_n^2 - 2\xi_n \underline{a}^T \underline{\xi}_{n-1} + \underline{a}^T \underline{\xi}_{n-1} \underline{\xi}_{n-1}^T \underline{a}\right\}$$

Amiből az  $N$  változós kvadratikus alak:

$$P_\delta = r_\xi(0) - 2\underline{a}^T \begin{bmatrix} r_\xi(1) \\ r_\xi(2) \\ \dots \\ r_\xi(N) \end{bmatrix} + \underline{a}^T \begin{bmatrix} r_\xi(0) & r_\xi(1) & \dots & r_\xi(N-1) \\ r_\xi(1) & r_\xi(0) & & r_\xi(N-2) \\ \dots & \dots & \dots & \dots \\ r_\xi(N-1) & r_\xi(N-2) & \dots & r_\xi(0) \end{bmatrix} \underline{a},$$

ahol:

$r_\xi(m) = E\{\xi_n \xi_{n+m}\}$  az autokorrelációs függvény,

$$\underline{r} = \begin{bmatrix} r_\xi(1) \\ r_\xi(2) \\ \dots \\ r_\xi(N) \end{bmatrix}, \text{ és}$$

$$\underline{\underline{R}} = \begin{bmatrix} r_\xi(0) & r_\xi(1) & \dots & r_\xi(N-1) \\ r_\xi(1) & r_\xi(0) & & r_\xi(N-2) \\ \dots & \dots & & \dots \\ r_\xi(N-1) & r_\xi(N-2) & \dots & r_\xi(0) \end{bmatrix},$$

ami a folyamat  $N$ -ed rendű autokorrelációs mátrixa (egyben Toeplitz mátrix).  
A minimum megkereséséhez a


$$\text{grad}_{\underline{a}} \sigma_\delta^2 = -2\underline{r} + 2\underline{\underline{R}}\underline{a} = 0$$

normál egyenletet kell megoldani. A megoldás:


$$\underline{a}_{opt} = \underline{\underline{R}}^{-1} \underline{r}.$$

megj: az inverz autokorrelációs mátrixot Levinson módszerrel számítják.

A predikciós egyenletből látható, hogy a lineáris predikció egy hurokmentes FIR szűrőt valósít meg, vagyis



ahol a predikciót végző blokk (P(z)):



$$P(z) = \sum_{i=1}^N a_i z^{-i}.$$

### 6.3.3. A predikciós nyereség elvi határa

Az  $N$ -ed fokú predikció optimális együtthatóira kapott  $\underline{a}_{opt} = \underline{\underline{R}}_N^{-1} \underline{r}_N$  eredményünket a predikciós hiba teljesítményének  $P_\delta = r_\xi(0) - 2\underline{a}^T \underline{r}_N + \underline{a}^T \underline{\underline{R}}_N \underline{a}$  képletébe visszaírva kapjuk, hogy

$$P_{\delta N \min} = r_\xi(0) - \underline{r}_N^T \underline{\underline{R}}_N^{-1} \underline{r}_N$$

és a predikációs nyereség értéke:

$$G_{PN} = \frac{r_{\xi}(0)}{r_{\xi}(0) - \underline{r}_N^T \underline{R}_N^{-1} \underline{r}_N}$$

Nyilvánvaló, hogy a predikációs nyereség az N fokszámnak monoton nem csökkenő függvénye, így létezik határértéke, melyre bebizonyítható, hogy

$$\lim_{N \rightarrow \infty} G_{P,N} = G_{P\max} = \frac{1}{\gamma_{\xi}}, \quad \gamma_{\xi} = \frac{\exp\left(\frac{1}{F} \int_{-F/2}^{F/2} \ln(S_{\xi}(f)) df\right)}{\frac{1}{F} \int_{-F/2}^{F/2} S_{\xi}(f) df}$$

ahol a  $\gamma_{\xi}$  szám a stacioner  $\xi$  forrás spektrális laposság mértéke, mely az  $S_{\xi}(f)$  teljesítménysűrűség spektrum mértani közepének és számtani közepének a hányadosa.

