

Dr. Pécsi Gábor

Általánosítás

Olyan elv és technikák gyűjtése, amik a mérésért segítik.
→ Fizikai, kémiai, biológiai stb. környezet
→ de! a technikák nem csak itt alkalmazhatók!

3 fontos terület:

- amire a mérés irántunk : A VALÓ VILÁG. "TÉR"

- tájékozódás, ismeretszerzés itt
- az ismeret számunkra értékes, hasznos
- adott körülményben stabilitást mutatnak.

↳ ÁLLAPOT.

- összefoglaló név
↳ RENDSZER → ezen belül: állapot állapota.
egymással kölcsönhatásban is kölcsönös összefüggésben lévő objektumok halmaza
↳ energiafolyamatok, interakciók.

JEL

→ ez segít a jellemzésben, értelmezésben.

PARAMÉTER - interakcióviszonyok, kölcsönhatások.

STRUKTÚRA - az objektumok egymáshoz való viszonya

VALÓ VILÁG: állapot, paraméter, struktúra → jel és rendszer jellemzőit, rendszerjellemzőit

↓
kölcsönhatásban lépünk a való világ egy megismerésével (direkt módon)

- MEGFIGYELÉS → ezeket szeretnénk megfigyelni, értelmezni.

→ tér koncepció

való világ tere és a megfigyelés tere

→ a való világ egy pontjának jellemzőit szeretnénk megismerni

→ egy pontból egy pontba történő lépés

egy helyben marad, amit mérünk?

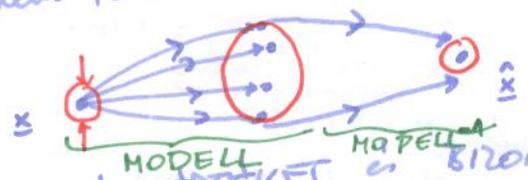
miéppen a száma (jelérték)? van rajta zaj?

→ egy másik mérés egy másik pontot fog kijelölni.
(másik mérés másik eredményt ad)

széles mérés → pont leképezése halmaza lesz (főbb pont)

- BECSLÉSEK ÉS DÖNTÉSEK

- mert tudnunk a megfigyelésből megbecsülni azt, amit megfigyeltünk
- hol van? mi a koordinátája?
- > megbecsülünk egy \hat{x} értéket
- > vesszük a megfigyelt értéket, és megpróbáljuk visszafejteni
- > a becslésnek valamilyen bizonytalansága van
- > nem kötelező a visszacsúszás



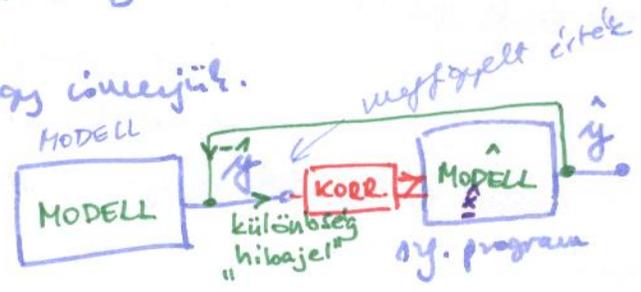
-> a mérés ÉRTEKÉT és BIZONYTALANSÁGOT szül.
 -> bizonytalanság nélkül NEM mérés!

-> amikor egy értéket elhelyezünk, bontjuk a hibákat
 követjük, amit figyelni akarunk!

előismeretbe lépünk, befolyásolunk...

- > pl. ellendületre dramát edzünk, ami ennek hatására működik.
- > ismeri kell az egyes paramétereket... hol mi történik?
- > az ezzel kapcsolatos ismeretből egy rendszeret ismerethalmozatot,
 MODELLT építünk.
- > ezután valósítsuk meg ezzel az INVERZET.
- > sikerül vagy nem? visszafordítható? (pl. ügyfélk. - k)

Közeljünk el, hogy ismerjük.



Működhető modellek
 -> működőképes program
 -> fizikai megvalósítás
 (Érdia)

$$e = y - \hat{y}$$

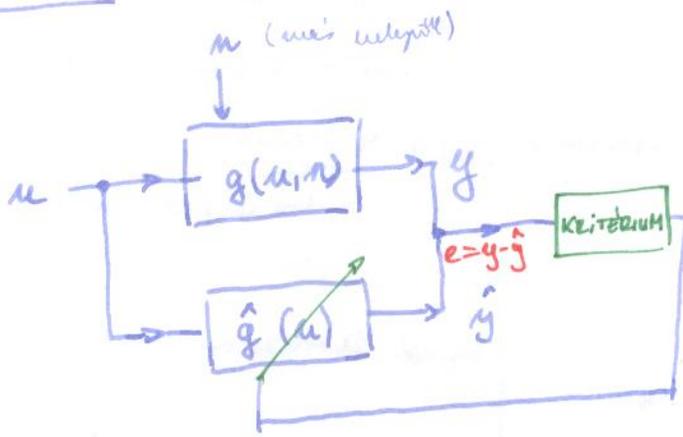
konfiguráljuk, alakítjuk a programot
 -> a hibát igyekszük csökkenteni
 (ideális esetben NULLA)
 => valós & eldőlés!
 } visszacsúszás.

-> akkor nagy valószínűséggel, hogy ha a modell követi,
 az \hat{x} nem tér el x -től.

-> a megismereti folyamatok egy univerzális sémája.

paraméter: a $\frac{dp}{dx}$
 $\underline{a} \cdot \underline{x}$ -vel megbecsülünk.

Regressziószámítás - függvények közelítése problémája.



adot g , két független változóval

↓
 van egy bemeneti változója, a matikat nem tudjuk megcsipni
 autonóm mechanizmus, ami perturbálja az eredményt.

Kritériumi kérdés: tudat-e baktumit reparálni?

- nem változtatható le a környezettől
- a környezettől fakadó, nem érzékelhető határ.

→ hozzuk g -t matematikailag kezelhető formába!

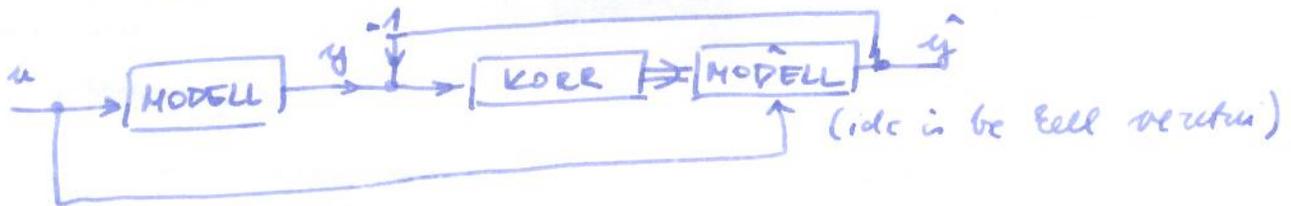
→ ismét strukturáljuk, nem ismeretlenül rögzített paraméterek fog. feldolgozhat.

Konverzió helyett kritérium → g szabadon kapott paramétereit állítjuk úgy, hogy a leírt leírás ne legyen túl nagy el.

(Eszközökkel hasonlít az előzőhöz)
 ↳ de! itt van „u” bemenet...

→ az előző modellt is perturbálhatjuk

→ ezután nincs értelme kité. a két gondolatmenet között.



y előjelelineáris függvényként (lineáris regresszió)

$$\hat{y} = a \cdot \hat{x} + b \quad \text{addig állítjuk, míg pontos nem lesz.}$$

→ legfontosabb az a_0, b_0 páros... → lehet végleges kritérium értéke

Technikai részletek

PÉCELI GÁBOR

peceli@mit.bme.hu

I épület 4. emelet (M17)

BMEVIMIM108

3/0/0/f

feldolgozó jegy, 4 kredit

↳ 4 szeminárium kell minimum

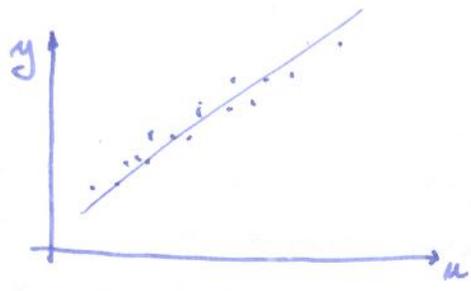
- ZH1 III. 25.
- ZH2 V. 15.
- HF1 II. 25 → IV. 18.
- HF2 IV. 08 - IV. 29.

} mind szerdai napok.

pótlás: V. 20., szerda.

helyezés.

(regressziós)



- a pontok utoljára: a függvénynek van nem észbeverték bemenete (raj)
- a raj nem biztos, hogy célszerű; lehet rendszeren belül rossz bemenet is

→ a valószínűségelméleti apparátust veszi igénybe.

$E[u]$ → u várható értéke.

$E[y]$ → y

{ a jelenség megfigyelésénél egy másik miatt

→ mi az, ami a bizonytalanságban megfigyelhető?

Képezzünk el egy valódi rendszert. → modell megvalósítása.

modell

- nemlinearitás (amit tapasztalunk, mint függő; nem konstans)
 - ↳ például feltételek
- lineáris → egyenlet síkban példák.

diszkrét állapotátviteli forma:

$\underline{x}(n)$

n indexű vizsgálati időpont, az előző faktor adatok

$\underline{x}(n+1)$

a következő adatok.

$\underline{x}(n+1) = A \underline{x}(n)$

$$\begin{bmatrix} \cdot \\ \cdot \\ \cdot \end{bmatrix}_N = \begin{bmatrix} \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \end{bmatrix}_{N \times N} \begin{bmatrix} \cdot \\ \cdot \\ \cdot \end{bmatrix}_N$$

A: állapotátviteli mátrix

✓ egy autonóm rendszert ritkán fel.
 → van belül valamilyen energiaja, ezt változtat (A)

ha van perturbáció? $\rightarrow u$

$$\underline{x}(n+1) = \boxed{A} \underline{x}(n) + B \underline{u}(n) \rightarrow \text{ezt most figyelmen kívül hagyjuk.}$$

$N \uparrow \left[\begin{array}{c} \leftarrow M \\ \leftarrow M \end{array} \right] \left[\begin{array}{c} \\ \\ \end{array} \right]_M$

↓ az értékelő előállítja az y jelet

$$y(n) = \boxed{C} \underline{x}(n)$$

$\left[\begin{array}{c} \\ \\ \end{array} \right]_N \left[\begin{array}{c} \\ \\ \end{array} \right]_N$

y legyen skálár \rightarrow skálárisonát.

ismert $\begin{cases} A: \text{mechanikus, ahogy a fiz. köv. vált. az állapotot} \\ C: \end{cases}$

\rightarrow saját sz. program elkészítése:

$$\hat{x}(n+1) = A \cdot \hat{x}(n)$$

\rightarrow eldöjtük, hogy jól előzletre majd az x -et.

$$\hat{y}(n) = C \cdot \hat{x}(n)$$

de! a korrekciós modellt pörköljük, perturbáljuk! (mintha u lenne)

$$\hat{x}(n+1) = A \cdot \hat{x}(n) + G [y(n) - \hat{y}(n)]$$

G : egy skálár értéket kiölempőle szülopókkal az alp. változókkal csatlakoztatva.

hogyan előzletünk?

$$\boxed{x(n+1) - \hat{x}(n+1)} = A(x(n) - \hat{x}(n)) - GC(x(n) - \hat{x}(n)) = \boxed{A - GC} \boxed{x(n) - \hat{x}(n)}$$

ez olyan, mint az eredeti alaprendszer:

n . és $(n+1)$. állapot között teremt kapcsolatot.

elváráis: az előzlet legyen kisebb. \rightarrow mi kell ehhez?

"kontraktív", összehúzó tulajdonságú.

$A - GC$ \rightarrow ismertel, de mi konkrétan a korrekciós?

\Rightarrow keressük meg, állítsuk be azt a G vektort, ami a kontraktivitást biztosítja.

$$A - GC \rightsquigarrow \text{lehet-e nulla? } \underline{A = GC}$$

miikor lehet?

① $A \cdot C^{-1} = G$ ha van C -vel inverze (azaz négyzetes mátrix)

\Rightarrow annyi értékelő, ahány alp. változó.

\rightarrow akkor egy lépésben konvergál; beáll a vald világba beállt érték.

ha G négyzetes, akkor a paraméterek száma $N \times N$
ha G vektor, akkor csak N .

② $[A - GC]^N = 0$ mitől kapjuk N-edik hatványt? • 6 •

$$x(1) - \hat{x}(1) = [A - GC] [x(0) - \hat{x}(0)]$$

$$\Downarrow$$

$$x(N) - \hat{x}(N) = [A - GC]^N [x(0) - \hat{x}(0)]$$

az N. lépésben eltűnik a hiba!

N lépéses konvergencia lehetséges.

→ csugi mértékét kell ezen állapot eléréséhez

⇒ G megválasztása így köthető.

abban az esetben, ha a rendszer nemdirigál véges

$N+1$ lépés után már nem emelkedik rd...

→ az ilyen mátrixnál az összes sajátérték 0. (állapotátmenet-mátrix)

→ pókusai az origóban, inverzje 1.

→ a karakterisztikus polinom a λ hatványban véges rd kitevőket tartalmaz

NIEMDEROGATÓRIUS NILPOTENS mátrix.

→ a mértékét megfelelő polinoma hatványozva nullát kapjuk.

(DEROGATÓRIUS NILPOTENS mátrix

→ elfajult, ahol már emeltek kisebb hatványon, hamarabb eldőltek)

Am... valószínűleg a világ nem ideális

$$x(n+1) = \dots + \underline{zAx} \dots$$

$$y(n) = \dots + \underline{zAx} \dots$$

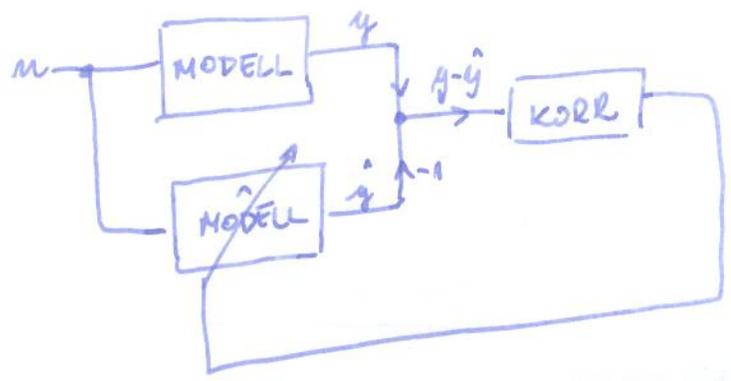
ha mindkét helyen van raj, akkor nincs baj. (?)

→ ha a sajátértékek nem nullák, még rd-es hatványban találatunk kontraktivitást biztosító A-GC mátrixot.

→ nem az életté, hanem az energia mentén méppel tovább
↳ végzetes!

Köpiagydrtes

fürtar és nánitési döröndz pdluzamontata



Állapolás

$$y(n) = \frac{1}{n} \sum_{k=0}^{n-1} u(k)$$

$$y(n) = \frac{1}{n} \sum_{k=0}^{n-1} u(k) \Rightarrow \sum_{k=0}^{n-1} u(k) = n \cdot y(n)$$

↑
n darab érték összege

$$y(n+1) = \frac{1}{n+1} \sum_{k=0}^n u(k) = \frac{1}{n+1} [n y(n) + u(n)]$$

→ fh. az értéket időben egymás után állnak elő
→ használjuk fel a korábbi állapt az új számításhoz

ha egyszer több adatot akartunk állapolni:

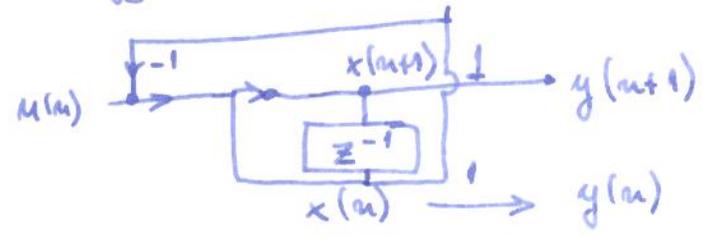
$$y(n+1) = \frac{n+1-1}{n+1} y(n) + \frac{1}{n+1} u(n)$$

Rekurzív séma, rekurzív állapolás

$$= y(n) + \frac{1}{n+1} [u(n) - y(n)]$$

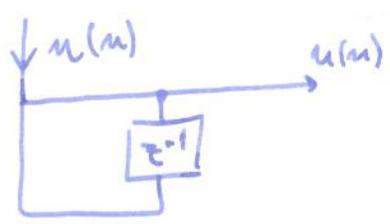
"új érték" = "rég érték" + "korrekció"

egy különbséggel módosítjuk az eredeti értéket!



a hiba vezérli a rendszert, ez hossa létre az állapotot, abból ismétlődik ki az eredmény

stabil állapot tartás



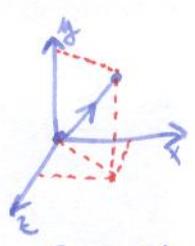
nj állapot:

$$\hat{x}(n+1) = \underline{A} \hat{x}(n) + \underline{G} C (x(n) - \hat{x}(n))$$

"új érték" "régi érték" "korrekció"

jellemelet:

- jelleprezentációk
- lineáris tér



[.....] vagy [:]

diszkrét értékesítmény

- koordinátákkal jellemezett vektor
- ez irányok (x,y,z) speciális vektorok
- ⇒ koordináták x-ve, y-ve, z-ve néve

(• ortogonális függvények ~ Fourier-sorfejtés.
→ egy adott frekvencia milyen súlyal szerepel)

- a koordináták megmértek ilyen koordinátákkal történik
- ez a jelnek egy modelleje, melyora x, y, ei z.

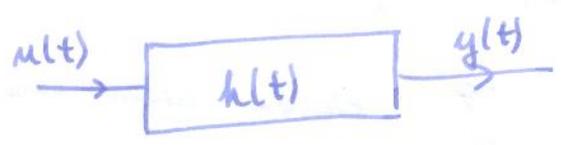
• $\begin{matrix} x \\ y \\ z \end{matrix} \Rightarrow$ Fourier sorfejtés koncepciója

• koordináták matematikai megfogalom!

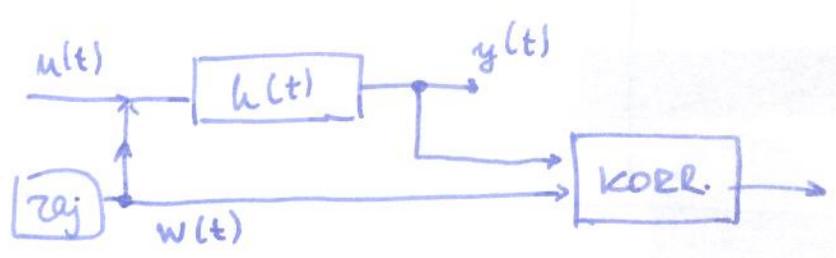
Konkrét mérési feladat.

Korrelációs mérési feladat

- technológiai folyamat
- folytonos
- súlyfüggvény.

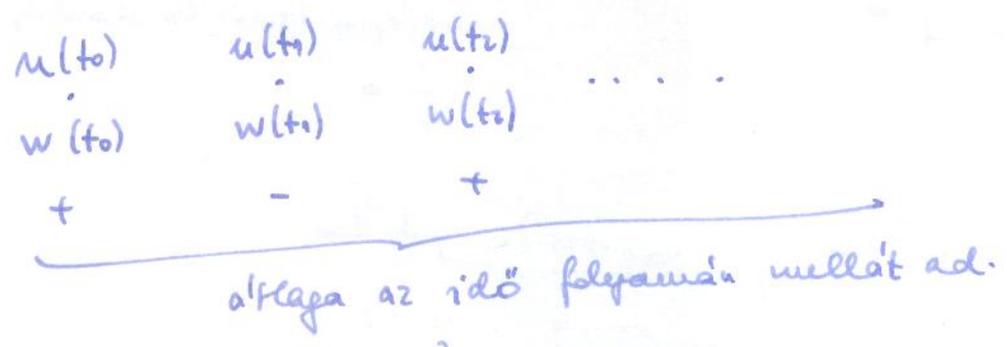


KORRELÁCIÓS MÉRÉSTECHNIKA → zajt superponálunk a bemenetre
 → mit csinál egy korrelátor?



hogyan korrelál?

$R_{uw}(\tau) = 0$ kereszt-korrelációként nulla.



$$R_{yw}(t) = E \{ y(t+\tau) w(t) \} = h(\tau)$$

$\sigma_w = 1$ a zaj mértéke egységnyi normált.

- a mérési eljárásokat teljes mértékben ismeri tudjuk.
- bizonyítható, hogy egy zaj hatásra perturbált rendszer is mérhető legyen. (a másik módszerrel nem hívható)

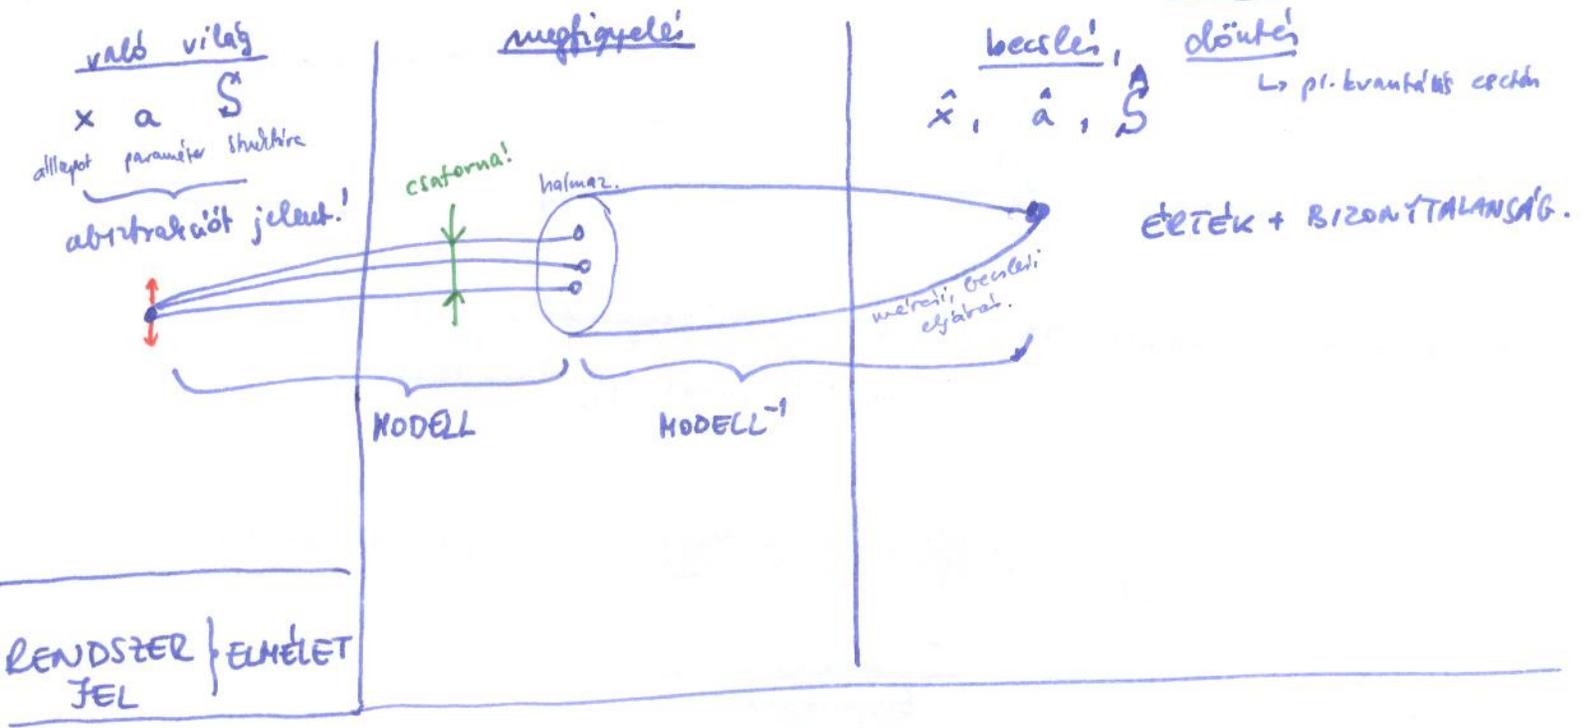
korábbi: explicit, determinisztikus bemenet
 most: véletlen, zajjal a bemenet (ciklandó)
 → ellenőrizhetetlen, ha a mérési feladat nem teszi lehetővé általában rálátást a bemenet alkalmazásait.

MÉRÉSELMÉLET: MÉRÉSI FELADATOK & JELFELDOLGOZÓ ELJÁRÁSOK MUTATJA BE MODELL ALAPÚ MEGKÖZELÍTÉSS EL.

HÍRKÖZVESELMÉLET:

SZIMBÓLUMOK való világ	csatorna VETT JEL megfigyelés	DEKÓDOLÁS döntés / becslés
mesterségesen generált		

analóg
ezzel.

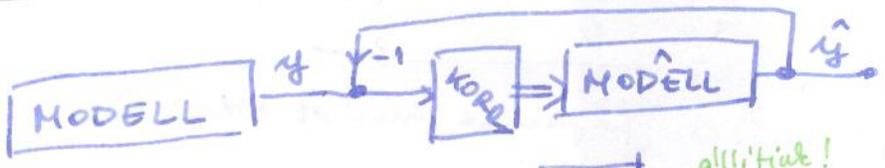
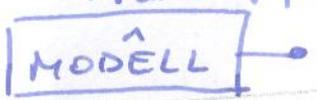


Mérési eljárás

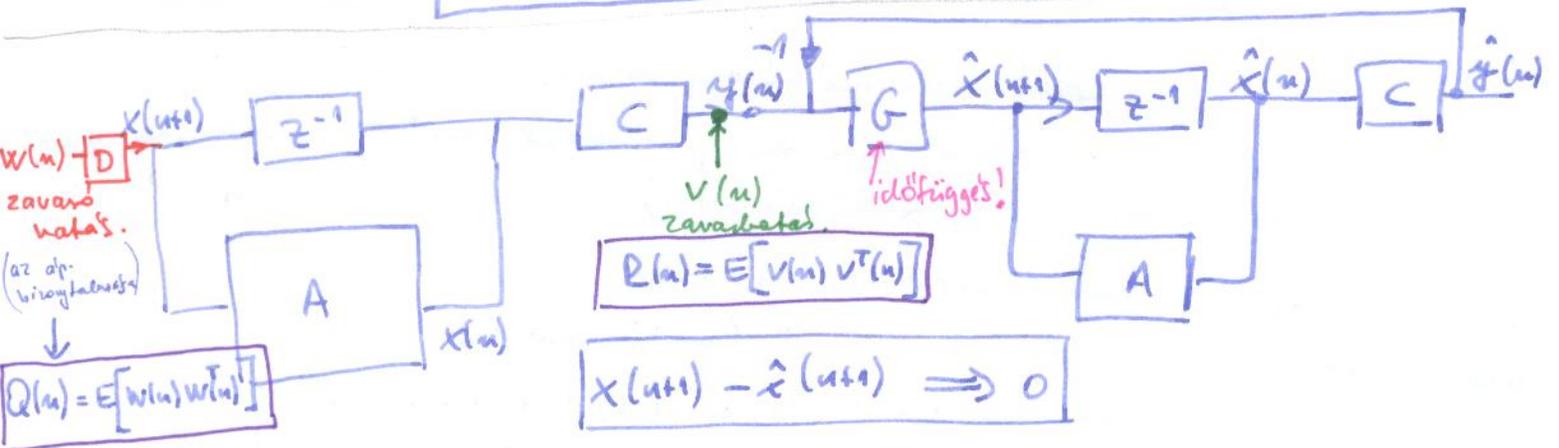
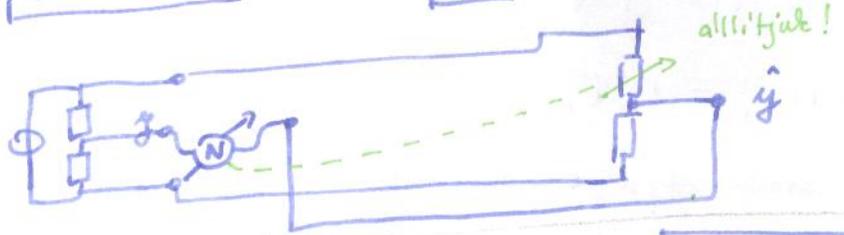


mi van a doboz belsejében?

- elbájtoltjuk az állapotot
- számítógépen becsüljük, előbájtoltjuk, simuláljuk.



pl.



hogyan rajzoljuk meg azt, hogy a megfigyelendő dolog bizonytalan?

→ a rajzon feltüntetjük, h. ez állapotot vanis "cibáljja"

→ pontosan nem ismerjük, mi... → stochasztikus (véletlen) jelmodell.

mi történik a valóságban? → zavaró hatás befolygat!

az eddigi elgondolásokról a címből miatt illuzórikusak!

Kalman
 prediktor
 RUDOLF KALMAN

KALMAN - prediktor → nagy előrelépés a mérnöktanulmányokban
~ 1960

→ a bizonytalansággal terhelt mérési folyamatok
lehetővé válik a pontos és igazságos értékek

→ a zajzavaró hatások nagyrészt időfüggetlenek is lehetnek

→ a Kalman's módszer is időfüggetlen, és TADULÁS folyamat
eredményeként kell eldöntenünk

$$X(u+1) - \hat{x}(u+1) \Rightarrow 0$$

$$P(u+1) = E \left\{ (X(u+1) - \hat{x}(u+1)) \cdot (X(u+1) - \hat{x}(u+1))^T \right\}$$

$$Q(u) = E [W(u) W^T(u)]$$

$$R(u) = E [v(u) v^T(u)]$$

„nevező”

$$G \rightarrow G(u) = A P(u) C^T [C P(u) C^T + R(u)]^{-1}$$

↳ ha $R(u) = 0 \Rightarrow G = \frac{A}{C}$ lenne; haszontalan!

↳ ha a számláló nagy, akkor a nevező nagy. → G kicsi
Cél: a beavatkozás, mindenképp legyen óvatos.

ha már megfigyeltük a mért adat, G növekedhet

$$P(u+1) = (A - G(u)C) P(u) (A - G(u)C)^T + G(u) R(u) G(u)^T + D Q(u) D^T$$

Cél: a hiba a konvergencia felé egyre kisebb.
→ végsőleges érték!

1. Rekurzív állapotbecslés ⇒ „modell-alapú” világ mérések + modellek

2. Modellelés, regressziós séma ⇒ modell-alapú ⇒ illentés
vethető az a mérés

3. Adatfeldolgozás / Feltevéselemzés ⇒ „blokkos” feltevéselemzés ⇒ rekurzív adatfeldolgozás

4. Korrelációs mérnöktanulmányok → erről nem beszéltünk a mérésben
↳ mit lehet csinálni olyan esetben, amikor a megfigyelendő
dolog egy mérési folyamat (fiziológia, biológia, ...)
melynek kölcsönhatásai léteznek egymással
→ nagy kell kötetlenül, hogy időközönként
mérésre kerüljön!!! (ne féltesd el)

JELEK REPREZENTÁCIÓJA

hogyan kapcsoljuk meg a jeleket (matematikaiilag)?

→ a való világ fizikai objektumok (stabil pontok) előre meghatározott távolságra lehetnek.

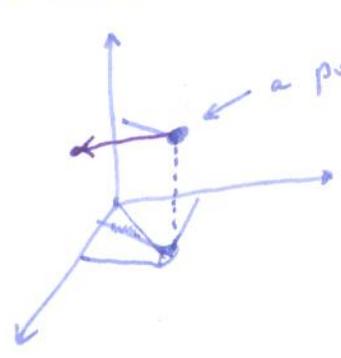
→ diszkrét vagy folytonos időtengely mentén változó értékek.

→ a rendszerből leolvasható az intenzitáviszony (jel)

a jel alapján reprezentációkat viszalépíthetők a rendszer.

pl. → rendszerparamétereket tudunk rögzíteni; jelt nem...

matematikai háttér: JELTÉR (Euklidészi-tér általánosítottai) → geometriai leírás.



a pont egy jelt reprezentál.
miért két pont távolságának a tartalma?

Erőtlenség: $x(u+1) - \hat{x}(u+1) \rightarrow 0$

Ezt a pont a jeltérben (diszkrét jel) éppen mint előrelátott egymással egyjött esetben ezonos.

TÁVOLSÁG → METRIKUS

ha a metrikus térben fennállnak az ALGEBRAI MŰVELETEK és a LINEARITÁS LINEÁRIS TÉR

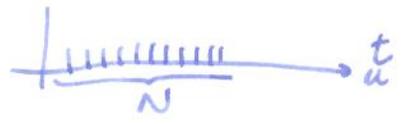
→ három művelet fogat használunk:

① LINEÁRIS VEKTORTÉR → Eritüntetett tulajdonságú vektortér alkalmazás
→ pl. koordináta vektorok → pont megadására
BAZIS → bázisvektorok, alapvektorok

$\varphi_m ; m=0,1,\dots,N-1$

$x = \sum_{m=0}^{N-1} a_m \varphi_m$ pl. a_m , koordináták.

jelek esetén: N db, időben egymással utána összerajzított érték



a_m meghatározásához szükséges: vektorok skalárszorzata
SKALÁR SZORZAT

$\underline{a}, \underline{b} \Rightarrow (a,b) = a^T b = b^T a$
mindkettő N dimenziós

α_m meghatározása:

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

skalárszorzat a bázisvektorokkal

→ RECIPROK BÁZISRENDSZER levezetése → leegyszerűsödik

$$\varphi_m \varphi_n = \delta_{mn} \quad m = 0, 1, \dots, N-1$$

$$(\varphi_m, \varphi_n) = \begin{cases} 1, & \text{ha } m=n \\ 0 & \text{egyébként} \end{cases} \quad \delta_{mn} = \begin{cases} 1, & \text{ha } m=n \\ 0, & \text{ha } m \neq n \end{cases}$$

matricák jelölés.

$$(x, \varphi_m) = \sum_{n=0}^{N-1} \alpha_n (\varphi_n, \varphi_m) \Rightarrow \boxed{\alpha_m = (x, \varphi_m)}$$

csak akkor nem 0, ha $m=n$

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

2) LINEÁRIS TER

a bázis nem véges, hanem végtelen dimenziójú!

$\varphi_m \rightarrow \varphi_m(t)$ folytonos időfüggvény, jelenti még

$\varphi_m(t)$ a reciprok bázis, ugyancsak időfvg.

$$x(t) = \sum_{m=0}^{\infty} \alpha_m \varphi_m(t) \quad ; \quad \boxed{\alpha_m = (x(t); \varphi_m(t))}$$

Fourier-sorfejtés: $\varphi_m(t) = e^{j2\pi mt}$

$\varphi_m(t) = e^{-j2\pi mt}$

skalárszorzathoz az egyikhez kélleni jgnak (az integrálból)

Cél: komplexitás redukálása, iszkéntetés

$$\hat{x}(t) = \sum_{m=0}^{N-1} \alpha_m \varphi_m(t)$$

végis!!!

egy végtelen dimenziós
vektorok véges ordumú
paraméterrel definiáltak
↓
adatredukciós feladat
(definiálás)

a keresés egy korlátozott befektetés;
rögzített méretű eljárás váltakozó.

milyen legyen a bázisrendszer? → Fourier!

mi az a módszer, ami összeköti x - \hat{x} minimalizálást is egy rögzített N - t ?

$(a|b) = a^T b = b^T a$

$\int_T x(t) e^{-j2\pi f t} dt$

→ a skálázott valószínűségi érték.

3. INTEGRÁLTRANSZFORMÁCIÓ

nem csak a végerdimenziós, hanem a diszkrét helyére is folytonos térre

$m \rightarrow s \quad x(t) = \int_S \underbrace{x(s)}_{\text{Eltérítési}} \underbrace{\varphi(t,s)}_{\text{bármifüggetlen}} ds$
(mátfüggetlen)

INTEGRÁLTRANSZFORMÁCIÓ

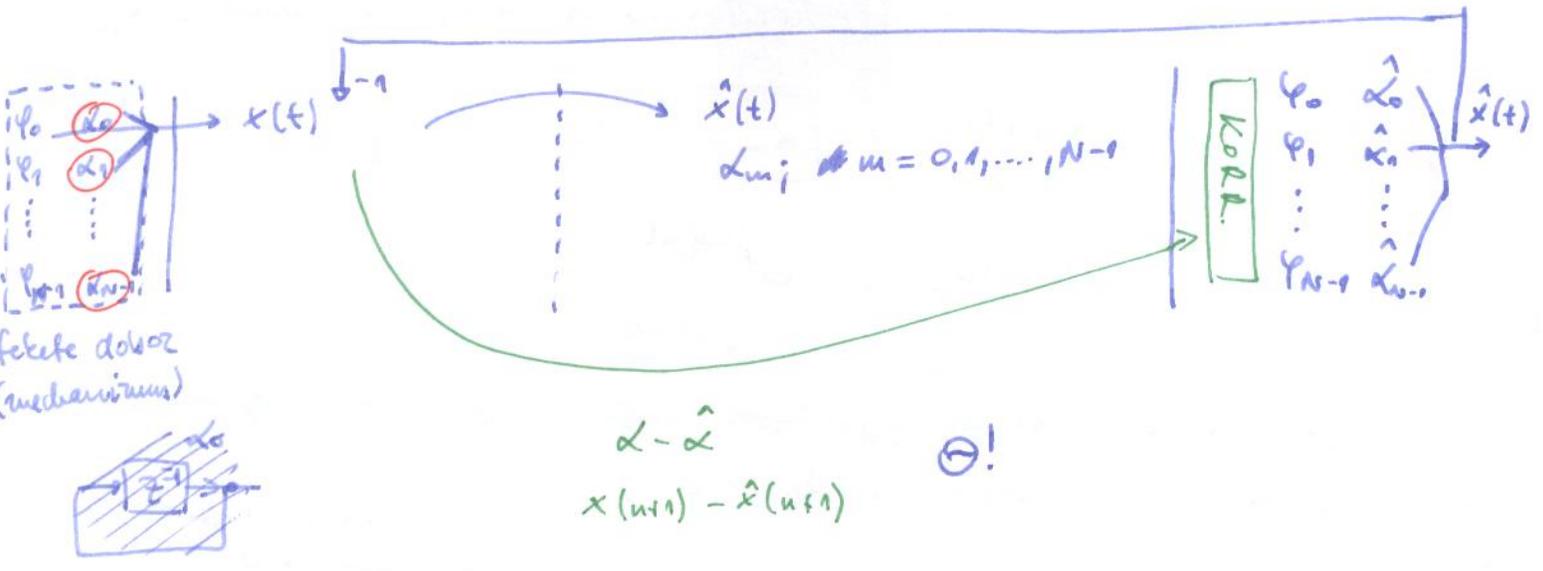
a Σ helyére \int kerül, m helyére pedig s

$x(s) = \int_T x(t) \Theta(t,s) dt$ $x(t)$ integráltranszformáltja.

