

6. Szűréselmélet alapjai (folyt.):

Kalman szűrő vektoros esetben:

A rendszermodell: $x(n) = Ax(n-1) + w(n-1)$, a megfigyelés: $y(n) = Cx(n) + n(n)$. Mind a rendszer, mind a megfigyelési zaj vektor nulla várható értékű és fehér. Korreláció mátrixaik:

$Q(n) = E\{w(n)w^T(n)\}$ (ez lép σ_w^2 helyébe), $R(n) = E\{n(n)n^T(n)\}$, (ez lép σ_n^2 helyébe). Az optimális rekurzív szűrő

$$\begin{cases} \hat{x}(n) = A\hat{x}(n-1) + K(n)(y(n) - CA\hat{x}(n-1)) \\ K(n) = P_1(n)C^T [CP_1(n)C^T + R(n)]^{-1}, \text{ ahol} \\ P_1(n) = AP(n-1)A^T + Q(n-1) \\ P(n) = P_1(n) - K(n)CP_1(n) = (I - K(n)C)P_1(n) \\ P_1(n+1) = A(I - K(n)C)P_1(n)A^T + Q(n) \end{cases} \quad (165)$$

Itt $K(n)$ a Kalman erősítés, $P(n)$ a hiba kovariancia mátrixa, $P_1(n)$ pedig segédmátrix a számítások egyszerűsítése céljából.

Kalman prediktor vektoros esetben:

A rendszermodell: $x(n+1) = Ax(n) + w(n)$, a megfigyelés: $y(n) = Cx(n) + n(n)$. Mind a rendszer, mind a megfigyelési zaj vektor nulla várható értékű és fehér. Korreláció mátrixaik:

$Q(n) = E\{w(n)w^T(n)\}$ (ez lép σ_w^2 helyébe), $R(n) = E\{n(n)n^T(n)\}$,

(ez lép σ_n^2 helyébe). Az optimális rekurzív prediktor:

$$\hat{x}(n+1) = A\hat{x}(n) + G(n)(y(n) - C\hat{x}(n)), \quad (166)$$

és keressük azt a $G(n)$ mátrixot, amely mellett a becslés

$$P(n+1) = E\{[x(n+1) - \hat{x}(n+1)][x(n+1) - \hat{x}(n+1)]^T\} = E\{e(n+1)e^T(n+1)\} \quad (167)$$

kovariancia mátrixa minimális. Képezzük (167) deriváltját $G(n)$ szerint. Az optimumot akkor kapjuk, ha ez a derivált nullával egyenlő:

$$\frac{\partial P(n+1)}{\partial G(n)} = -2E\{[x(n+1) - \hat{x}(n+1)][y(n) - C\hat{x}(n)]^T\} = 0. \quad (168)$$

Ha a (168) összefüggésbe behelyettesítjük a rendszermodell és a prediktor összefüggéseit, akkor:

$$\begin{aligned} E\{[Ax(n) + w(n) - A\hat{x}(n) - G(n)(Cx(n) + n(n) - C\hat{x}(n))][Cx(n) + n(n) - C\hat{x}(n)]^T\} = \\ = E\{[(A - G(n)C)e(n) + w(n) - G(n)n(n)][Ce(n) + n(n)]^T\} = \\ = [A - G(n)C]P(n)C^T - G(n)R(n) = 0 \end{aligned} \quad (169)$$

A (169) összefüggés felírásakor felhasználtuk az alábbi előzetes ismereteinket:

$$E\{e(n)n^T(n)\} = E\{w(n)e^T(n)\} = E\{n(n)e^T(n)\} = E\{w(n)n^T(n)\} = 0 \quad (170)$$

A (169) összefüggésből a keresett prediktor erősítés:

$$G(n) = AP(n)C^T [CP(n)C^T + R(n)]^{-1}. \quad (171)$$

A becslés (167) szerinti kovariancia mátrixa:

$$\begin{aligned}
 P(n+1) &= [(A - G(n)C)e(n) + w(n) - G(n)n(n)][(A - G(n)C)e(n) + w(n) - G(n)n(n)]^T = \\
 &= [A - G(n)C]P(n)[A - G(n)C]^T + Q(n) + G(n)R(n)G^T(n). \quad (172)
 \end{aligned}$$

Megjegyzés: A (172) összefüggés alapján látható, hogy a becslés kovariancia mátrixa három hatás eredményeképpen alakul:

- A megfigyelő tárgyalásakor megismert hibacsökkentő hatás az $[A - G(n)C]$ kontraktivitásának következtében, de most – a kritériumnak betudható módon – négyzetes formában.
- A rendszerzaj kovariancia mátrixa által közvetített, statisztikai értelemben vett hibanövelő hatás, amely annak tudható be, hogy a $w(n)$ diszkrét érték „perturbálja” $x(n+1)$ – az előző állapot alapján – jóslott értékét.
- A megfigyelési zaj kovariancia mátrixa pedig ugyancsak hibát növel statisztikai értelemben, ami annak tudható be, hogy az $n(n)$ diszkrét érték „perturbálja” $\hat{x}(n+1)$ – az előző állapot alapján – jóslott értékét.