Ennek belátásához tételezzünk fel egy  $\Delta f = F/N$  szélességű intervallumok felett  $S_i$  konstans értékű, lépcsős  $S(f)$  spektrumot, (vagy ami ezzel ekvivalens, az integrálokat téglányösszeggel közelítjük):

$$\gamma_{\xi} = \frac{\exp\left(\frac{1}{F} \sum_i \ln(S_i) \Delta f\right)}{\frac{1}{F} \sum_i S_i \Delta f} = \frac{\exp\left(\frac{1}{N} \sum_i \ln(S_i)\right)}{\frac{1}{N} \sum_i S_i} = \frac{\sqrt[N]{\prod_i S_i}}{\frac{1}{N} \sum_i S_i},$$

ezért  $\gamma_{\xi} \leq 1$ .

Tehát  $G_{P\max} \geq 1$  és akkor 1, ha a forrás fehér zaj. A fehér zaj tehát nem predikálható.

Egy jel annál hatásosabban predikálható, minél egyenlőtlenebb a teljesítménysűrűség spektruma.


Az is nyilvánvaló, hogy a nulla sávszélességű, azaz vonalas spektrumú összetevő periodikus komponenst jelent, mely nulla predikációs hibával rekonstruálható. Ez azt jelenti, hogy a harmonikus összetevők mintáit nem kell kvantálni és átvinni a csatornán, a dekóderben egy megfelelően beállított kezdőértékekkel működő oszcillátor tökéletesen rekonstruálja őket.

### 6.3.4. A differencia képző és rekonstruáló lineáris hálózatok


A differenciális kódolásnál a jel-zaj viszonyának a predikciós nyereséggel megnövelt értékének remélt realizálásához vizsgáljunk meg néhány differenciaképző ötletet.

Egyelőre tegyük fel, hogy normál üzemmódú, nagyon finom kvantálókat használunk, azaz most eltekintünk a nemlineáris kvantálási torzítástól, és a lineáris modell keretein belül a kódolóbeli differencia képzés és a hozzátartozó dekódolóbeli rekonstrukció néhány strukturális lehetőségét vizsgáljuk meg. A vizsgált struktúrákban a  $H(z)$  transzferfüggvényű dobozok alatt mindig a bemeneti minták késleltetettjeinek valamilyen súlyozott összegét értjük (FIR szűrők).

#### 1. Előrecsatolt differenciaképzés



all zero koder (MA)





all pole dekoder (AR)

Megjegyzések:

- $H(z)$  együtthatóinak optimális értékét a **jól ismert lineáris predikció** feladatának 6.2.2.-beli „egyszerű” megoldása adja.
- A kódoló hurokmentes hálózat, így feltétel nélkül **stabil**.
- A differenciális jel **hurkon kívül** keletkezik.
- A rekurzív dekóder esetleges instabil pólusainál a bemeneti differenciális jelnek zérusa van (a kódoló miatt), így az esetleges instabil pólus nem gerjesztődik.
- Minél nagyobb predikciós nyereséget érünk el a kódolóban, azaz minél kisebb a differenciális jel teljesítménye, annál inkább „**teljesítmény-erősítőként**” üzemel a **dekóder**.

#### 2. Hátracsatolt differenciaképző




all zero decoder (MA)

Megjegyzések:

- $H(z)$  együtthatóinak optimális értékét egy nagyon bonyolult, nemlineáris optimalizálási feladat „nem ismert” megoldása adja.
- A rekurzív kódoló stabilitását semmi sem garantálja.
- A differenciális jel hurkon belül keletkezik.


### 3. Hátracsatolt differencia képzés lineáris prediktorral



Megjegyzések:


- Ha  $H(z)$  ugyanaz az egyszerű lineáris prediktor, mint az első esetben, akkor a kódoló (és természetesen a dekódoló is) ekvivalens az 1. esettel, és így megőröklí annak ismert és stabil tulajdonságait.
- Ugyanakkor ez a kódoló rekurzív hálózat, a differenciális jel egy hurkon belül keletkezik.

### 4. Többfokozatú differencia képzés



Megjegyzések:

- Az egyes fokozatokra ugyanaz igaz, mint az 1. esetre.
- Több fokozatú predikció lehetővé teszi a különböző típusú predikciók (például közeli mintákon alapuló és távoli mintákon alapuló) szétválasztását.


5. Több hurkú differencia képzés

Megjegyzések:

- A kódoló és így a dekódoló is ekvivalens az előzővel
- A differenciális jelek hurkokban képződnek, így ezekre ugyanaz igaz, mint a 3. esetre.