Fourier világhoz: $\varphi(t,s) = e^{j2\pi f t} = \frac{1}{\Theta(t,s)} \Leftrightarrow \Theta(t,s) = e^{-j2\pi f t}$

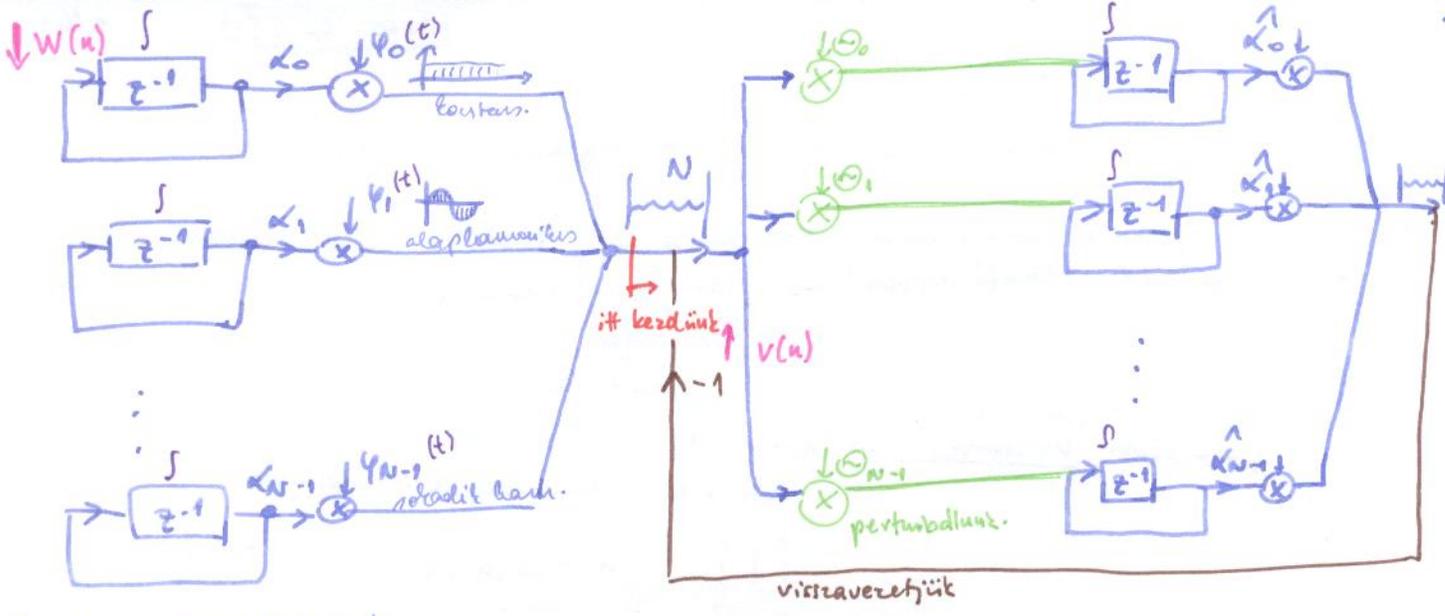
integráltranszformációkkal nem fogunk foglalkozni.

Σ : koncepcióban igen hasznos szempont van az



hogyan lehet modellezni ezt egy iteratív eljárattal?

- kell egy rendszer a konstansok rögzítésére (memóriarekesz)
- állapotvektorok értéket tárol; lefektetve lefektetve.



(konstans, ugyanazt kárk.)

ez a fekete dobozban van.

ha a jel nem periodikus, α másképp δ

Megjegyzés (Ezt fontos vonatkozás):

1.) ~~csak~~ a kétféle jelreprezentáció's fedmélésből az előst használjuk; (N)
 a jel folyamatosan hőmpölégig befelé
 ez egyfajta csúszdablatos megoldást jelent \xrightarrow{N}
 → a jelma a zérus értékre is megállapítható.

2.) a jelfeldolgozás ezen megközelítése: prekonceptus alapján
 vagyunk a feldolgozandó jel feldolgozásra
 egy elképzelési vázlatára.

→ ezt a KALMAN-prediktor képsébe is elintéztük
 a jel dominánsan az ismeretel alapján jön létre;
 de! itt is lehet zavarás, zaj
 ⇒ a korrekcióban elindulhatunk hasonló irányban

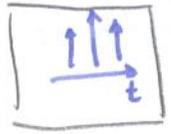
3.) a komplex exponenciális bontás. → komplex kéveréstől értelmezhető
 konstans feltétel és összerakom

↳ összerakom

↳ lekeverem a megfelelő frekvenciát

Jelek mérése, jelek reprezentációja

jel: időtengely mentén értelmezhető értéksorozat (folytatos / diszkrét)



hogyan rendelkezünk az adatok úgy, hogy a lehető legjobban felhasonlítható legyen? → jelek reprezentációja

FELTÉTEL.

feltétel: (lineáris) vektorter → diszkrét értéksorozat.

$$\uparrow \uparrow \uparrow \quad x = \sum_{m=0}^{N-1} \alpha_m \psi_m \quad ; \quad \{\alpha_m\}$$

$m = 0, 1, \dots, N-1$

az időben diszkrét eset
dolgait rekonstruáljuk

lineáris tér → folytatos függvény (végtelen sok elem)

$$\uparrow \uparrow \uparrow \uparrow \quad x(t) = \sum_{m=0}^{\infty} \alpha_m \cdot \psi_m(t) \quad \{\alpha_m\}$$

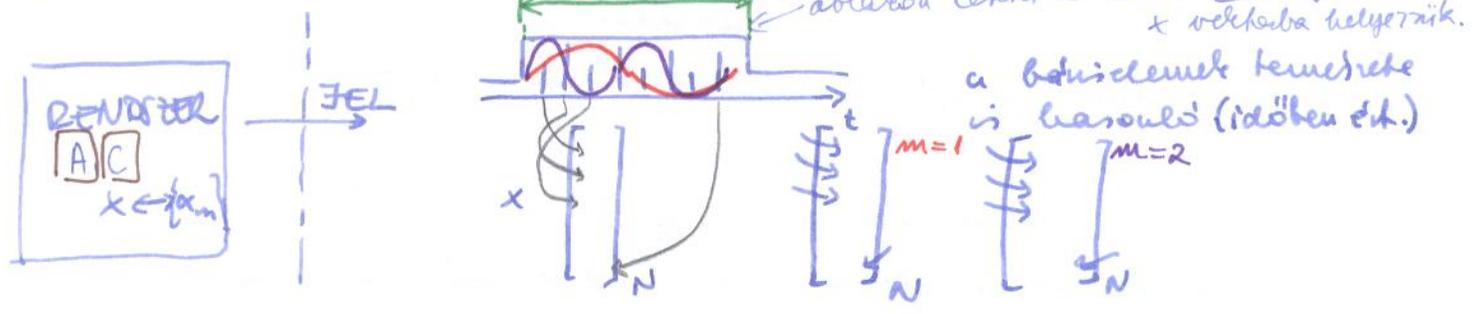
$m = 0, 1, \dots$

→ véges számú feltételezővel reprezentálunk (Fourier)

(integráltranszformáció → folytatos koordináták)

Mi lenne, ha a jel reprezentáció előzetes feltételezéssel úgy építenénk el a jelet, mint egy reprezentációt előállítani: képes rendszer kimenetét? Milyen véges számú feltételezővel lehet ezt jellemezni?

Feltételezni, hogy a jel, amit mérünk, egy rep. rendszerre segítségével áll elő. Ebben a rendszerben képelem azokat a megmérhető paramétereket, melyek a megismerete a cél. (α_m meghatározásra utazunk!)



milyen szöveggel van szerepe a bázisoknak x kiértékelésében?

$$\begin{bmatrix} 0 \\ x \end{bmatrix} = \alpha_0 \begin{bmatrix} 0 \\ \psi_0 \end{bmatrix} + \alpha_1 \begin{bmatrix} 0 \\ \psi_1 \end{bmatrix} + \dots + \alpha_{N-1} \begin{bmatrix} 0 \\ \psi_{N-1} \end{bmatrix} \left. \begin{matrix} \leftarrow \\ \leftarrow \\ \leftarrow \\ \leftarrow \\ \leftarrow \end{matrix} \right\} \text{idő!}$$

$$x(n) = \alpha_0 \psi_0(n) + \alpha_1 \psi_1(n) + \dots + \alpha_{N-1} \psi_{N-1}(n)$$

↳ egy időpontban tartózkodó értékek megadása

$n = 0, 1, \dots, N-1, N, N+1, \dots$

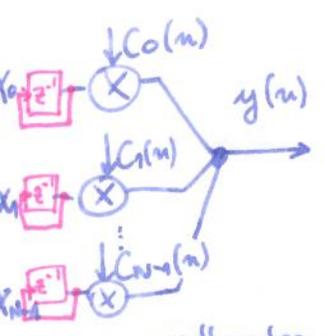
Mi történni, ha az idővel csúszni előre? CSÚSZÓABLAKOS FELT.

N minta $\rightarrow N$ érték (egyetleni körrelrendelés)

- csiszó megvalósítással történő továbbléptetés esetén 2 dolog vehető fel:
- \rightarrow a bdszót az idővel együtt csiszolni; az ablak elejéhez visz. eltolás nélkül.
 - \rightarrow vagy az ablak csiszol, de a bdszót a helyükön maradnak.
- \leadsto az adott műszelvény viszonyítva hogyan viselkedik a jelével?

Hogyan néz ki az a rendszer, ami a jelünk előállítására képes?

A és C.

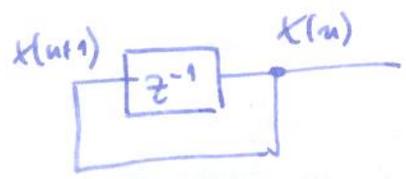


minden ágot figyelembe véve kirajzolódik az N elemű vektor

$y(n)$ sajátosága, hogy időpillanattól időpillanatra jelkomponensekkel terjedik össze (mieszor)

a létszámok: kell hogy legyen (n) indexe \rightarrow nem konstansnál marad (csak adott időpillanatban konstans), de minden pillanatra más i mat.

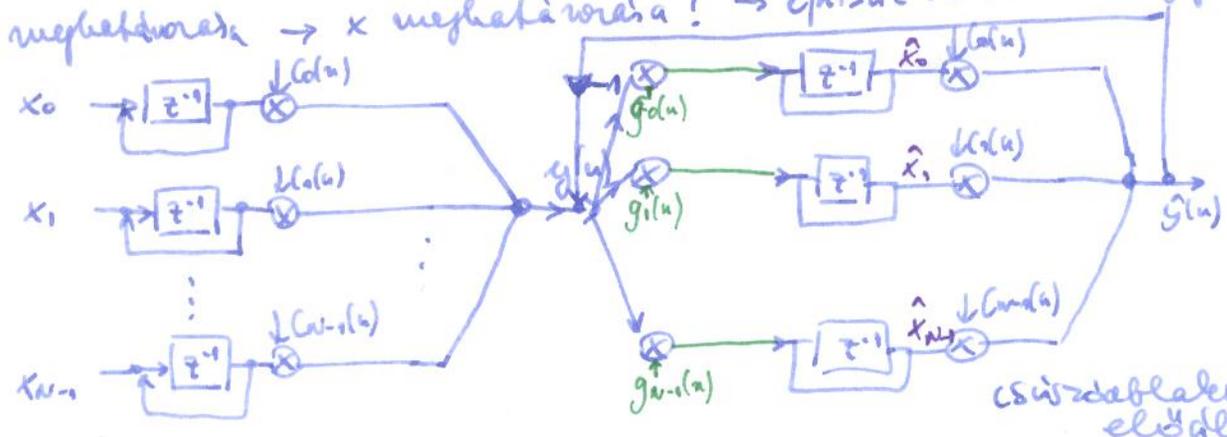
x_0, x_1, \dots, x_{N-1} még per pillanatot ismeretlen
 hogyan legyen a memóriaelem? (egyéni: késleltető)
 hogyan jut tartalomhoz? \rightarrow pl. differ. megvalósítással kezdési érték; valaki éppen beletette is azóta tartja ezeket.



az állapotmeneti mátrixot (A) itt az identitás mátrix valószínűleg meg
 $"A" \rightarrow I$

a létszámvektor pedig időtől függ!

x meghatározása $\rightarrow x$ meghatározása? \rightarrow építsük be a számítógépes programba!



$A - GC$
 \Downarrow
 $A - G(n)C(n)$
 \uparrow
 a reciprok bdszót adják meg

csiszóablakos repr. előállítás!

→ a reciprok bázisvektorok trandó $g_0(n), g_1(n), \dots, g_{n-1}(n)$ helyére? Bizonyítsuk!

$$A - G(n) \cdot C(n)$$

$$\uparrow$$

$$I - g(n) \cdot c^T(n)$$

$$g(n) = \begin{bmatrix} g_0(n) \\ g_1(n) \\ \vdots \\ g_{n-1}(n) \end{bmatrix} ; C(n) = \begin{bmatrix} c_0(n) \\ c_1(n) \\ \vdots \\ c_{n-1}(n) \end{bmatrix}$$

definiáljuk őket így.

→ vizsgáljuk az \hat{x} -t és x -t eltéréseit!

$$x(n+1) - \hat{x}(n+1) = [A - GC] [x(n) - \hat{x}(n)]$$

$$[A - GC]^{n+1} [x(0) - \hat{x}(0)]$$

a hatványok helyett különböző indexeket alkalmazunk.

$$x(n+1) - \hat{x}(n+1) = \prod_{i=0}^n (I - g(i) \cdot c^T(i)) (x(0) - \hat{x}(0))$$

Ezzelben felváltó ki'ba → a memóriaterhelés, bővíti eltérő

biz: mit csinál a produktum, ha megteszünk N lépést?

N lépés: N érték megvalósítása = N minta.
a ki'ba eltéréseit vizsgál!

$$\prod_{i=0}^{N-1} (I - g(i) \cdot c^T(i)) = 0$$

tipikus szemel a produktum ki'állításakor:

- ez egy szimmetrikus
- lesz olyan, hogy $g(i) \cdot c^T(i)$ -t nevezze I - vel.
- $\sum_{i=0}^{N-1} g(i) \cdot c^T(i) = I \Rightarrow$ a negatív előjel miatt kijön az szimmetrikus.
- több $g(i) \cdot c^T(i)$ önmegosztása

$$g(i) \cdot c^T(i) \cdot g(j) \cdot c^T(j) \quad i \neq j$$

különböző index $\Rightarrow 0$

\Rightarrow az összes ilyen térfogata 0!

$$\prod_{i=0}^{N-1} (I - g(i) \cdot c^T(i)) = I - \underbrace{\sum_{i=0}^{N-1} g(i) \cdot c^T(i)}_I = 0$$

↓ bizonyítási lépés

A fenti veiz egy N mintát léts általában rendelt reprezentációját.

Fourier esetben harmonikusok vannak jelen.

Az a bázis - rec. bázis rendszer, amit ilyenkor használunk, a direkt Fourier-párfélekből adódik.

$$\begin{cases} C_m(n) = e^{j \frac{2\pi}{N} m \cdot n} & \text{(bázis)} \\ g_m(n) = \frac{1}{N} e^{-j \frac{2\pi}{N} m \cdot n} & \text{(reciprok bázis)} \end{cases}$$

→ fejtsük ki egy bázist ki.

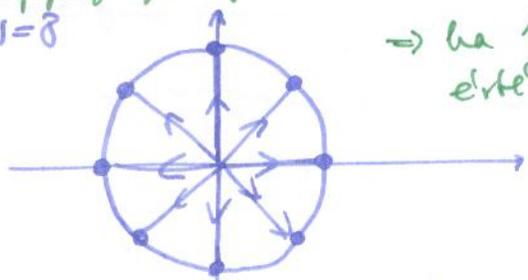
$$\frac{1}{N} \begin{bmatrix} e^{-j \frac{2\pi}{N} m \cdot 0} & e^{-j \frac{2\pi}{N} m \cdot 1} & e^{-j \frac{2\pi}{N} m \cdot 2} & \dots & e^{-j \frac{2\pi}{N} m \cdot (N-1)} \end{bmatrix} \begin{bmatrix} e^{j \frac{2\pi}{N} k \cdot 0} \\ e^{j \frac{2\pi}{N} k \cdot 1} \\ e^{j \frac{2\pi}{N} k \cdot 2} \\ \vdots \\ e^{j \frac{2\pi}{N} k \cdot (N-1)} \end{bmatrix} =$$

$$= \frac{1}{N} \cdot \sum_{n=0}^{N-1} 1 = 1$$

és ha nem azonosak az indexek? → k

$$= \frac{1}{N} \left[1 + e^{j \frac{2\pi}{N} \frac{(k-m)}{1} \cdot 1} + e^{j \frac{2\pi}{N} \frac{(k-m)}{1} \cdot 2} + \dots + e^{j \frac{2\pi}{N} \frac{(k-m)}{1} \cdot (N-1)} \right]$$

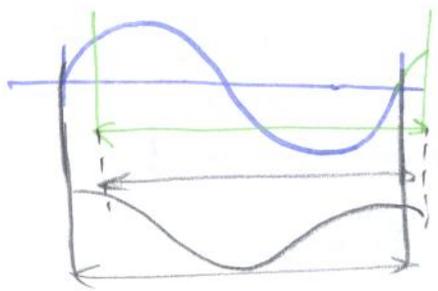
ha számszerűsítésre vesszük
→ egyenesen ugyanígy megjelenő exponenciális sorozat
pl. $N=8$



→ ha 1 az érték, a sorozat értéke NULLA, ezért egyenlő.

ha L találsz egy lévő tagokra vesszük
→ akkor is mindet megkapjuk egyszer, csak más sorrendben
⇒ itt is NULLA lesz.

És ha az ablak továbbcsúszik? → a definíció az előzőhöz volt...



→ újratöltés történik, a régi pedig elcsúszik
→ ez sorrendváltást jelent.
→ ha az ablakra nézve periodikus jel, ugyanazt fogja adni!

Mit jelent ez?

egy u sorozatból egy T trafa segítségével állított elő x-et.



$x = T u$
[] [] []

forrásjel reciprok
[x elemek] $x^T \begin{bmatrix} G_0(0) & G_0(1) & \dots & G_0(N-1) \\ G_1(0) & G_1(1) & \dots & G_1(N-1) \\ \dots & \dots & \dots & \dots \\ G_{N-1}(0) & G_{N-1}(1) & \dots & G_{N-1}(N-1) \end{bmatrix} \begin{bmatrix} g_0(0) & \dots & g_{N-1}(0) \\ g_0(1) & \dots & g_{N-1}(1) \\ \dots & \dots & \dots \\ g_0(N-1) & \dots & g_{N-1}(N-1) \end{bmatrix} = x^T$
 $u^T \quad T^T$

Az x elemeket megismerjük az összes c értékek a 0, 1, N-1 időpillanatokban. Ezen elemek összefüggésén keresztül kapcsolhatók.

Mit jelent ez, ha egy folytonos x(t) jelet megismerjük a „reciprok terület”, majd int.?

$X(f_0) = \int x(t) \cdot e^{-j2\pi f_0 t} dt$

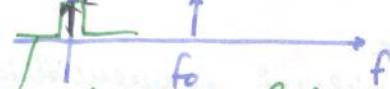
→ ez egy komplex levetés, melynek eredménye egy olyan j' d, ami az f frekvencián jellemző (f legyen Euleré!).

Visszafordítást.

① $x(t) = e^{j2\pi f_0 t} = \cos 2\pi f_0 t + j \sin 2\pi f_0 t$

lejtésedő, transzformációk

⇒ ha beírjuk ez integrálba, I-et kapunk.



az integrál egy keskeny aluláteresztő szűrő

⇒ megkapjuk az f_0 komponens amplitúdóját

⇒ ezzel a technikával lehet tudni valójában is jellemzői egy komponensét.

diszkrét világban:
 $X(m) = \sum x(n) e^{-j \frac{2\pi}{N} mn}$

→ frekvenciaátalakításban értelmezett jellemző.

az m. frekvenciapozíció a nulla komplexre transzformálódik, majd inverzítjük.



Esetünkben: egy konstans értékkel nyilvánított egy adott komponens frekvenciáját; egy jelgenerátor előállítás a komponens, amiből „nyitányezményt” vesszünk igénybe!

FREKVENCIA TRANSZFORMÁCIÓ (Ezeres)

Visszefelé a hibakomponenst tartalmazó kibajelt visszepoz.

az első kompotéere, majd ezzel befolyásoljuk azt a memóriatömböt, ami az z értéket adja meg.

Tetszőleges bázis/rec. bázis választással hasznos manőverek végrehajtani, ha $0 \leftrightarrow$ adott frekvencia körüli transzponálás.

Hétfőnapos étkelemben ez csak Fourier, de belátható, hogy más bázis is reciprok bázis erejébe is működik.

A jel egy jelgenerátor eredménye \rightarrow standard elemek bázis } komponensek.
 \rightarrow paraméterek

a rendszer belsejében kezdési érték jellel
vannak jelen \rightarrow egy kioldás inköire van művelet.

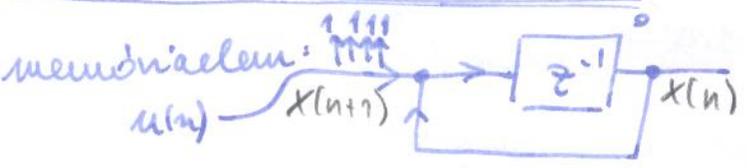
A bázis is reciprok bázis komponensekkel vagy a szabadságunk, akár alkalmazásfüggő módon határozhatjuk meg. Fontos az adat-redukció igénye. (pl. EKG)

\hookrightarrow az összetevő alap hullámokból melyikből memóri van?
normális, közös időfgr.?
milyen memóri, merre van a normalizálás?

Hatékony adatredukció: a jelrejtés vonását egy megfelelő bázis segítségével megfigyelhetjük.

Mi egyelőre maradtunk a Fourier-nál.

Az \int is a \sum mechanizmusa.



ha a bejövő oldalra 1-et tesszünk, (folyamatosan), de bevan 0-vel.
 $\Rightarrow 0, 1, 2, 3, \dots$
 \Rightarrow összegző gép;
DISZKRET INTEGRÁTOR.

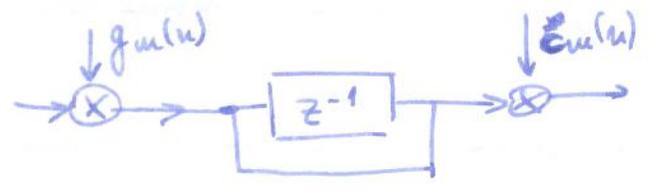
$$x(n+1) = x(n) + u(n)$$
$$zX(z) = X(z) + U(z)$$

miképpen sorozat összegzője?

$$\frac{X(z)}{U(z)} = \frac{1}{z-1} = \frac{z^{-1}}{1-z^{-1}} = 1 + z^{-1} + z^{-2} + z^{-3} + \dots$$

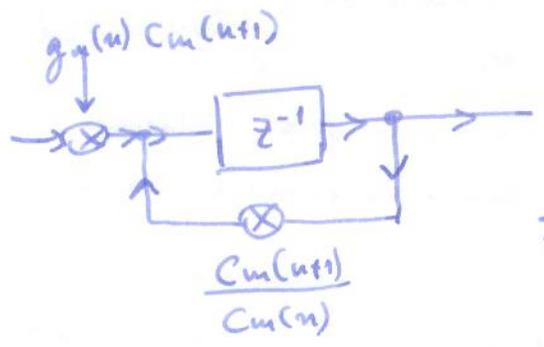
mintahog összegzésre sorban.
realizációs elrendezésben a késleltetés!

Kéverés és diszkrét integrálás



N lépésben 0 utat eredményez

Fatmunka a normál lépéssel. → C_m(n) lépés maradt!
 → már előbb lehetne
 → de ott késleltetés van!
 → ezzel előbbi mintát vegyük!
 → vonjuk össze!



mit igazoljon ez a visszacsatolás? → normál.

Fourier esetében:

$$C_m(n) = e^{j \frac{2\pi}{N} m n}$$

$$g_m(n) = \frac{1}{N} e^{-j \frac{2\pi}{N} m n}$$

$$g_m(n) \cdot C_m(n+1) = \frac{1}{N} e^{-j \frac{2\pi}{N} m \cdot n} \cdot e^{j \frac{2\pi}{N} m (n+1)} = \frac{1}{N} e^{j \frac{2\pi}{N} m}$$

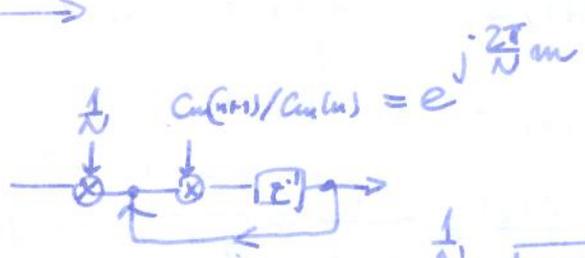
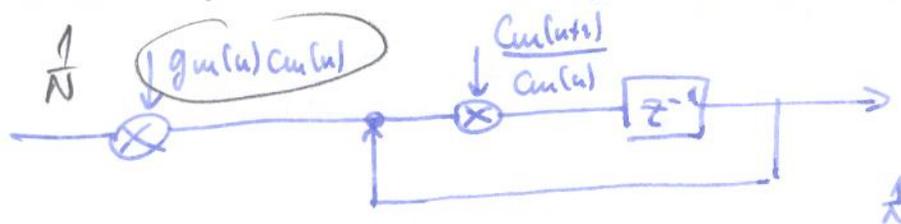
elevett az n.

$$\frac{C_m(n+1)}{C_m(n)} = \frac{e^{j \frac{2\pi}{N} m (n+1)}}{e^{j \frac{2\pi}{N} m n}} = e^{j \frac{2\pi}{N} m}$$

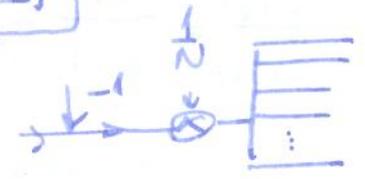
itt is elevett az n.

→ megpróbálni az az állapot, hogy időpillanatról időpillanatra miest kelljen betenni, egy konstans jellemző meg.
 miért normál két helyen e^{j \frac{2\pi}{N} m} -mel?

→ teszteljük be az összegzőpont mögött a normál.

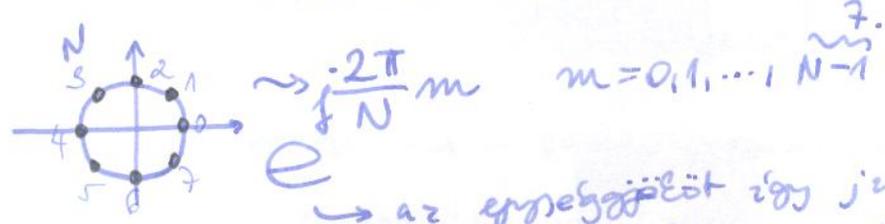


1/N az összes ágban meglesz kivétel nélkül előre.



A csabondból a jelkomponens vektorát értékeit kapjuk, tehát ez egy másfajta vektor. Akkor a sin ei a cos 1 amplitúdójú, a térfeljes amplitúdót leválasztva megkapjuk a felfelét.
 Hogy az a ből folyamatosan venni lehet, folyamatosan kiolvasható.
 Mit is csinál pontosan az új rajzolás?

→ egy ugyanolyan derivát integrátor, de nemcsak benne egy komplex számmal való szorzat.
 → ez az egységkör! egysége!



→ az egységkört egy jelöljük.
 → hossza 1, fázisa m-től függ.

rövidített írásmód (ponció az egységkörön)
 $e^{j \frac{2\pi}{N} m} = z_m$ (ha N-t ismerjük)

$$\frac{1}{1 - z_m z^{-1}} \dots \frac{z_m z^{-1}}{1 - z_m z^{-1}} = z_m z^{-1} (1 + z_m z^{-1} + (z_m z^{-1})^2 + (z_m z^{-1})^3 + \dots)$$

ami itt mutat, az egy olyan vektor, ami a belsőben lévő értéket az m. frekvenciára transzformálja, majd előállít egy szinuszt és kosinuszt (komplex formában) (?)

egy „jelgenerátor - körlet” → OSZCILLÁTOROK ALAPJAI!
 azt, hogy az egyes komponensek mennyire oszlanak ki,
 a kérdés értéke határozza meg

Főbb üzenet: a halmazokkal megpróbáljuk az n-től, de ezt csak a komplex exponenciálisokkal tudjuk előadni

De: az ilyen rendszerek alapfüggvényei ezek.
 (pl. Euler is csak exp. függ. mint jól ki)

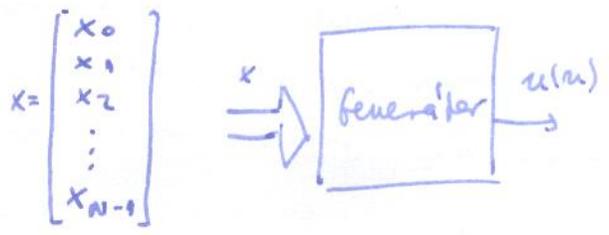
(közvetlen alapú jelmodell! ezeket leírhatjuk!)

Hf. kitra's a leuayan nyftalalalato!

↳ jlek vektorbelyi reprezentalalaja; oszkoablak.

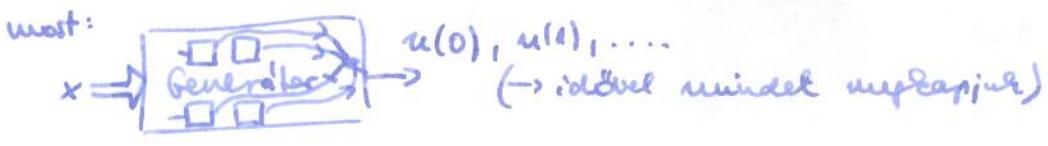
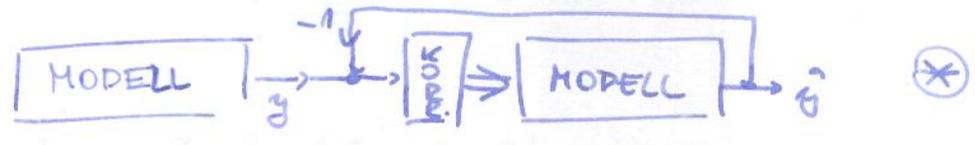
Adott egy vektor: $u = \begin{bmatrix} \vdots \\ u^{(0)} \\ \vdots \\ u^{(N-1)} \end{bmatrix}$ idelben értelmezett vektorok, diszkrét idelögv.

elölalalajul emek a jeltelyeli reprezentalalaját fejlesztik



emekbe vektörül egy generálót, ami az u-kat meplakalozza

mátrikosan: $x = T \cdot u$; ha u diszkrét jel, akkor x emek egy vektoros koordalalata rendszerbelyi reprezentalalaja (ezt a koord. v.-t T adja meg)



- generátor Ety.: belső sajátságok az x hozzárendelési szabály
- sok Ety. egyet; egy-egy bárujgv.
- ezek lineáris kombinálalaját képezik
- "jelkomponáló" → fix báruvektorok
- súlyozó faktorok Etyelése.

ebben az esetben: T transzformálaló zínereketben keresem, mi lehetett a súlyfaktor.

$$u = \begin{bmatrix} \vdots \\ u^{(0)} \\ \vdots \\ u^{(N-1)} \end{bmatrix} = \begin{bmatrix} \vdots \\ \vdots \\ \vdots \\ \vdots \end{bmatrix} x$$

báruvektorok mátrixa
(a báruvektorok UFTETUS némez)

$$x = T \cdot u$$

$$T^{-1} x = T^{-1} T u = u$$

báruvektorok $T^{-1} = \begin{bmatrix} \downarrow \downarrow \dots \downarrow \\ 0.1. \dots n. \end{bmatrix}$

reciprokal báruvektorok $T = \begin{bmatrix} \rightarrow \rightarrow \dots \rightarrow \\ \vdots \end{bmatrix}$

$T T^{-1} = \begin{bmatrix} \rightarrow \\ \rightarrow \\ \rightarrow \end{bmatrix} \begin{bmatrix} \downarrow \\ \downarrow \\ \downarrow \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = [I]$

egységmátrixot adnak!

Hf: Fourier-típusú bázisrendszerrel generálni

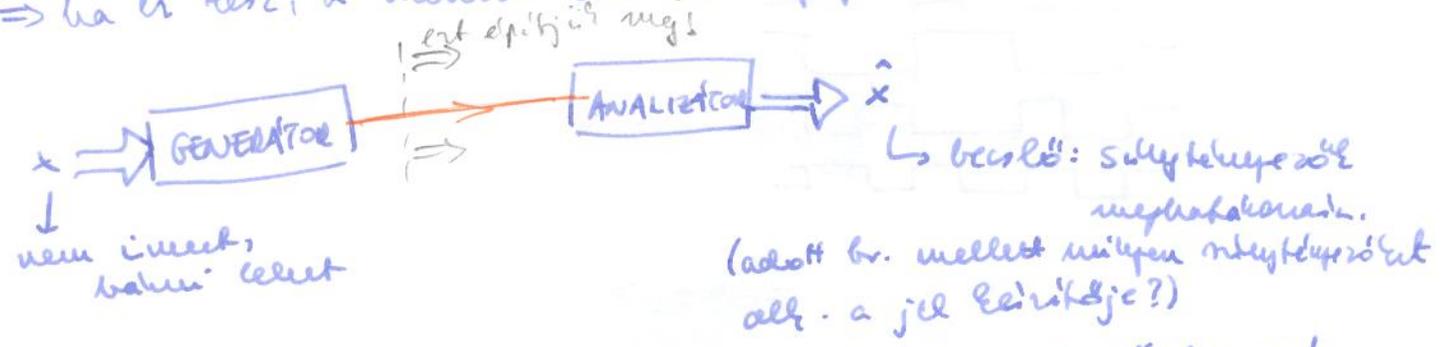
- van olyan báziselem, ami DC komponens
- van koszinusos alaprészek
- van szinusos váltórez

0	1.	3.	5.	...
	2.	4.	...	

→ a reciprok tr. megállapítása a mátrixinverzid!

Tovább: mit eredményez egy báziselem uweje?

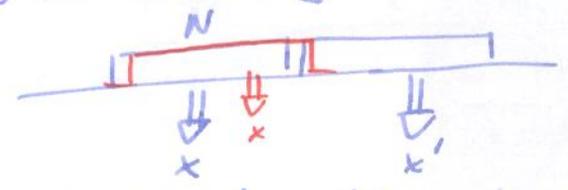
⇒ ha ez lesz, a modellt kell (*) megépíteni.



Cél: a jel egy jél mintákkal leírható adattal jellemezhető legyen! (generálható)

MEGFIGYELÉS SÉMA
REKURZÍV TRANSZFORMÁCIÓ:

kezdőfeltétel: valóságszám (N) minta, adattömb



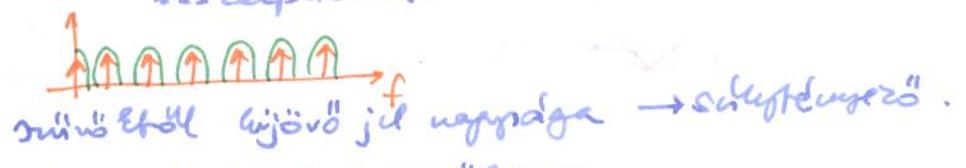
itt: csúszdablat jelleg! → folyamatosan van értelmezés adat!

de! odafigyeléssel a mátrix nem nar...!
a generátor periodikusan működő rendszer!
(az eredetileg mindig 0 a kezdőérték)

megoldás: CÍKULÁRIS mozgás! (belső és v.br. csúszás is)

ez alapján egy determinált jelfeldolgozó sémát építünk fel.
generátor és analízator

→ szűrő "belső": a bemenő jeltől néhány arszak a komponenseket, amikből a kimenőjeleket issszeépítjük.