A (172) összefüggés írható kompaktabb formában, mert első tagját kifejtve:

$$\begin{aligned}
 P(n+1) &= AP(n)A^T - AP(n)C^T G^T(n) - G(n)CP(n)A^T + G(n)CP(n)C^T G^T(n) + \\
 &+ G(n)R(n)G^T(n) + Q(n). \quad (173)
 \end{aligned}$$

A negyedik és az ötödik tag összevonásával, és (171) felhasználásával:

$G(n)[CP(n)C^T + R(n)]G^T(n) = AP(n)C^T G(n)$, ami viszont kiejti (173) második tagját. Marad az első, harmadik és hatodik tag, amiből:

$$P(n+1) = [A - G(n)C]P(n)A^T + Q(n) \quad (174)$$

Összefoglalva:

A rendszermodell: $x(n+1) = Ax(n) + w(n)$, a megfigyelés: $y(n) = Cx(n) + n(n)$. Az optimális rekurzív (ún. Kalman) prediktor:

$ \begin{aligned} \hat{x}(n+1) &= A\hat{x}(n) + G(n)(y(n) - C\hat{x}(n)) \\ G(n) &= AP(n)C^T [CP(n)C^T + R(n)]^{-1} \\ P(n+1) &= (A - G(n)C)P(n)A^T + Q(n) \end{aligned} $	(175)
--	-------

Mejegyzés: Az optimális rekurzív becslő használható modellillesztésre is. Az illesztett modell továbbra is az adaptív lineáris kombinátor. Ilyenkor, használva a korábbi jelöléseket, továbbá feltételezve, hogy $Q(n)=0$, a (175) összefüggés az alábbiak szerint alakul:

$$W(n+1) = W(n) + G(n)(y(n) - X^T(n)W(n)) = W(n) + G(n)e(n) \quad (176)$$

$$G(n) = P(n)X(n)[X^T(n)P(n)X(n) + R(n)]^{-1} \quad (177)$$

$$P(n+1) = (I - G(n)X^T(n))P(n) \quad (178)$$

ahol most $P(n)$ a paraméterbecslés „kovariancia” mátrixa: $P(n) = E\{V(n)V^T(n)\}$, $X(n)$ pedig a regressziós vektor. Érdemes visszalapozni a (108)-(121) összefüggésekhez.

Megjegyzés:

Érdemes összevetni a 2. ábrán látható megfigyelő modellt a 36. ábrán látható Kalman prediktorral.

1. Figyeljük meg, hogy a (172) összefüggés első tagja nagyon hasonlít az (5) összefüggéshez, az eltérés csupán a négyzetes jelleg. Értelemszerűen itt is igaz, hogy a

hiba csökkenéséhez a hibarendszer állapotátmenet mátrixának, az $F(n) = A - G(n)C$ mátrixnak kontraktívnak kell lennie.

2. Ha a zajfolyamatok stacionáriusak, akkor $Q(n)=Q, R(n)=R$.
3. Vegyük észre, hogy a megfigyelt rendszer modellje hogyan épül be a megfigyelőbe.

7. Modell-alapú jelfeldolgozás

A fejezet keretében modell-alapú jel-reprezentációs kérdésekkel foglalkozunk. Az alkalmazott megközelítés lényege, hogy a jeleket az őket generálni képes modellekkel reprezentáljuk, és ezeknek a modelleknek a feltételezésével megfigyelőket készítünk. A keresett jel jellemzők a megfigyelő jellemzőiből kiolvashatók.

7.1. Az alapok felidézése

Előljáróban a digitális jelfeldolgozás legalapvetőbb módszereit tekintjük át. Ezek között kiemelt szerepet kapnak a rekurzív átlagolások.