## 6.3.5. A differencia képzés és kvantálás

A továbbiakban a differenciális jel kvantálását is figyelembe vesszük, feltéve, hogy a differenciális jelhez illesztett kvantálókat alkalmazunk, és így a normál üzemmódú kvantálókat lineáris, additív zajhelyettesítő képükkel vesszük figyelembe. Ebben az esetben két bemenetű ( az x jel, és az e kvantálási hibajel, zaj) és egy kimenetű (az y rekonstruált jel) lineáris hálózatokat vizsgálhatunk, alkalmazva a szuperpozíció elvét.

1. Előrecsatolt lineáris prediktor

Az analízis eredménye:


$$Y(z) = X(z) + \frac{1}{1 - H(z)} E(z)$$



Megjegyzések:

- Nagy baj van: a rekonstruált jelben a kvantálási hiba a dekóder teljesítményerősítő jellegű transferfüggvényén keresztül, felerősítve jelenik meg, így nem realizálódik a predikciós nyereség, értelmetlen a differenciális kvantálás.

## 2. Hátracsatolt differenciaképző



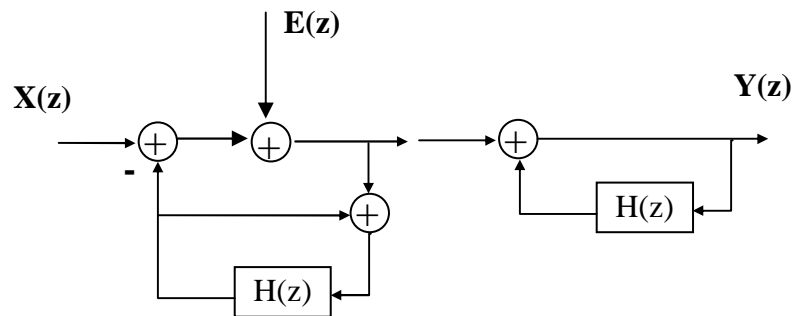
Az analízis eredménye:

$$Y(z) = X(z) + E(z)$$

Megjegyzések:

- A kvantálási hiba erősítés nélkül kerül a rekonstruált kimenetre, realizálható lenne a predikciós nyereség,
- ha a többi, az előző pontban leírt nehézség nem állna fenn továbbra is.

## 3. Lineáris prediktor visszacsatolt változata



Az analízis eredménye:

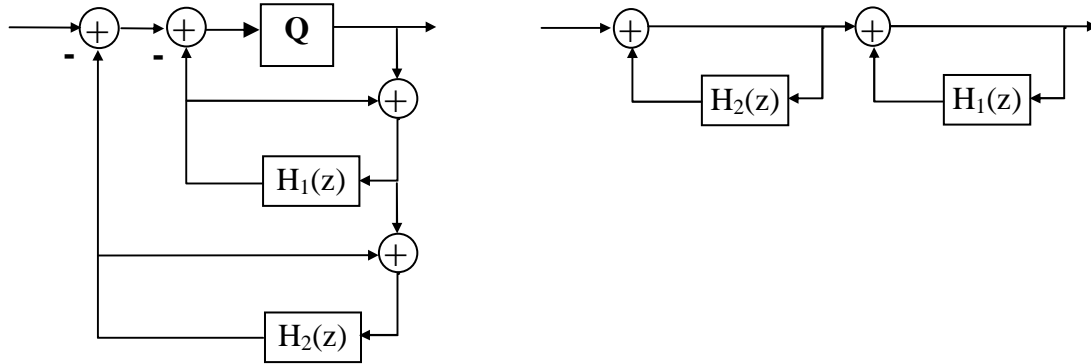
$$Y(z) = X(z) + E(z)$$

Örömteli felismerés:

- Sikerül realizálni a predikciós nyereséget a  $H(z)$  lineáris prediktor felhasználásával stabil kódolóval, ha
- a kvantálót a differenciaképző hurkon belül helyezzük el.

Ez a struktúra a differenciális, prediktív kódolók alapstruktúrája.