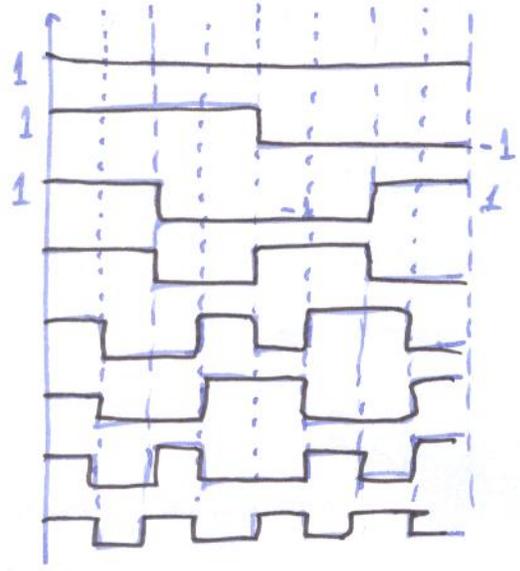


⇒ ez többszörös br. -r.br. pára működés.

a frekvenciahatárokbeli jellemzés az első lépés.

meg egy szempont: nem mindegy, milyen aritmétikai lépésszámot kell az analízatorban használni → ILLUSZTRÁCIÓ:

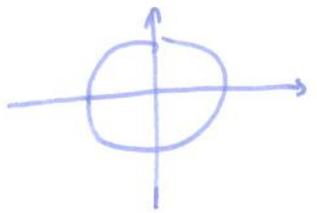
Walsh kódok $N=8-ra$



- könnyen implementálható
- a reciprok önmaga
- ortogonális

- 1.) ortogonális: $(C_m, C_n) = 0$, ha $m \neq n$
- 2.) reciprok bázis önmaga.

Hf: a fundamentális $\sin \cdot \cos$ képlet az egy egyező-bőrlőz rendelkezésk

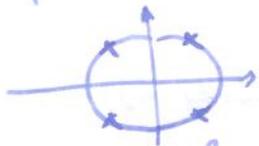


$x^n - 1 = 0$ } egyenlet összes gyöke
 konvencionális Fourier
 itt N ptkan!

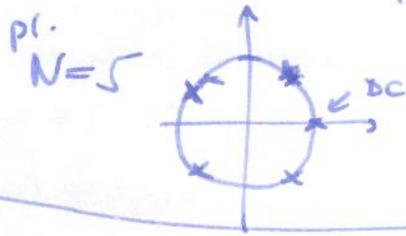
vagy $x^n + 1 = 0$
 $\sqrt[n]{-1}$

van DC komponens
 2 db alaph.
 2 db. 2. harmonikus
 2 db 3. harmonikus
 összesen ptkan db.
 komponens a
 körívendületen.

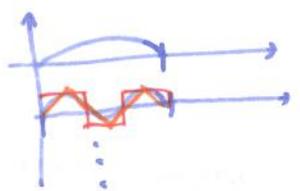
itt N ptkos.
 pl. $N=4$



nincs DC komponens!
 az alaph. : $2\pi/8$



↳ de az ortogonális rendszer, ahol egy feltevéssel jut
 másképp per. jut N léptet.



ellenfelelősen folytatódhat,
 de ez nem jelent gondot

↳ itt is 2 felki jön azonosításhoz: alapharm. felé
 alapharm. mátfeléné.

mindkettő: elbűt haem. por. ban Δv . \square -jére esélyük \rightarrow hűvöng
 a r. br.?

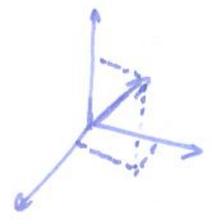
→ a br. elvendi ortogonalitását!

plus: számos báziselemekkel, de nem harmonikus (modulus) jellekkel kapcsolatba hozható bázis is több lehet; nem mindig harmonikusnak lenniük, de ez már nem az általános jellegzetesre nézve elvárás!

a vevő az analízis, feladata az eredeti infó „előállítás”.

Tér is kétféle dimenzió:

3D → egyvektorokkal állítunk elő kétdimenziós vektort

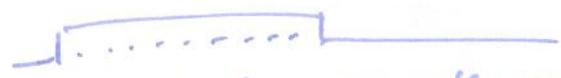


3 vektor segítségével jellemezhet egy aggódást mindig amíg vektor kell, ahány Dim. **N**; ha a vektorok függetlenek (mindegyik egy egyenest)

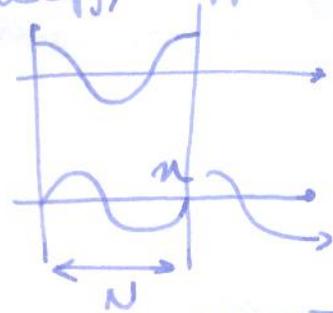
⇒ szigorúan összeadunk N db. vektort, így megkapjuk, amit reprezentálni akarunk.

→ diszkrét értékeket (N db. elemű vektort)

→ ehhez N db-ot gyűjtünk be



⇒ nem mindegy, hogyan vettük a vektorokat!



mintavételes reprezentáció (N db minta)

a minták indexe

→ egy teljes T periódus éppen.

$$T = N \Delta t \leftarrow \frac{T}{N} = \Delta t, \text{ mintavételes időlépés.}$$

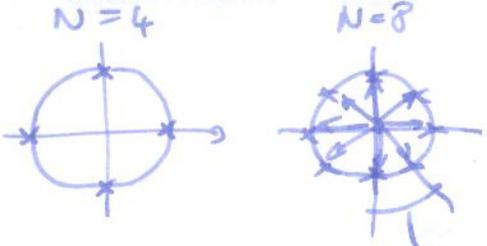
$$\cos \omega t = \cos 2\pi f t$$

frekvencia → az alapam. értékén $f_0 = \frac{1}{T}$

→ az m. harmonikus $m \cdot f_0 = \frac{m}{T}$

$$\rightarrow \cos 2\pi f t \stackrel{m \cdot \Delta t}{=} \cos 2\pi \frac{m}{T} \cdot n \cdot \Delta t = \cos 2\pi \frac{m}{N \Delta t} n \Delta t = \cos \left[\frac{2\pi}{N} m \cdot n \right]$$

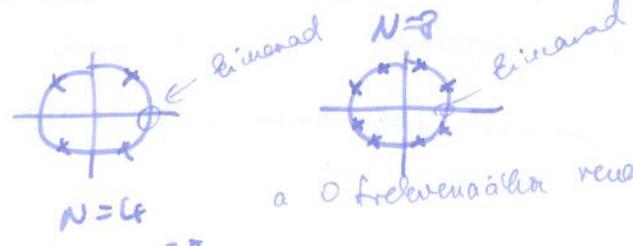
együttgyűjt → N részre osztott egyenest



az egységkörből generalizáljuk a komponenseket

$\frac{2\pi}{N}$ az alaphérvényiséget adja

-1 gyökéül elfordul

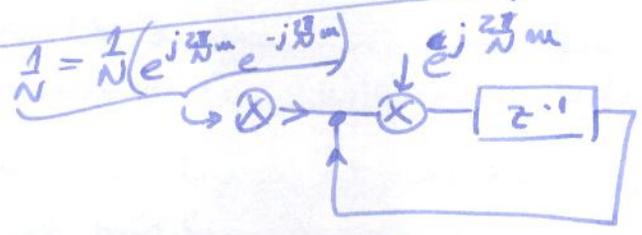


a 0 frekvenciánál kezdődik mindig Ekinasod

egy-egy adott pont: $e^{j \frac{2\pi}{N} \cdot n}$

$$1 + \underbrace{e^{j \frac{2\pi}{N}}}_{\cos \frac{2\pi}{N} + j \sin \frac{2\pi}{N}} + \underbrace{e^{j (\frac{2\pi}{N}) 2}}_{\cos \frac{2\pi}{N} 2 + j \sin \frac{2\pi}{N} 2} + \dots$$

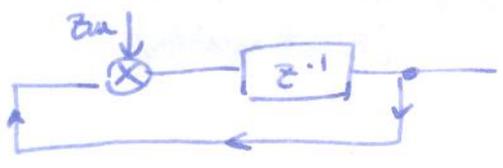
$\cos \frac{2\pi}{N} m \cdot n$



rezonátor.

$$z_m = e^{j \frac{2\pi}{N} m}$$

az egységkörön egy megfelelő pozíciójű gyök.



jell: $\frac{z_m \cdot z^{-1}}{1 - z_m z^{-1}}$ lenne az ábrítási függ.

mérték sor összeállítását figyelembe véve:

$$(z_m z^{-1})^0 + (z_m z^{-1})^1 + (z_m z^{-1})^2 + \dots$$

$$1 + e^{j \frac{2\pi}{N}} z^{-1} + e^{j \frac{2\pi}{N} \cdot 2} z^{-2} + \dots$$

az elhanyagolás miatt

eggyel korábbi miatt

előzővel korábbi miatt

valószínűleg korábbi miatt

m. m-1. m-2. m-3. ...

KOMPLEX EGÝÜTT HATÓS REZONÁTOR,

→ a gyökösével ugyan a komplex konjugált pálya is!

$$\frac{z_m z^{-1}}{1 - z_m z^{-1}} + \frac{z_m^* z^{-1}}{1 - z_m^* z^{-1}} \quad (\neq)$$

konjugált

→ a röge minusz lesz ⇒ a minusz előtt megjelenti egy-1.

→ van 2 olyan, ami ugyanolyan frekvenciát deit elő; vegyük őket párba!

→ $(e^{j \frac{2\pi}{N} m})^* = e^{-j \frac{2\pi}{N} m} = (e^{j \frac{2\pi}{N} m})^{-1}$ (az exponens amplitúdó miatt)

$$\left(\neq \right) \frac{z_m z^{-1}}{1 - z_m z^{-1}} + \frac{z_m^{-1} z^{-1}}{1 - z_m^{-1} z^{-1}} = \frac{z_m z^{-1} - z^{-2} + z_m^{-1} z^{-1} - z^{-2}}{1 - (z_m + z_m^{-1}) z^{-1} + z^{-2}} \quad (=)$$

Ha két közbélyet képvisel...

z^{-2} elcsúsz!

↑ $2 \cos \frac{2\pi}{N} m$ valós! ↓ $j \frac{2\pi}{N} m$ ↑ valós

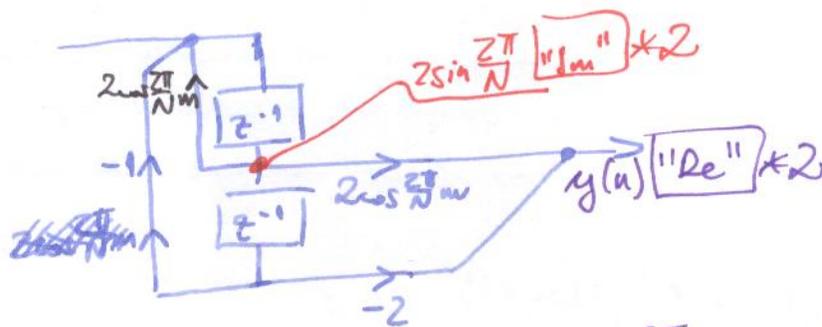
$$\frac{e^{j \frac{2\pi}{N} m} + e^{-j \frac{2\pi}{N} m}}{2} = \cos \frac{2\pi}{N} m$$

valós, metadefekti uweröt kapunk.

$$= 2 \frac{z^{-1} \cos \frac{2\pi}{N} m - z^{-2}}{1 - 2z^{-1} \cos \frac{2\pi}{N} m + z^{-2}} = \frac{Y(z)}{U(z)}$$

valós egytlenvalós, cosinus jel esdeletatadra képes!!!

rajban:



$$u(n-1) \cos \frac{2\pi}{N} m - 2u(n-2) = y(n) - y(n-1) 2 \cos \frac{2\pi}{N} m + y(n-2)$$

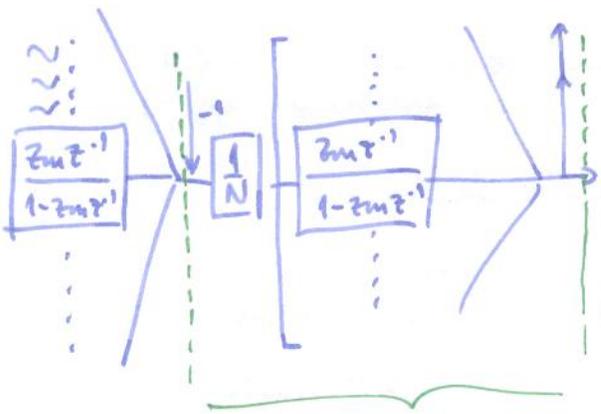
és miúnt kapunk (képletet)

$$2j \frac{e^{j \frac{2\pi}{N} m} - e^{-j \frac{2\pi}{N} m}}{2j} = 2j \sin \frac{2\pi}{N} m$$

$$\frac{2j z^{-1} \sin \frac{2\pi}{N} m}{1 - 2z^{-1} \cos \frac{2\pi}{N} m + z^{-2}}$$

A modellülétet helyezett rezonátor felírása:

$$\frac{z_m z^{-1}}{1 - z_m z^{-1}}$$



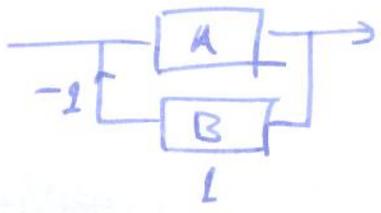
Mi történik itt?

azért nem tudunk, hogy az töltődjen renni, ugyanaz legyen!

Mi van köztük? Összesített kimeneti dobok alakulata.

$$\frac{\frac{1}{N} \sum_{m=0}^{N-1} \frac{z_m z^{-1}}{1 - z_m z^{-1}}}{1 + \frac{1}{N} \sum_{m=0}^{N-1} \frac{z_m z^{-1}}{1 - z_m z^{-1}}} = z^{-N}$$

először vizsgáljuk.



Érdekes, ami egy ablakot kerekítet (egy ablak mindig is dt rajta) → de! ez ismétlődik! mindig ugyanaz vanja ki, tökéletes és pirosabb → N az mintát kell beletenni.

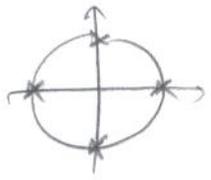
Érdekes kört =>

$$\begin{aligned} z_0 z^{-1} (1 + z_0 z^{-1} + (z_0 z^{-1})^2 + \dots) \\ z_1 z^{-1} (1 + z_1 z^{-1} + (z_1 z^{-1})^2 + \dots) \\ z_2 z^{-1} (1 + z_2 z^{-1} + (z_2 z^{-1})^2 + \dots) \end{aligned}$$

azt mind sille kell adni $z^{-N} + z^{-2N} + \dots$ végtelen sor

$$\frac{z^{-N}}{1 - z^{-N}}$$

ez a megoldás.



$$z^{-N} (z_0 + z_1 + \dots + z_{N-1})$$

határozzuk meg 0, kivéve N, ahol 1-et ad. (ez a zártkörben belül az N-1.)

$$\frac{\frac{z^{-N}}{1-z^{-N}}}{1+\frac{z^{-N}}{1-z^{-N}}} = \frac{z^{-N}}{1-z^{-N}+z^{-N}} = \boxed{z^{-N}}$$

Mi is történi a rajzban? Egy jelminőségis eredményre jellevalósi előzetes len. Az analízis során előlélyül ugyanaz a jel. Nem történt egyéb, csak egy blokkot kért. Nem lehet megadni, hogy ne legyen képlettel; a munkában felhamalyul.
(Tandeleian előlélythető képlettel is lehet, de ezt feleltük el.)

Egy további vonatkozás

z^{-N} -t kapjuk de miiket egy blokk kivételével ez analízisban.

$$\frac{\frac{1}{N} \sum_{k=0}^{N-1} z^k z^{-k}}{1 + \frac{1}{N} \sum_{k=0}^{N-1} z^k z^{-k}} = \frac{1}{N} (1-z^{-N}) \frac{z^0 z^{-0}}{1-z^0 z^{-0}}$$

ez egy olyan alak, ami elemzés eredmény a jelfeldolgozás folyamatában.

FREKVENCIAÁNTAVÉTELI ELJÁRÁS

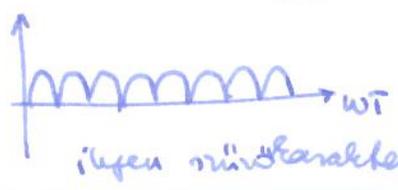
Milyen alviteki tulajdonsága van $\frac{1}{N} (1-z^{-N})$ -nek?

$$\frac{1}{N} (1-z^{-N}) = \frac{1}{N} z^{-N/2} (z^{N/2} + z^{-N/2}) = z = e^{j\omega T} \quad z_j = \frac{e^{j\frac{N}{2}\omega T} + e^{-j\frac{N}{2}\omega T}}{2j} = \sin \frac{N}{2} \omega T$$

Δt helyett T
az a mintavétel idő

$$= \frac{2j}{N} e^{-j\frac{N}{2}\omega T} \sin \frac{N}{2} \omega T$$

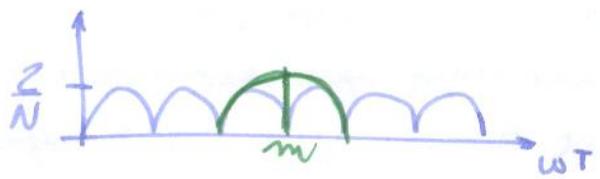
abszolút értéke: $\frac{2}{N} \left| \sin \frac{N}{2} \omega T \right| = \left| \frac{\sin \frac{N}{2} \omega T}{\frac{N}{2}} \right|$



hisz argumentuma ωT szerint inakt

Az egyégsúlyú körökben lévő porciókban lenivással rendelkező, FÉLÜS SZÜRŐ.

Az m . pólsoporiót a fog eltolására használom!



$$\prod_{m=0}^{N-1} (1 - z_m z^{-1})$$

⇒ olyan művelet, ami egy kivételével mindent kitör, azt átengedi, méghát (jelanalízis tervezes spektruma)

⇒ minden generátorkomponenst elnyom egy kivételével.

⇒ lehet mérési feladatra használni.

Ezzel a rémival nem mindig vennyűzős a minbavétel.

Az alábbiak miatt van az a N -vel korlátos.

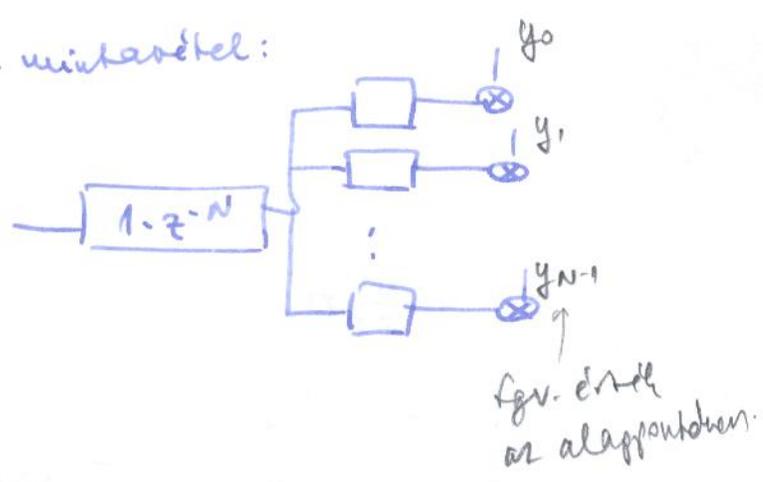
Gyámsági ügyek:

- teljesen precíz implementáljuk a művelet, a fixpontos realizáció miatt bajba kerülhet; A \cos is a \sin nem biztos, hogy
- 1 olyan amplitúdót jelöl ki (a kerékítés miatt); a stabilitás határán vannak a gyökös.; ha belül maradunk, fokozatosan csökken az amplitúdó.

Itt nem igaz, mivel kisebb hibás a pozíció, a légitel tördelés.

- 2. Mivel z_m éppen van implementálva, az eltolást ugyanazok lennek, a két stabilan visszacsatolja. az 1 évantélelől függetlenül az erős visszacsatolás miatt körül marad gyűlés. Miértől ekkor a másik (1) rossz megvalósításból.

Fr. minbavétel:



$$\begin{aligned} y_0 &= y(x_0) \\ y_1 &= y(x_1) \\ &\vdots \\ y_{N-1} &= y(x_{N-1}) \end{aligned}$$

keress egy
POLINOMOT amely

független változó helyett a fgv. értéke

$$Y(x) = \prod_{n=0}^{N-1} (x-x_n) \sum_{m=0}^{N-1} \frac{a_m}{x-x_m}$$

összes \Rightarrow egy kicsit

$1 - z_m z^{-1}$
"elkezd"!

az alappontok és x különbsége produkciójában

$$a_m = \frac{y_m}{\prod_{\substack{n=0 \\ n \neq m}}^{N-1} (x_m - x_n)}$$

alappontok:

z_0

z_1

z_{N-1}

a frekvenciaintervallusi egyenes
MEGEGYZÉK

\leftarrow Lagrange - interpolációval!!

\rightarrow az alappontokra tartozó a fgv. értéket alapul véve fel tudunk építeni egy polinomot.

mit kell csinálni? felejtjük el az egyenlet megoldását, és vegyük tetszőleges polinomot.

\Rightarrow a Lagrange-vel alkalmas becslőképletekkel tudunk számolni.

Megoldás: konvergens sorozat (6)

$$1 + \sum_{n=0}^{\infty} \frac{g_n z^{-n}}{1 - z_n z^{-1}} = \frac{1}{\prod_{n=0}^{N-1} (1 - z_n z^{-1})}$$

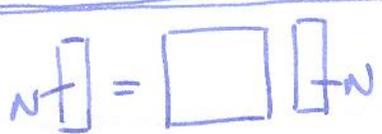
↑ adja ki a felső rúgó gyökeket!

ezzel feltétel felírva: (végtelenségig bontás)

$$g_m = z_m \frac{1}{\prod_{\substack{n=0 \\ n \neq m}}^{N-1} (1 - z_n z_m^{-1})}$$

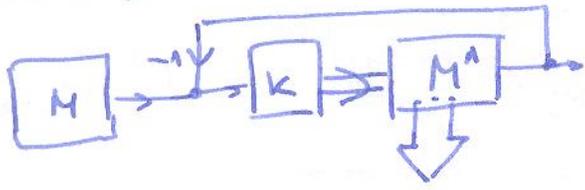
ugyanígy meghatározuk még,
ahogy a Lagrange
egyenletét.

Kerülszében van egy olyan érték, amivel nem harmonikus
sorozattal reprezentációját analízisben is generáljuk
és tudjuk



hogyan lesz ez vizsgáztatható?
 cél: létszöveges transzformációra meg tudjuk csinálni

→ ha a jel műtékre van modellünk... → a kiadás értéke egy
 új műveletet meg. program
 → becsült előállítás,
 korrekció



konkrét példák! (diszkrét Fourier, ezen reprezentáció értéke)
 → szinusz és koszinusz lin. kom.
 → itt jelreprezentáció egy fiz. jel két tartományban
 → egyes frekvenciakomponensek jelenlétét mutatja

$$X(m) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j \frac{2\pi}{N} mn}$$

szárazos képező, átkaplati eljárás

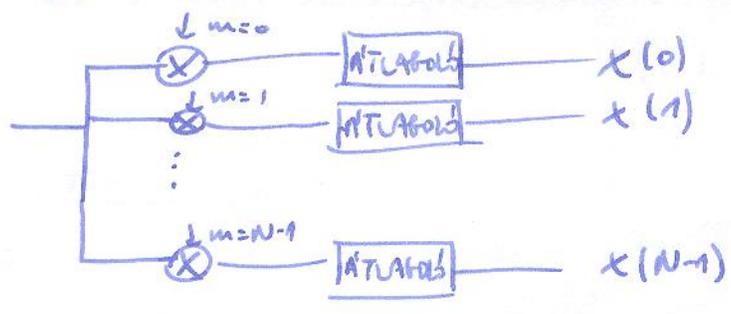
cél: olyan nélcím, ami
 folyamatosan gyártja a
 komponenseket, ha meglátja
 a bevételeket

Két alternatíva bontjuk fel:

1.) fogjuk a jelet, és komplex élevesreket tesszük ki.

$$X(m) = \underbrace{e^{-j \frac{2\pi}{N} mn}}_{\text{komplex élevesreket}} \cdot \underbrace{\frac{1}{N} \sum_{n=0}^{N-1} x_n}_{\text{összeg}}$$

2.) ezt átkaplatjuk



előállunk a frekvencia-
 tartományban két.
 komponensek.

→ ezt a párhuzos eljárást alkalmazhatjuk

→ az átkaplató átviteli függvény típusú leírása:

$$H(z) = \frac{1 - z^{-N}}{N(1 - z^{-1})} = \left(1 + z^{-1} + z^{-2} + \dots + z^{-(N-1)}\right) \frac{1}{N}$$

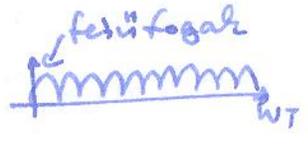
→ összeadjuk a korábbi mintákat és osztjuk N-nel

$$\frac{1}{N}(1 - z^{-N})$$

→ olyan frek. tartományban értelmezhető
 karakterisztika, amit férfis szinusz nevezünk

amplitúdó-karakterisztika: szinusz függvény

$$z_j \frac{z^{\frac{N}{2}} - z^{-\frac{N}{2}}}{z_j} = \frac{z^{\frac{N}{2}} - z^{-\frac{N}{2}}}{z_j} = \left| \sin \frac{N}{2} \omega T \right|$$



→ egy alkalmas frekvenciájú komponens megnevezésével
 inkább az adott fésűfog kitörése

→ az ottaladó a 0-frekvenciájú fog kitörése

$$\frac{1}{N} \left| \frac{\sin \frac{N}{2} \omega T}{\sin \frac{1}{2} \omega T} \right| \Rightarrow 1$$

his argumentummal $\sin x = x$

minden felsőbb harmonikusnál
 0 arányú

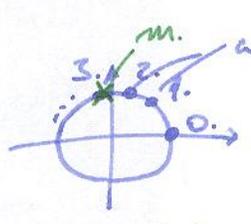
→ tiszta periodikus jel esetén csak
 tiszta frekvenciák vannak, azaz csak
 a 0-nál levőt cserélt át 1 nullával

a kérés hatása, hogy a nyílcsúcs középre tolja

mit mérőnköz:

$$\frac{1}{N} \frac{1 - z^{-N}}{1 - z_m^{-1}}$$

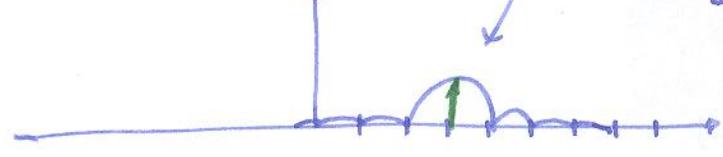
az m. pontján
 kitörése



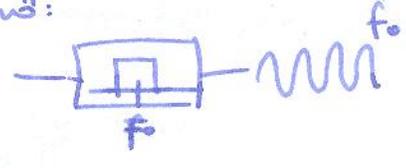
a körívén pontok csak
 egy körívvel
 rajzolhatók le

$$1 - z^{-N} = \prod_{m=0}^{N-1} (1 - z_m z^{-1})$$

altal → Fourier. együttható értéke. (egy komponens)
 Fourier. komponens



Szűrő:



Hegyzet:

1) A számítógépünk valódi és képzett része bontva számít.

Mi a helyzet a f. implementációval:

$$\frac{z_m z^{-1}}{1 - z_m z^{-1}}$$

a komplex egyenlő két kömp
 elbontani, mivel a konjugált
 pár is rendelkezésre áll.

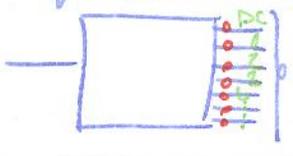
⇒ pontosított összeronva

$$\frac{z_m z^{-1}}{1 - z_m z^{-1}} + \frac{z_m^* z^{-1}}{1 - z_m^* z^{-1}} \rightarrow 2Re$$

$$\rightarrow 2Im$$

~~1)~~

2) Alkalmazás érdekében tett jelfeldolgozó eszközök tudunk
 generálni: frekvenciaamplitúdóvali elvárással.



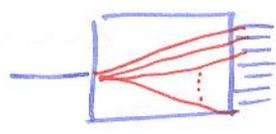
komponens

→ összeronva visszaadja az eredeti jelet
 → új sávszélességet adva új jelet
 tudunk csinálni (szűrés)
 felül/alulátereszt jelek, kétféle komponens

$$\frac{1}{N} (1-z^{-N}) \sum_{m=0}^{N-1} \frac{1}{1-z_m z^{-1}} = 1 \quad \left\{ \text{eredeti jelle} \right.$$

vagy

$$\frac{1}{N} (1-z^{-N}) \sum_{m=0}^{N-1} \frac{z_m z^{-1}}{1-z_m z^{-1}} = z^{-N}$$



A súlytényező azt mondja meg, milyen legyen az átvitel az adott fr. komponensnél.

H(z_m)

① Ez összefügg a Lagrange-interpolaáció tulajdonságával. Itt olyan értéket számítunk fel, amivel megadjuk, adott függvény hogyan jessen át a csomópontokon.

$x_0, x_1, x_2, \dots, x_{N-1}$
 $y_0, y_1, y_2, \dots, y_{N-1}$

$$Y(x)_m = \prod_{n=0}^{N-1} (x-x_n) \sum_{m=0}^{N-1} \frac{A_m}{x-x_m}$$

a produktumban az összes gyököt szerepel, de kiejtünk egyet és ott a számláló juttatuk az értékezt.

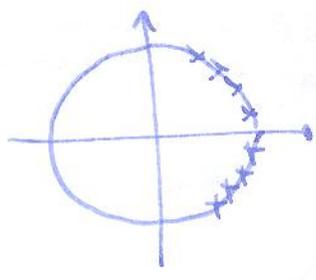
⇐ rektifikációra bontási probléma megoldása.

Lagrange: a_m számítása rektifikációra bontási segítségével

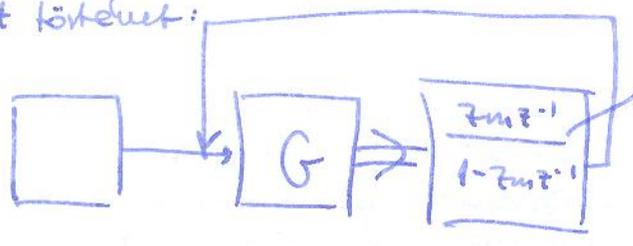
$$a_m = \frac{y_m}{\prod_{\substack{n=0 \\ n \neq m}}^{N-1} (x-x_n)}$$

↳ a megfelelő fog. értéke

Az egyen felvételünk mintavétel: eljövünk többszörös alappontra értelmezhetőség terén. Azaz súlyúknak egymás mellett lévő fr. komponensek is alkalmasnak lehetnek.



Visszacsatolt körtérlet:



rezonancia

$$\frac{z_m z^{-1}}{1 - z_m z^{-1}} \text{ alakú kiejt. vissza}$$

z_m meghatározása Lagrange-interpolaációval.

CSATORNA ÁTVITEL sávszélesség előtt 1

$$g_m = \frac{z_m}{\prod_{\substack{n=0 \\ n \neq m}}^{N-1} (1 - z_n z_m^{-1})}$$

- a Lagrange interpoláció lehetőségét nyit.
- univerzális jellemzőkkel rendelkező eszköz, ami nem csak harmonikus bemenés kompozitására képes bontani.
- ezután a nincsenit alkalmasan jutunk el a célunkhoz.

Ha ama körülmények, hogy ne csak polinomszerűen gondolkodjunk, akkor a jel rekonstrukcióját nem véges bázissal tudjuk egyíteni, hanem polinomiális jöjjelekre kellene. (?)

köv téma: adaptív jelfeldolgozás

- olyan módszer, ami a veletlenszerűségtől tanul
- saját működéséhez figyelembe veszi.

ADAPTÍV RENDSZEREK

cél: eszköz a probléma megfogalmazására, a valóság leírására, a modellreállításra

modellleltétel: egy előredefiniált struktúra + változó/változtatható paraméterek.

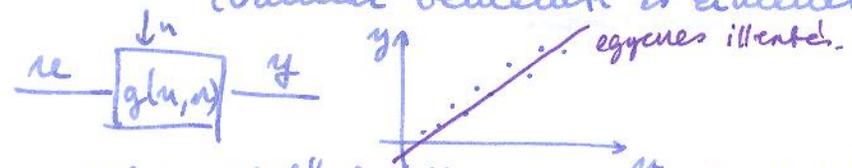
A: pontosabb megismerés (identifikáció)
→ a továbbiakban az adatokat ismét blokkként kezeljük.

B: követési tulajdonságok megvalósítása

A: minél pontosabb legyen a rendszer }
B: minél jobb, gyorsabb követés a feladat, kisebb pontossággal } ⇒

⇒ rekurzív eljárásokat használunk, amiért ezt a két világot összekötik.

regressziós séma: van egy megfigyelt jelenség → függvény (vannak bemeneti is kimeneti értékei)

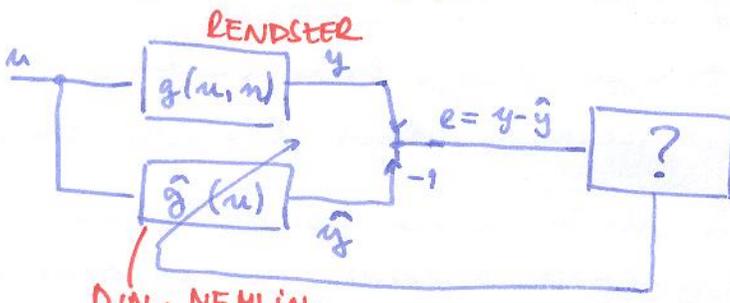


cél: a dolog utolsó legyártott, egyszerűen kalkulálható, jobban illeszkedő reprezentációját keressük el.

Mivel nincs semmilyen ismeretünk a belsejéről, prekoncepcióval élünk (pl. egyszerű feltételezések).

A jelenséget befolyásolja az „ u ” bemenet, amit mi adunk, és egy rajkötött értelmennt „ n ” aktivitás (ez a dobozon belül valahol működik) → bizonytalansághoz vezetnek te.

Lefejtünk egy \hat{g} függvényt, ebben mit nem ismerjük.



Mivel állítjuk vissza \hat{g} állítható paramétereit? Először a megfigyelhetőhez képest, hogy nem állapítható, hanem paramétereiket igazgatjuk.

DIN., NEHLIN. RENDSZERMODELL
pl. lineáris
↓
mi találtuk ki, hogy lin. legyen.

$\hat{g}(u) = a + bu$
paraméter a és b .

a kiba négyzetűvel, a várható érték alakulását követjük nyomon.



a parabolid alja az a/b síkon értelmezve adja a kibát. a deriválással keressük az extrém.

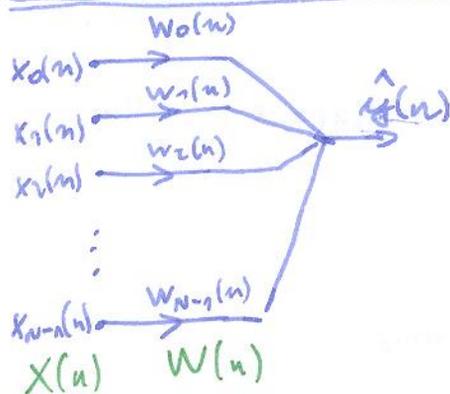
Mind a felső, mind az alsó dobozokat általában értelmezni. A din., neulin. részek legyen statikusak, a változtatható paraméterek pedig követően valamilyen lineáris világot.

pl.: $\hat{g}(u) = a + bu + cu^2 + du^3 + \dots$
 \Rightarrow paraméterekben lineáris struktúra, kiértékelhetőséget igényel.
 \Rightarrow lineáris effekteknél nem megfigyelhetőre jutunk.

ADAPTÍV LINEÁRIS KOMBINÁTOR



ADAPTIV LINEARIS KOMBINATOR

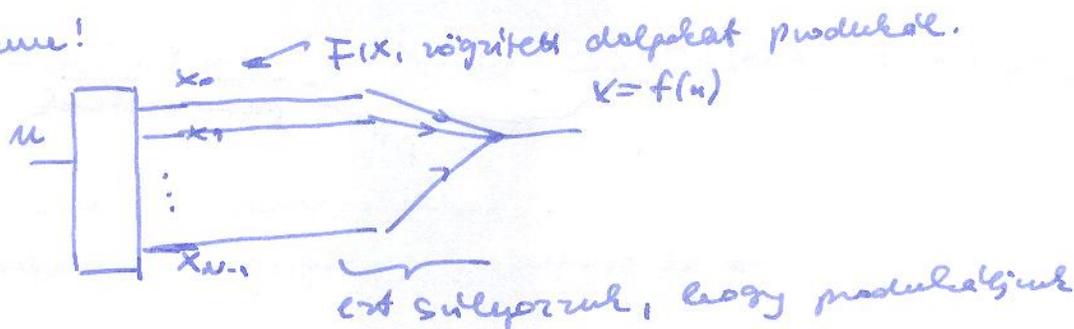


$$\hat{y}(n) = W^T(n) X(n)$$

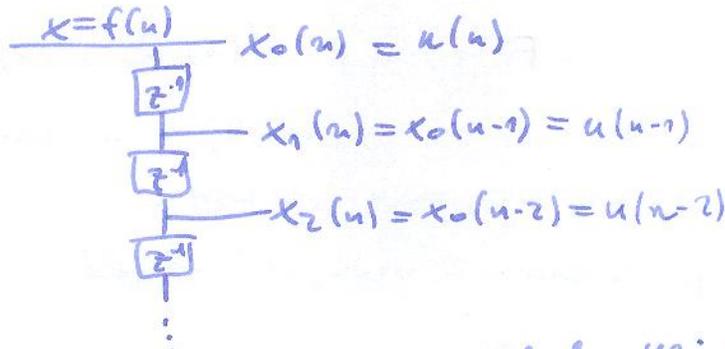
$\downarrow d(n)$

\hat{y} az előállítása sülyprott ~~paraméterekkel~~ $x_i(n)$ -ekkel ez az összekötés van az $X(n)$

Ez csak egy elem!