- Egyszerű átlagolás (lásd 37. ábra):

$$\hat{x}(n) = \frac{1}{n} \sum_{k=0}^{n-1} y(k) \Rightarrow \hat{x}(n+1) = \frac{1}{n+1} \sum_{k=0}^n y(k) = \frac{n}{n+1} \hat{x}(n) + \frac{1}{n+1} y(n) = \hat{x}(n) + \frac{1}{n+1} [y(n) - \hat{x}(n)] \quad (179)$$

Vegyük észre, hogy itt $A=C=1, G(n) = \frac{1}{n+1}$. $G(n) \rightarrow 0$, ha $n \rightarrow \infty$.

- Exponenciális átlagolás (lásd 38. ábra):

$$\hat{x}(n+1) = a\hat{x}(n) + by(n), \quad (180)$$

ahol a és b konstansok. A frekvenciatartománybeli viselkedés leírására használható a z -transzformáció: $z\hat{X}(z) = a\hat{X}(z) + bY(z)$, amiből kifejezhető az exponenciális átlagoló átviteli függvénye:

$$H(z) = \frac{\hat{X}(z)}{Y(z)} = \frac{b}{z-a} = \frac{bz^{-1}}{1-az^{-1}} \quad (181)$$

Ez egy alul-áteresztő szűrő, amely, ha konstans jelet kap, akkor a tranziens lejátszódása kimenetén ugyanez a konstans jelenik meg. Ehhez pedig az kell, hogy (181) ennek megfelelően legyen normálva, vagyis $H(z) = 1$, ha $z=1$. Ezzel (181) behelyettesítési értéke

$\frac{b}{1-a} = 1$, vagyis $a = 1-b$. Ezzel a (180) összefüggés

$$\hat{x}(n+1) = \hat{x}(n) + b(y(n) - \hat{x}(n)). \quad (182)$$

Vegyük észre, hogy itt is $A=C=1$, továbbá $G(n)=b$. Ennek megfelelően ilyenkor a megfigyelt új értéket egy konstanssal szorozzuk, ellentétben a lineáris átlagolással.

Megjegyzés: A (182) összefüggés felhasználásával:

$$\begin{aligned} \hat{x}(0) &= 0, \quad \hat{x}(1) = by(0), \\ \hat{x}(2) &= \hat{x}(1) + b(y(1) - \hat{x}(1)) = (1-b)by(0) + by(1), \\ \hat{x}(3) &= \hat{x}(2) + b(y(2) - \hat{x}(2)) = (1-b)^2by(0) + (1-b)by(1) + by(2), \end{aligned} \quad (183)$$

A (183) összefüggés alapján, mivel $0 < b < 1$, a régebbi mintákat egyre kisebb súllyal vesszük figyelembe.

Megjegyzés: Az exponenciális átlagolás egy rögzített sávszélességű aluláteresztő szűrésnek felel meg. Hozzá képest az egyszerű átlagolás úgy illusztrálható, mint folyamatosan egyre kisebb sávszélességű aluláteresztő szűrő.

- Csúszó-ablakos (sliding window, moving average) átlagolás (lásd 39. ábra):

$$\hat{x}(n) = \frac{1}{N} \sum_{k=n-N}^{n-1} y(k) \Rightarrow \hat{x}(n+1) = \frac{1}{N} \sum_{k=n-N+1}^n y(k) = \hat{x}(n) + \frac{1}{N} [y(n) - y(n-N)] \quad (184)$$

Itt is $A=C=1$, de a becsatolás módja más. Itt is tudjuk értelmezni az átlagoló átviteli függvényét, mert (184) z-transzformáltja: $z\hat{X}(z) = \hat{X}(z) + \frac{1}{N}(1-z^{-N})Y(z)$, amiből:

$$H(z) = \frac{\hat{X}(z)}{Y(z)} = \frac{z^{-1}1-z^{-N}}{N1-z^{-1}} \quad (185)$$

Megjegyzés:

- $1-z^{-N}$ osztható az $1-z^{-1}$ tényezővel, az eredmény: $1+z^{-1}+z^{-2}+\dots+z^{-(N-1)}$, ami azt fejezi ki, hogy N egymást követő mintát adjunk össze.
- A $1-z^{-N}$ tényező gyökei az N -edik egységgyökök: $\sqrt[N]{1} = z$.