A többfokozatú prediktív kódolókat több hurkú, differenciális kódolókkal valósíthatjuk meg:



## 6.4. Részszávú, kódolás

### 6.4.1. A részszávú kódolók felépítése, analízise

Az eddigiek során az  $F$  órajelű,  $P$  átlagteljesítményű  $\xi_n$  stationer forrást az  $F$  órajellel működtetett  $R$  bites illesztett (optimális) kvantálóval kvantáltuk:



Az illesztett kvantálás eredményeként a normál működésű kvantálóban keletkező  $\varepsilon = \eta - \xi$  zaj teljesítményre írhatjuk, hogy

$$P_\varepsilon = c P 2^{-2R}, \text{ ahol } c \text{ eloszlás és kvantáló típus függő konstans,}$$

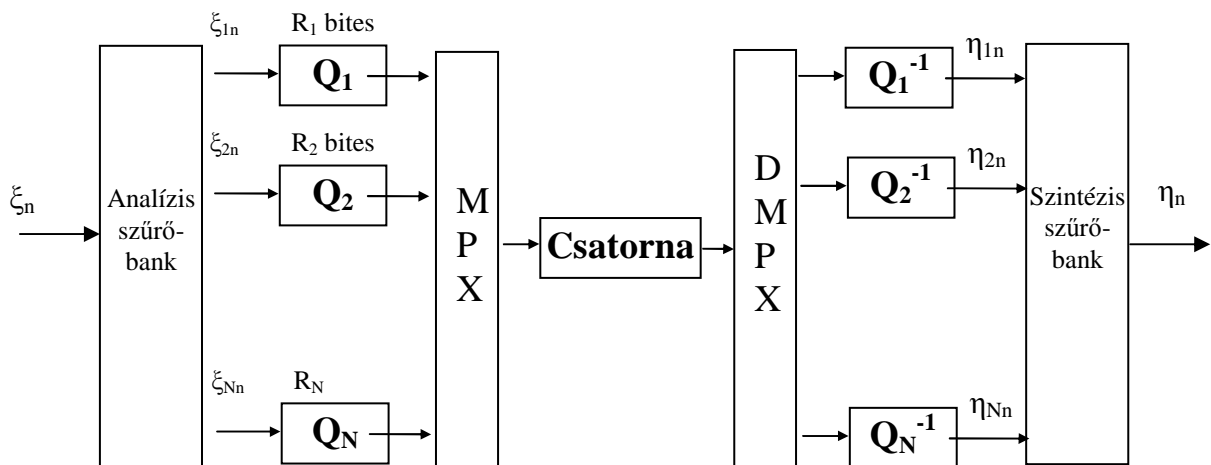
tehát jel-zaj viszony:

$$\text{SNR}_Q = k 2^{2R}, \quad k=1/c.$$

Az adott minőséghez (jel-zaj viszony) szükséges csatorna sebesség:

$$I_Q = F \cdot R \text{ (bit/sec).}$$

A részszávú kódolás esetén a nagy  $F$  sebességű  $\xi_n$  bemenetet az analízis szűrőbank  $N$ -darab kisebb  $F_i$ ,  $i = 1, 2, \dots, N$  sebességű  $\xi_{in}$ ,  $i = 1, 2, \dots, N$  összetevőkre bontja, melyek teljesítményei  $P_i$ ,  $i = 1, 2, \dots, N$ .  $\xi_{in}$  részszávú összetevőket külön-külön,  $F_i$  sebességgel működtetett  $R_i$  bites illesztett kvantálókkal kvantáljuk. A részszávú összetevők kvantálóinak kimeneteit az MPX multiplexer szervezi a digitális csatornán átvihető szimbólum sorozattá. A dekóder a DMPX demultiplexerrel kezdődik, a kisebb sebességű részszávú összetevők mintáit az inverz kvantálók rekonstruálják, majd az eredő nagysebességű kimenetet a szintézis szűrőbank állítja elő.



A részsávú összetevők  $P_i$  teljesítményeire feltesszük, hogy

$$P = \sum_{i=1}^N P_i ,$$

ugyanis át nem lapolódó részsávokba eső spektrumú stacioner folyamatok korrelálatlanok, tehát összeg négyzetes várható értéke egyenlő a négyzetek várható értékeinek összegével. Hasonlóképpen a részsávú kvantálás eredő zajteljesítménye egyenlő a rész kvantálók zajteljesítményeinek összegével:

$$P_\varepsilon = \sum_{i=1}^N P_{\varepsilon,i}$$

Továbbá a részsávú összetevők illesztett kvantálásainál keletkező zajteljesítményre írhatjuk, hogy

$$P_{\varepsilon,i} = c P_i 2^{-2R_i} ,$$

ahol  $c$  ugyanaz a konstans, amit az referenciául tekintendő nem részsávú illesztett kvantálónál bevezettünk.