Első lépésben benne leírtuk az adatot x_i :



Adaptív művelet, mely a bemenő jelet korábbi értékeivel kombinál.
 \hookrightarrow a paraméterei változnak.

Hogyan működtesse?

Hogyan történhet a regressziós feladat megoldása, mi a módszerünk?

Gyermek: $E[e^2]$ \rightarrow valamilyen rögzített mennyiség becsültése utáni 'kapacitás'; nagy vagnak előre!
 (nem blokkos regisztrátum!)

$$N \Rightarrow \frac{1}{N} \dots n \in []$$

\rightarrow csak valamilyen mértékelven tudja a várható értéket megválasztani.

\rightarrow követelmény, hogy eredményt mindig hamarabb legyen.

A feladatban: azonosítandó d(n) jel.
cell: uozó kódot mint a közelebbi kényelmű

A lita: d(n) - W^T(n)x(n) = e(n) W^T(n)x(n) = x^T(n)W(n)

Hogyan határozunk meg a súlyfüggvényeket?

E(e^2) legyen minimális.
(lineáris regressziós feladat átalakításaként)

~~E(e^2) = E(d^2(n) - W^T(n)x(n) + x^T(n)W(n))~~

E(e^2) = E(d^2(n)) - 2E[d(n)x^T(n)] W(n) + W^T(n)E[x(n)x^T(n)]W(n)

↓ P^T ↓ R
skalár és vektor notáció → vektort kapunk
→ az eredmény egy korrelációs vektor P
↓
alló és felső vektor,
négyzetes mátrix mialatt R

E(e^2) = E(d^2(n)) - 2P^T W(n) + W^T(n) R W(n)

mi az optimális beállítás? → előállítjuk a deriváltat (grad. vektor)
∇(n) → W(n) len független változó!
→ milyen vektornak számít? → alló!

∇(n) = -2P + 2RW(n)

keressük az alsó pontot a paraboloidon → ∇(n) = 0
a lényegesebb W* len az optimális beállítás

W*(n) = R^-1 · P Wiener-Hopf egyenlet

az adaptív lin. komb. döntési megoldása

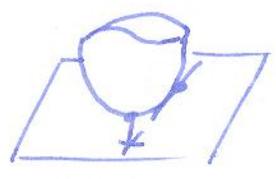
jó!, de csak ha rendelkezésre áll R és P
normál körülmények között csak ritkán, v. közelítőleg.

tanulási eljárás: P- és R- ~~is~~ is súlyfüggvények (w) együttes tanulása!
→ helyettes, mert a tényleg eredmények csak közelítőleg ~~len~~ ismert
→ példamutatóan kell műköltetni P-t és R-t megismerkednek.
Ugy ISMERET!!! → többletinformációk biztosítva mondok többet.
W(n+1) = W(n) + KORREKCIÓ (...) x(n) len ez! iteratíván újabb
→ az adaptív eljárások alapsémája; paraméterbecslőt
allítok elő!

Teljes: jobb inernet vizsgálom a kerábbi lépésben
 beült paraméterek finomítását mutatjuk
 → ebben segítünk lejjel a gradiens
 (a hibafüggvény való mérése)

$$W(n+1) = W(n) - \mu \hat{\nabla} W(n)$$

↳ μ : ballenségi tényező,
 kellő távolsággal, de szaksan kell haladni.



⇒ egy memóriát beült modulálunk. $\hat{\nabla} W(n) = \frac{\partial e^2(n)}{\partial W(n)}$ (standard feltevések)

$e(n)$ -től ut lejjel, hogy

$$e(n) = d(n) - W^T(n) x(n) = d(n) - x^T(n) W(n)$$

$$e^2(n) = (d(n) - W^T(n) x(n))^2$$

deriválás eredménye: $-2e(n) x(n) = \hat{\nabla} W(n)$, a gradiens értéke

$$W(n+1) = W(n) + 2\mu e(n) x(n)$$

primitív, de sok szempontból
 eredményes eljárás.

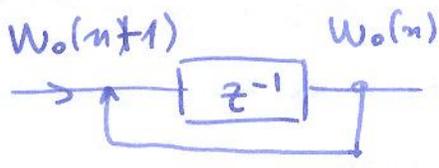
"~~classical~~"

LMS - eljárás

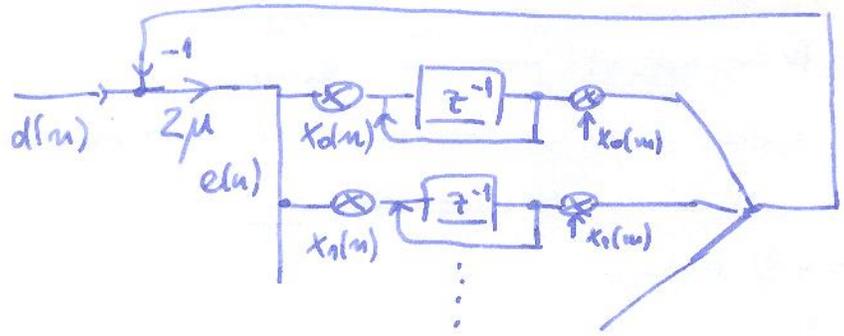
Sok iterációval de eredményesen működik

↳ Least Mean Square.

mindet nagyobb a dimenzió, annál gyorsabb a gradiens.



konkretds fog megalkotni
 ⇒ bejón d(n), ebben
 igazodni kell.



REC. BAZIS BAZIS

$2\mu x(n) \Rightarrow G(n)$
 $x(n) \Rightarrow C(n)$ $\mu = \frac{1}{N}$
 viszonyul a rel. transformációs struktúrájához
 nagy lépés
 konv.

a básony maddentárol
 értékes eredményeket
 lehet juttatni.

végtelen N blokkok (egymás mellett)
 felhalmozásra képes exponenciális
 átlapolással



P-re, R-re és W-re egyenre kell utazni.

Hogyan érhetsz el olyan mértékűvel, mekkor, amikor nem csak W-re utazol, hanem P-re is R-re kapj információkat?

$$W^* = R^{-1} \cdot P \quad E[e^2]_{\min} = E[d^2(n)] - P^T W^*$$

(a paraboloid legalsó pontja a ritkig fejedős értéke)

→ optimális esetben NULLA.

→ ez akkor érhető el, ha az „intézet” megző modell tökéletesen leírja a valóságot. (lecsúszni kell)

$$E[e^2] = E[e^2]_{\min} + \underbrace{(W(n) - W^*)^T}_{\text{optimalis beállításnál 0, innen indul a paraboloid.}} R \underbrace{(W(n) - W^*)}_{V(n)}$$

$E[e^2] = E[e^2]_{\min} + V^T(n) R V(n)$

a kibifelület leírása.

a gradiens:

$$\nabla(n) = 2 R V(n)$$

(a paraméterek függvényében)

→ amikor elyűrt a nulla feltételt, akkor a valóságot értéke a leírás és az x korrelációjával 0, azaz korrelálatlanok (ez az ortogonalitás feltétele)

$$E[e(n) x(n)] = 0$$

A kibifelület R függvénye; ez azt jelenti, hogy a paraboloid különböző irányokban mennyire lapult, azaz h. a gradiens mentén a lépések milyen hatékonysági lehetnek.

h₁ gradiens lapos → hatékonyság nagy
→ " " meredek → " " kicsi

Szerencsés, ha minden par. irányra nézve hasonló a mérték. vagyis, ha az alapvektorok párhuzamos mértékben éj.
→ ez mintén R-ből fakad.

Milyen legyen ez az R?!

$$W(n+1) = W(n) - \mu \nabla(n)$$

a gradiens minden irányokra jó feltevést állítsunk be!

Sajátérték, sajátvektor rendszer: (R vinygalkedő)

$$(R - \lambda I) Q_n = 0 \quad n = 0, 1, \dots, N-1$$

\uparrow \uparrow
 sajátérték sajátvektor

sajátérték: $\det(R - \lambda I) = 0 \Rightarrow \lambda_0, \lambda_1, \dots, \lambda_{N-1}$

$$P[Q_0 Q_1 \dots Q_{N-1}] = [Q_0 Q_1 \dots Q_{N-1}] \text{diag} \langle \lambda_0, \lambda_1, \dots, \lambda_{N-1} \rangle$$

\uparrow
 a sajátértékeket a főtengelyen tartalmazó diagonális mátrix

$$RQ = Q\Lambda$$

$$R = Q\Lambda Q^{-1} \text{ (normálforma)}$$

→ ezen vinygálat eredményeként fogunk becsülni az új a valószínűségi képzőrt.

R tulajdonságai:

• $R = R^T$, azaz szimmetrikus mátrix.

örv ↓ $E[x(n) x^T(n)]$

• a sajátvektorok ortogonálisak.

Biz.: $\left. \begin{matrix} RQ_1 = \lambda_1 Q_1 \\ RQ_2 = \lambda_2 Q_2 \end{matrix} \right\} \Rightarrow \left. \begin{matrix} Q_1^T R Q_2 = \lambda_1 Q_1^T Q_2 \\ Q_1^T R Q_1 = \lambda_2 Q_1^T Q_1 \end{matrix} \right\} R = R^T$

$\lambda_1 \neq \lambda_2 \Rightarrow Q_1^T \cdot Q_2 = 0$ kell, azaz ortogonalitás.

• $V^T R V$ pozitív szemidefinit.
 ⇒ a sajátértékek nemnegatívak.

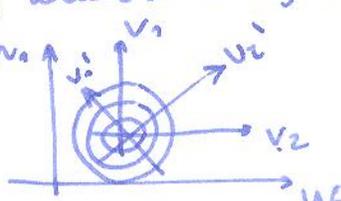
↓ $Q^T = Q^{-1}$

↓ ↓ $E[e^2] = E[e^2]_{\min} + V^T R V = E[e^2]_{\min} + \underbrace{V^T Q \Lambda Q^T V}_R =$

$E[e^2] = E[e^2]_{\min} + [Q^T V]^T \Lambda [Q^T V]$

a hibafelület dtrendezésé.

van olyan koordináta rendszer, amiben a sajátvektorok orientálási tényleg minél.



→ a vinygás koordináta-rendszer a metszések főtengelyeit mutatja ki.

$$\begin{aligned} \nabla(n) &= Z \Lambda V^T = \\ &= Z [x_0 v_0^T(n), \\ &\quad x_1 v_1^T(n), \dots, \\ &\quad x_{N-1} v_{N-1}^T(n)] \end{aligned}$$

A zérushelyre gyűrűk!

→ számítógépi bemutatása

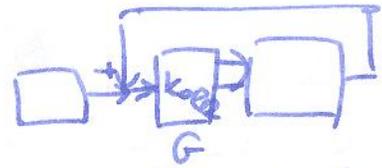
1) Modellkivétel számítógépes programmal

→ autómata diszkrét lin. rendszer

állapotátmeneti mátrix:

$A = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} = \text{diag} \langle 1; -1 \rangle$
↑
csak felületben
kül. 0-1

éricsabalmátrix $C = [1 \quad 1]$



Ért spec. esetet nézzük $\begin{cases} x(u+1) - \hat{x}(u+1) = (A-GC)(x(u) - \hat{x}(u)) \\ \text{cél: } A-GC \text{ gyors kicseréléshez} \\ \text{az eltérést, konst. aktív.} \end{cases}$

- 1.) C vezérelés
- 2.) C nem vezérelés
de: $(A-GC)^N = 0$

itt: a z. esethez milyen G mátrix tartozik?
↳ arányvektor (mivel C sor)

$G = \begin{bmatrix} g_0 \\ g_1 \end{bmatrix}$

Ért célbűség: (stratégia)

- A) $(A-GC)(A-GC) = 0$
- B) sajátérték vizsgálata
 $\det(\lambda I - (A-GC)) = \lambda^2$ kell.

A) : $GC = \begin{bmatrix} g_0 \\ g_1 \end{bmatrix} [1 \quad 1] = \begin{bmatrix} g_0 & g_0 \\ g_1 & g_1 \end{bmatrix}$

$A-GC = \begin{bmatrix} 1-g_0 & 0-g_0 \\ -g_1 & -1-g_1 \end{bmatrix}$

$(A-GC)(A-GC) = \begin{bmatrix} 1-g_0 & -g_0 \\ -g_1 & -1-g_1 \end{bmatrix} \begin{bmatrix} 1-g_0 & g_0 \\ -g_1 & -1-g_1 \end{bmatrix} = \begin{bmatrix} 1-2g_0+g_0^2+g_0g_1 & -g_0+g_0^2+g_0g_1 \\ -g_1+g_0g_1+g_1^2 & g_0g_1+1-g_1-g_1^2 \end{bmatrix}$

mivel eleme!
0 kell legyen

⇒ minden mátrixelemet nullának kell lennie!

$$\left. \begin{aligned} 1 - 2g_0 &= 0 \\ 1 + 2g_1 &= 0 \end{aligned} \right\} \underline{g_0 = \frac{1}{2}} \quad \underline{g_1 = -\frac{1}{2}}$$

$(\lambda I - (A - GC))$

$$\begin{bmatrix} \lambda - 1 + g_0 & g_0 \\ g_1 & \lambda + 1 + g_1 \end{bmatrix} \rightarrow (\lambda - 1 + g_0)(\lambda + 1 + g_1) - g_0 g_1 = \lambda^2 - (1 - g_0)(\lambda - 1) - g_0 g_1$$

$$\lambda^2 + \lambda + \lambda g_1 - \lambda - 1 - g_1 + \lambda g_0 + g_0 + g_0 g_1 - g_0 g_1 = \lambda^2$$

λ^2 -en kívül mindenet nullának kell lennie

$$\lambda(g_0 + g_1) + g_0 - g_1 - 1 = 0$$

elköt:

$$\underbrace{g_0 + g_1 = 0}_{+} \underbrace{- 2g_1 = -1}_{g_0 - g_1 = 1} \rightarrow \underline{g_1 = -\frac{1}{2}}$$

$$2g_0 = 1 \rightarrow \underline{g_0 = \frac{1}{2}}$$

2. Mutaáció

$$A = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$$

$$C = \text{diag} \langle 1, 1 \rangle \rightarrow \text{végsőleges mátrix!}$$

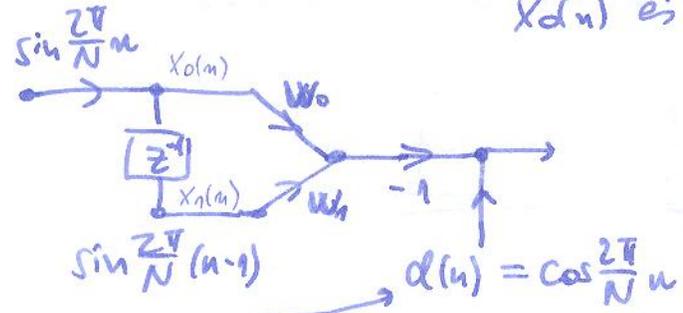
végső állapotban történő kompenzációra vágyunk $B = ?$

[3.] $A = GC$
 $G = A \cdot C^{-1}$ $C = I = C^{-1}$
 $G = A$

~~Kontraktív~~ jellegű mátrixra B -t is lehetne tenni.
 → amit Eiszermatrus, exponenciális jellegű, utólagosan 0-t elkerülően fogható fel.

3) Két értékes lineáris kombinációját

$x_0(n)$ és $x_1(n)$ kombinációjából.



valamilyen jól követésre a feladat

milyen súlytényezőket kell alkalmazni (w_0, w_1 , hogy a cos előjelyen?)

Wiener-Hopf egyenlet: $W^* = R^{-1}P$
(korrelációs mátrixok)

$$P^T = E \begin{bmatrix} d(n)x_0(n) & d(n)x_1(n) \end{bmatrix}$$

valószínűségi értékek, két jól korrelációját tartalmazó

$$R = E \begin{bmatrix} (x_0(n))^2 & x_0(n)x_1(n) \\ x_1(n)x_0(n) & (x_1(n))^2 \end{bmatrix}$$

w_0 és w_1 ?

$$E \left[\cos \frac{2\pi}{N}n \cdot \sin \frac{2\pi}{N}n \right] = 0$$

$$\frac{\sin(2 \cdot \frac{2\pi}{N}n)}{2}$$

(0 a valószínűségi érték)
P első eleme nulla.

$$E \left[\underbrace{\cos \frac{2\pi}{N}n}_\alpha \cdot \underbrace{\sin \frac{2\pi}{N}(n-1)}_\beta \right] \neq 0$$

itt segítségért az argumentumok...

→ trigonometrikus azonosságok

1. $\sin(\alpha + \beta) = \sin\alpha \cos\beta + \cos\alpha \sin\beta$

2. $\sin(\alpha - \beta) = \sin\alpha \cos\beta - \cos\alpha \sin\beta$

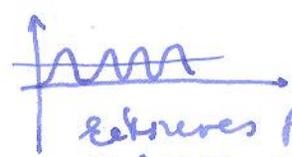
1. - 2. $\Rightarrow \cos\alpha \sin\beta = \frac{1}{2} [\sin(\alpha + \beta) - \sin(\alpha - \beta)]$

$$\frac{1}{2} \left[\underbrace{\sin \frac{2\pi}{N}(2n-1)}_{0 \text{ a valószínűségi érték}} - \underbrace{\sin \frac{2\pi}{N}}_{\text{konstans}} \right] = \underline{\underline{-0,5 \sin \frac{2\pi}{N}}}$$

$$P^T = \begin{bmatrix} 0 & -0,5 \sin \frac{2\pi}{N} \end{bmatrix}$$

Q matrix elemei

$$E[x_0^2(n)] = E\left[\sin^2 \frac{2\pi}{N}n\right] \stackrel{!}{=} \underline{\underline{\frac{1}{2}}}$$


Esközves frekvenciájú
szinusz, maximum 1,
váltakod értéke 1/2.

$$E[x_1^2(n)] = E\left[\sin^2 \frac{2\pi}{N}(n-1)\right] = \underline{\underline{\frac{1}{2}}} \rightarrow \text{ugyanaz!}$$

$$E[x_0(n)x_1(n)] = E\left[\sin \frac{2\pi}{N}n \sin \frac{2\pi}{N}(n-1)\right] = \frac{1}{2} \cos \frac{2\pi}{N}$$

* trigonometrikus
remlék: $\alpha - \beta = \frac{2\pi}{N}$

1.) $\cos(\alpha + \beta) = \cos\alpha \cos\beta - \sin\alpha \sin\beta$

2.) $\cos(\alpha - \beta) = \cos\alpha \cos\beta + \sin\alpha \sin\beta$

2. - 1.: $\sin\alpha \sin\beta = \frac{1}{2} [\cos(\alpha - \beta) - \cos(\alpha + \beta)]$

$$Q = \begin{bmatrix} 0.5 & 0.5 \cos \frac{2\pi}{N} \\ 0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix}$$

~~Q^-1 = ...~~

$$Q^{-1} = \frac{1}{0.125 - 0.125 \cos^2 \frac{2\pi}{N}} \begin{bmatrix} 0.5 & -0.5 \cos \frac{2\pi}{N} \\ -0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix}$$

~~Q^-1 Q = I~~

elemeinek:

$$\frac{1}{0.125 - 0.125 \cos^2 \frac{2\pi}{N}} \begin{bmatrix} 0.5 & -0.5 \cos \frac{2\pi}{N} \\ -0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix} \begin{bmatrix} 0.5 & 0.5 \cos \frac{2\pi}{N} \\ 0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix}$$

$Q^{-1} \quad Q$

~~$Q^{-1} Q = I$~~

$$W^* = R^{-1}P = \frac{1}{0.125 \sin^2 \frac{2\pi}{N}} \begin{bmatrix} 0.5 & -0.5 \cos \frac{2\pi}{N} \\ -0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix} \begin{bmatrix} 0 \\ -0.5 \sin \frac{2\pi}{N} \end{bmatrix} = \begin{bmatrix} w_0 \\ w_1 \end{bmatrix} =$$

$$= \begin{bmatrix} \frac{0.25 \sin \frac{2\pi}{N} \cos \frac{2\pi}{N}}{0.125 \sin^2 \frac{2\pi}{N}} = \frac{1}{\sin \frac{2\pi}{N}} \\ \frac{-0.25 \sin \frac{2\pi}{N}}{0.125 \sin^2 \frac{2\pi}{N}} = -\frac{1}{\sin \frac{2\pi}{N}} \end{bmatrix}$$

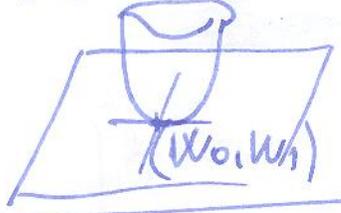
Saleyholypozíció!

Nézzük meg, mit csinál a neuront:

$$\cancel{\sin \frac{2\pi}{N} n} \cdot \frac{\cos \frac{2\pi}{N}}{\cancel{\sin \frac{2\pi}{N}}} + \underbrace{\sin \frac{2\pi}{N} (n-1)}_{\cancel{\sin \frac{2\pi}{N} n \cos \frac{2\pi}{N} - \cos \frac{2\pi}{N} n \sin \frac{2\pi}{N}}} \cdot \left[-\frac{1}{\cancel{\sin \frac{2\pi}{N}}} \right] = \cos \frac{2\pi}{N} \text{ u } \cos \frac{2\pi}{N}$$

$$- \frac{\sin \frac{2\pi}{N} n \cos \frac{2\pi}{N} - \cos \frac{2\pi}{N} n \sin \frac{2\pi}{N}}{\cancel{\sin \frac{2\pi}{N}}} \text{ legiről!}$$

→ kibábkenni, nincs menedéléklika



4. LMS eljárás
van-e esély arra, hogy egytől a többiig
elő R-t is P-t? nincs...
→ határozzuk meg a derivált alapján!

$$\boxed{w(n+1) = w(n) + 2\mu e(n) x(n)}$$

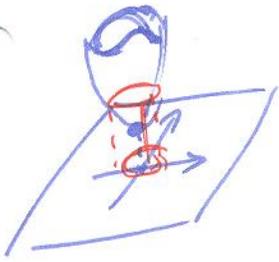
a deriválttal marad. } nézzük meg az előző példára!

$$e(n) = \cos \frac{2\pi}{N} n - w^T(n) x(n) = \cos \frac{2\pi}{N} n - w_0(n) \sin \frac{2\pi}{N} n - w_1(n) \sin \frac{2\pi}{N} (n-1)$$

$$w_0(n+1) = w_0(n) + 2\mu \left(\cos \frac{2\pi}{N} n \cdot \sin \frac{2\pi}{N} n - w_0(n) \sin \frac{2\pi}{N} n \sin \frac{2\pi}{N} n - w_1(n) \sin \frac{2\pi}{N} n \sin \frac{2\pi}{N} (n-1) \right)$$

μ -t általában kisire választjuk, és nevesítjük lefelé hajtott úgymint • 49.

→ sőt értéke általában reális, ha μ tényleg 0 valósággal értéket eredményez \circ -ra



nem tudjuk befejezni?...

5

A gradiens námitata tehát hogyan tudunk csinálni?
 Mi befolygatja a paraboloid formáját?

és sajátérték / sajátvektor?

$\sin \frac{2\pi}{N} \sim$ kicsi

$\cos \frac{2\pi}{N} \sim 1.$

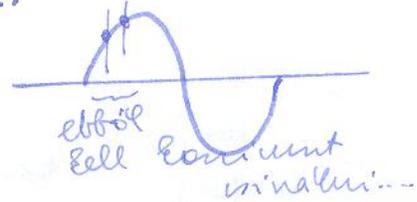
$\frac{2\pi}{N}$ kicsi miúgya kicsi.

$$W = \begin{bmatrix} \cos \frac{2\pi}{N} \\ \sin \frac{2\pi}{N} \\ -1 \\ \sin \frac{2\pi}{N} \end{bmatrix}$$

→ nagy nülgyi értékek
 → nagy nülgyi értékek

$$W \approx \begin{bmatrix} 1 \\ \frac{1}{\sin \frac{2\pi}{N}} \\ -1 \\ \frac{1}{\sin \frac{2\pi}{N}} \end{bmatrix}$$

→ nagy N értékek esetén numerikusán megközelítéssel megközelíthető, jellelhető, ingózkodó megoldat...



$$L = \begin{bmatrix} 0,5 & 0,5 \cos \frac{2\pi}{N} \\ 0,5 \cos \frac{2\pi}{N} & 0,5 \end{bmatrix}$$

Sajátértékek: $\det \begin{bmatrix} \lambda - 0,5 & -0,5 \cos \frac{2\pi}{N} \\ -0,5 \cos \frac{2\pi}{N} & \lambda - 0,5 \end{bmatrix} = (\lambda - 0,5)^2 - 0,5^2 \cos^2 \frac{2\pi}{N} =$

$$= \lambda^2 - \lambda + 0,25 \sin^2 \frac{2\pi}{N} = 0$$

$$\lambda = \frac{1 \pm \sqrt{1 - \sin^2 \frac{2\pi}{N}}}{2}$$

$$= \begin{cases} (1 + \cos \frac{2\pi}{N}) \cdot 0,5 \stackrel{\approx 1}{=} \lambda_0 \\ (1 - \cos \frac{2\pi}{N}) \cdot 0,5 \stackrel{\approx 0}{=} \lambda_1 \end{cases}$$

ha N elég nagy, a cos. kb. egy!

Sajátvektorok

• $RQ_0 = \lambda_0 Q_0$ $Q_0 = \begin{bmatrix} q_{00} \\ q_{01} \end{bmatrix}$

$$\begin{bmatrix} 0.5 & 0.5 \cos \frac{2\pi}{N} \\ 0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix} \begin{bmatrix} q_{00} \\ q_{01} \end{bmatrix} = 0.5 + 0.5 \cos \frac{2\pi}{N} \cdot \begin{bmatrix} q_{00} \\ q_{01} \end{bmatrix}$$

~~$0.5 q_{00} + 0.5 \cos \frac{2\pi}{N} q_{01} = 0.5 q_{00} + 0.5 \cos \frac{2\pi}{N} q_{00}$~~

1. sor

$$\boxed{q_{01} = q_{00}}$$

2. sor ~~$0.5 \cos \frac{2\pi}{N} q_{00} + 0.5 q_{01} = 0.5 q_{01} + 0.5 \cos \frac{2\pi}{N} q_{01}$~~

$$\boxed{q_{00} = q_{01}}$$

• $RQ_1 = \lambda_1 Q_1$ $Q_1 = \begin{bmatrix} q_{10} \\ q_{11} \end{bmatrix}$

$$\begin{bmatrix} 0.5 & 0.5 \cos \frac{2\pi}{N} \\ 0.5 \cos \frac{2\pi}{N} & 0.5 \end{bmatrix} \begin{bmatrix} q_{10} \\ q_{11} \end{bmatrix} = 0.5 - 0.5 \cos \frac{2\pi}{N} \begin{bmatrix} q_{10} \\ q_{11} \end{bmatrix}$$



$$\boxed{q_{10} = -q_{11}}$$

ortogonalitás?

$$Q_0 = \begin{bmatrix} q_{00} \\ q_{00} \end{bmatrix}$$

$$Q_1 = \begin{bmatrix} q_{10} \\ -q_{10} \end{bmatrix}$$

$$Q_0^T Q_1 = \begin{bmatrix} q_{00} & q_{00} \end{bmatrix} \begin{bmatrix} q_{10} \\ -q_{10} \end{bmatrix} =$$

$$= q_{00} q_{10} - q_{00} q_{10} = \underline{\underline{0}}$$

a sajátvektorok ortogonalitása igazolható.

transzformáció is megfeleltetés: (tetszőleges R mátrixot rá lehet transzformálni)

$$Q = [Q_0 \ Q_1]$$

hogyan tudjuk a Q mátrixot normalizálni?
(egyszerű normalizáció nem jár használati)
összefoglaló módon egyszerűen ad)

$$Q Q^T = \begin{bmatrix} q_{00} & q_{10} \\ q_{00} & -q_{10} \end{bmatrix} \begin{bmatrix} q_{00} & q_{00} \\ q_{10} & -q_{10} \end{bmatrix} = \begin{bmatrix} q_{00}^2 + q_{10}^2 & q_{00}^2 - q_{10}^2 \\ q_{00}^2 - q_{10}^2 & q_{00}^2 + q_{10}^2 \end{bmatrix}$$

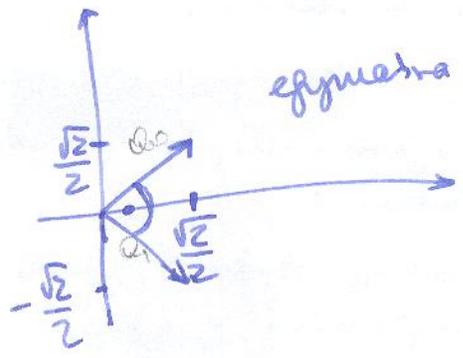
ha $q_{00} = q_{10}$, akkor jelölt elemet 0.4 lemelet

$$Q Q^T = \begin{bmatrix} 2q_{00}^2 & 0 \\ 0 & 2q_{00}^2 \end{bmatrix} = I \text{ eell.} \\ (Q^{-1} = Q^T \text{ -hez})$$

$$2q_{00}^2 = 1 \Rightarrow \underline{\underline{q_{00} = \frac{\sqrt{2}}{2}}}$$

$$Q = \begin{bmatrix} \sqrt{2}/2 & \sqrt{2}/2 \\ \sqrt{2}/2 & -\sqrt{2}/2 \end{bmatrix}$$

\downarrow Q_0 \downarrow Q_1



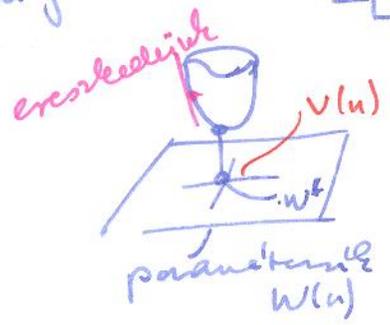
egymásra merőleges vektorok.

$$\left. \begin{aligned} \lambda_0 &= 0.5 \left(1 + \cos \frac{2\pi}{N} \right) \\ \lambda_1 &= 0.5 \left(1 - \cos \frac{2\pi}{N} \right) \end{aligned} \right\} \rightarrow N \text{ bdmellőndőre váltás lehetséges!}$$

\hookrightarrow a sajátérték még leoldozza, a sajátvektor már nem!

hova jöttünk?

$$E[e^2(u)] = E[e^2(u)]_{\min} + \underbrace{(w(u) - w^*)^T}_{\text{a paraboloid alsó partján alatti távolság}} \underbrace{E[w(u) - w^*]}_{\text{a paraboloid leírása}}$$



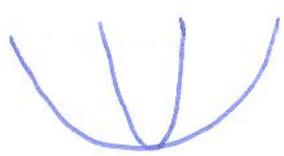
ha becsenélünk w^* beállításra, a maradék tag 0.

\rightarrow az optimum keresésénél gradiens módszerrel kell. (denitált esetben szűlyedő függvény)

\rightarrow hogyan függ az keresztelés a paraboloid geometriájától?

\rightarrow keskeny ellipszis metszést produkál, ha előtér a sajátérték

\rightarrow kör lesz, ha a sajátérték egyformán



} más-más keresztelési lehetőség: szatoron, ha meredek; szőnyeg, ha lapos

Pontszámítás:

HF1	40
ZH1	40
HF2	40
ZH2	40
<hr/>	
Σ	160 pont.

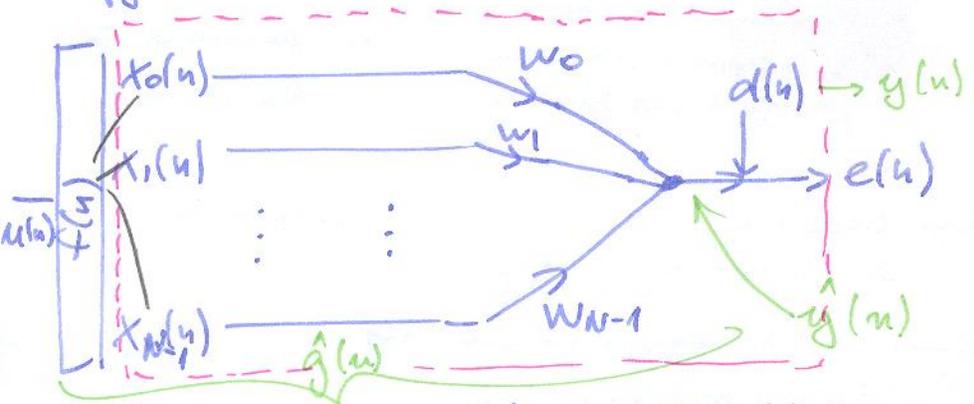
- 40 pontes rendszerre normalva
- 0-15 ① nem jó
 - 16-20 ② éppen jó
 - 21-25 ③ kicsit jobb
 - 26-31 ④ már elnevez
 - 32-40 ⑤ én is kelkes vagyok

A zh-é megírása követelmény.

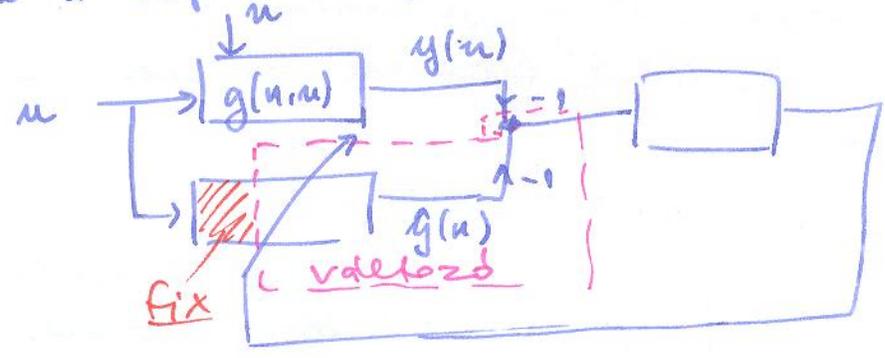
Nagy dráma, hogy igazán nem kell némtani.
 Bevezetés dolgot eljuttatni megírni a zárthelyet.
 (Formálisán pótolni kell.)

- ZH :- az eddig elhangzottakból kisebb létszámú és feladatból
- a nagyobb célrendszer felé
 - meredek feladatokat részre bontva a hatásosság;
 - körül 60 perc, létszámú a levezetés.
 - előtte válsághelyzet levezetése

A cell, hogy a lineáris kombinációval nevezett némtant egy értékesítést követni éppen éppen



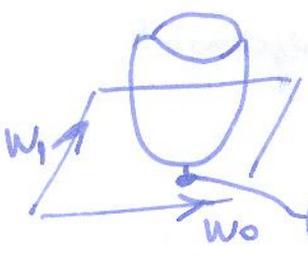
hasznos a regresszió problémákra



ez emel az interpretációját

A kupa négyzetű a vázlatok dőléket minimalizálja,
és a változathatóságot jellemző négyzetes függvény.

(Eredetileg lineárisan reprezentálható.)



ezen a paraboloid felületen mozog
Értékfüggő $W(u)$ beállításival

(w_0^*, w_1^*)
optimális

ha ettől bármilyen irányba meglökünk,
a kupa magasabb lesz,
a paraboloid felületére meg a mélységet

Hogyan jön ide a sajátvektor / sajátérték probléma?

$$R = Q \Lambda Q^{-1} = Q \Lambda Q^T$$

↑
1-re normáltuk

all.: az R mátrix helyett használhatunk olyan
mátrixot, aminél csak a főátlóban vannak elemek

$$\Lambda = \begin{bmatrix} 0.5 \left(1 + \cos \frac{2\pi}{N}\right) & 0 \\ 0 & 0.5 \left(1 + \cos \frac{2\pi}{N}\right) \end{bmatrix}$$

$$\boxed{Q^{-1} R Q = \Lambda}$$

→ az elemeket átadjuk
mindenkori figyelembe

A négyzetes kifejezés másfajta felírása:

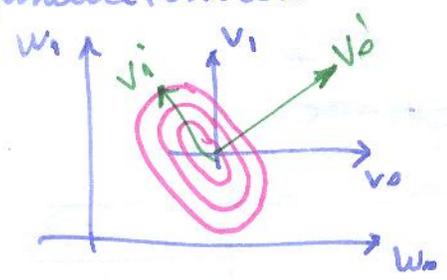
$$V^T(u) R V(u) = \underbrace{V^T(u) Q}_{V^T(u)} \Lambda \underbrace{Q^T V(u)}_{V(u)} = V^T(u) \Lambda V(u)$$

u_j paraméterezés kifejezés!

$$V(u) = Q^T V(u)$$

$$V^T(u) = V(u) Q(u)$$

ha R kizárólag diagonális elemet tartalmaz, akkor változás
a paraméterezésben



elforgatott koordináta
rendszerben - vagyis a
transzformáció elővetítésben

Az elfogadott koordinátarendszerben a ~~paraboloid~~ "irányai" = "fő mérték irányok".