1. Példa: Egyszerű átlagolás, frekvenciatartománybeli viselkedés:

$\hat{x}(n+1) = \frac{y(n) + y(n-1)}{2}$, illetve a z-transzformációval: $z\hat{X}(z) = \frac{1+z^{-1}}{2}Y(z)$, ill. az átviteli függvény: $H(z) = z^{-1} \frac{1+z^{-1}}{2}$. $z = e^{j\omega T}$ helyettesítéssel:

$$H(e^{j\omega T}) = e^{-j\omega T} \frac{1+e^{-j\omega T}}{2} = e^{-j\frac{3}{2}\omega T} \frac{e^{j\frac{\omega T}{2}} + e^{-j\frac{\omega T}{2}}}{2} = e^{-j\frac{3}{2}\omega T} \cos \frac{\omega T}{2}. \quad (186)$$

Ebből az amplitúdó-karakterisztika: $|H(e^{j\omega T})| = \left| \cos \frac{\omega T}{2} \right|$, a fázis-karakterisztika:

$\varphi(\omega) = -\frac{3}{2}\omega T$, az $\omega T = k\pi$ helyen, ahol $k = \pm 1, \pm 3, \dots$ π fázisugrással (az előjelváltás miatt).

Lásd 40. ábra.

2. Példa: Egyszerű differenciálás, frekvenciatartománybeli viselkedés:

$\hat{x}(n+1) = \frac{y(n) - y(n-1)}{2}$, illetve a z-transzformációval: $z\hat{X}(z) = \frac{1-z^{-1}}{2}Y(z)$, ill. az átviteli függvény: $H(z) = z^{-1} \frac{1-z^{-1}}{2}$. $z = e^{j\omega T}$ helyettesítéssel:

$$H(e^{j\omega T}) = e^{-j\omega T} \frac{1-e^{-j\omega T}}{2} = je^{-j\frac{3}{2}\omega T} \frac{e^{j\frac{\omega T}{2}} - e^{-j\frac{\omega T}{2}}}{2j} = je^{-j\frac{3}{2}\omega T} \sin \frac{\omega T}{2}. \quad (187)$$

Ebből az amplitúdó-karakterisztika: $|H(e^{j\omega T})| = \left| \sin \frac{\omega T}{2} \right|$, a fázis-karakterisztika:

$\varphi(\omega) = \frac{\pi}{2} - \frac{3}{2}\omega T$, az $\omega T = k2\pi$ helyen, (ahol $k = 0, \pm 1, \pm 2, \dots$) π fázisugrással (az előjelváltás miatt). Lásd 41. ábra. (Vedd észre, hogy a fáziskarakterisztika hibás, mert a fázisugrás nem π -nél van!)

3. Példa: Csúszó-ablakos átlagolás, frekvenciatartománybeli viselkedés:

A (185) összefüggés szerint az átviteli függvény: $H(z) = \frac{\hat{X}(z)}{Y(z)} = \frac{z^{-1} 1 - z^{-N}}{N 1 - z^{-1}}$. $z = e^{j\omega T}$ helyettesítéssel:

$$H(e^{j\omega T}) = \frac{e^{-j\omega T} 1 - e^{-jN\omega T}}{N 1 - e^{-j\omega T}} = \frac{e^{-j\frac{N-1}{2}\omega T} e^{j\frac{N\omega T}{2}} - e^{-j\frac{N\omega T}{2}}}{N \frac{e^{j\frac{\omega T}{2}} - e^{-j\frac{\omega T}{2}}}{2}} = \frac{e^{-j\frac{N-1}{2}\omega T} \sin \frac{N\omega T}{2}}{N \sin \frac{\omega T}{2}}. \quad (188)$$

Ebből az amplitúdó-karakterisztika: $|H(e^{j\omega T})| = \frac{1}{N} \left| \frac{\sin \frac{N\omega T}{2}}{\sin \frac{\omega T}{2}} \right|$ (lásd 42. ábra), a fázis-

karakterisztika: $\varphi(\omega) = -\frac{N-1}{2}\omega T$, az $\omega T = k \frac{2\pi}{N}$ helyen, (ahol $k = \pm 1, \pm 2, \dots$) π

fázisugrással (az előjelváltás miatt), kivéve azokat a helyeket, ahol $\sin \frac{\omega T}{2}$ is előjelet vált.

7.2. Jelek reprezentációja jelterekben

Jelterek: az euklideszi tér általánosításai

- általánosított távolság > metrikus tér
- algebrai alapműveletek + linearitás > lineáris tér
- norma (kapcsolat a metrikával) > normált lineáris tér
- skalár v. belső szorzat > $(a, b) = a^T b = b^T a$.