A részsávú (SubBand) kódolás eredő jel-zaj viszonya tehát

$$\text{SNR}_{\text{SB}} = \frac{\sum_i P_i}{\sum_i c P_i 2^{-2R_i}} = k \frac{\sum_i P_i}{\sum_i P_i 2^{-2R_i}} = \frac{2^{-2R} \sum_i P_i}{\sum_i P_i 2^{-2R_i}} k 2^{2R} = G_{\text{SB}} \text{SNR}_Q$$

ahol

$$G_{\text{SB}} = \frac{2^{-2R} \sum_i P_i}{\sum_i P_i 2^{-2R_i}}$$

az egyszeri illesztett kvantálóhoz képest elért részsávú nyereség, ami tehát a részsávú felbontás által létrejött  $P_i$  teljesítmény eloszlástól és a kvantálók bitszámainak  $R_i$  kiosztásától függ.

A szükséges csatorna sebesség:

$$I_{\text{SB}} = \sum_i F_i R_i \text{ (bit/sec).}$$

Ha egyenközű részsávú felbontást végzünk, akkor  $F_i = F/N$ ,  $i = 1, 2, \dots, N$  és ekkor az azonos csatorna sebességhez ( $I_{\text{SB}} = I_Q$ ) szükséges bitkiosztásra adódik:

$$\sum_i R_i = NR$$

### 6.4.2. Az optimális bitallokáció

Ha a frekvencia tengely felett egyenközű részsávú felbontás mellett döntünk, akkor már adott a részsávú felbontás  $P_i$  teljesítmény eloszlása és a részsávú kódolástól várható nyereség már csak a kvantálók bitszámainak  $R_i$  kiosztásától függ.

A feladat tehát:

- adott  $P_i$ ,  $i = 1, 2, \dots, N$  teljesítmény eloszlású sávfelbontás és
- adott összbítszám mellett,  $\sum_i R_i = NR$
- keressük a kvantálók azon  $R_i$  kiosztását, melynél minimális ez eredő kvantálási zaj teljesítménye:

$$\min_{R_1, R_2, \dots, R_N} P_{e,SB} \quad \text{feltéve, hogy } \sum_i R_i = NR$$

azaz

$$\min_{R_1, R_2, \dots, R_N} \sum_{i=1}^N P_i 2^{-2R_i}, \quad \sum_i R_i - NR = 0$$

Többváltozós függvény **feltételes szélsőértékét** keressük. A Lagrange multiplikátoros módszer szerint a feladatot visszavezetjük az alábbi  $(N+1)$  változós, **feltétel nélküli** szélsőérték keresésre:

$$\min_{R_1, R_2, \dots, R_N, \lambda} \left\{ \sum_{i=1}^N P_i 2^{-2R_i} + \lambda \left( \sum_i R_i - NR \right) \right\} = \min_{R_1, R_2, \dots, R_N, \lambda} \varphi(R_1, R_2, \dots, R_N, \lambda)$$

A differenciálható célfüggvény szélsőértékére írhatjuk:  $\text{grad } \varphi(R_1, \dots, R_N, \lambda) = 0$ , azaz

$$\frac{\partial}{\partial R_i} \left\{ \sum_{i=1}^N P_i 2^{-2R_i} + \lambda \left( \sum_i R_i - NR \right) \right\} = \frac{\partial}{\partial R_i} (P_i 2^{-2R_i}) + \lambda = -2 \ln 2 P_i 2^{-2R_i} + \lambda, \quad i = 1, 2, \dots, N$$

ahol  $\ln$  a természetes alapú logaritmus.  $R_i$ -t kifejezve:

$$R_i = \frac{1}{2} \text{ld } P_i + \frac{1}{2} \text{ld} \left( \frac{2 \ln 2}{\lambda} \right) \quad i = 1, 2, \dots, N$$