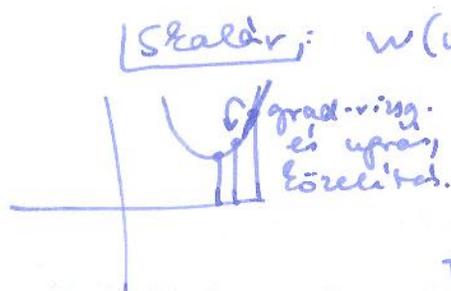
A végső hibafüggvény minimalizálását ezen, megadott mellett célszerű el... → a derivált a V' szerint végezni!

a gradiensvektor $\nabla(u) = 2 \cdot \Delta V'(u)$

$$\nabla(u) = 2 \cdot \Delta V'(u) = [2 \cdot \lambda_0 v_0'(u) \quad 2 \cdot \lambda_1 v_1'(u) \quad \dots]^T$$

A problémát egyszerűsítve, 1D-re redukálva:

(az aktuális par. becslést úgy korrigáljuk, hogy a kisebb hibairányba megy)



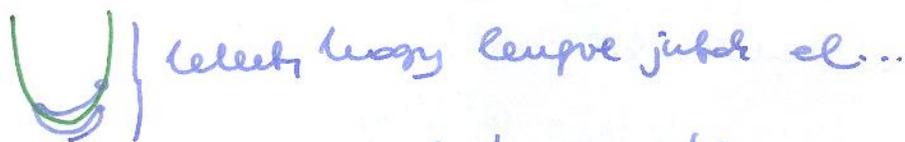
a deriválttal ellentétes irányban lépünk valamelyként

$$\nabla(u) = 2\lambda (w(u) - w^*)$$

$$w(u+1) = w(u) - 2\mu\lambda (w(u) - w^*) = w(u)(1 - 2\mu\lambda) + 2\mu\lambda w^* = w^* + (1 - 2\mu\lambda)^{u+1} (w(0) - w^*)$$

$$\underbrace{w(u+1) - w^*}_{V(u+1)} = \underbrace{(1 - 2\mu\lambda)^{u+1}}_{\text{szorzó}} \underbrace{(w(0) - w^*)}_{V(0)}$$

hogyan történik az iteráció? egyre kisebb "lépések" pontosabban



→ minél több iteráció, annál nagyobb épség.

→ a legjobb stratégia a konvergencia tény. megval. fgv.-e. konvergenst ellenőrizni!

a hiba azonnal eltűnik, ha ~~$1 - 2\mu\lambda = 0$~~

$$1 - 2\mu\lambda = 0 \Rightarrow \mu = \frac{1}{2\lambda}$$

kritikusan állapított.

- ez a kritikusan csillapított ugrás.
- ha rögtön leereszted, az túlcillapított.
- ha ide-oda, akkor ~~le~~ alulcsillapított lengő

$$\frac{1}{2\lambda} < \mu < \frac{1}{\lambda} \text{ alulcsillapított.}$$

$$0 < \mu < \frac{1}{2\lambda} \text{ túlcillapított.}$$

éiméj: $|1 - 2\mu\lambda| = |r| < 1$, akkor ez konvergen.

Az skalárna is látni, hogy a sajátérték összefügg μ -vel.

Magasabb dimenzióra:

$$V'(n+1) = [I - 2\mu A]^{n+1} V'(0) \quad *$$

arra vágyunk, hogy a paraméterekbe csökkenjen.
 A megfelelő sajátértékek körül a legrapesebbat kell választani,
 ami korlátosra μ választási tartományát. (?)

$$0 < \mu < \frac{1}{\lambda_{\max}}$$

$0,5 + 0,5 \cos \frac{2\pi}{N} \sim 1$
 volt ez a példánkban.
 (a mátrix nagy inverzelet.
 tartományt hagyhat.)

R és P mátrixnal kapcsolatos ismereteink?

$R = ? \quad P = ?$

$$\sum_{n=0}^{N-1} \lambda_n = \text{tr}[R]$$

trace, nyomon
 a főátlóban lévő elemek
 összege

~~ha nem~~ ha nem ismert, a stratégia:

$$0 < \mu < \frac{1}{\text{tr}[R]}$$

A főátló meghatározása nem rendkívül nehéz.

$$R = \begin{bmatrix} 0,5 & \dots \\ \dots & 0,5 \end{bmatrix} \Rightarrow \text{tr}[R] = 1$$

(ezt kellett alaposan
 összeírni, hogy μ -t
 éppen kiirtott
 választáshoz)

Ha a sajátértékkel nem rendelkező, nagyjából
gyfunda, akkor a tr. m. a megjelölésen durva.

→ ezzel az eszközzel jó nagy tempót adunk,
is felgyorsítva a beállást (?)

→ sok ilyen praktika van, mind több info van
R-völ is P-völ, annak jobb.

- állapotfigyelés
 - *
 - rekurrens transzformáció
- } hibaelhárítási öreklési matematik
 rezonancia gennyil töltés
 ↓
 megérzik LMS eljárás esetére

LMS: $w(n+1) = w(n) + 2\mu e(n) x(n)$

$e(n) = w^{*T} x(n) - w^T(n) x(n)$ → az optimális eset
 → a helyes

$e(n) = w^{*T} x(n) - w^T(n) x(n) = x^T(n) [w^* - w(n)]$

bevezetett értékek elbárállható (x):

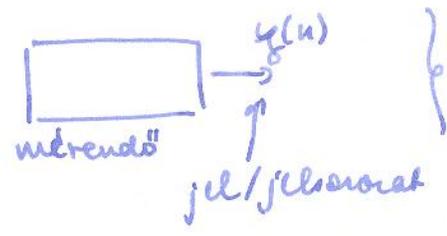
$$V(n+1) = \prod_{i=0}^n \left(I - 2\mu x(i) x^T(i) \right) V(0)$$

→ ez olyan kifejezés, mint amivel a rekurrens transzformáció
idején beállhatunk

- plendis írás, összefoglalás, ráhangolódás
- hatásosság első fele
- hatásosság második fele

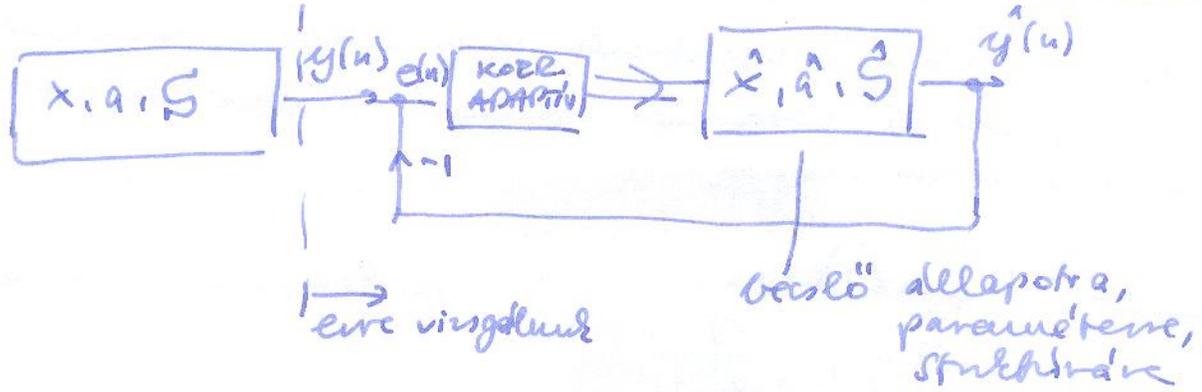
2 két művelet: az adaptív eljárás az az adaptációval
polarizációnal adaptált is lehet.

Összefoglalás az első hat letről - ZH előtt



hogyan használható fel y , hogy a belvillaggal kapcsolatba kerüljünk?

számítógépes pr., ami y -val kapcsoló működést produkál



három fontos vetület:

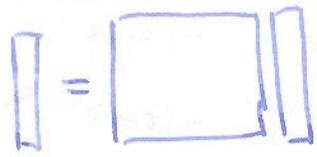
1: Lehetséges követni azt a gondolatmenetet, hogy a működő jel önálló katasztrófa, aktivitások összefüggés áll elő

⇒ ph.-soros átalakítás



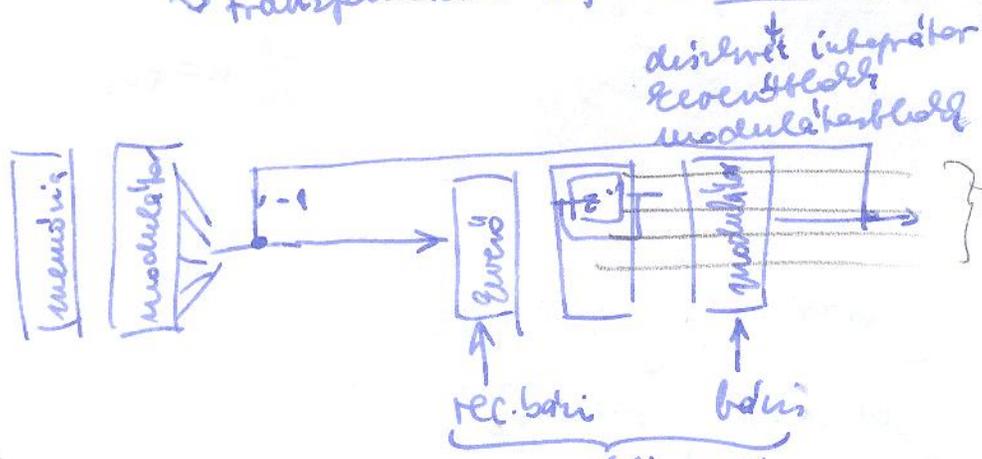
transzformációkat értelmezés

hogyan rajzolható ez folyamatosan, az idő végtelg? → csúszóablak, mindig az utolsó N



CSÚSZÓABLAKOS FELFELDOLGATÁS mindig az utolsó N mintá alapú kapunk becslet.

transzformációs eljárást, rekurzív számítással.



digitális integrátor, keveréskor modulátorból

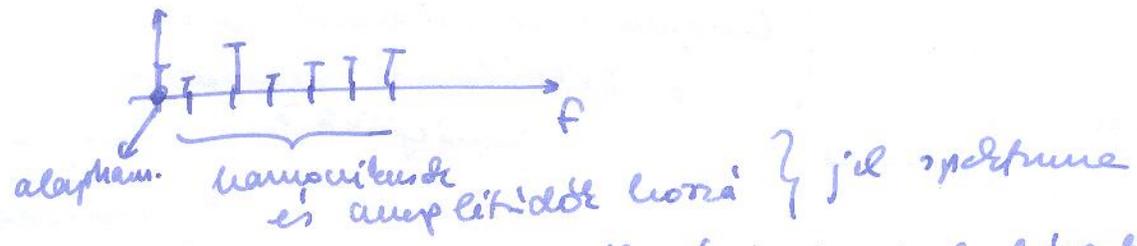
összeadó gép, minden iramára egy darab

kiolvasás

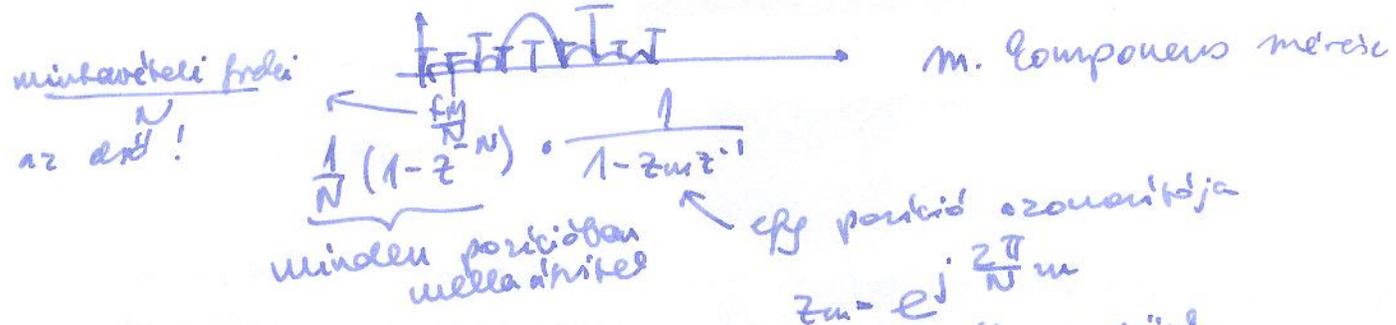
~~z^-N~~ ⇒ egy ablaknyi képletelés

⇒ a memóriából kiolvasható az adatok.

2. Ha szűrszábles, interpretálható művelet.
 → diszkrét frekvenciák DFT



⇒ Elvéri helyett az amplitúdó is meghatározható, hogy egy konkrét frekvencián átfedő művelet használunk (ami a többi elvon)



$$\frac{1}{N} (1 - z^{-N}) \cdot \frac{1}{1 - z_m z^{-1}}$$

minden pontidőben melládrítel

egy pontidő oszorosítója
 $z_m = e^{j \frac{2\pi}{N} m}$
 ⇒ itt átfedésül

$$1 - z^{-N} = \prod_{n=0}^{N-1} (1 - z_n z^{-1})$$

→ ahol $m=n$, kiesik, átfed.

előadás: $H(z) = \frac{1}{N} (1 - z^{-N}) \frac{1}{1 - z_m z^{-1}}$

↳ abszolút & fázis?

$$H(z) = \frac{1}{N} \frac{(z_m z^{-1})^{\frac{N}{2}} [(z_m z^{-1})^{-\frac{N}{2}} - (z_m z^{-1})^{\frac{N}{2}}]}{(z_m z^{-1})^{\frac{1}{2}} [(z_m z^{-1})^{-\frac{1}{2}} - (z_m z^{-1})^{\frac{1}{2}}]} \stackrel{K}{=} \dots$$

$$(z_m z^{-1})^{\frac{N}{2}} \cdot (z_m z^{-1})^{\frac{N}{2}} = z_m^N (z^{-1})^N = 1 z^{-N}$$

$$z_m z^{-1} = e^{j \frac{2\pi}{N} m} \cdot e^{-j\omega T} = e^{-j(\omega T - \varphi_m)}$$

$$\frac{2\pi}{N} m = \varphi_m$$

$$T = \frac{1}{f_m}$$

$$* = \frac{1}{N} (z_m z^{-1})^{\frac{N-1}{2}} \frac{e^{j(\omega T - \varphi_m) \frac{N}{2}} - e^{-j(\omega T - \varphi_m) \frac{N}{2}}}{e^{j(\omega T - \varphi_m) \frac{1}{2}} - e^{-j(\omega T - \varphi_m) \frac{1}{2}}}$$

abszolút $\frac{1}{N}$

$$\left| \frac{\sin \frac{N}{2} (\omega T - \varphi_m)}{\sin \frac{1}{2} (\omega T - \varphi_m)} \right|$$

kis értékre $\sin x \sim x$

⇒ $N \cdot \frac{1}{N} = 1$ egyenlő az m . komponensül.

→ ez a Lagrange-interpolációs technika volt:

fgv. közelítés speciális polinonnal
(ami egy érvetelenül nulla átviteli)

Sűrűtövevényi eljárás: úgy kell működtetni, hogy a $\sum_{n=-\infty}^{\infty} x(n) \delta(n-k)$ generáljuk a kombinációs technikát.

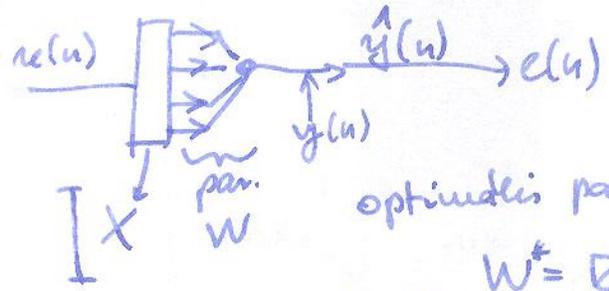
→ ennek végrehajtására egy olyan művelet, amivel meg tudom mondani ki: $x \frac{f(n)}{N}$ -re, hogy mennyi legyen frekvenciaamplitúdó eljárási

3. Modellidentifikáció

alapteret 1.,-gyel megegyezős, de itt abban utazunk, hogy egy meghatározott modell és a szabad paraméterek (kereslet)

→ elegendő megfigyelni a valódi adatot.

→ lineáris kombinátor (ha érvetelenre lépés, akkor adaptív)



optimális paraméter:

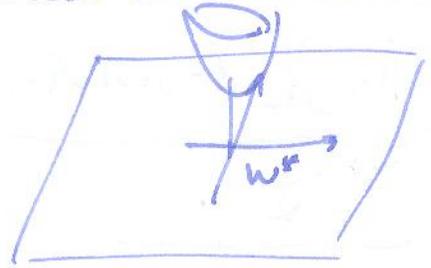
$$R = E \begin{bmatrix} x_0^2 & x_0 x_1 & \dots & x_0 x_{N-1} \\ x_0 x_1 & x_1^2 & \dots & x_1 x_{N-1} \\ \vdots & \vdots & \ddots & \vdots \\ x_0 x_{N-1} & x_1 x_{N-1} & \dots & x_{N-1}^2 \end{bmatrix}$$

szimmetrikus

$$W^* = R^{-1} P$$

$x(n)$ komponensek és $y(n)$ korrelációja
 $P = E \begin{bmatrix} y(n) & x(n) \end{bmatrix}$

→ helyettesítve követő tulajdonságokra hivatkozva helyettesítve minimalizálásra lépés ezekéll



W^* : legkisebb értékű illenkedés (a paraboloid mélypont)

ZH. 1.

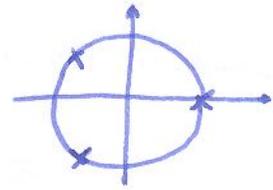
DFT $N=3$ -ra

$e^{j \frac{2\pi}{N} m n}$
 ↑
 "frekvencia"
 hányados? konst.
 ↓
 diszkrét idő

$m=0,1,2$
 $n=0,1,2$

$m=0 \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$

$m=1 \begin{bmatrix} 1 \\ e^{j2\pi/N} \\ e^{j2\pi/N \cdot 2} \end{bmatrix}$



120 fokos elv' per.

$m=2 \begin{bmatrix} 1 \\ e^{j2\pi/N \cdot 2} \\ e^{j2\pi/N \cdot 2 \cdot 2} \end{bmatrix} = \begin{bmatrix} 1 \\ e^{-j2\pi/N} \\ e^{j2\pi/N} \end{bmatrix}$ $m=1 \rightarrow \begin{bmatrix} 1 \\ e^{j2\pi/N} \\ e^{-j2\pi/N} \end{bmatrix}$

balosrendszer $\begin{bmatrix} 1 & 1 & 1 \\ 1 & e^{j2\pi/N} & e^{-j2\pi/N} \\ 1 & e^{-j2\pi/N} & e^{j2\pi/N} \end{bmatrix}$

↳ együttes!

reciprokális $\frac{1}{3} \begin{bmatrix} 1 & 1 & 1 \\ 1 & e^{-j2\pi/N} & e^{j2\pi/N} \\ 1 & e^{j2\pi/N} & e^{-j2\pi/N} \end{bmatrix}$
 ↑
 normálás!

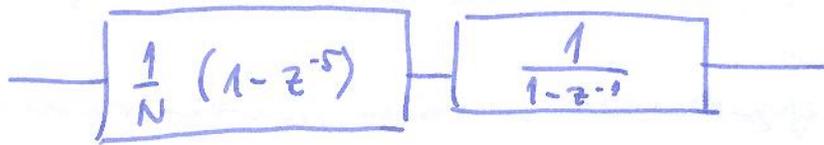
$\sum \begin{bmatrix} | & | & | \end{bmatrix} + \begin{bmatrix} | & | & | \end{bmatrix} + \begin{bmatrix} | & | & | \end{bmatrix} = I$

$\underbrace{[I - g(0)c^T(0)] [I - g(1)c^T(1)] [I - g(2)c^T(2)]}_{=0} = 0$

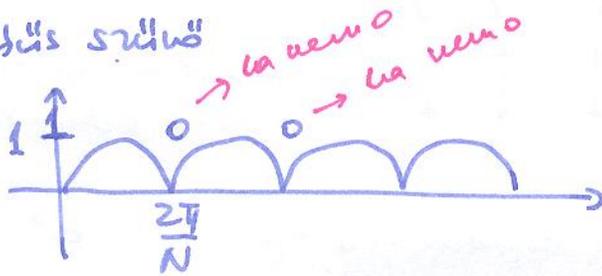
$I - \sum_{i=0}^2 g(i)c^T(i) + \underbrace{\quad}_{=0}$

$I \quad (eB \cdot B = I)$

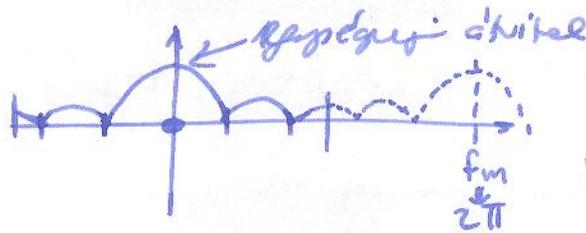
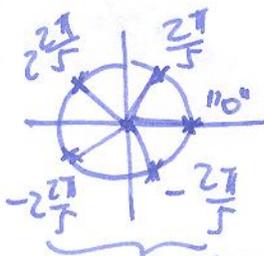
ZH.2. Laplace - interpolációs változat



Cél: a felülis szűrés



N=5

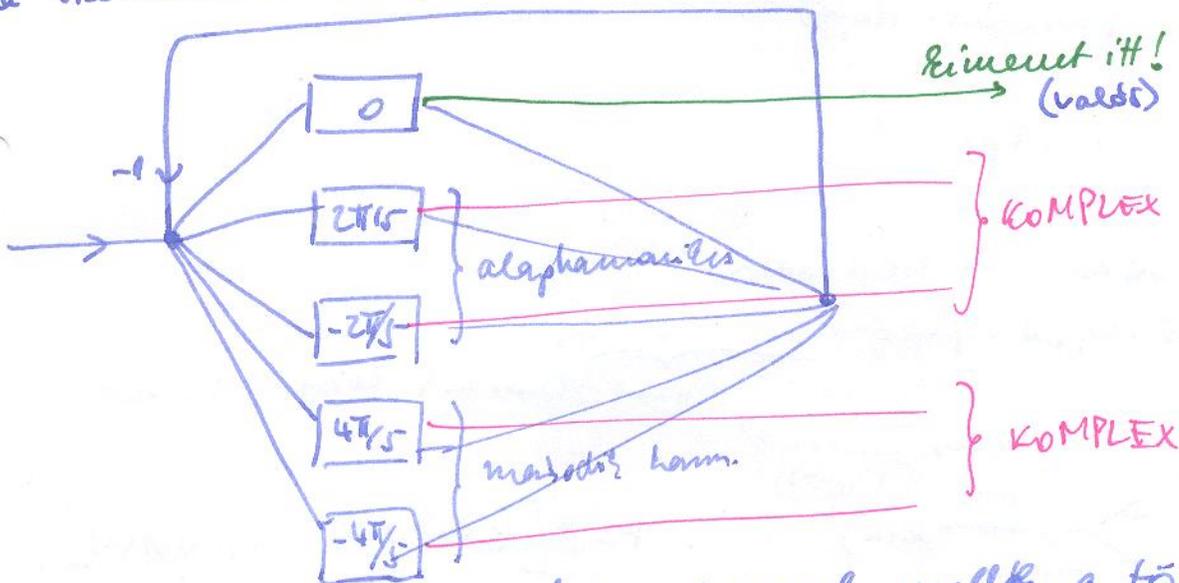


amplitúdóval:

$$\frac{1}{5} \frac{1 - z^{-5}}{1 - z^{-1}} \xrightarrow{\text{lecsúszás}} \frac{1}{5} \left| \frac{\sin \frac{5}{2} \omega T}{\sin \frac{1}{2} \omega T} \right|$$

a mintavételi frekvenciákat (π) valamit ahhoz...

ha visszacsúsztatva elnyújtással, sokkal redőndősebb



ha minsemit nullk, a többi dőtel is kicapatelhető megfelelő súlyozással;

(itt ez a nyíralgósítás HILkomplitot.)

1. feladat - transzformálások!

$1 ; 1+j ; 1-j \rightarrow$ mi a desired időfüggő?

a sorjatis együtthati a balis / jobbais rendszerben

$n=0 \quad e^{j \frac{2\pi}{3} \cdot 0 \cdot n} \quad \begin{matrix} 1 & 1 & 1 \\ \uparrow & \uparrow & \uparrow \end{matrix} \Rightarrow$ 1 amplitúdójú DC \rightarrow selytdug: 1

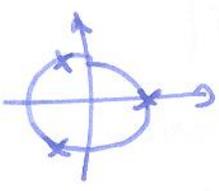
$n=1 \quad e^{j \frac{2\pi}{3} \cdot 1 \cdot n} \rightarrow$ selytdug: $1+j$ $e^{j \frac{2\pi}{3} n} (1+j)$

$n=2 \quad e^{j \frac{2\pi}{3} \cdot 2 \cdot n} \rightarrow$ selytdug: $1-j$ $e^{-j \frac{2\pi}{3} n} (1-j)$

időfüggő: a kívánt dolog serege

$$1 + e^{j \frac{2\pi}{3} n} + j e^{j \frac{2\pi}{3} n} + e^{-j \frac{2\pi}{3} n} - j e^{-j \frac{2\pi}{3} n} =$$

$$1 + 2 \cos \frac{2\pi}{3} n - 2 \sin \frac{2\pi}{3} n$$



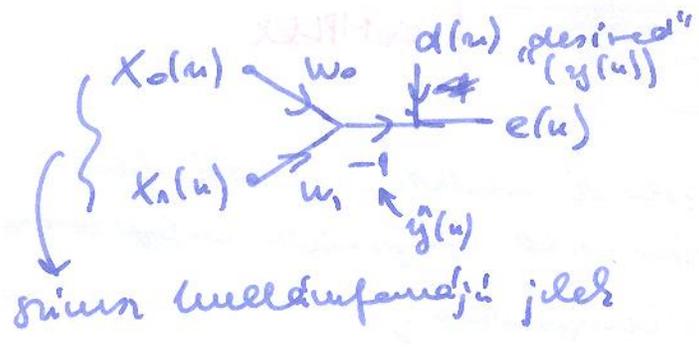
3. feladat (Wiener-Hopf)

$W = D^{-1} P \quad (5p)$

Wanted's

Egyenletet vizsgálhatunk felírhatunk?

\rightarrow 2 selytdugozás: W_0 és W_1
 ezzel leírhatjuk a beoszt



$P = E \begin{bmatrix} x_0(n) d(n) & x_1(n) d(n) \\ x_0(n) x_0(n) & x_0(n) x_1(n) \\ x_1(n) x_0(n) & x_1(n) x_1(n) \end{bmatrix}$

$D = E \begin{bmatrix} x_0^2(n) & x_0(n) x_1(n) \\ x_1(n) x_0(n) & x_1^2(n) \end{bmatrix}$

kor-matrixok \rightarrow elvárták min.

feladat: megoldat:

$$E[x_0(n) x_1(n)]$$

a felismerésről az argumentumok kiértékelésével kezdjük

$$0,5 \cos\left(\frac{4\pi}{N}\right) \Rightarrow 2 \text{ minta}$$

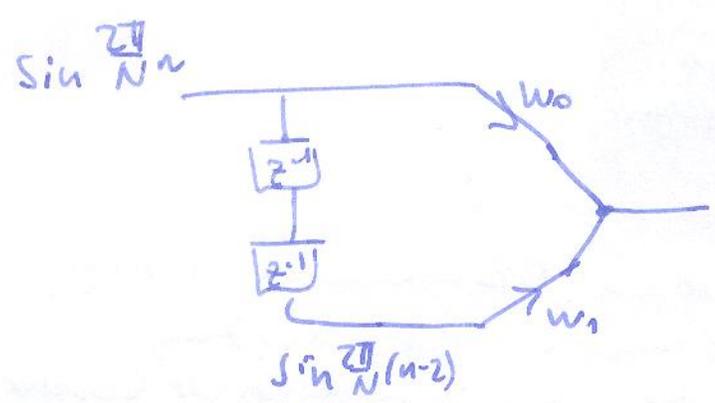
örv $\cos \frac{2\pi}{N} \Rightarrow 1 \text{ minta}$

$$\sin \frac{2\pi}{N} n \quad \leftarrow \text{Egyszerűsített felírás}$$

$$\sin \frac{2\pi}{N} (n-1) = \sin \frac{2\pi}{N} n - \sin \frac{2\pi}{N}$$

$$\sin\left(\frac{2\pi}{N} n - \frac{4\pi}{N}\right) = \sin \frac{4\pi}{N} (n-2)$$

2 mintavétel!



$$w_0 \sin \frac{2\pi}{N} n + w_1 \sin \frac{2\pi}{N} (n-2)$$

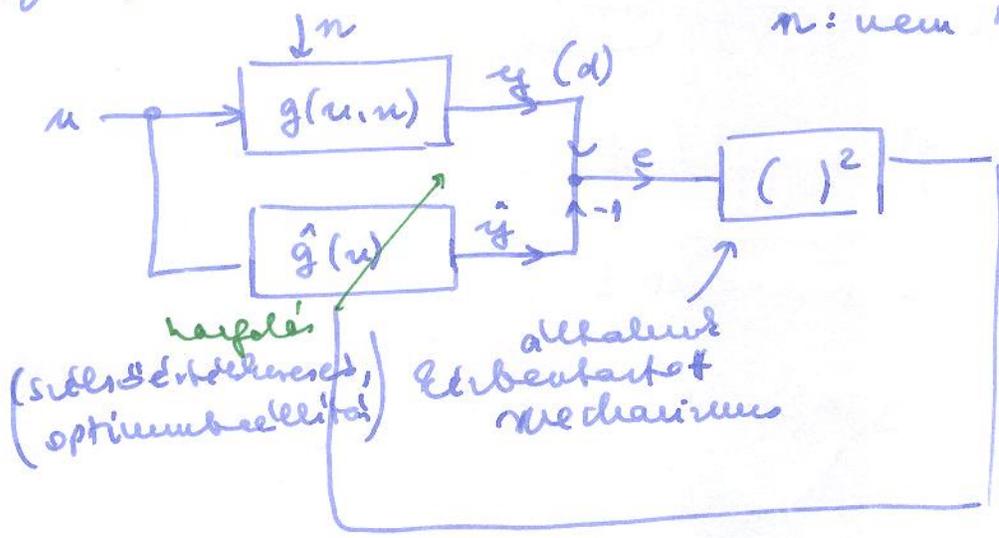
analitikus helyettesítés

konjugált alakban, az örvi megacisja!

adaptív - követőképendő, azaz működés közben is "identifikációs" is működés

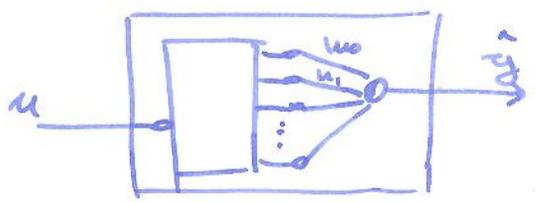
↳ mindkettő sokszor egybeesik, iteratív, tanulós eljárás, nemivites a regressziós feladat alapfeladata; erre hívjuk rá a modellillesztés ma adaptív technikákat tekintünk át, mindkettő van van többletfejtés, ami hatékonyabbá teszi eredményez.
 → a többletfejtés módosít, mat. és intuitív elemeket hoz be
 → az alap gondolat uaz. (regresszió)

fgv. tapasztalat leírása:



megj: párhuzamos referencia (Eimermetek illentare)
 soros referencia (beamermetek illentare)
 ↳ ilyen beábrakéntek követel r y
 ↳ az problémák, utána all.

További példa: $\hat{g}(u)$ általánosítása → két rész
 ↳ fix érték (akár több érték párhuzamos)
 ↳ lépés lin. komb.



dekor: fgv. tapasztalat (akár nem is)
 • u hatékonyan épülhet fel
 • beállítási elemekkel

↳ paraméterben lineáris állítás. → utáprates → deriv. → lineáris!

analitikus megoldás értéke a Wiener-theorf epelet •65.

→ a P és az R mátrixok } teljes ismeretük tipikusan
↓
Eredekorelatió } illuzorikus, részleges
ismerete részleges
eredményt ad!

mi legyen a stratégia a beállításokor?

↳ adaptivitás, iteratív eljárás

$$W(n+1) = W(n) - \mu \nabla(n)$$

menyiben konvergencia a vektor?

hogyan monogoni?

hogyan hat. meg a ∇ és a μ ?

elemi vektorok \mathbb{R} ismerete mellett.

pl. 2×2 mátrix

$$\begin{bmatrix} 1 & 0.9 \\ 0.9 & 1 \end{bmatrix}$$

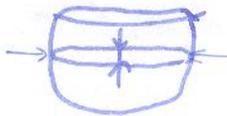
→ a két oszlopa jelle erős korrelált (0.9)

⇒ ennek sajátértékei rendszeren elhelyez

1.9 és 0.1

{ a paraboloid jól elválasztott lesz!
→ az eredmény irányműködés, nem trív.

a sajátérték sajátvektor ismeretében mátrix
koordinátarendszerbe helyrehozható!



ha nem ismert P és R, akkor is előfordulhat nagy
korreláció → modellbecslés: a cél a legjobb

száma kialakítása, melyben nincs a korreláció

⇒ először a sajátértékek bölcsebb kivétel
(a sajátértékek + köv. lépés)

mit lehet tenni? variáció!

① - (praktikus) LMS eljárás

→ nélkülöz a pillanatnyi hibát, ennek vezérsz. kifejezésével
deriváltját vektor alapul az előrehaladatlal

$$\text{LMS: } \underset{[N]}{W(n+1)} = \underset{[N]}{W(n)} + \underbrace{2\mu}_{\text{skalar}} \underset{[N]}{e(n)} \underset{[N]}{X(n)}$$

hibakifejezés:

$$V(n+1) = \left[\prod_{i=0}^n \left[I - 2\mu \underbrace{x(i) x^T(i)}_{\text{rec. bázis}} \right] \right] V(0)$$

W akt. értéke
- optim. értéke

rec. bázis
"BÁZIS"
o. időpill. paraméterek
→ analógia!

$$\begin{aligned} \left[\det(A-GC)^n \right] &= 0 \\ \prod (I - g(i)c^T(i)) &= 0 \end{aligned}$$

→ hatékonyabbá térdőjelen; nem nevezetes nagy μ alkalmazásra

2. α - LMS módszer

→ ezt próbálják megfogadni; hogy x értéke néhéz
feltételekben változhat \Rightarrow a konvergenz. viszonyok
konstans bázisú paraméterértéket pontos x függvényében
(az idő előrehaladtával egyre kisebb perturbáció)
→ jó lenne ezt villantani \rightarrow normalizálás!

→ az x hosszára normalizálunk

$$W(n+1) = W(n) + \alpha \frac{e(n) x(n)}{x^T(n) x(n)}$$

skalár, hossza
normál

elkor a paraméterek:

$$V(n) = \left[\prod_{i=0}^n \left[I - \underbrace{\frac{\alpha}{x^T(i) x(i)}}_{2\mu \text{ helyett}} x(i) x^T(i) \right] \right] V(0)$$

μ nem konstans, x hosszával van kapcsolatban
 \Rightarrow a produktum a konvergenz hatás érdekében van
(minél kisebb hibájú állapot)

3. R inverz (felbontás) \Rightarrow Newton-módszer

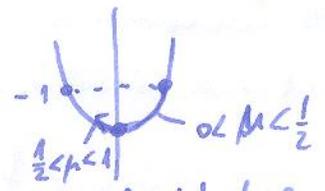
Wiener-kepf: $W^* = R^{-1}P$ $\nabla = 2RW - 2P$
 $W - W^* = \frac{1}{2} R^{-1} \nabla$

$$W^* = W - \frac{1}{2} R^{-1} \nabla$$

→ kiindulás a derivált iterációs eljárásra vonatkozóan!

$$W(n+1) = W(n) - \left(\frac{1}{2}\right) R^{-1} \nabla W(n)$$

μ - a bármelyi hely. bevezetésrel fixamittűs
 $\mu = \frac{1}{2}$ optimális, de
 $0 < \mu < 1$ lehet.



- pont jó helyre ($\mu = \frac{1}{2} \rightarrow 1$ lépés)
- tillendülésként (pl. ha $\mu = 1$: nemörvki oldal)
- erenkedés ($\mu < \frac{1}{2}$)

$$W(n+1) = W(n) - \mu R^{-1} \nabla W(n)$$

paraméterek: $V(n+1) = (1 - 2\mu)^n V(0)$

~~titok~~ tirta beadt: $\mu = \frac{1}{2}$ egy lépés!

egytrre uford / erenkedés.

! ez feltételezi az R inverzét, is ∇ adott értékek tartozás beállítást!

Σ : visszanyúl az előreltekeltetés, azaz hogy R inverz uonemur...

(2. hf. nek keltékompágnizsgálatok lesz)

Alogy a paramétereket elődeltjük, R -re is végzetünk bevezetést: $E(x(n) x^T(n))$ } ha összerpjtjük a diagonális elemeket, a legkisebbel előzdjük becsülni (erre matr van rekurrens technika)

$$W(n+1) = W(n) + 2\mu \underbrace{R^{-1}(n+1)}_{\text{becslo}} e(n) x(n)$$

az LMS eljárásnak képest megjelölés R inverze

LMS-Newton módszer

\rightarrow iteratív módon becsülni R^{-1} -t

R mátrix inverzét igényli

paraméterek: $V(n+1) = \left[\prod_{i=0}^n (I - 2\mu R^{-1} x(i) x^T(i)) \right] V(0)$

\hookrightarrow Newton módszer után $R^{-1}(n+1)$ hogyan áll elő?