Lineáris vektortér: bázisvektorok: $\varphi_m, m=0, 1, \dots, N-1$. Ezekkel az x vektor reprezentációja:

$$x = \sum_{m=0}^{N-1} \alpha_m \varphi_m, \quad (189)$$

ahol $\{\alpha_m\}$, $m=0, 1, \dots, N-1$, a báziselemekből készített lineáris kombináció súlytényezője. Meghatározása:

$$(x, \varphi_n) = \sum_{m=0}^{N-1} \alpha_m (\varphi_m, \varphi_n), \quad n=0, 1, \dots, N-1 \quad (190)$$

egyenletrendszer megoldásával.

Hasznos az ún. reciprok bázis alkalmazása: $\theta_m, m=0, 1, \dots, N-1$; $(\varphi_m, \theta_n) = \delta_{mn}$, ahol

$$\delta_{mn} = \begin{cases} 1, & \text{ha } m = n \\ 0 & \text{egyébként} \end{cases}.$$

Ezzel:

$$(x, \theta_n) = \sum_{m=0}^{N-1} \alpha_m (\varphi_m, \theta_n), \text{ vagyis } \alpha_m = (x, \theta_m), \text{ amivel}$$

$$x = \sum_{m=0}^{N-1} (x, \theta_m) \varphi_m = \sum_{m=0}^{N-1} (x, \varphi_m) \theta_m. \quad (191)$$

A bázis ortonormált, ha $(\varphi_m, \varphi_n) = \delta_{mn}$, amivel $x = \sum_{m=0}^{N-1} (x, \varphi_m) \varphi_m$.

Megjegyzés: $\varphi_m = [\varphi_m(0), \varphi_m(1), \dots, \varphi_m(N-1)]^T$, ahol a zárójelben megadott indexek értelmezhetők diszkrét időindexként.

Lineáris tér: a bázisok folytonos függvények, azaz $\varphi_m \rightarrow \varphi_m(t)$, $\theta_m \rightarrow \theta_m(t)$. Ezzel az $x(t)$ jel reprezentációja:

$$x(t) = \sum_{m=0}^{\infty} \alpha_m \varphi_m(t), \text{ ahol } \alpha_m = (x(t), \theta_m(t)) \quad (192)$$

Példa: Fourier sorfejtés: $\varphi_m(t) = \exp(j2\pi mt)$, $\theta_m(t) = \exp(-j2\pi mt)$, $m=0,1,\dots,N-1$.

Integrál-transzformáció: a bázisoknál m szerint is végtelen finom felbontás, ill. végtelen dimenzió: a bázisokból összeáll egy kétváltozós függvény, a súlyozó együttható helyére pedig egy egyváltozós függvény lép. $m \rightarrow s$, ilyenkor

$$\boxed{x(t) = \int_s \alpha(s) \varphi(t, s) ds \quad \alpha(s) = \int_T x(t) \theta(s, t) dt} \quad (193)$$

integrál-transzformáció párok.

Példa: Fourier integrál: $\varphi(t, s) = 1 / \theta(s, t) = \exp(j2\pi st)$.

Megjegyzések:

1. Diszkrét integrátor: a 43. ábrán látható rendszer időtartományi leírása:

$$\hat{x}(n+1) = \hat{x}(n) + y(n), \text{ átviteli függvénye: } \frac{z^{-1}}{1-z^{-1}} = z^{-1} + z^{-2} + \dots$$

Egy ilyen rendszer a bemenetére adott értékeket az előző összeghez adja. Figyeljük meg, hogy az átviteli függvény átírásakor felhasználtuk a mértani sor összegképletét.

2. A Fourier integrál hatása: Az $x(t)$ jelet szorozzuk az $\exp(-j2\pi f_0 t)$ komplex exponenciálissal, aminek hatására a jel spektruma balra tolódik f_0 -val. (Lásd 44. ábra.) Az integrálás végtelen keskeny alul-áteresztő szűrőnek felel meg, amelynek kimenetén az f_0 frekvenciánál érvényes spektrum-értéket kapjuk.