Ezeket összegezve és  $\sum_i R_i = NR$  feltételt felhasználva:

$$\sum_i R_i = \frac{1}{2} \sum_i \text{ld } P_i + N \frac{1}{2} \text{ld} \left( \frac{2 \ln 2}{\lambda} \right) = NR, \quad \text{melyből } \frac{1}{2} \text{ld} \left( \frac{2 \ln 2}{\lambda} \right) = R - \frac{1}{2N} \sum_i \text{ld } P_i. \quad \text{Ezt } R_i \text{-be}$$

visszahelyettesítve kapjuk:

$$R_i = \frac{1}{2} \text{ld } P_i + R - \frac{1}{2N} \sum_i \text{ld } P_i = R + \frac{1}{2} \left( \text{ld } P_i - \frac{1}{N} \text{ld} \left( \prod_i P_i \right) \right) \quad \text{azaz}$$

$$R_i = R + \frac{1}{2} \text{ld} \frac{P_i}{\sqrt[N]{\prod_i P_i}}, \quad i = 1, 2, \dots, N$$

Eredményünk szerint, tehát az optimális bit kiosztás azt jelenti, hogy az átlagos  $R$  bitszámnál nagyobb  $R_i$  bitszámot (azaz finomabb kvantálást) azon részsávok kvantálására osztunk ki, melyek  $P_i$  teljesítménye nagyobb a részsáv felbontásnál kapott teljesítmény eloszlás mértani közepénél, azaz  $P_i > \sqrt[N]{\prod_i P_i}$ . A kis teljesítményű részsávok az átlagnál kevesebb bitszámot kapnak, azaz ezeket durvábban kvantáljuk.

Az optimális bit kiosztásnál az egyes részsávokban keletkező kvantálási zajra kapjuk:

$$P_{ei} = c P_i 2^{-2R_i} = c P_i 2^{-2R} \left( \frac{P_i}{\sqrt[N]{\prod_i P_i}} \right)^{-1} = c \sqrt[N]{\prod_i P_i} 2^{-2R}$$

Tehát  $P_{ei}$   $i$ -től független, a kvantálási zaj teljesítményegyenletes eloszlású a részsávokban.

A részsávú kódolással elérhető nyereség:

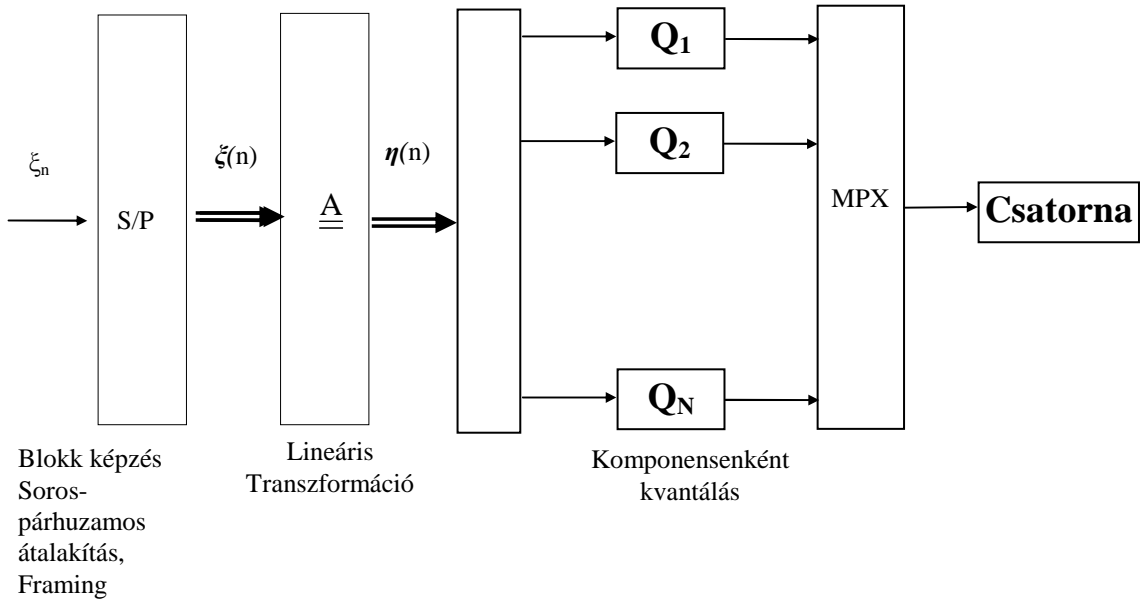
$$G_{SB} = \frac{\text{SNR}_{SB}}{\text{SNR}_Q} = \frac{P_{e,Q}}{\sum_i P_{e,i}} = \frac{c P 2^{-2R}}{N c \sqrt[N]{\prod_i P_i} 2^{-2R}} = \frac{\frac{1}{N} \sum_i P_i}{\sqrt[N]{\prod_i P_i}} \geq 1$$

Részsávú kódolással tehát, annál nagyobb jel-zaj viszony érhető el, minél jobban eltér a részsáv összetevők teljesítményeinek mértani közepe a számtani középtől, azaz minél egyenlőtlenebb a teljesítmény eloszlás. Az elérhető jel-zaj viszony javulásra kapott eredményünk lényegében ugyan az mint a differenciális-prediktív kódolóknál megismert határ.