$R(u+1)$ lineáris kombinációból adódik (eddig: e_i új)

$$R(u+1) = \lambda R(u) + \gamma x(u)x^T(u)$$

Stratégia: nagyobb súly az újabb adatokra
→ összesen $u+1$ adat, ha lineáris átlapolás

$$\lambda = 1 - \gamma \text{ kell} \Rightarrow \underline{0 \leq \gamma \leq 1}$$

$$\underline{0 \leq \lambda \leq 1}, \text{ tipp: } \lambda = 0,9 \dots 0,99$$

⇒ exponenciális átlapolás hatással
éppen a becslőt

R^{-1} számítása (trouba, de hatékonyan kiértesíthető)

$$R^{-1}(u+1) = \frac{1}{\lambda} \left[R^{-1}(u) - \frac{R^{-1}(u)x(u)x^T(u)R^{-1}(u)}{\frac{\gamma}{\lambda} + x^T(u)R^{-1}(u)x(u)} \right]$$

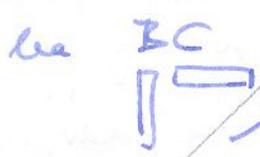
nagy rivindely R iteratív számolása

→ a fix értékkel konvergenca bevezethető,
egyre jobb a becslés λ -skalár!

alapja: mátrix inverziós lemma

$$[A + BC]^{-1} = A^{-1} + A^{-1}B \left[I + CA^{-1}B \right]^{-1} CA^{-1}$$

nem egyszerű, de egy ponton bonyolult lehetőségek



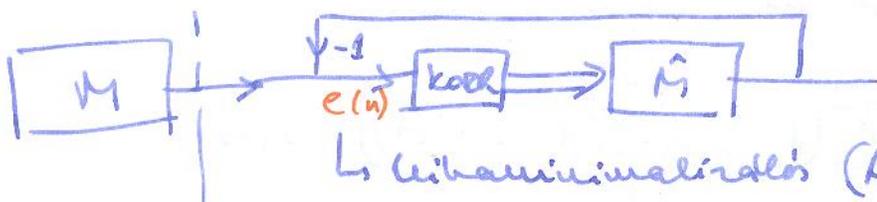
diadikus szorzat!

↓
egy diagonál módosított mátrix!

hatékonyan implementálható!

a nevezőben

4. Modell identitás: Kalman-prediktorral

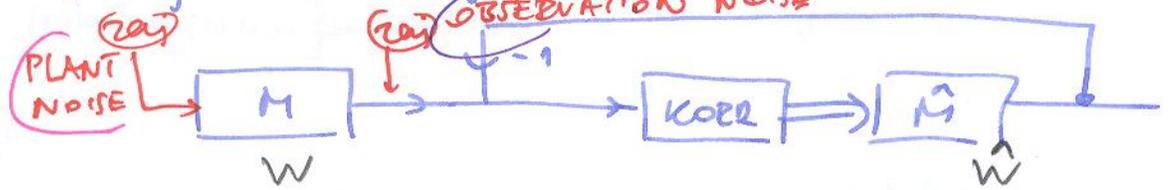


↳ minimális (A-BC) kontraktilitás!

de! itt nem volt zaj!

itt van nem körbehatott & változó!

→ bővíthető: van zajhatal, van zajhatár



- előfajta zajhatal nehezebb → rendszerezés
- megfigyelés → megfigyelési zaj
- emellett lineáris és kvadratikus minimalizálást
- figyelés és kritériumok!

{ rendszerezés: plant noise (a megfigyelés v., melynek állapotait nem tudjuk beállítani)
 megfigyelés: zaj: observation noise

→ a korrelációs mechanizmus intelligens kell beállítani;
 → ha nagyobb zajos a megfigy., nem illik korrelációt venni (kicsi korreláció)
 → ha kisebb, növelhetjük a korrelációt

$$\begin{aligned}
 x(u+1) &= A x(u) \\
 w(u+1) &= I w(u) \\
 \cancel{x(u)} & \\
 w(u+1) &= w(u) + \underbrace{v(u)}_{\text{PLANT}} \\
 d(u) = \underbrace{\hat{y}(u)}_{\text{becsl.}} &= x^T(u) w(u) + \underbrace{n(u)}_{\text{OBSERVATION}}
 \end{aligned}$$

leírómodell: korrelációsmodell

$$E[n(i) v^T(j)] = Q(i) \delta(i,j) ; \quad \delta(i,j) = \begin{cases} 1 & \text{ha } i=j \\ 0 & \text{egyébként} \end{cases}$$

használati példa:

$$E[n(i) n^T(j)] = R(i) \delta(i,j) \quad \delta = \dots \text{---} \text{---}$$

→ egymástól is függetlenek

$$\hat{w}(u+1) = \hat{w}(u) + [d(u) - x^T(u) \hat{w}(u)]$$

↓
 korrekció + korrekció

$v(u)$ és $n(u)$ additív perturbáció nehezebb elkerülni

cél: stratégia a létra minimalizálására

$$E \left[(W(u+1) - \hat{w}(u+1))^T (W(u+1) \hat{w}(u+1))^T \right] = E \left[e(u+1) e^T(u+1) \right] = P(u+1)$$

• 70.
= P(u+1)

mi a keresett jellemző? azivel n'lyrunk a kovarianciát!
(G matrix)

G mátrixot keressük, úgy, hogy a négyzetes leibát minimalizáljuk

$$\frac{\partial P(u+1)}{\partial G(u)} = \dots$$

négyzetes kifejezés deriválása
→ először első fogu deriválunk
→ majd belül

$$\frac{\partial P(u+1)}{\partial G(u)} = -2 E \left[e(u+1) [d(u) - x^T(u) \hat{w}(u)]^T \right] = 0 \text{ kell!}$$

\hat{w} -ba helyely $\rightarrow G(u)$ kifejezésbe marad!

$$d(u) - x^T(u) W(u) + u(u)$$

$e(u+1)$ -et behelyettesítjük

$$E \left[\underbrace{(W(u) + V(u))}_{w(u)} - \underbrace{(\hat{w}(u) - G(u) [d(u) - x^T(u) \hat{w}(u)])}_{\text{behelyettesítjük}} \underbrace{[x^T(u) (W(u) - \hat{w}(u)) + u(u)]}_{e(u)} \right]^T = 0$$

$$E \left[e(u) - G(u) x^T(u) e(u) - G(u) n(u) + V(u) \right] \left[\begin{array}{c} \text{---} \\ e^T(u) x(u) + n^T(u) \end{array} \right] = 0$$

$\hat{w}(u) - \hat{w}(u)$
↓
d-ből

mindent mindennel szorzunk

$$E \left[\underbrace{e(u) e^T(u) x(u)}_{P(u)} + \underbrace{e(u) n^T(u)}_{\text{0 a kovariancia miatt}} - \underbrace{G(u) x^T(u) e(u) e^T(u) x(u)}_{P(u)} - \underbrace{0}_{\text{0 a kovariancia miatt}} \right]$$

$$- \underbrace{0}_{\text{0 a kovariancia miatt}} - \underbrace{G(u) n(u) n^T(u)}_{P(u)} + \underbrace{V(u) e^T(u) x(u)}_{\text{0 valós. dt.}} + \underbrace{V(u) n^T(u)}_{\text{szintén 0}} = 0$$

$\Rightarrow G(u)$ kifejezése!

$$G(u) = P(u) X(u) \left[X^T(u) P(u) X(u) + R(u) \right]^{-1}$$

$X(u)$, $P(u)$ és $R(u)$ ismeretében számukból áll.

$$\frac{PX}{X \cdot P \cdot X + R}$$

ilyeneket feladni kell,
de a formális analízis
segíti a megfogadást.

→ ha R éles, vagy elhanyagolható

→ formálisan $\frac{1}{X} = G$.

Korábban:

$$A - GC = 0 \Rightarrow G = AC^{-1}$$

$$I - GX = 0 \Rightarrow G = IX^{-1}$$

Érték: ha G záros, R izmos, a G éles!

ha greufe, az arányozási tényező leanduyabó lehet!

programozás: $P(u)$ és $R(u)$ a Korábbi, iterációs
eljárással birtokoltak.

$$P(u+1) = E \left[\underbrace{(I - G(u)X^T(u))e(u) + G(u)u(u) - v(u)}_{\text{a citarendőnek}} \right] \left[\dots \right]^T$$

állapotátmenete

átrendezés:

$$P(u+1) = (I - G(u)X^T(u))P(u) + Q(u)$$

$$P(u) \Rightarrow P(u+1)$$

$Q(u)$ ezt additív terhelés:
(bizonytalanság, zajzavarok)

Követőképeség
 paraméter előállítás \rightarrow iteratív séma

$$\textcircled{1} W(u_{k+1}) = W(u) + \mu \underbrace{(-\nabla W(u))}_{\text{ismertek értéke}} \rightarrow \text{előretek, tanulni próbáljuk.}$$

Sokféle megközelítés; alapvető, h. iterációval javítunk.

Keretfő gondolat: az illetékes hibájának tekintett hibát egy előzőbtegedésként újul fel

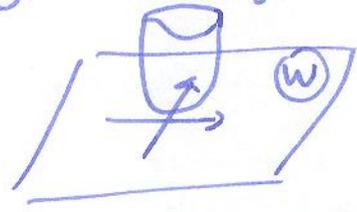
$$\left. \begin{array}{l} d(u) - \hat{y}(u) \\ y(u) - \hat{y}(u) \end{array} \right\} \text{négyzetes Euleriumok (2)}$$

\downarrow deriváltak utána lineáris
 $\frac{\partial}{\partial W}$

paraméterekben lineáris modell

\rightarrow a hiba értékelésénél paraboloid alakú hibafelület tart. a paraméteresíró felett (ha elég, leleltérő a tökéletes ill.)

$e(u) \Rightarrow E(\cdot)^2$



ezek feloldatával végtelen sok, összesen végtelen sok fel.
 \Rightarrow általában meredek fel, strapás feladat.

A kereséssel iteratív, keresés eljuttatás;
 a keresési stratégia sok ötletet életre hívott.

\rightarrow olyan lehetőség, amiben az összes pontot megvizsgáljuk (leimelő keresés), előzetesen adott, de elforratigélmes

Lényeg: Kalman prediktív par. beállítás

$\textcircled{2}$ hisztetifikésen a megfigyelt sémat mutatva
 \hookrightarrow hogyan redukálható a hiba képletből képletre?

$$V(u_{k+1}) = \left(\begin{array}{c} \downarrow \\ \uparrow \end{array} \right) V(u) = \left(\begin{array}{c} \downarrow \\ \uparrow \end{array} \right) V(0)$$

Controlatív, h. a paraméterektől csökken.

\Rightarrow kapunk egy par. beállítás, iterációra alk. képletet

Hf: A kiterjedés eljárás hajlathatóság - e olyan egyszerű, hogy mindig hatékonyabb legyen az opt. par. meghat.

③ A kiterjedés eljárást lefedő körülmények között a kapcsolatok között C függvények $C(w)$

Kiterjedés függvény Taylor sorfejtése

$C(d(n), y(n))$ d és y függvénye (azaz e)

$C(d(n), y(n)) = C(d, y(w)) = C(w)$
↑ paraméter a független változó
↑ paraméter függvény, ami hajlathatóság

$w = w_k$ zömökös feltételre!
→ zömököség elhárításra, hogy

$C(w) \approx C(w_k) + \nabla C^T(w)(w - w_k) + \frac{1}{2}(w - w_k)^T H(w_k)(w - w_k) \dots$
↑ első derivált
↑ második derivált

$H = \frac{\partial \nabla C(w)}{\partial w} \Big|_{w=w_k}$

→ a modellillemelési ezen rögzítési értékeket: ∇C elvált az ∇C értéke, és megpróbálunk valamit kitalálni...

a) → első két tagot figyeljük.

w_{k+1} meghatározandó kell, hogy a kiterjedés függvény 0-t adjon

$w_{k+1} = ? \quad C(w) \Big|_{w=w_{k+1}} = 0$

$C(w_k) + \nabla^T C(w_k)(w_{k+1} - w_k) = 0$
 $w_{k+1} = w_k - \frac{C(w_k)}{\nabla C^T(w_k) \nabla C(w_k)}$

Newton-Raphson módszer (Skalársorozat)

alapja: induljunk el a gradiens mentén, és az optimumból távol jól működik; de, a maradék ∇C (nem mindig) nulla

ha $C(w^*) \approx 0$, akkor jó módszer

b) → a módszer deriválhat nem konvergál el.
→ C(w) minimumát deriválással határozhat meg.

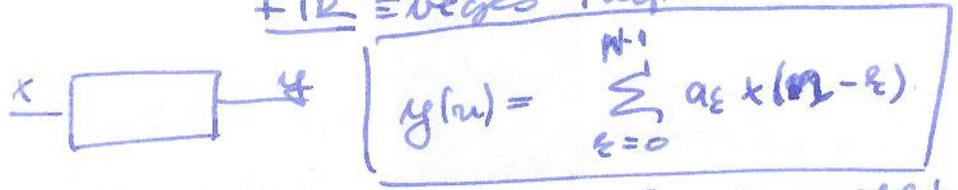
$$w_{k+1} = w_k - H^{-1}(w_k) \nabla C(w_k)$$

Még egy valami. Adaptív rendszeres létezik, ahol az állóképes paraméteres neurális a beemenet változóban van, tehát, levelem visszatér. nével a beemenet szabályozásában is...

ADAPTÍV SZŰRŐK

• Ismét beemenet által befolyásolt par.

FIR ≡ véges impulzusválasz



(adaptív lin. komb. probléma)

n. pillanatbeli értéke meghatározásához az x[n-N+1] mintát vissza utoljára figyelembe → véges a memória!

• Itt y[n] a beemenet mellett van is...

IIR ≡ végtelen impulzusválasz

$$y[n] = \underbrace{\sum_{k=0}^{N-1} a_k x[n-k]}_{(N)} - \underbrace{\sum_{k=1}^{M-1} b_k y[n-k]}_{(M)} \left\{ \begin{array}{l} \frac{Y(z)}{X(z)} = \frac{A(z)}{B(z)} \end{array} \right.$$

Az y-on keresztül permanens, implicit függés.
A utafelület nem paraboloid, komplexitással is iterszió.
Kérdésjele továbbá az értékelés.

Implicit függés megpróbálhatjuk additív eljárást.
(visszatér a FIR problémához)

← mintla operációk nem

y[n] felírása $y[n] = \frac{A(z)}{B(z)} x[n]$

$$e[n] = d[n] - y[n] = d[n] - \frac{A(z)}{B(z)} x[n]$$

$B(z) e(u)$ minimalizálása (zárt vektor)

$$B(z) e(u) = \frac{B(z) d(u) - A(z) x(u)}{B}$$

B hatadt viselkedés...

$$e'(u) = \sum_{k=0}^{M-1} b_k d(u-k) - \sum_{k=0}^{N-1} a_k x(u-k) \quad b_0 = 1$$

ez független az y -tól, csak a Eszközök jét alakítja ki korábbi mintáival is a művelet kombinációja.

→ a végtelen hosszúságú nem kiterjedésű olyan jó eljárást

Tapasztalat: ha a művelet zárt, akkor kódot kell kapni

→ van dna a türelmetlen...

→ bizonyos feladatoknál viszont célszerű, hogy kevesebb paraméterrel megoldható.

IR: 10...20 egyértelmű
IR: 100...200

STABILITÁS ELMÉLETI MEGKÖZELÍTÉS

cél: meghatározni az optimális konvergencia feladatoknál
 → analógia ideal operációk.

$$V(u+1) = \dots \quad V(u) = \dots \quad V(0)$$

Ugy a rendszer úgy működik, mint a stabil rendszer; energiafőlegesen az illető zéróval való tördelés, nem tudnak megfújni; megvalósulni.

→ stabilitás.

~~Factor~~ Először egy rövid fejtétel: kapcsolási, végző alapul az LMS eljárás.

$$w(u+1) = w(u) + 2\mu e(u) x(u) \Rightarrow V(u+1) = (I - 2\mu x(u) x^T(u)) V(u)$$

$V(u) \rightarrow 0$

illetve $V(u)$ energiája tartson nullához

LJAPUNOV: energiafüggvényeket kell találni

Leppen most ez $G(u) \quad G(u) = V^T(u) V(u)$

a maradék par. lehet energiája

minden definitívul negatívul legyen:

$$\Delta G(u+1) = G(u+1) - G(u) \leq 0$$

(vagy <)

ha $G(0)$ valamilyen véges érték, a lit. azt mondja, hogy ΔG nek is az inverzvaló majd 0-hoz kell tartania

$$\Delta G(u+1) = \underbrace{V^T(u+1)}_{\text{skaláris}} V(u+1) - \underbrace{V^T(u)}_{\text{skaláris}} V(u) = V^T(u) (I - 2\mu x(u)x^T(u))^T \cdot (I - 2\mu x(u)x^T(u)) V(u) - V^T(u) V(u) =$$

$$= -4\mu e^2(u) (1 - \mu x^T(u)x(u))$$

Mivel μ pozitív,

$$0 < \mu < \frac{1}{x^T(u)x(u)}$$

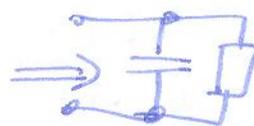
ha ez minden n -re teljesül, akkor biztosított a ΔG nullához tartása, és a monotonitás nullához tartása, és $W(u)$ nullához tartása $(V^T(u)x(u) \rightarrow 0)$

→ stabilitáselméleti megközelítés

→ a rendszer viselkedésére jellemző paraméter megegyezik, energiadissipáció szempontjából.

pl. pl. RC-tag

(csak nyelvi tud)



$V^T(u)x(u) \rightarrow 0$ úgy is lehet, hogy a par. leltá nem 0, ha ortogonális a két vektor

⇒ nem mindegy $x(u)$ megválasztása!

kvadrátus mértékelméleti problémák, hogy hogyan gerjünk ki a paraméterre, hogy a szétválasztás lefolytassa minden rendelkezésre álló módon

Optimális rávó

→ véletlen változó valóság modellél helyettesítés.

- Fokos családok: - Wiener
- Kalman

→ a legegyszerűbb beutató, a hibák legkisebb gyakoriságát részesítve.

Skalár Wiener rávó ~ batch processor

optimális neurális háló becsülő

megfigyelt: adatokból indulunk ϵ_i , N db-ot látunk
→ erre a becsült értéket elő (\hat{x})

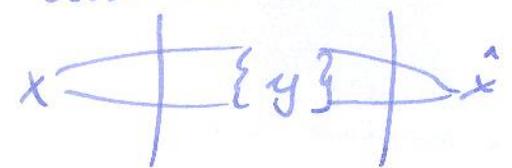
$$y_0, y_1, \dots, y_{N-1} \Rightarrow \hat{x} = \sum_{\epsilon=0}^{N-1} w_{\epsilon} y_{\epsilon}$$

szűrés, lineáris kombináció
elbárállítása.

Háttérben prekonceptuális kell lennie.

Vannak valahol x , vannak valahol y -ok.

Szeretnénk x -et becsülni.



hasznos a Wiener-Hopf egyenlet alkalmazása.

$e = x - \hat{x}$ a megfigyelt érték nem megfigyelhető, de becsülhető...

a jószágot úgy minimalizáljuk (?), hogy

$$E\{e^2\} = E\{(x - \hat{x})^2\} = E\left\{\left(x - \sum_{\epsilon=0}^{N-1} w_{\epsilon} y_{\epsilon}\right)^2\right\}$$

Egyszerű a deriválás!

$$\frac{\partial E\{e^2\}}{\partial w_j} = -2E\left[\left(x - \sum_{\epsilon=0}^{N-1} w_{\epsilon} y_{\epsilon}\right) y_j\right] = 0 \text{ kell.}$$

A hiba és a megfigyelt érték nem szabadul valahol értéke legyen nulla!... $E\{e y_j\} = 0$ ($\forall j$ -re, N db)

A megoldás legyen 0, azaz a hiba és a ref. érték szorzata...

Másik megfigyelés:

a lista ortogonális a megfelelő értékekre
=> megvalósítható az ortogonalitás feltétele (?)

továbbírás:

$$\sum_{\epsilon=0}^{N-1} w_{\epsilon} E[y_{\epsilon} y_j] = E[x y_j] \quad j=0,1,\dots,N-1$$

↑
keresztkorreláció!

$E[x y_j] = P_{xy}(j)$ a korrelációs mátrix megfelelő eleme
↳ keresztkorreláció.

$E[y_{\epsilon} y_j] = R_{yy}(\epsilon, j)$ autokorreláció (kovariancia)
↑
a korábbi, mert y és y közötti eltérése

A feladat annál vizsgálható, ha egyenlőre a lista az opt. beállítású. => behelyettesítet.

$$E[e^2]_{\min} = E\left[e \left(x - \sum_{\epsilon=0}^{N-1} w_{\epsilon} y_{\epsilon} \right) \right]_{\min} = E[ex] = *$$

az egész e-t kifejtettük...

e és x_{ϵ} még e és y_{ϵ} és nulla ad...

$$* = E[(x - \hat{x}) x] = E[x^2] - \sum_{\epsilon=0}^{N-1} w_{\epsilon} E[x y_{\epsilon}] =$$

a lista minimális értéke.

$$= E(x^2) - \sum_{\epsilon=0}^{N-1} w_{\epsilon} P_{xy}(\epsilon)$$

minimális: az az adekvát list. elemsz. világa, ha

$$R_{yy} w_{\text{opt}} = P_{xy}; \quad \boxed{w_{\text{opt}} = R_{yy}^{-1} P_{xy}};$$

$$E(e^2) \text{ minimuma: } E(e^2) = E[x^2] - P_{xy}^T R_{yy}^{-1} P_{xy}$$

Példa: Egyszerű átlapolású közös bbfj. centertől való távolság.

$$y_k = x + u_k$$

A zaj: $E[u_j u_k] = \begin{cases} 0 & j \neq k \\ \sigma_u^2 & j = k \end{cases}$

$$E[x u_j] = 0, \text{ korrelálatlan a jel és a zaj} \\ \forall j = 0, \dots, N-1.$$

x: nulla várható értékű, σ_x^2 varianciájú véletlen mennyiség.
 $E[x] = 0 \quad E[x^2] = \sigma_x^2$
(véletlen érték átlapolása).

Mi kell a redukciósra?

• $R_{yy}(k, j) = E[y_k y_j] = E[(x + u_k)(x + u_j)] =$

$x \cdot x \Rightarrow \sigma_x^2$
Ezenkívül korrelálatlan $\Rightarrow = \sigma_x^2 + \sigma_u^2 \delta_{kj} = R_{yy}(k, j)$
 $u_k u_j = 0$
 $\delta_{kj} = \begin{cases} 0, & \text{ha } k \neq j \\ 1, & \text{ha } k = j \end{cases}$

• $R_{xy}(k) = E[x y_k] = \sigma_x^2$

megvan a w meghatározására szolgáló egyenlet.

Legelső sor: tartalmazza a zajt, az első mérési pontot.

$$\begin{aligned} (\sigma_x^2 + \sigma_u^2) w_0 + \sigma_x^2 w_1 + \dots + \sigma_x^2 w_{N-1} &= \sigma_x^2 \\ \sigma_x^2 w_0 + (\sigma_x^2 + \sigma_u^2) w_1 + \dots + \sigma_x^2 w_{N-1} &= \sigma_x^2 \\ \vdots & \\ \sigma_x^2 w_0 + \dots + (\sigma_x^2 + \sigma_u^2) w_{N-1} &= \sigma_x^2 \end{aligned}$$

Képezzük össze az összes egyenletet!...

$$\sigma_u^2 + N \sigma_x^2 \cdot \sum_{k=0}^{N-1} w_k = N \cdot \sigma_x^2$$

$$\sum_{k=0}^{N-1} w_k = \frac{N \cdot \sigma_x^2}{N \cdot \sigma_x^2 + \sigma_u^2}$$

eredményt visszahelyettesítve addig amíg hogy az összes súlyszám egyforma

$$w_0 = w_1 = \dots = w_{N-1} = \frac{N \sigma_x^2}{N \sigma_x^2 + \sigma_u^2} = \frac{1}{N + \frac{\sigma_u^2}{\sigma_x^2}}$$

$$R_{yy}(i, j) = E[(x_{i+1} + u_i)(x_{j+1} + u_j)] = (i+1)(j+1) E(x^2) + E(u_i u_j) =$$

$$= (i+1)(j+1) S + \sigma_n^2 \delta_{ij}$$

$$E[x^2] = S \quad S = E(x^2) = \sigma_x^2 + [E(x)]^2$$

$$R_{xy}(j) = E[x y_j] = E(x_{j+1}(x + u_j)) = (j+1) E(x^2) = (j+1) S \quad j=0,1.$$

beluly:

$$\left. \begin{aligned} (S + \sigma_n^2)w_0 + 2Sw_1 &= S \\ 2Sw_0 + (4S + \sigma_n^2)w_1 &= 2S \end{aligned} \right\} \begin{aligned} w_0 &= \frac{1}{S + \frac{\sigma_n^2}{\sigma_x^2 + E^2(x)}} \\ w_1 &= \frac{2}{S + \frac{\sigma_n^2}{\sigma_x^2 + E^2(x)}} \end{aligned}$$

$$\text{ha } \sigma = \frac{\sigma_n^2}{\sigma_x^2 + E^2(x)} = \frac{\sigma_n^2}{S}$$

$$\hat{x} = \frac{y_0 + 2y_1}{5 + \sigma} \quad E(e^2) = \frac{S\sigma}{5 + \sigma}$$

Mit kapunk? Jó ez az érték?

Mi van, ha nincs zaj? $\sigma = 0$ $\hat{x} = \frac{y_0 + 2y_1}{5}$ hf!...

A továbbiakban: az alkalmazott batch processing...
reprezentáció \Rightarrow redundancia...

Levegőn aludtunk ez dt x-nak a redundanciája?

Jólle dt az 1. példát folyamatos futásra.

Az első példa átírása:

$$\hat{x} = \hat{x}_n = \sum_{k=0}^{n-1} w_k y_k$$

n: mennyit vettünk figyelembe

$$\sigma = \frac{\sigma_n^2}{\sigma_x^2} = \left(\frac{\sigma_n}{\sigma_x}\right)^2$$

$w_k = \frac{1}{n + \sigma}$ volt az eredendően

$$E(e^2) = E[(x - x_n)^2] = \frac{\sigma_n^2}{n + \sigma}$$

ha $N \rightarrow \infty$ után $n \rightarrow n+1$ -et aludul...

$$\hat{x}_{n+1} = \sum_{k=0}^n w_{k,n} y_k$$

$$w_k = w_{k,n+1} = \frac{1}{n+1+\gamma}$$

$$E(e_{n+1}^2) = \frac{\sigma_n^2}{n+1+\gamma}$$

$$w_{k,n} = \frac{1}{n+\gamma} = \frac{E[e_{n+1}^2]}{\sigma_n^2}$$

$$\neq \frac{E[e_{n+1}^2]}{\sigma_n^2}$$

$$\frac{E[e_{n+1}^2]}{E[e_n^2]} = \frac{w_{k,n+1}}{w_{k,n}} = \frac{n+\gamma}{n+1+\gamma} = \frac{1}{1 + \frac{1}{n+\gamma}} = \frac{1}{1 + \frac{E[e_n^2]}{\sigma_n^2}} \quad (*)$$

⇒ ezeket használjuk fel a rekurrens námitai előállításban.
⇒ az opt. rek. szűrés a Kalman (ez ... ?)

$$\hat{x}_{n+1} = \frac{1}{n+1+\gamma} \sum_{k=0}^{n+1} y_k + \frac{1}{n+1+\gamma} y_n = \frac{n+\gamma}{n+1+\gamma} \hat{x}_n + \frac{1}{n+1+\gamma} y_n =$$

az utolsó kérésérték

$$\hat{x}_{n+1} = \frac{E[e_{n+1}^2]}{E[e_n^2]} \hat{x}_n + \frac{E[e_{n+1}^2]}{\sigma_n^2} y_n$$

ha $\gamma = 0$ lenne, a rekurrens itegrelést látnánk.

3. példa: $\gamma = 2$ éppen (a zaj és a jel szórásának aránya)
↳ σ_x^2 adott. (\hat{x}_0 lehet 0...)

első becslő: $\hat{x}_1 = \frac{y_0}{3}$ $\gamma = 2 \quad \underbrace{n=0}_{3} + 1.$

az első lépésben a négyzetes hiba: $E(e_1^2) = \frac{\sigma_n^2}{3}$ $n=1, \gamma=2$

$$\hat{x}_2 = \frac{\sigma_n^2/4}{\sigma_n^2/3} \hat{x}_1 + \frac{\sigma_n^2/4}{\sigma_n^2} y_1 = \frac{3}{4} \hat{x}_1 + \frac{1}{4} y_1$$

Megjegyzés: Az $\hat{x}_1 = \frac{1}{3} y_0$ volt. Ha ezt behelyettesítjük: $\frac{1}{4}(y_0 + y_1)$, ez a nem rekurrens esettel éppen, hiszen ez csak egy átlag

Ha bevezetünk egy jelölést:

$$a_{n+1} = \frac{E(e^2_{n+1})}{E(e^2_n)} \quad b_{n+1} = \frac{E[e^2_{n+1}]}{\sigma_{e^2}}$$

~~x_{n+1} = a_{n+1} x_n + b_{n+1} y_n~~

$$\boxed{\hat{x}_{n+1} = a_{n+1} \hat{x}_n + b_{n+1} y_n}$$

$$\frac{a_{n+1}}{b_{n+1}} = \frac{1}{b_n} \quad \text{és} \quad a_{n+1} = \frac{1}{1+b_n} = \frac{1}{1+\frac{b_{n+1}}{a_{n+1}}}$$

$$a_{n+1} = \frac{a_{n+1}}{a_{n+1} + b_{n+1}} \Rightarrow a_{n+1} = 1 - b_{n+1} \quad \text{ez a visszahely. utdn.}$$

Az x_{n+1} utdn. így íható:

$$\hat{x}_{n+1} = \hat{x}_n + \underbrace{b_{n+1}(y_n - \hat{x}_n)}_{\text{korrekciós tag}}$$

↑
előző időpillanat.

⇒ A rendszer becsölő az eddig megzoltott utdn. állítjál elő
(korrekciós, iteratív séma... ez itt az ap. dtmenet meg tud jelenni)

2009.04.15.

OPTIMÁLIS SZŰRŐK

megfigyelési adatok: y_0, y_1, \dots, y_n

ezek alapján szeretnénk egy becslőt előállítani

levegyműt: lineáris kombinátor

$$\hat{x} = \sum_{k=0}^{N-1} w_k y_k$$

időtartományban v. esetleg transformált-
tartományban értelmezhető

Cél: a hibát négyzetes értelemben minimalizálni.
 $e = x - \hat{x} \Rightarrow$ WIENER-HOPF.

példákkal is nézzünk;

továbbiakban: hogyan lehet ezt dtmen. okosn. v. alább?

→ a szűrt illetően megadó becslő kisműtben (predikciós, korrekciós)

indexek: időtartomány n. időp. imenethelyben (nt), becslő
 ⇒ korrekciós tag megjelölése

$$\boxed{\hat{x}_{n+1} = \hat{x}_n + b_{n+1}(y_n - \hat{x}_n)}$$

} predikciós
+ korrekciós.

a lin. becsl. proc. rekurrens dtmen.

Optimális rekurzív becslés alkalmazása } Skalar Kalman-szűrő. 084.

- Szűrőket ideje fel; változó állapothelye;
- rekurzív becslés → aktuális időpillanatra becsül.

SZŰRŐ v. PREDIKTOR.



jóslat: n.-ből még dt kell telnie az n+1.-be.

rekurzív séma: x állapotát becsüljük az előző pillanattaliból kiindulva, a'-val való számszorzás és perturbáció egy 0 várható értékű felül zaj

$$x_n = a \cdot x_{n-1} + w_{n-1}$$

A $\{w_n\}$ sorozat ($n=0,1,\dots$) 0 várható értékű és felül. ~~fast~~ $E[w_n] = 0$.

→ saját mindeddel nem korrelál, vagy önmagával korreláció ad 0-tól küll. értéket.

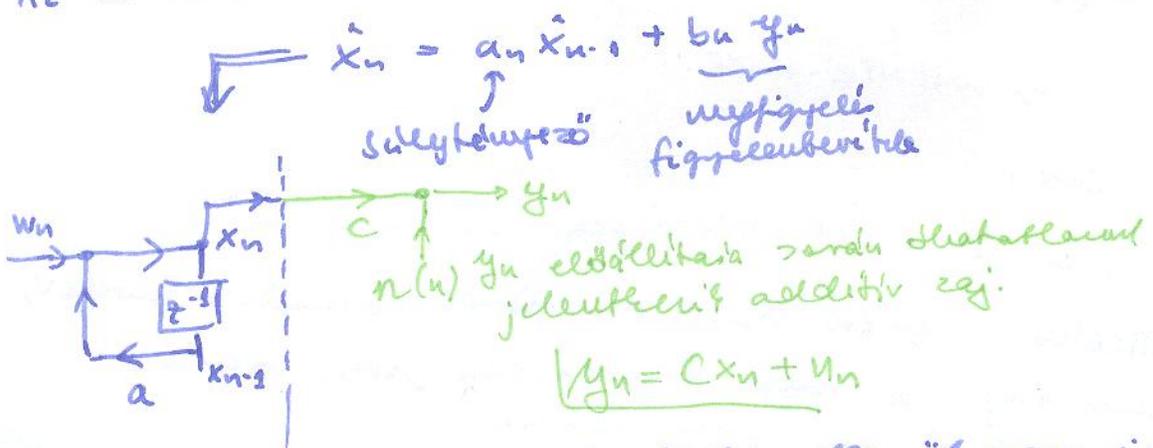
x_n és w_n bekapcsolt jellemzők tulajdoníthatók, negatív értékre is, \oplus nem független állapotból indulunk!

$$x_n, w_n \} = 0; n < 0; x_0 = 0$$

$$E[w_n] = 0 \quad E[w_n w_j] = \begin{cases} 0, & \text{ha } n \neq j \\ \sigma_w^2, & \text{ha } n = j \end{cases}$$

ebből indulunk, illetve keresünk rekurzív becslést.

Az n. időpillanattal ZECSD:



konceptuális modell; a belsőt erővel nem ismerjük
 ⇒ előző felületén tudunk érzékelni; megfigyelt
 ⇒ ez generálja matematikán az y_n -t.

ilyen folyamat feltételezhető reális.
 $a_n = ?$
 $b_n = ?$

Hosszadalmas, kitüntetett igényű követelés.

kiindulás: $\hat{x}_n = a_n \hat{x}_{n-1} + b_n y_n$

főfeladat: optimumkritérium Eklejtése
↳ ebben leírtá definíciók (bizonyít is valószínűségi elvárások)

$e_n = \hat{x}_n - x_n$
a hiba négyzetének várható értékével dolgozunk
 $E(e_n^2)$ minimalizálása.

$E[e_n^2] \stackrel{!}{=} \min.$

A kifejezés minimumát keressük a_n és b_n állításával.
a lependindexet leoldozzuk, azaz változatok!

$E[e_n^2] = E[(a_n \hat{x}_{n-1} + b_n y_n - x_n)^2]$

minimum eldőléséhez → deriválás par. szerint.
 a_n és b_n szerint deriváljuk. (belső fog.!!!)

$\frac{\partial E[e_n^2]}{\partial a_n} = 2E[(a_n \hat{x}_{n-1} + b_n y_n - x_n) \hat{x}_{n-1}] =$
 $\frac{\partial E[e_n^2]}{\partial b_n} = 2E[(a_n \hat{x}_{n-1} + b_n y_n - x_n) y_n] =$
} optimum, ha ezeket nullával tesszük egyenlővé, és keressük a paramétereket

visszatér az eredeti feladatra:

$E[e_n \hat{x}_{n-1}] = 0$
 $E[e_n y_n] = 0$
} azaz, hogy kovariánciátlanok legyenek (ortogonalitási feltétel) (szaldvonalat uelle)
ORTOGONALITÁSI EGYENLETEK.

További részletek.

a_n megfelelősége \rightarrow 1. ortogonalitás: gyenge

ez a másik oldalra került

$$E[(a_n \hat{x}_{n-1} + b_n y_n - x_n) \hat{x}_{n-1}] = 0$$

$a_n x_{n-1}$ korrelációja is (vonduk)

$$a_n E[\underbrace{e_{n-1}}_{-a_n x_{n-2}} \hat{x}_{n-1}] + \underbrace{x_{n-1}}_{(a_n x_{n-1})} = E[(x_n (1 - b_n c) - b_n u_n) \hat{x}_{n-1}]$$

y_n -t behelyettesítettük.
 \rightarrow itt az u_n is jelen van!

jó kiérték: ortogon. egy. köv:

- $E[e_{n-1} \hat{x}_{n-1}] = 0$

miért: e_n korrelálatlan \hat{x}_{n-1} -gyel!

mert $\hat{x}_{n-1} = a_{n-1} \hat{x}_{n-2} + b_{n-1} y_{n-1}$

e_{n-1} e_{n-1}
 ezek nulla-t adnak, tehát 0.