7.3. Megfigyelő jelfeldolgozási feladatokra

Jelölés: $\{c_m(n)\}$, $\{g_m(n)\}$ jelöli a bázis/reciprok bázis rendszereket, $m, n = 0, 1, \dots, N-1$. A mérendő jelről azt tételezzük fel, hogy a bázis-rendszer elemek lineáris kombinációjaként áll elő, és a bázisvektorok dimenziójának megfelelő mintából álló diszkrét jel. A súlyozó együtthatókat bemenet nélküli, diszkrét integrátorokban tárolt értékek adják. (lásd 45. ábra.) Ezek az értékek a jelet generáló hipotetikus rendszer $x(n) = [x_0(n) \ x_1(n) \ \dots \ x_{N-1}(n)]^T$ állapotváltozóit. Ezek $\hat{x}(n) = [\hat{x}_0(n) \ \hat{x}_1(n) \ \dots \ \hat{x}_{N-1}(n)]^T$ becslőjét megfigyelővel állítjuk elő. A hipotetikus jelgeneráló rendszert leíró egyenletek:

$$x(n+1) = x(n) \quad y(n) = c^T(n)x(n); \quad (194)$$

a megfigyelőt leíró egyenletek pedig:

$$\hat{x}(n+1) = \hat{x}(n) + g(n)c^T(n)[x(n) - \hat{x}(n)] \quad (195)$$

A hibarendszer:

$$x(n+1) - \hat{x}(n+1) = (I - g(n)c^T(n))[x(n) - \hat{x}(n)] \quad (196)$$

$$x(n+1) - \hat{x}(n+1) = \prod_{k=0}^n (I - g(k)c^T(k))[x(0) - \hat{x}(0)] \quad (197)$$

N lépéses konvergenciát akkor kapunk, ha:

$$\prod_{k=0}^{N-1} (I - g(k)c^T(k)) = 0 \quad (198)$$

Ez viszont teljesül, ha $\{c_m(n)\}$, $\{g_m(n)\}$ bázis/reciprok bázis párt alkotnak ($m, n = 0, 1, \dots, N-1$), ugyanis minden olyan tag, melyben szerepel $g(i)c^T(i)g(j)c^T(j)$, és $i \neq j$: nullát ad a bázis/reciprok bázis elemek ortogonalitásának köszönhetően, továbbá

$$\prod_{k=0}^{N-1} (I - g(k)c^T(k)) = I - \sum_{i=0}^{N-1} g(i)c^T(i) = 0. \quad (199)$$

Megjegyzések:


1. A diszkrét Fourier transzformáció (DFT) esetén:

$$\{c_m(n) = \exp(j \frac{2\pi}{N} mn)\}, \quad \{g_m(n) = \frac{1}{N} \exp(-j \frac{2\pi}{N} mn)\} \quad (200)$$


2. A $\sum_{k=0}^{N-1} g(k)c^T(k) = I$ bizonyítása: Írjuk fel a $g(k)c^T(k)$ diadikus szorzatot:

$$\begin{bmatrix} g_0(k) \\ g_1(k) \\ \vdots \\ g_{N-1}(k) \end{bmatrix} \begin{bmatrix} c_0(k) & c_1(k) & \dots & c_{N-1}(k) \end{bmatrix} = \begin{bmatrix} g_0(k)c_0(k) & g_0(k)c_1(k) & \dots & g_0(k)c_{N-1}(k) \\ g_1(k)c_0(k) & g_1(k)c_1(k) & \dots & g_1(k)c_{N-1}(k) \\ \vdots & \vdots & \vdots & \vdots \\ g_{N-1}(k)c_0(k) & g_{N-1}(k)c_1(k) & \dots & g_{N-1}(k)c_{N-1}(k) \end{bmatrix}$$


Ha ezek után, k -t futtatva, minden mátrix elemre végrehajtjuk az összegzést, akkor minden elem helyén egy-egy skalár-szorzatot számítunk ki, aminek eredményeképpen a főátlóban 1-esek, az összes többi helyen pedig 0-ák fognak állni.





36. ábra




37. ábra




38. ábra




39. ábra




40. ábra



41. ábra



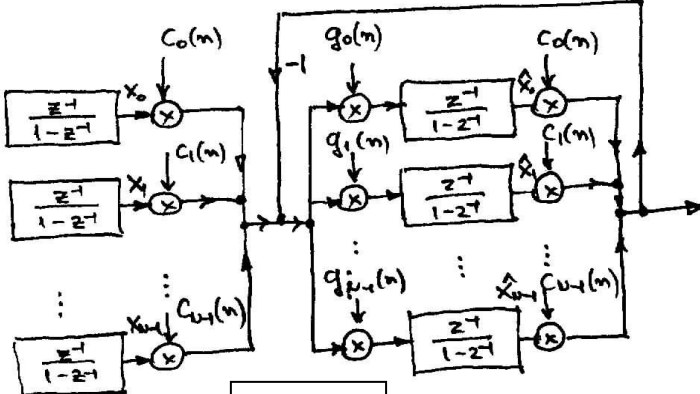
42. ábra



43. ábra



44. ábra



45. ábra