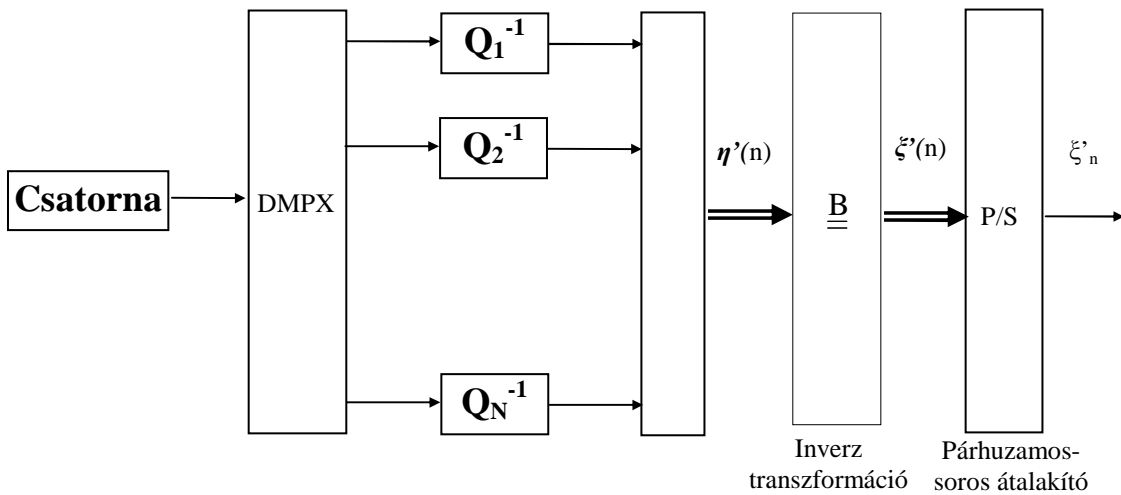
### 6.5. Transzformációs, kódolás

#### 6.5.1. A transzformációs kódolók felépítése, analízise

A kódoló:



Dekódoló:



ahol:  $\xi(n) = [\xi_n, \xi_{n-1}, \dots, \xi_{n-(N-1)}]^T$ ,  $\eta(n) = \underline{\underline{A}} \xi(n)$  és  $\underline{\hspace{2cm}}$ .

### 6.5.2. Az optimális transzformációs kódolás: KLT

Olyan transzformációs mátrixot keresünk, amely a stacioner folyamat korrelált  $\xi(n-i)$ ,  $i=0,1, \dots, (N-1)$  mintáinak egyenletes energia-eloszlású vektorából egyenletlent állít elő.

A stacioner  $\xi_n$  forrás  $N$  hosszú blokkjainak autokorrelációs mátrixa az alábbi

$$E\{\underline{\xi}(n) \cdot \underline{\xi}^T(n)\} = \underline{\underline{R}}_{\xi} = \begin{bmatrix} R(0) & R(1) & \dots & R(N-1) \\ & R(0) & \dots & \\ & & \dots & \\ & & & \dots \end{bmatrix},$$

mely egy Toeplitz mátrix, átlójában a konstans átlag teljesítménnyel.

A transzformált vektor autokorreláció mátrixa:

$$E\{\underline{\eta}(n) \cdot \underline{\eta}^T(n)\} = E\{\underline{A}\underline{\xi}(n) \cdot \underline{\xi}^T(n)\underline{A}^T\} = \underline{\underline{A}}\underline{\underline{R}}_{\xi}\underline{\underline{A}}^T = \underline{\underline{R}}_{\eta}$$

Olyan transzformációs mátrixot keresünk, amely a stacioner folyamat korrelált  $\xi(n-i)$ ,  $i=0,1, \dots, (N-1)$  mintáinak egyenletes energia-eloszlású vektorából olyan  $\underline{\eta}(n)$  vektort állít elő, melynek komponensei

- korrelálatlanok, azaz az  $\underline{\underline{R}}_{\eta}$  mátrix diagonál mátrix (nulla várható értékű forrást tételezzünk fel) és
- teljesítményeinek eloszlása a lehető legegyszerűsebb, azaz adott összeg mellett minimális a szorzatuk, mert az optimális bitallokáció mellett ekkor realizálható a legnagyobb nyereség.