- $E[u_n \hat{x}_{n-1}] = 0$ ugyancsak teljesül, ~~hisz~~
 mivel a köv. időpillanatbeli csatlakozással
 ez nem áll összefüggésben!
 (u_n nem redukálható y_{n-1} -et)

gyengebb és átélhetőbb az eredmény.

$$a_n \cdot E[x_{n-1} \hat{x}_{n-1}] = [1 - c b_n] E[x_n \hat{x}_{n-1}]$$

az eredeti kiindulás szerint:

$$x_n = a x_{n-1} + u_{n-1} \quad E[u_{n-1} \hat{x}_{n-1}] = 0 \text{ len!}$$

(ut behelyettesítjük) (mivel a becsült korrelálatlan).

$$a_n \cdot E[x_{n-1} \hat{x}_{n-1}] = a \cdot (1 - c b_n) E[x_{n-1} \hat{x}_{n-1}]$$

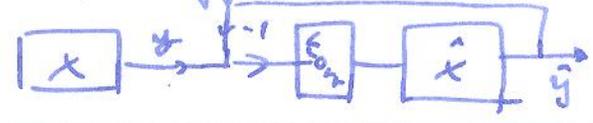
$a_n = a \cdot (1 - c b_n)$

 pontos eredmény.

ha visszahelyettesítjük a becsültbe...

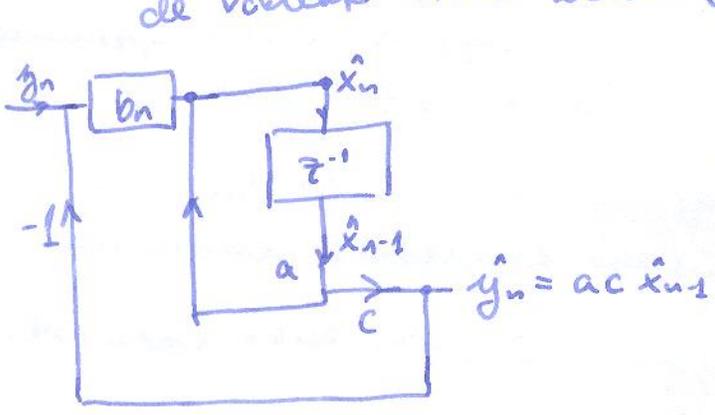
$\hat{x}_n = a \hat{x}_{n-1} + b_n [y_n - a c \hat{x}_{n-1}]$

az összefüggés strukturája megfelelő.
 \rightarrow megjelenti a valószínűleg feltételezett mechanizmus.
 (monas is perturbációk érvényes kiegészítés)
 (a becsült is a megfigyelt különbsége)



Hu a valóságban vonatkozóan feltételekhez a legtöbb feltételezés, akkor az a stratégia a legjobb, amit korábban is megkaptuk.

- lépésről lépésre visszatérő előrelépés a hibát
- a teljesen felgyűrt miatt a hiba nem csak nulla, de valószínű értéke alakosság maradt.



dekor,
konverzió,
-1 visszacsatolás } mint eddig.

b_n meghatározása.

→ a konverziót vesd elő, a hibát teljesen csökkenteni.

kezdés: $E[e_n^2] = E[e_n(x_n - x_n)] = -E[e_n x_n]$

miért: $\hat{x}_n = a_n x_{n-1} + b_n y_n$
 $e_n x_{n-1}$ } ortogon. függvények miatt 0 vár. érték.
 $e_n y_n$ }

szűkebbi feltétel:

~~$x_n = a_n x_{n-1} + b_n y_n$~~ $y_n = c x_n + u_n$

$c x_n = y_n - u_n$

amiből: $c E[e_n x_n] = -E[e_n u_n] \Rightarrow E[e_n^2] = \frac{1}{c} E[e_n u_n]$

miért $e_n y_n$ az ort. függ. miatt 0 vár. érték. (másos referencia!) \leftarrow

köv. lépés: e_n belépésértéke. \hat{x}_n belépésértéke csak ez marad!

$$E[e_n^2] = \frac{1}{c} E[(\hat{x}_n - x_n) u_n] = \frac{1}{c} E[(a_n x_{n-1} + b_n y_n - x_n) u_n] =$$

$$= \frac{1}{c} b_n E[y_n u_n] = \frac{1}{c} b_n \sigma_{u_n}^2, \text{ mivel: } E[\hat{x}_{n-1} u_n] = 0 \text{ } \left\{ \begin{array}{l} \text{konvergenstétel} \\ E[x_n u_n] = 0 \end{array} \right.$$

$E[u_n u_j] = \begin{cases} 0, & \text{ha } n \neq j \\ \sigma_{u_n}^2, & \text{ha } n = j \end{cases}$

$E[u_n u_j] = \begin{cases} 0, & \text{ha } n \neq j \\ \sigma_{u_n}^2, & \text{ha } n = j \end{cases}$

$b_n \Rightarrow$

$$b_n = c \cdot \frac{E[e_n^2]}{\sigma_n^2}$$

fontos allomások.

latszik b_n kapcsolata a megfelelői rajjal;
ha ezzel mérata nagy, akkor kis rólpi a korláció.
 \rightarrow logikus lépésnek tűnik.

A korláció mértéke abból is függ, mennyire vannak közel az optimumok.
Ha job közelebb vannak, nem nagyon különbözik a becslés.

Még egy melett; azt mutatja be, hogyan lehet a b_n értékeket
korábbi b_n értékekből, vagyis. valahány értékekből kiszámítani.
Először b_n megadhatósága a korábbi utasítások lista alapján.

$$b_n \Leftarrow E[e_{n-1}^2]$$

Árverés, hogy hogyan tudjuk számolni korábbi értékekből!

$$E[e_n^2] = E[(\hat{x}_n - x_n)^2] = E[(a\hat{x}_{n-1} + b_n[y_n - ac\hat{x}_{n-1}] - x_n)^2] =$$

$$\hat{x}_n = a\hat{x}_{n-1} + b_n[y_n - ac\hat{x}_{n-1}]$$

korábbi eredmény

$$y_n = cx_n + u_n$$
$$x_n = ax_{n-1} + w_{n-1}$$

$$= E[(a[1 - cb_n]e_{n-1} + b_n u_n - (1 - cb_n)w_{n-1})^2]$$

- 3 tag.
- $e_{n-1} \rightarrow$ lista
 - $u_n \rightarrow$ megfelelői rés
 - $w_{n-1} \rightarrow$ folyamat zaj!

\Rightarrow a keresztmetszet korrelálatlanok egymással

- \bullet $e_{n-1} \Rightarrow x_{n-1} \Rightarrow w_{n-1}, u_{n-1}$ lenne, ~~de nincs~~
ami korrelál, azaz nincs
- \bullet csak a változók egymás közötti közöttség.

$$E[e_n^2] = a^2(1 - cb_n)^2 E[e_{n-1}^2] + (1 - cb_n)^2 \sigma_w^2 + b_n^2 \sigma_u^2$$

az előző pillanatbeli lista segítségével a következőt
az állapotátmenettel helyettesítjük.

$\rightarrow a^2(1 - cb_n)^2$ éppen kontraktív.

\rightarrow a perturbáció rajhatás $(1 - cb_n)^2$ -tel nyilvános jut be

$e_n = \hat{x}_n - x_n$ } az első lista a különbséget nyilvános közzéteszi;
a második a perturbációt vizsgálja,
a 3. a becsült perturbációt vizsgálja.

hiszen fenn van b_i birt. mivel e_n és e_{n-1} is benn van;
 még egy behelyettesítést szükséges

⇒ a korábbi lépésben kiszámolt négyzeteslika eltolással
 jutunk a beindulathoz...

$$(b_n = c \frac{E[e_n^2]}{\sigma_n^2}) \Rightarrow E[e_n^2] = \frac{b_n}{c} \sigma_n^2$$

$$\frac{b_n}{c} \sigma_n^2 = b_n^2 \sigma_n^2 = (1 - cb_n)^2 [a^2 E[e_{n-1}^2] + \sigma_w^2] \quad / : c^2$$

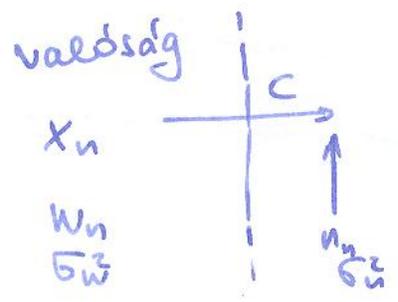
$$cb_n \sigma_n^2 - c^2 b_n^2 \sigma_n^2 = c^2 (1 - cb_n)^2 [a^2 E[e_{n-1}^2] + \sigma_w^2]$$

$$c b_n [1 - cb_n] \sigma_n^2 = c^2 (1 - cb_n)^2 [a^2 E[e_{n-1}^2] + \sigma_w^2]$$

$$b_n [a^2 c^2 E[e_{n-1}^2] + c^2 \sigma_w^2 + \sigma_n^2] = c [a^2 E[e_{n-1}^2] + \sigma_w^2]$$

$$b_n = \frac{c [a^2 E[e_{n-1}^2] + \sigma_w^2]}{c^2 a^2 E[e_{n-1}^2] + c^2 \sigma_w^2 + \sigma_n^2}$$

A b_n -et korábban kiszámították hibából hátrahozza még.
 nézzük meg speciális esetekre...



- ha a megfelelői rajz elcsúszhat,
 azaz 0-val helyettesíthet σ_n^2
 ⇒ $b_n = \frac{1}{c}$
 (azaz az optimális esetben a
 kiszámítás reciproka...;
 független a perturbáció mértékétől)

Összefoglalva: az optimális rekurzív becslés a követési
 spekulációkhoz el:

$$a_n = a(1 - cb_n)$$

$$\hat{x}_n = a_n \hat{x}_{n-1} + b_n y_n$$

a és c a rendszerrel kapcsolatos előzetes ismeretek.

$$\hat{x}_n = a \hat{x}_{n-1} + b_n (y_n - ac \hat{x}_{n-1})$$

$b_n =$

$$E[e_n^2] = \frac{1}{c} \sigma_n^2 b_n$$

$$E[e_{n-1}^2] = \frac{1}{c} \sigma_{n-1}^2 b_{n-1}$$

az új megfelelő után
 megállapítandó az új
 állapotbecslés, ehhez b_n kell;
 ezt a korábbi e_{n-1} -ből jön.
 ⇒ b_n összefüggésbe
 rekurzív!

Pelda rekurrens becslo mitokodexre...

$x_n = a x_{n-1} + w_{n-1}$ alapjdo gyokidolek x_n

$y_n = c x_n + u_n$ megfelelo elso követjöl.

$c=1$ leffer
 $y_n = x_n + u_n$

tfh: ismet a medianus, $E[x_n] = 0$

$\hat{x}_0 = 0$ (azaz 0-rde indul)

$\hat{x}_n = b_n y_n$

ortogonalitási egyenlet:

$E[(\hat{x}_n - x_n) y_n] = 0$

$\hat{x}_n = b_n x_n + b_n u_n$

$E[(b_n - 1)x_n + b_n u_n](x_n + u_n) =$

$\hat{E} = (b_n - 1)\sigma_x^2 + b_n \sigma_u^2$

$\Leftrightarrow b_n = \frac{\sigma_x^2}{\sigma_x^2 + \sigma_u^2}$

ha $\sigma_u^2 = \sigma_w^2$, azonos energiájú perturbáció
és $a^2 = \frac{1}{2}$ akkor $\sigma_x^2 = \frac{\sigma_w^2}{1 - a^2} = 2\sigma_u^2$
(az a.p. egyenletből számolható)

$b_1 = \frac{2}{3}$

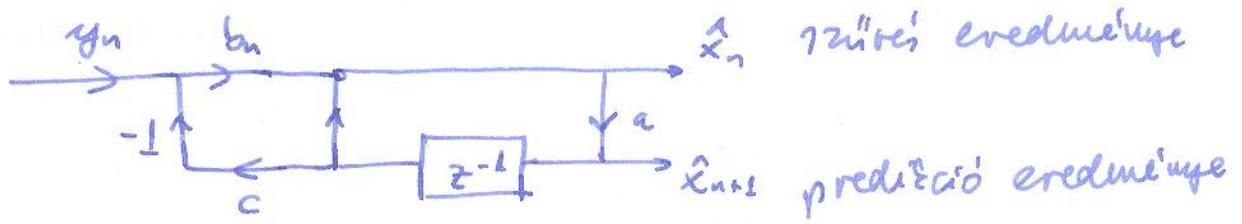
$E[e_n^2] = \frac{2}{3} \cdot \sigma_u^2$

$b_2 = \frac{a^2 E(e_1^2) + \sigma_w^2}{\sigma_n^2 + \sigma_w^2 + a^2 E(e_1^2)} = \frac{\frac{1}{3} + 1}{1 + 1 + \frac{1}{3}} = \frac{4}{7} = 0,57$

$E[e_2^2] = \frac{4}{7} \sigma_u^2$ és ez így folytatható.

Az első becsloés tévesztés ~67%, a következő 57%
=> csökkenő négyzetes hiba, csökkenő elbete!
=> ahogy törekszik, egyre kisebb kör. tévesztés és hiba
Többször ellenkező irány, de aszimptotikusan elér
egy megfelelő állapotot.
(a korábbiak prediktor struktúráját váltak, itt most rendszeresen, nőve velt)

A'bra (szűrés) / prediktor kiértékelés



A mint értéke n -re, a prediktor $n+1$ -re vonatkozik.
 Mindeközben az n . időpillanatra felmérés történt, tehát információink miatt lépésben ugyanakkora.

Technikai információ; az eljárás programozására.

a mint előtti összefüggések pótozása (matrixos majd ebbe...)

$$\hat{x}_n = a x_{n-1} + b_n [y_n - a c \hat{x}_{n-1}]$$

b_n kifejezést kicsit egyszerűbb formára hozzuk

$$b_n = C \cdot p_n [C^2 p_n^2 + \sigma_n^2]^{-1}$$

ahol $p_n = a^2 E[e_{n-1}^2] + \sigma_w^2$

(jövőlejtés)

$$E\{e_n^2\} = p_n - C b_n p_n$$

→ az előzővel alternatív.

Valószínűségi változó ⇒ minden vektor ill. mátrix tud lenni.
 ⇒ zéróindexes indexek.

$$x(n) = A x(n-1) + w(n-1) \rightarrow \text{zaj állapotvektor}$$

$$y(n) = C x(n) + N(n)$$

C fekvő vektor, ha y skalar
 ha y skalar, skalar egyelőrt vektor

Összefüggések átirata: $\sigma_n^2 \Rightarrow R(n) = E\{N(n) N^T(n)\}$
 (impulzus zaj) → observation noise

$\sigma_w^2 \Rightarrow Q(n) = E\{W(n) W^T(n)\}$
 (rendszer zaj) → plant noise

korreláció-
mátrixok

Skalár	matrix
$a+b$	$A+B$
$a \cdot b$	$A \cdot B$
$a^T b$	$A B^T$
$\frac{1}{a+b}$	$(A+B)^{-1}$

} a bekevertett önrejtgetek alapjdu adódik a matrixos eset

$$\hat{x}(n) = A \hat{x}(n-1) + K(n) [y(n) - C A \hat{x}(n-1)]$$

↳ Kalman gain művelete K-val jöögül.

Kalman - csőttesi vektor:

$$K(n) = P_1(n) C^T [C P_1(n) C^T + R(n)]^{-1}$$

$$P_1(n) = A P(n-1) A^T + Q(n-1)$$

négzetes utba:

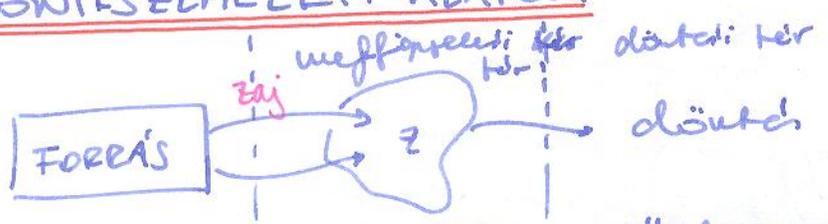
$$P(n) = P_1(n) - K(n) C P_1(n)$$

Emmyit az optimális rüres néven eltervelet eljárásnak.

A továbbiakban a becsléscsület irányába megyünk, egy feliditett csülettel döntéscsület mint a eset).

↓
nem mindig elterve valószínű, hanem besorolásra, clusterok-felésekre...
→ megfigyelésnek alapokra, utlyekül raj kerül.

DÖNTÉSELMÉLETI ALAPOK



Eindui döntési probléma: előzetesen vannak hipotézisek arról, hogy a forrás mit kiadótt számunkra
→ radama eldeltálás problémája

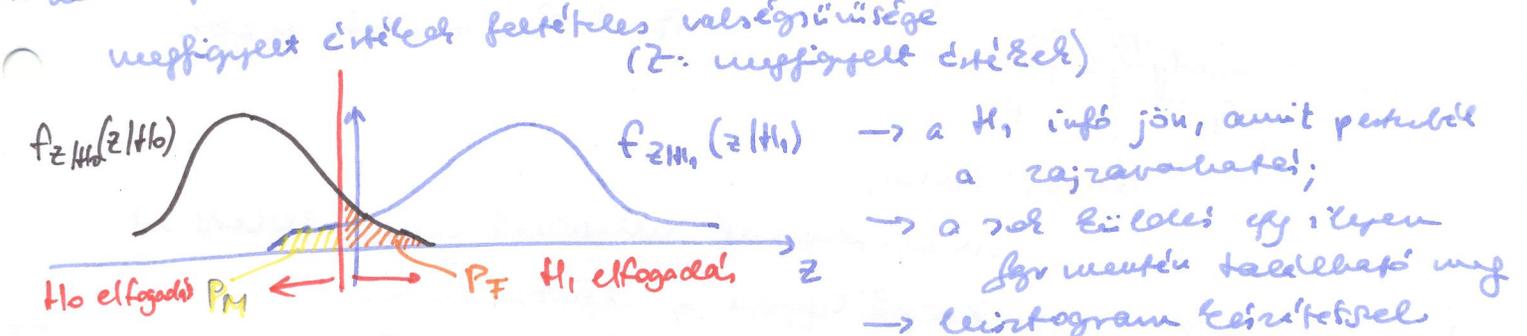
hipotézisek: H_0 és H_1
→ a ravalet határa hibákat követeltünk el.

hibák: elfogadjuk H_0 -t, ledott H_1 igaz; valamelykor valószínűség van, csak nem vesszük észre P_M (miss probability)

afogadjuk H_1 -t, ledott H_0 igaz; valamelykor valóseg
miss elterve objektum megis azt mondjuk, ki van. P_F (false alarm probability)

A zaj miatt a bizonytalanság kezelésére alkalmas eszközök kell

A döntési probléma kibontakozásának illusztrációja:



nem elegendő, bizonyos mértékig előrejelző a z tengelyen valószínűségi érték az állapotjelzés miatt.
 ⇒ a döntési eljárás célja egy olyan küszöbérték megállapítása, hogy a fölött H_1 , az alatt H_0 .
 ⇒ eleve véges valószínűség lesz annak, h. zomet mondunk...

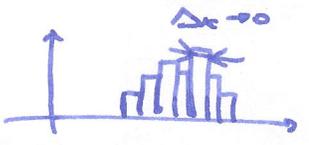
P_F és P_M lecsökkenthető, a küszöbön túli görbe alatti területtel.
 A tévesen irányított függvény más is más elvű a következmény, amit nem szabad figyelmen kívül hagyni. Értékszeg optimalizálást is be kellene. (P_F és P_M Értésg.-e más!)
 ⇒ a z tengely mentén melyik tartományba eljutunk.

DÖNTÉSELMELETI ALAPOK

2009. 04. 22.



Sűrűségfüggvény. → Események leírataja, ki mennyi a forrásoldalról
 ⇒ hisztogramkészítéssel szemlélünk, normellát...

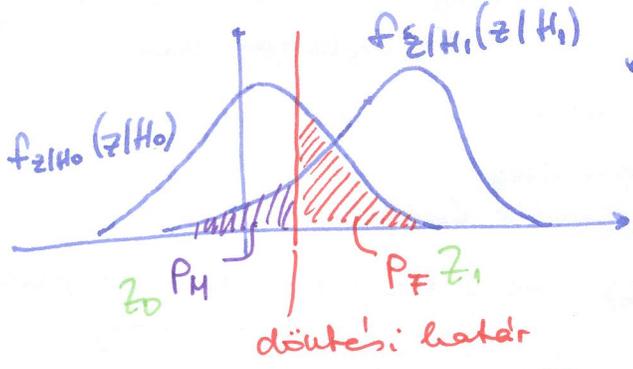


Két hipotézis van: H_0 és H_1 ; ezek közül az egyiket elfogadjuk.
 Milyen hibákat követünk el, ha nem azt fogadjuk el, ami valóban bekövetkezett?

hibák: H_0 , holott H_1 év. be } nem efferma
 H_1 , holott H_0 év. be } a következmény.

P_M
 miss probability

P_F : false probability (felismerés)



őslátatlanul átlapolódnak!
 → Ezt csoportra bonthatók.
 → P_F és P_M a görbe alatti.

Mi ez apparátus a valószínűségi helyesnek megjelölésére?
 A lekelett kétféleképp költés a döntés létezője.

KÉT HIPOTÉZISES BAYES DÖNTÉS

C_{ij} i -t fogadtuk el, de j -t választottunk
 → ez egy költés

→ Költésgyakorlatok értelmezése.
 iH : $i, j = \{0, 1\}$

előrejelzési valószínűség:
 $P(H_i | H_j)$

H_i -t döntünk, H_j előv. be

Cél: költés minimalizálása

$\min R$

$R \equiv$ riskó, kockázat.

H_0 a priori valószínűség P_0
 H_1 a priori valószínűség P_1

apriórival valószínűség: előzetes ismeret, mellyel valószínűséggel van/ nincs ellenséges objektív.

$$R = C_{00} P_0 P(H_0 | H_0) + C_{10} P_0 P(H_1 | H_0) + C_{01} P_1 P(H_0 | H_1) + C_{11} P_1 P(H_1 | H_1)$$

valószínűségi paraméter: hogy kezdjük a vonalat...

$$P(H_i | H_j) = \int_{z_i} f_{z|H_j}(z|H_j) dz$$

sűrűségf. alatti terület (integrál)

$$R = C_{00} P_0 \int_{z_0} f_{z|H_0}(z|H_0) dz + C_{01} P_1 \int_{z_0} f_{z|H_1}(z|H_1) dz + C_{10} P_0 \int_{z_1} f_{z|H_0}(z|H_0) dz + C_{11} P_1 \int_{z_1} f_{z|H_1}(z|H_1) dz$$

minimál sűrűségf. alatti terület 1

$$R = C_{10} P_0 + C_{11} P_1 + \int_{z_0} (C_{00} P_0 - C_{10} P_0) f_{z|H_0}(z|H_0) dz + \int_{z_0} (C_{01} P_1 - C_{11} P_1) f_{z|H_1}(z|H_1) dz$$

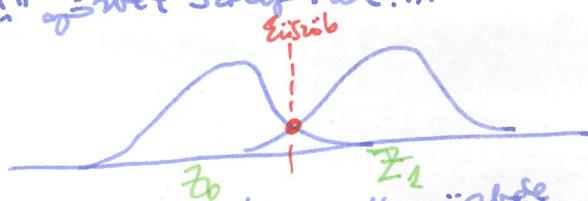
$\underbrace{\hspace{10em}}_{P_0(C_{00}-C_{10})}$
 $\underbrace{\hspace{10em}}_{P_1(C_{01}-C_{11})}$

fh: $C_{10} > C_{00}$ $C_{01} > C_{11}$ *mindkét döntés drágább!...*

minimális, ha a két integrál ^{összege} ~~effektív~~ ^{effektív} ~~... melegal~~ ^{... melegal} ~~effektív~~...

$$P_0(C_{00}-C_{10}) f_{z|H_0}(z|H_0) = P_1(C_{01}-C_{11}) f_{z|H_1}(z|H_1)$$

a „étpár” ^{összege} ~~... melegal~~ ^{... melegal} ~~effektív~~... *görbe alatti terület már nem 1*



ahol a ^{összege} ~~... melegal~~ ^{... melegal} ~~effektív~~ *ahol a szuprottt görbék megegyeznek, ott lesz a küszöb.*

balra van a ^{összege} ~~... melegal~~ ^{... melegal} ~~effektív~~ *balra van a küszöb, ahol a két görbe egyenlő.*

a z függvényében értelmezni egy arányfügg.-t!

$$\Lambda(z) = \frac{f_{z|H_1}(z|H_1)}{f_{z|H_0}(z|H_0)} \approx \frac{P_0(C_{10}-C_{00})}{P_1(C_{01}-C_{11})} = \eta$$

likelihood függvény (arány)

$$\text{ha } \Lambda(z) > \eta \Rightarrow H_1$$

$$\text{ha } \Lambda(z) < \eta \Rightarrow H_0$$

Bayes döntési szabály.

Speciális eset: $C_{01} = C_{10} = 1$
 $C_{11} = C_{00} = 0$

akkor $\eta = \frac{P_0}{P_1}$

$$P_1 f_{z|H_1}(z|H_1) \begin{matrix} > & H_1 \\ < & H_0 \end{matrix} P_0 f_{z|H_0}(z|H_0)$$

Bayes összefüggés (felt. valószínűség)

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

$$P_{H_1|z}(H_1|z) \begin{matrix} > & H_1 \\ < & H_0 \end{matrix} P_{H_0|z}(H_0|z)$$

a-posteriori valószínűsége!

a speciális esetben az a-posteriori ~~döntés~~ ^{valószínűség} alapján döntünk \Rightarrow MAXIMUM A-POSTERIORI DÖNTÉS.

pl. 1) konstanta julet detektore.

H0 zε = uε epy rajetete

H1 zε = a + uε konstant et raj

k = 1, 2, ..., N

N mufijete!

fH: a mufijeteletet fujgeten (nem cibelye epmet)

faun eesetisei valdosi valdetetet feteletet

→ 0 valdetetete, σn^2 variavak...

fz|H0(z|H0) = 1 / (sqrt(2π) σn) e^(-z^2 / 2σn^2) } ez a viselkedes egyenle, miyfen dteletet epmet... a csatema letete!

fz|H1(z|H1) = 1 / (sqrt(2π) σn) e^(-(z-a)^2 / 2σn^2)

egyites szisotefu andaja!

Λ(z) - E N mufijeteletet tije fel!

Λ(z) = Π_{ε=1}^N f_{z|H1}(z|H1) / f_{z|H0}(z|H0) = Π_{ε=1}^N e^(-((zε-a)^2 - zε^2) / 2σn^2)

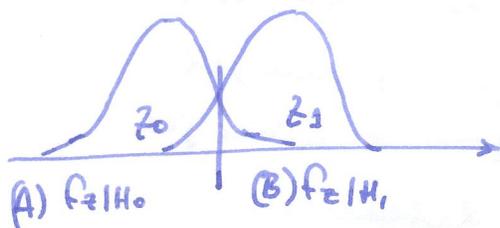
benen eesetete, ha nem tudunk epmetet feteletet szu - eteteit → logaritmusfava.

ln Λ(z) = - Σ_{ε=1}^N ((zε-a)^2) / 2σn^2 + Σ_{ε=1}^N zε^2 / 2σn^2 = a / σn^2 Σ_{ε=1}^N zε - a^2 N / 2σn^2

-(zε^2 - 2zεa + a^2) } eijti!

atkapdai: 1/N Σ_{ε=1}^N zε ≥ σn^2 / N a ln η + a/2

Ha a megfigyelésünk küszöb feletti $\Rightarrow H_1$
 küszöb alatt $\Rightarrow H_0$



$$\Delta(z) = \frac{f_z|H_1}{f_z|H_0} \begin{matrix} > \eta \\ < \eta_0 \end{matrix} = \frac{A}{B} = \eta$$

$$\ln \Delta(z)$$

$$= \ln \eta$$

több megfigyelésből
 szeretnénk döntést hozni
 egyszerűen minél többet.

$\left. \begin{matrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{matrix} \right\} N \text{ db}$

függetlenek ezek a Gauss-
 mondatok.

az átlagérték:

$$\frac{1}{N} \sum_{i=1}^N z_i \begin{matrix} > \frac{\sigma_n^2}{N \cdot a} \ln \eta + \frac{a}{2} \\ < \end{matrix}$$

pl. (2) Változó amplitúdójú jel detektálás.

hipotézis: H_0 nincs jelen $z_\varepsilon = u_\varepsilon$ $\varepsilon = 1, 2, \dots, N$
 H_1 jelen van $z_\varepsilon = -a_\varepsilon + u_\varepsilon$

a detektor változó megfigyeléseket

$$f_{z|H_0}(z|H_0) = \frac{1}{\sqrt{2\pi}\sigma_n} e^{-\frac{z^2}{2\sigma_n^2}}$$

$$f_{z|H_1}(z|H_1) = \frac{1}{\sqrt{2\pi}\sigma_n} e^{-\frac{(z-a_\varepsilon)^2}{2\sigma_n^2}}$$

az előző analógiájára...

$$\ln \Delta(z) = - \sum_{\varepsilon=1}^N \frac{z_\varepsilon^2 - 2z_\varepsilon a_\varepsilon + a_\varepsilon^2}{2\sigma_n^2} + \sum_{\varepsilon=1}^N \frac{z_\varepsilon^2}{2\sigma_n^2}$$

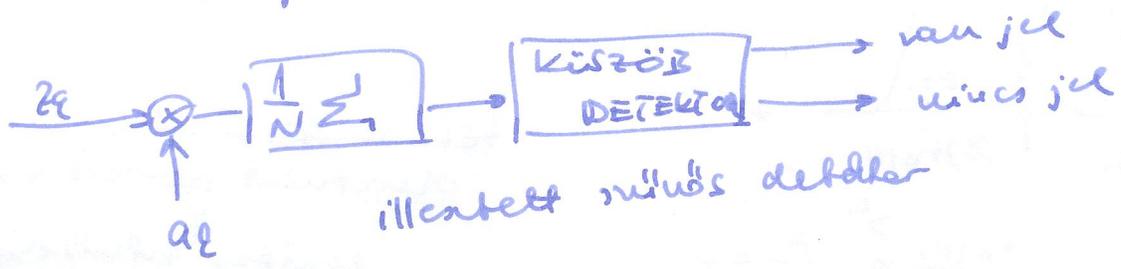
z_ε^2 kiejt!

$$\ln \Delta(z) = \sum_{\varepsilon=1}^N \frac{z_\varepsilon a_\varepsilon}{\sigma_n^2} - \sum_{\varepsilon=1}^N \frac{a_\varepsilon^2}{2\sigma_n^2} \begin{matrix} H_1 \\ > \\ H_0 \end{matrix} \ln \eta$$

variáns...

$$\frac{1}{N} \sum_{\varepsilon=1}^N a_\varepsilon z_\varepsilon \begin{matrix} H_1 \\ > \\ H_0 \end{matrix} \frac{1}{2N} \sum_{\varepsilon=1}^N a_\varepsilon^2 + \frac{\sigma_n^2}{N} \ln \eta$$

A berendezés nagy műbődjön, nagy z_s rendjű a_s -val, majd átlapdijuk \rightarrow küszöbdetektor...



3. Válasszunk raj detektálást rajban (a két raj eltérő viselkedésű) két stochasztikus feltevéssel.

~~Ha~~ a jellel kapcsolatban: σ_a^2
 a zajjal kapcsolatban: σ_n^2

$k =$ adott \rightarrow megfigyelt értékek

$$f_{z|H_0}(z|H_0) = \frac{1}{\sqrt{2\pi}\sigma_n} e^{-\frac{z_s^2}{2\sigma_n^2}}$$

$$f_{z|H_1}(z|H_1) = \frac{1}{\sqrt{2\pi}\sqrt{\sigma_a^2 + \sigma_n^2}} e^{-\frac{z_s^2}{2(\sigma_a^2 + \sigma_n^2)}} \rightarrow$$

a két műbős egyike határozott végül!

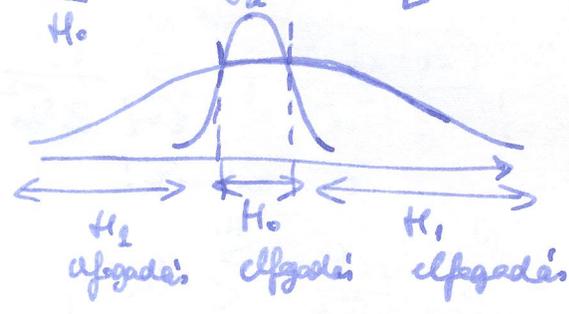
$$\ln \Lambda(z) = \sum_{i=1}^N \left[\frac{z_i^2}{2\sigma_n^2} - \frac{z_i^2}{2(\sigma_n^2 + \sigma_a^2)} \right] + \frac{N}{2} \ln \frac{\sigma_n^2}{\sigma_n^2 + \sigma_a^2} \stackrel{H_1}{\geq} \ln \eta \stackrel{H_0}{\leq}$$

(N megfigyelés) korreláció

N esetben képezzük a hányadosok, és a megfigyelt miatt adódik az $\frac{1}{2} \dots$

Átalakítás; ~~am~~ a megfigyelések nagyságösszege utazunk...

$$\sum_{i=1}^N z_i^2 \stackrel{H_1}{>} \frac{\sigma_n^2 (\sigma_a^2 + \sigma_n^2)}{\sigma_a^2} \left[\frac{N}{2} \ln \frac{\sigma_n^2 + \sigma_a^2}{\sigma_a^2} + \ln \eta \right] \stackrel{H_0}{<}$$



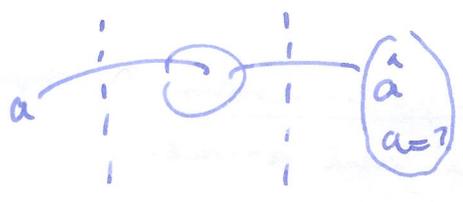
úgyis: a hamis jel jelenléte (H_1) népszerűtől tapasztalunk...
 ha nincs hamis jel, előbbi van népszerűtől...
 \Rightarrow azaz a hamis feltételezés "két rétegnek marad"

berendezés: folytonos értékelés! \rightarrow ez követendő.

BECSLÉSELMÉLETI ALAPOK

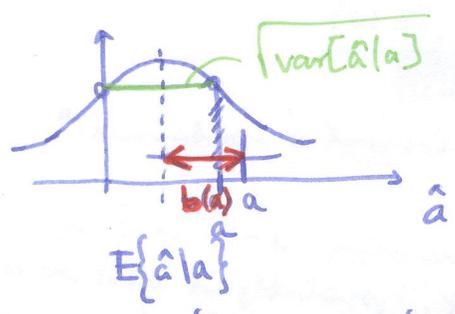
nem két/nyolc típusú problémára, hanem adott értékre, differenciára kiváncsi becsléssel előállni...

- a kerettörténetet ugyanaz, rajos csatolanda megfig. a.
- feltételes várhatósgfg. ez itt is markánsan szerepel.



\hat{a} is a várhatósgfg.?

a-t tudja nem tudjuk pontosan meghatározni:



megint mintogramot nyitunk le...

↓
várhatósgfg. értéke, értékek becsle.

szélességét a varianciájellemező adja meg.

$$\sqrt{\text{var}[\hat{a}|a]}$$

tenítés (nem találok helyre)

$$b(a)$$

BECSLÉS JÓSAGA (minimális)

$$f_{\hat{a}|a}(\hat{a}|a)$$

1. elsőrendű...

$$E\{\hat{a}|a\} = \int_{-\infty}^{\infty} \hat{a} f_{\hat{a}|a}(\hat{a}|a) d\hat{a}$$

feltételes várható érték $E\{\hat{a}|a\}$

2. varianciával (kovarianciával) kapcsolatos; értékek közötti eltérés

$$\text{Cov}\{\hat{a}, \hat{a}|a\} = E\left[(\hat{a} - E(\hat{a}|a))(\hat{a} - E(\hat{a}|a))^T | a\right]$$

feltételes kovariancia mátrix.

3. feltételes tenítés

$$b(a) = E[\hat{a}|a] - a$$

4. átlagos négyzetes hiba (Mean Square Error = MSE)

$$E\left[(\hat{a} - a)(\hat{a} - a)^T | a\right] = \text{Cov}[\hat{a}, \hat{a}|a] + b(a) b^T(a)$$

5. feltétel nélküli várható érték \equiv a feltételes v. d. v. értéke.

$$E[\hat{a}] = E_a\{E\{\hat{a}|a\}\}$$

az összes előfordulása átlagolunk...

6. feltétel nélküli kovariancia

$$\text{Cov}[\hat{a}, \hat{a}] = E_a\{\text{Cov}(\hat{a}, \hat{a}|a)\}$$

ismert $f_a(a)$ \rightarrow a megfigyelt eset jellemzője.
független változó
paraméter megnevezése \rightarrow a tény, a tények stb. minden megfigyeléséből.
újraírd! az!

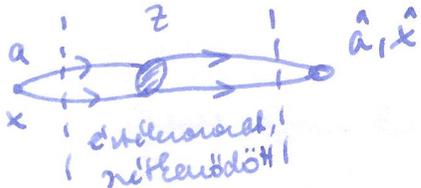
amit még tudni kell: a valószínűségi sűrűségfüggvény.

$$f_{z|a}(z|a)$$

\rightarrow Eseményt tudunk teremteni a megfigyelt utáni viszonyban.
 Eseményt vagyunk megfigyelni, de már mi van a-val.

$$f_{a|z}(a|z) = \frac{f_a(a) f_{z|a}(z|a)}{f(z)}$$

"mit csinál az 'a' paraméterrel a valószínűség?"



Ha ismerem z-t, mondhat valamit a-ról, próbáljuk visszacsinálni; ami történet...