A feladat megoldását a  $\xi_n$  forrás  $N \times N$ -es  $\underline{\underline{R}}_{\xi}$  autokorrelációs mátrixának sajátvektorai és sajátértékei alapján kapjuk meg:

Az  $\underline{\underline{R}}_{\xi}$  mátrix  $d_i$  saját értékei és a hozzájuk tartozó  $\underline{v}_i$  saját vektorai definíciója:

$$\underline{\underline{R}}_{\xi} \underline{v}_i = d_i \underline{v}_i \quad i = 1, 2, \dots, N$$

ami másként is felírható:

$$\underline{\underline{R}}_{\xi} \underline{\underline{V}} = \underline{\underline{V}} \underline{\underline{D}} \quad \text{ahol } \underline{\underline{V}} = [\underline{v}_1, \underline{v}_2, \dots, \underline{v}_N] \text{ és } \underline{\underline{D}} = \text{diag}\{d_1, d_2, \dots, d_N\}$$

A pozitív definit  $\underline{\underline{R}}_{\xi}$  autokorrelációs mátrixra igaz, hogy sajátértékei pozitív számok, sajátvektorai ortogonálisak (és egyre normáltak)

$$\underline{v}_i^t \underline{v}_j = \delta_{i,j} \quad \text{azaz } \underline{\underline{V}}^t \underline{\underline{V}} = \underline{\underline{I}} \quad , \quad \text{azaz } \underline{\underline{V}}^{-1} = \underline{\underline{V}}^t$$

Tehát

$$\underline{\underline{R}}_{\eta} = \underline{\underline{D}} = \underline{\underline{V}}^t \underline{\underline{R}}_{\xi} \underline{\underline{V}}$$



Az optimális transzformációs kódolóban alkalmazandó transzformációs mátrix a stacioner forrás autokorrelációs mátrixa sajátvektoraiból mint sorokból álló mátrix:

$$\underline{\underline{\mathbf{A}}} = \underline{\underline{\mathbf{V}}}^t = \begin{bmatrix} \underline{\underline{\mathbf{v}}}_1^t \\ \underline{\underline{\mathbf{v}}}_2^t \\ \dots \\ \underline{\underline{\mathbf{v}}}_N^t \end{bmatrix} \quad \text{illetve} \quad \underline{\underline{\mathbf{B}}} = \underline{\underline{\mathbf{A}}}^{-1} = \underline{\underline{\mathbf{V}}} = [\underline{\underline{\mathbf{v}}}_1, \underline{\underline{\mathbf{v}}}_2, \dots, \underline{\underline{\mathbf{v}}}_N]$$

Ezt a transzformációt Karhunen-Loeve transzformációnak nevezzük.

### 6.5.3. Szuboptimális transzformációk

Transzformációk:

- 4 pontos DWHT

$${}^4\underline{\underline{\mathbf{H}}} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & -1 & 1 \\ 1 & -1 & 1 & -1 \end{bmatrix}$$

- 4 pontos DFT

$${}^4\underline{\underline{\mathbf{F}}} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & -j & -1 & j \\ 1 & -1 & 1 & -1 \\ 1 & j & -1 & j \end{bmatrix}$$

- 4 pontos DCT

$${}^4\underline{\underline{\mathbf{C}}} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ a & b & -b & -a \\ 1 & -1 & -1 & 1 \\ 1 & -a & a & -b \end{bmatrix} \quad \begin{aligned} a &= \sqrt{2} \cos \frac{\pi}{8} \\ b &= \sqrt{2} \sin \frac{3\pi}{8} \end{aligned}$$

DCT-t használják gyakran, ami visszavezethető DFT (FFT)-re. Az N-pontos, valós DCT transzformáció N-pontos bemenetét kiegészíthetjük 2N pontos valós-páros bemenetű a komplex 2N-pontos FFT számára, ekkor a kimenet 2N-pontos valós-páros lesz, melynek N-pontos része az N-pontos valós DCT transzformáció kimenete.

#### **6.5.4. Képlek transzformációs kódolása**