$f(z)$ kiszámítása:

$$f(z) = \int_{-\infty}^{\infty} f_z(a) f_{z|a}(z|a) da$$

mit csinál az eredeti értékpárossal a valószínűség...

\Rightarrow ezt használva a népszerűségi góddat.

de! az a-val is van népszerűségi adat, amit a valószínűség még jobban népszerűségi, ezt tudjuk jellemeni $f(z)$ -vel.

Miért a visszacsinálás, az ilyen előállítás foglalkoztat.
 A legjobb becslés a legkisebb hibát előállítás. Képes becslést csinál.
 \Rightarrow költségfüggvénye van minőségileg - (RISK)

$$R(\hat{a}, a) = E\{C(\hat{a}, a)\} = \int_{-\infty}^{\infty} C(\hat{a}|z) f_{a|z}(a|z) da$$

valószínűségi eloszlás

\rightarrow szubsztitúcióval áll elő az optimális becslés.

$$R_B = \min_{\hat{a}} R(\hat{a}, a) = \min_{\hat{a}} E\{C(\hat{a}, a)\}$$

Eltérítésvég.

Kövérített módszerrel a minimalizálásra...

$$R = E_z \{ E_a \{ C(\hat{a}, a) \} \} = \int \int C(\hat{a}, a) f_{z,a}(z|a) da dz =$$

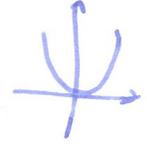
Értékvülső - ből átlagos liha. \Rightarrow ezt minimalizáljuk...

$$= \int_z \left[f_z(z) \int_a C(\hat{a}, a) f_{a|z}(a|z) da \right] dz$$

nem negatív \rightarrow a feltételes átlagos liha minimalizálható! \rightarrow elependő!

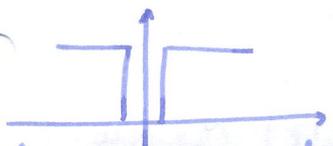
Értékvülső - el:

• $C(\hat{a}, a) = \sum_{i=1}^m (\hat{a}_i - a_i)^2$

négyzetes eltérések Σ 

• $C(\hat{a}, a) = \sum_{i=1}^m (|\hat{a}_i - a_i|)^2$

abszolútérték eltérések Σ 



Eis intervallumban nem büntet, egyébként nagyon.

• $C(\hat{a}, a) = \begin{cases} 0 & |\hat{a}_i - a_i| \leq \frac{\Delta}{2} \quad \forall i. re. \\ 1 & \text{egyébként} \end{cases}$

\rightarrow a értékvülsővel tartozó becslés eljuttatás előállítás

$$\frac{\partial}{\partial \hat{a}} \int C(\hat{a}, a) f_{a|z} = 0 \text{ alapján.}$$

① Minimális átlagos négyzetes liháji becslés. (MS) (Mean square \equiv MS)

$$R_{MS} = \int \int (\hat{a} - a)^T (\hat{a} - a) f_{z,a}(z|a) da dz$$

Értékvülső, nem feltételes!

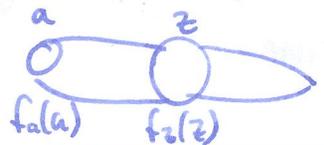
$\rightarrow \frac{\partial}{\partial \hat{a}} = 0$ éppen!... $\frac{\partial}{\partial \hat{a}} \int_{-\infty}^{\infty} (\hat{a} - a)^T (\hat{a} - a) f_{a|z}(a|z) da = 0$

a deriválás eredménye:

$$\hat{a}_{MS} = \int_{-\infty}^{\infty} a f_{a|z}(a|z) da$$

a-posteriori sűrűségfüggvény

négyzetes értelemben optimális becslés...



a z ismeretében a-ra előállítás ismeretében, mint sűrűségfüggvény jel jellemző a priori valószínűségi eloszlás alapján.

② Minimális abszolút hibájú becslés... (ABS)

→ ugyanaz...

$$R_{ABS} = \int_{\mathbb{Z}} \int_a^{\hat{a}} |\hat{a} - a| f_{z,a}(z,a) da dz$$

\hat{a} ~~minimális~~ ^{allításával} ~~val~~ ^{emel} ~~val~~ ^{minimálisan}

feltételes sűrűségfn. alkalmazása

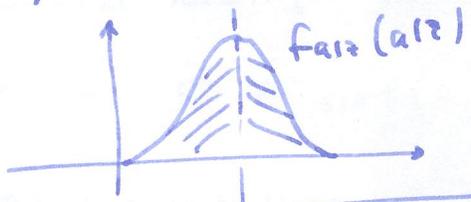
$$R_{ABS}(\hat{a}|z) = - \int_{-\infty}^{\hat{a}} (\hat{a} - a) f_{a|z}(a|z) da + \int_{\hat{a}}^{\infty} (\hat{a} - a) f_{a|z}(a|z) da$$

2 lefutás miatt
2 lefutás vegyesen
integrálás

deriválás után a minimum beállása:

$$\int_{-\infty}^{\hat{a}_{ABS}} f_{a|z}(a|z) da = \int_{\hat{a}_{ABS}}^{\infty} f_{a|z}(a|z) da$$

Az a-posteriori sűrűségfn. meddigyátra $f_{a|z}(a|z)$ legyen a beállítási; a két terület egyenlő mfg.



\hat{a}_{ABS} $f_{a|z}(a|z)$ meddigyátra legyen.

A két területi eljárást adhat elbűt eredményt. Csak akkor azonosak, ha a fgv. szimmetrikus, ami a csat. raj miatt ritkán fordul elő.

③ Maximum a-posteriori becslés... (MAP)

$$R_{MAP} = \int_{-\infty}^{\infty} f(z) \cdot \left[1 - \int_{\hat{a} - \frac{\Delta}{2}}^{\hat{a} + \frac{\Delta}{2}} f_{a|z}(a|z) da \right] dz$$

Először... tartományon kívül lévő delfok.

A [...] minimumát keresni...
ha Δ kicsi, de $\Delta \neq 0$



optimális beállítás az a-p. sűrűségfn. maximumukra (az integrál akkor az a legnagyobb, ha a legmagasabbig nyújtjuk el)

Mit kaptunk ma?

→ döntési problémaiban (igen/nem) a csatéma behatárolja a lipotériszket alapul véve kaptunk javaslatot, hogy hogyan kell eljárni a döntési kúrszob meghatározásának ellen tartományjelölés kellest...

→ a Bőltérséket kellest minimalizálni:

$$\Delta(z) = \frac{f_{z|H_1}(z|H_1)}{f_{z|H_0}(z|H_0)}$$

← csatéma karakterisztika
← H_1

$$\Delta(z) \underset{H_0}{\geq} \eta$$

← kúrszobhoz utrongatva.

több mint együttes figyelembevétel...

kúrszob {
- altag ← - konstans
- illetett súrú ← - változó } jellemző problémák.
- zétleat súrúcsfgyv. ← - zraj

→ teljesem folytonos lipotériszket.

a paraméterre vonatkozó teljes leírás, a működésről lemm.

$$f_a(a)$$

amdan a csatéma behatárolt vizsgálata (a-ből z)

$$f_{z|a}(z|a)$$

utána visszafelé (z-ből a)

$$f_{a|z}(a|z)$$

nem döntési kúrszob a cél, hanem a előállítók.

⇒ az a-posteriorit alapul véve 3 esetet utóként

- teljesem kúrszob → valószínűségi eloszlás
- abszolút kúrszob → valószínűségi eloszlás
- MAP kúrszob → valószínűségi eloszlás

(beszélgetés alap technika)

csak annyiban nyilván, hogy valójában fejtással jól jellemelhető reprezentációt alkalmazunk...

jövő hét: beszélgetési példák, gyakorlatok.

2 hét: megismert delfor új, kúrszob, címszóval.

3 hét: utolsó zH, zH... → az elhangzottakat számolás ellen példák a elvi eredmények

Két irányban folytatódik:

I. → Gauss sűrűségfüggvények

II. → nonszenz, hogy előzetesen ismerjük; (azaz a sűrűségf. - t)
→ nem ismert az a priori sűrűségf. - t,
a valószínűségi eloszlás stb. stb. $f_a(a)$ nem ismert
→ mit lehet tenni?

Ⓛ p_j - két céljellel csak utalunk korábbiakra; ezzel nem időzünk!!

I. NEMREKURZÍV BAYES BESZLŐ GAUSS ELOSZLÁSOK ESETÉN

kiindulási feltételek: minden Gauss
- a keresett paraméter
- a megfigyelési zaj

$$\left. \begin{aligned} E[a] &= \mu_a \\ \text{Cov}[a, a] &= \Sigma_{aa} \text{ ismert} \end{aligned} \right\} \text{paraméter}$$

$$\left. \begin{aligned} E[u] &= 0 \\ \text{Cov}[u, u] &= \Sigma_{uu} \end{aligned} \right\} \text{zaj}$$

az, hogy Gauss, az az előnyös, mert az a posteriori sűrűség.
momentumai explicit módon megadhatók

U: megfigyelés vektora

$$\text{mérés elv.: } \underbrace{z}_{n \times 1} = \underbrace{U}_{n \times m} \underbrace{a}_{m \times 1} + \underbrace{u}_{n \times 1}$$

vektores esetben: $\dim a = m$
 $\dim z = n$
 $\dim U = n \times m$

többváltozós „a” jellemző, több mértékegysége (U)
mit akarunk: hogyan generalizáljuk a felt. sűrűségf.?

eredmény: explicit módon számozhatjuk ki
az első és második momentum
↳ valóság értéke.

$$\hat{a}_{MS} = \mu_a + \left\{ \left[U^T \Sigma_{uu}^{-1} U + \Sigma_{aa}^{-1} \right]^{-1} U^T \Sigma_{uu}^{-1} (z - U \mu_a) \right\}$$

feltételes sűrűségf. -hez valószínűségi eloszlás
a priori ismeret
konvenció

hogy egy példát keresztül emeljük át.
mire ad, ha a megfig. U · a
→ ha nem, konvergencia az előzetes ismeret.

A 2. és 3. metró:

$$\hat{a}_{MS} = \hat{a}_{AKS} = \hat{a}_{MAP}$$

mivel az a-posteriori sűrűségf. egy csúcsú, szimmetrikus \Rightarrow ugyanazt eredményezni minde

1. metró: \hat{a} ellenálló; ismét a ram által adott fész. mértékkel.

$$U = I \cdot a + u$$

↑
raj
az „a” paraméter

N db megfigyelés \Rightarrow z_k értékek

$$z_k = a + u_k \quad k=1, 2, \dots, N$$

ha feltételezzük az ellenállásról, hogy Gauss reprezentációjú a „u” is Gauss van ma-ra, $\sum \sigma_a^2$ -re $\mu_u = 0$, $\text{cov}[u_k, u_j] = \sigma_u^2 \delta_{kj}$ ismételtül

megfigyelési vektor:

$$z = U \cdot a + u$$

$$z^T = [z_1, z_2, \dots, z_N]$$

$$u^T = [u_1, u_2, \dots, u_N]$$

$$U^T = [1 \ 1 \ 1 \ 1 \ \dots]$$

$$\sum_{nn} = \sigma_u^2 \cdot \underline{I} \leftarrow \text{egységmátrix}$$

becslés: $\hat{a}_{MS} =$
a főbbek is így

bevezetése E -ben: a nevelő vektor len stb. a típusok, végeredményt j utáni:

$$\hat{a}_{MS} = \frac{\mu_a + \left(\frac{\sigma_a}{\sigma_u}\right)^2 \sum_{k=1}^N z_k}{1 + N \left(\frac{\sigma_a}{\sigma_u}\right)^2}$$

ha az ismét megfigyelés ma-ra nézünk, akkor $N \mu_a$, ami kicsenhet.

Gauss-est: kedves bevezet, a módszer momentum felírás is valóban alkalmos.

$$\text{var}[\hat{a}] = \frac{\sigma_a^2}{1 + N \left(\frac{\sigma_a}{\sigma_u}\right)^2}$$

jellegzetes: ha a mérés nem tényleg a jelenlegi mértékben, több megfigyelés a tapasztalás növelti a varianciát.

↳ kapstany a leírásból, utána kell nézni!... :) ↳

A végcímzés:

1. függvény \rightarrow amit kapunk, feltételen tanított becslés.

valószínűségi eloszlás:

$$E\{\hat{a}_{MS} | a\} = \frac{\mu_a + \left(\frac{\sigma_a}{\sigma_n}\right)^2 \cdot N \cdot a}{1 + N \left(\frac{\sigma_a}{\sigma_n}\right)^2}$$

eltér egymástól a becslés és az eredeti érték, meghatározható egy tanítási érték.

$$\rightarrow \text{az: } b(a) = \frac{\mu_a - a}{1 + N \left(\frac{\sigma_a}{\sigma_n}\right)^2}$$

mi történt? mértékül egy "a" jellemzőt.

Eredeti értéket tekintve a függvényben (feltételek, hogy mindig van a tartomány)

\rightarrow ha "a" eltér az állapottól, a becslés eltérhet a valószínűségi eloszlástól, ezzel a tanítással (feltételen tanított)

2. függvény:

- ha σ_a és σ_n nem azonos nagyságrendű,

$\frac{\sigma_a}{\sigma_n} \ll 1$, akkor a függvények helye kicsi.

\rightarrow akkor egy ideigmines értékes kiemelés. (függvény nem hat)

\Rightarrow ha a függvények nagy a vegyesen is, a

\sum ban vegyesen is, a max? tag elhanyagolható,

$N \rightarrow \infty$ miatt minden elhagyható a max? tag,

$$\frac{1}{N} \sum_{k=1}^N z_k$$

- ha sokadik függvény, értékelés az előzetes ismeret!
- sok mérés, az mérés számával ismeretével számolunk tovább.

variancia: ha $\frac{\sigma_a}{\sigma_n}$ kicsi, a szórás is kicsi.

\Rightarrow ha N nagy, kellőképpen megnövekedni, érvényre jut, hogy kisebb varianciát kapunk.

This part of the page was left intentionally blank.

Következő becsületi feladat (pt.)

3 bit nyílt kódolású rejtett Gauss üzenet \Rightarrow hamisíthatóság azt, ami egyenlőtlen ad eredményt

üzenet alakja jel, üzeneteken amplitúdója

megfigyelések:

← üzeneteken közp.

$$z_k = a \cdot s_k + u_k$$

\uparrow \uparrow
 üzeneteken üzenet jel
 amplit. mintái

megint minden Gauss.

$$\begin{cases} E[a] = \mu_a & \text{várható: } \text{var}(a) = \sigma_a^2 \\ E[u] = 0 & \text{várható: } \text{cov}(u_i, u_j) = \sigma_n^2 \delta_{ij} \end{cases}$$

$\text{cov}(a, u_i) = 0$ $\forall i=1, \dots, N$, tehát korrelálatlanok, nem csatoltak egymással.

\Rightarrow hamisíthatóság MAP becsület.
 szűrés/értékelés.

$$\left. \frac{\partial \ln f(a|z)}{\partial a} \right|_{a=\hat{a}_{MAP}} = 0 \quad (\text{feltétel})$$

a Gauss miatt $\hat{a}_{MAP} = \hat{a}_{MS} = \hat{a}_{MSE}$ is.

Bayes-módszer alkalmazásával az a-posteriori eloszlás.

$$\left. \frac{\partial \ln f(a)}{\partial a} + \frac{\partial \ln f_{z|a}(z|a)}{\partial a} \right|_{a=\hat{a}_{MAP}} = 0$$

$$f(a) = \frac{1}{\sqrt{2\pi}\sigma_a} \cdot e^{-\frac{(a-\mu_a)^2}{2\sigma_a^2}}$$

$$f_{z|a}(z|a) = \frac{1}{\sqrt{2\pi}(\sigma_n)^{N/2}} e^{-\frac{1}{2\sigma_n^2} \sum_{k=1}^N (z_k - a s_k)^2}$$

\uparrow
csatolva

N db megfigyelés \Rightarrow N db Gauss együttes.

$$\frac{\partial \ln f(a)}{\partial a} = -\frac{a - \mu_a}{\sigma_a^2}$$

$$\frac{\partial \ln f_{z|a}(z|a)}{\partial a} = \frac{1}{\sigma_n^2} \sum_{k=1}^N s_k (z_k - a s_k)$$

} $\oplus = 0?$

$$\hat{a}_{MAP} = \frac{\mu_a + (\sigma_a/\sigma_n)^2 \sum_{k=1}^N s_k z_k}{1 + (\sigma_a/\sigma_n)^2 \sum_{k=1}^N s_k^2}$$

$$\text{var}[\hat{a}_{MAP}] = \frac{\sigma_a^2}{1 + (\sigma_a/\sigma_n)^2 \sum_{k=1}^N s_k^2}$$

$\tilde{a} = a - \hat{a}_{MAP}$

Megjegyzések:

1. $S_k = 1 \quad \forall k \rightarrow a$

- \Rightarrow a \sum értéke N , visszalapjuk az előző példát
- \Rightarrow az ismét jel konstans volt.
- \Rightarrow az ~~eset~~ erre kapott becslés megegyezik

2. értelmentül korábban az illesztett szűrt, ez itt is elbírható.

3. $\hat{a}_{MAP} = \hat{a}_{MS}$ feundle.

mi van akkor, ha nincs ismeretünk a véletlen folyamatról?

II. $f_a(a)$ nem ismert!

- \rightarrow a gondolkodási utjának, mint eddig, csak nincs a priori sűrűségfüggvényünk.

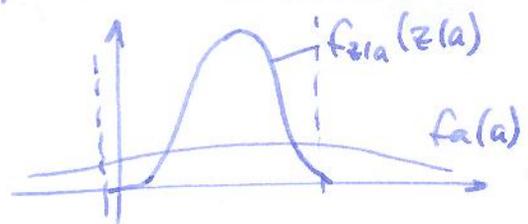
MAXIMUM LIKELIHOOD BECSLŐ

- megad valahát, h. nem ismerjük az a priori sűrűségfüggv-t.
- az a feltételre hivatkozunk, hogy ez egy nagyon széles körben alkalmazott sűrűségfüggvény.

- \Rightarrow meglepjük a statisztikáshoz a MAP-ot.
- \Rightarrow az az 0 , ott kapunk olyan becslést, amit maximum likelihood becslésnek nevezünk.

$$\left. \frac{\partial f_{z|a}(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0 \qquad \left. \frac{\partial \ln f_{z|a}(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = 0$$

ha lepos $f_a(a)$, és elkerülhet valahol elhelyezkedik $f_{z|a}(z|a)$, akkor a megkezdött munka feljogosít minket arra, hogy az a-posteriorit a statisztikáshoz a priori sűrűségfüggvényével azonosítsuk.



a nem ismert, a nem tudás, az információhiány ilyen értelemben is értelmezhető.

van olyan eset, ahol a becslés alapja Gauss \Rightarrow Gauss-Markov becslés.

Gauss-Markov becsles: az a maximum likelihood becsles, amennyi Gauss a csatemasul.

↓
a megfigyelesi csatama linearis ($z = Ua + n$)

ahol a $E[n] = 0$ $cov(n, n) = \Sigma_{nn}$

$$f(n) = \frac{1}{(2\pi)^{N/2} |\Sigma_{nn}|^{1/2}} e^{-\frac{1}{2} n^T \Sigma_{nn}^{-1} n}$$

a sűrűségfüggvény.

$z = Ua + n$ alakú; a csatemasulaterminálisa sűrűségfüggvénye:

$$f_{z|a}(z|a) = \frac{1}{(2\pi)^{N/2} |\Sigma_{nn}|^{1/2}} e^{-\frac{1}{2} (z - Ua)^T \Sigma_{nn}^{-1} (z - Ua)}$$

⇒ ha ebből eldőlhet, a valószínűségi az előző fejelethez

$$\frac{\partial \ln f_{z|a}(z|a)}{\partial a} = \frac{\partial}{\partial a} \left[-\frac{1}{2} (z - Ua)^T \Sigma_{nn}^{-1} (z - Ua) \right] \Big|_{a = \hat{a}_{ML}} = 0$$

deriváljuk!...

eredmény:

$$U^T \Sigma_{nn}^{-1} Ua - U^T \Sigma_{nn}^{-1} z = 0$$

Gauss-Markov: $\hat{a}_{GM} = [U^T \Sigma_{nn}^{-1} U]^{-1} \cdot U^T \Sigma_{nn}^{-1} z$

olyan ML becsles, ahol Gauss elonlati a csatemasul.
az eredmény levezeti a Gauss csatemasul alkalmasan
Bayes-becslesre, az a paramétervektor covarianca-
mátrixából feltételezve, hogy invertálható.
⇒ invene 0!

(az előzőt előzőt vagy korrelatív)

Megjegyzés: $\Sigma_{aa}^{-1} = 0$ helyettesítéssel van, mint a Bayes

Nézünk erre is egy példát.

Példa: van egy ilyen megfigyelés:

$$z_k = a + u_k \quad k=1, 2, \dots, N, \text{ függetlenek.}$$

$$E(u_k) = 0 \\ \text{cov}(u_k, u_j) = \sigma_u^2 \delta_{kj}$$

a feltételes sűrűség. (csak a z van):

$$f_{z|a}(z|a) = \prod_{k=1}^N f_{z_k|a}(z_k|a) = \frac{1}{[2\pi \sigma_u^2]^{N/2}} e^{-\sum_{k=1}^N \frac{(z_k - a)^2}{2\sigma_u^2}}$$

az addig ismert összhangban

Maximum likelihood Gauss esetben (ML-becslés)

$$\left. \frac{\partial \ln f_{z|a}(z|a)}{\partial a} \right|_{a=\hat{a}_{ML}} = \frac{N}{\sigma_u^2} \left[\frac{1}{N} \sum_{k=1}^N (z_k - a) \right] \Big|_{a=\hat{a}_{ML}} = 0$$

$$\hat{a}_{ML} = \frac{1}{N} \sum_{k=1}^N z_k$$

a ML-becslés az ideális átlagolás.

Amikor ideális átlagolást használunk, feltételeink egy Gauss-csokornát, és a paraméterek nem feltételeink. Akkor optimális az átlagolás (és akkor ML), ha a világot azt feltételeink, hogy a csokor Gauss elosztás nem tudunk.

Rekurzív \rightarrow $N-1$ megfigyelés:

$$\hat{a}_{N-1} = \frac{1}{N-1} \sum_{k=1}^{N-1} z_k$$

$$\Rightarrow \hat{a}_N = \frac{1}{N} [N-1 \hat{a}_{N-1} + z_N] = \hat{a}_{N-1} + \frac{1}{N} [z_N - \hat{a}_{N-1}]$$

az új megfigyelés akkor korrigálja a korábbi, ha becsültől eltérő értéket mutat.

Már csak egy lépés van, ez visszafelé oda, ahová már jártunk.

(Létezik egyenes úton is becsült, ahol

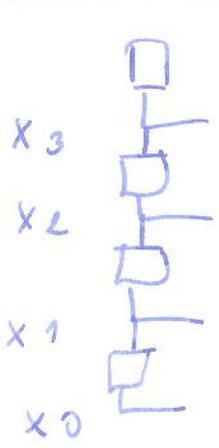
minden valószínűleg lehet megfigyelés ismét rajtunk)

Hf: 1 feladat egy matrix készítés

elemet felülről valóban mutatva
korreláció értékeit tartalmazza
=> diagonális mátrix átka

előáll-udgya: mikor a meg: minta bejött, hogy már nem üres
9-10... => 1. diagonális elem
=> csak a maradék részre kell áttelepíteni

kezeléssel előállított silyozd értékek



ettől független kell az $E(x_i, x_j)$ -t előállítani
a belső részeknek nem kell vele foglalkozni.

Legkisebb négyzetes hibájú becslők

$$z_k = f_k(a) + u_k \quad k=1, 2, \dots, N$$

kihívás: négyzetes

$$C(a, \hat{a}) = \sum_{k=1}^N (z_k - \underbrace{f_k(\hat{a})}_{\text{modell}})^2$$

↑
megfigyelés

ha a függvény...

$$z = Ua + u \quad \text{strukturális, akkor}$$

$$C(a, \hat{a}) = z^T z + (u \hat{a})^T (u \hat{a}) - z^T U \hat{a} - (U \hat{a})^T z$$

beillesztés, amit ismerünk, a végtelenben kifejezést a négyzetes kifejezés.

$$z_k = f_k(a) + u_k$$

megfigyelés strukturális kihívás regressziós feladat!

meretünk egy olyan illesztést csinálni,
ami minél jobban konstruálódik és az utolsó
legkisebb hibájú becslést állít elő.

A kritériumf. állítás par. nemzeti deriváltja legyen 0: • 113 •

$$\frac{\partial C(a, \hat{a})}{\partial \hat{a}} \Big|_{\hat{a}_{LS}} = 0$$

$$g(u, u)$$

$$\hat{g}(u)$$

$\hat{g} := g_0 + g_1 u$ elnevezés, általában beállított paraméter

hasznos elnevezésben keressük a mérésiértéket z_i .

felhasználjuk: $[U\hat{a}]^T = \hat{a}^T U^T \Rightarrow U^T U \hat{a} - U^T z = 0$

$$\hat{a}_{LS} = [U^T U]^{-1} U^T z$$

(iff: $\sum_{i=1}^n u_i = 1$
paraméter bázisban)

least square

Stabilitásai jól mutat,
a regresszió feladat
f. fordítójával megfoghatóan

A kritérium minimumtalak (súly is benne):

$$C(a, \hat{a}) = \sum_{i \in I} [z_i - f_i(\hat{a})] \underbrace{q_{ii}}_{\text{súlyok}} [z_i - f_i(\hat{a})]$$

nehézségi kritériumf.

$$Q = [q_{ii}] \text{ matrix.}$$

$$\hat{a}_{LS} = [U^T Q U]^{-1} U^T Q z$$

Súlyozott least square beállítás.

ha Q meggyengül: ha $Q = \sum_{i=1}^{I-1} \dots$ (Gauss-Markov, ortogonálisitási tétel)
G-M beállítás!

Súlyok variációjai, interpretációjai, mutatóid...

figyelmeztetések és értelmezések bemutatott példák jön.

Példa:

$$z_k = f_k(a) + n_k = e^{-a t_k} + n_k \quad \text{exponenciális lecsengés}$$

valamivel a minták?

$k = 1, 2, \dots, N$

$\hat{a} = ?$

$C(a, \hat{a})$ kritériumfnc.

$$C(a, \hat{a}) = \sum_{k=1}^N [z_k - f_k(\hat{a})]^2$$

$$\sum_{k=1}^N [z_k - f_k(\hat{a})] \frac{\partial f_k(\hat{a})}{\partial \hat{a}} \Big|_{\hat{a} = \hat{a}_w} = 0$$

$$\frac{\partial f_k(\hat{a})}{\partial \hat{a}} = -t_k e^{-\hat{a} t_k}$$

behelyettesít!

$$\sum_{k=1}^N [z_k t_k e^{-\hat{a} t_k}] - \sum_{k=1}^N t_k e^{-2\hat{a} t_k} \Big|_{\hat{a} = \hat{a}_w} = 0$$

megoldást általában nem létezik.
 \hat{a} Előbecslés...

Ugye, értem még ezzel az apparátussal a harmonikus ill. szögletes...
 Mozgóátlagos művelet (MA \equiv Moving Average) paraméterek LS becslet

Egy y_n kimeneti értéket úgy állítunk elő: (Lin. Kombi)

$$y_n = \sum_{k=0}^p b_k x_{n-k}$$

Ugye, értem még a paraméterek LS becsletét. (0-t zárezés)

megfigyelési mátrix

~~$$z = U b + n$$~~

$$z^T = [z_1, z_2, \dots, z_N]$$

$$b^T = [b_0, b_1, \dots, b_p]$$

ígyben direkt megfigyelések:
 $z_n = y_n + n$

$$\hat{b}_{LS} = [U^T U]^{-1} U^T z$$

bevdolajul egy mátrix Edzetet...

$$U^T U = \sum_{n=0}^N \begin{bmatrix} x_n^2 & \dots & x_{n-p} x_n \\ x_n x_{n-1} & x_n^2 & \\ \vdots & & \\ x_n x_{n-p} & & x_{n-p}^2 \end{bmatrix}$$

\hat{R}_{xx}

$$U^T z = \sum_{k=1}^N \begin{bmatrix} x_k z_k \\ x_{k-1} z_k \\ \vdots \\ x_{k-p} z_k \end{bmatrix} = \hat{R}_{xz}$$

\hat{r}_{xz}

ben. mint a
 az v. bef. lecseng.

$$\hat{b}_{LS} = \hat{R}_{xx}^{-1} \hat{R}_{xz}$$

(Wiener-Kopf-koz hasznal)

benneki m. értékek közül auto. korreláció

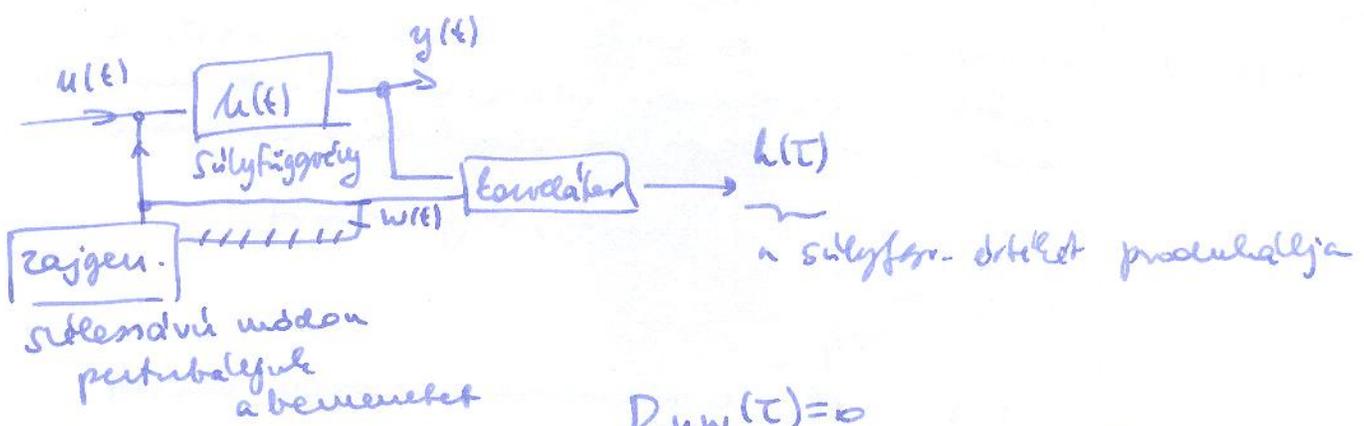
miért: amit meg tudunk figyelni, az az kapcsolásain
 egyben bírni, hogy ez LS technika valamit leírhat.
 → kiterjedt a hangulat apparátust vizsgálás miatt
 amit a regresszióval. Égésen feltételünk.
 → egy juttatás ide, L. egyre évesebb dolgot feltételünk.

kiindulás: mérés: véletlen, aprisan miért
 nincs szűrővel egyaránt, ami a
 való életben korlátozott forrás.

törvény: kell annak figyelembe, hogy a kódot elvétele mit mutat

Megjegyzés:

Korrelációs módszer: egy olyan eszköz, amivel az a tétel.
 Tulajdonságokat úgy lehet mérni, hogy
 minimális perturbáció a rendszer
 alappulcsát. Alkalmazható, hogy a fázis feltételünk kell,
 hogy produkál aktivitást, vagy szűrővel kell
 kor. utca.



$$R_{uw}(\tau) = 0$$

$$R_{ww}(\tau) = \sigma_w^2 \delta(\tau) ; \sigma_w = 1$$

$$R_{yw}(\tau) = E[y(t+\tau)w(t)] =$$

$$= E[h(t+\tau) * u(t+\tau)] \cdot w(t) +$$

$$+ E[h(t+\tau) * w(t+\tau)] \cdot w(t) =$$

$$= E \left\{ w(t) \int_{-\infty}^{\infty} w(\nu) h(t+\tau-\nu) d\nu \right\} = h(\tau)$$

$\sigma_w = 1$
egység normált.

a zajnem csupán káros a mérési feladatot rontja el
 a kor. utca. szép példája annak, hogy a determinisztikus
 működést minimális mértékben de zölés során végig
 ortogonális függvények. (függetlenség)

Főbb témák 2. zh. után a feladatokban

[2009.05.06.]

30 perc ráterhelés

2x60 perc munka.

Fellegre az előző korszak, de az 1. zh. utáni részről

optimális mérték

döntéselém.

bracketelém.

+ mai kérték.

- egyenlő feladatmegoldás

→ ezt a stílust igyekezzük megadni.

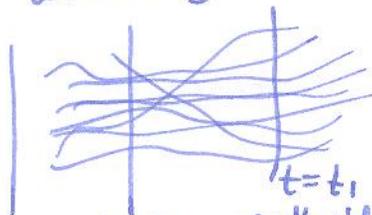
Ma: megjött miután téma, jelreprezentációs kétség a
stochasztikus jelhez ⇒ analógiahoz hoz példát.
ortogonális rendszerrel preferenciája
→ térbeli pontok koordinátáival megadható.

TKOMPONENS ANALÍZIS / FAKTORANALÍZIS / KARHUNEN-LOÈVE

TRANSZFORMÁCIÓ

stochasztikus jel → erre még nem rendelkezünk

$x(t, \omega)$ kétféle változó; az egyik változó az idő, a
másik a véletlenség modelljeitől han-
udalt ω ; sokasághoz rendelkezünk valamit.



időfüggvény-sokaság

$t=t_0$ adott időpillanatban vizsgálva valódi.

⇒ különböző időpillanatokban megismételhetők,
a véletlenség nem feltétlenül ugyanaz;

⇒ ezekben momentumok rendelkeznek, amik
az időben változnak.

egy fgv.-t utána: $\omega = \omega_0 \rightarrow$ sokaság vizsgálati technikák.
Ugyan generáljuk el a stochasztikus rendszert?

megoldandóként, reppont, ki optimális éppen
valamelyik reppontból.

→ alkalmas meggyűlés elveiben optimális reprezentációs

stochasztikus jelre is lehet, hogy a "közvetlen" kérték, de az
spóroljon. ⇒ adatredukció.

pl. Fourier-szfértétel első néhány komponens dominál.

Fő reprezentációt keresünk. Egy x vektortípus jellel. 1170
 Ismét olyan T trafó rendelkez, ami $y \rightarrow x$ ad.

$$x^T = [x_0, x_1, \dots, x_{N-1}]$$

$$y = Tx$$

$$y^T = [y_0, y_1, \dots, y_{N-1}]$$

T trafó felírása:

$$T^T = [\varphi_0, \varphi_1, \dots, \varphi_{N-1}]$$

ortogonális trafóval elvétel, vagy

$$\varphi_i^T \varphi_j = \delta_{ij} \quad (\text{csak } i=j \text{ esetben } \neq 0)$$

$$T^T T = I \Rightarrow \underline{T T^T = T^{-L}}$$

transzponált effektív az inverz.

hogyan áll elő x a trafó eleveiből?

$$x = T^T y = \sum_{i=0}^{N-1} y_i \varphi_i$$

lineáris kombináció.

Leffenn egy olyan \hat{x} reprezentáció, ami annyiban tér el, hogy $M-1$ -ig marad, ahol $M < N$ (adatredukció)

$$\hat{x} = \sum_{i=0}^{M-1} y_i \varphi_i + \sum_{i=M}^{N-1} b_i \varphi_i$$

nem remít iglyre az övület, csak M -et.

Válasz: Leffenn olyan φ -k, amikből az első M elemében leírható, a többi pedig nem jelentős

\Rightarrow az elhagyható nem befolyásolná.

Hogyan alakít, hibővületet tartunk létre?

$$\Delta x = x - \hat{x} = \sum_{i=0}^{N-1} y_i \varphi_i - \sum_{i=0}^{M-1} y_i \varphi_i - \sum_{i=M}^{N-1} b_i \varphi_i$$

de, elhagyott egy másik megközelítést alkalmazunk...

$M \dots N-1$ bözőti tapótera

\rightarrow fix, előre megadott értékekkel építjük tovább.

ent leírható, a Δx megközelítése:

$$\Delta x = \sum_{i=M}^{N-1} (y_i - b_i) \varphi_i$$

a liha felírása.

entdu a legrossz négyzet. eltelemben beresit a legjobb
vedelikest Ekt dologra: $b_i - r_e$ es $\varphi_i - r_e$.

négyzetes uiba: $(b_i - r_e)$

$$\varepsilon = E [|\Delta x|^2] = E [\Delta x^T \Delta x]$$

$\begin{bmatrix} \varphi_1^T \\ \vdots \\ \varphi_{N-1}^T \end{bmatrix} \begin{bmatrix} y_1 - b_1 \\ \vdots \\ y_{N-1} - b_{N-1} \end{bmatrix}$

$\varphi_i^T \varphi_j = \delta_{ij}$

$$= \sum_{i=1}^{N-1} E [(y_i - b_i)^2]$$

elivalas, minimumteresei:

$$b_i = E [y_i]$$

az egyit fajta minimalizalasi esper.

Mivel az y_i -ket azt tudjuk mondani, hogy a φ_i es r_e szabaly
ment $\varphi_i^T x$

trap szabaly $\rightarrow y_i = \varphi_i^T x \Rightarrow b_i = \varphi_i^T E[x] = \varphi_i^T \bar{x}$
 \uparrow
a'legp.

A kifejezett ε négyzetes uiba:

$$\varepsilon = \sum_{i=1}^{N-1} \varphi_i^T E[(x - \bar{x})(x - \bar{x})^T] \varphi_i = \sum_{i=1}^{N-1} \varphi_i^T C_{xx} \varphi_i$$

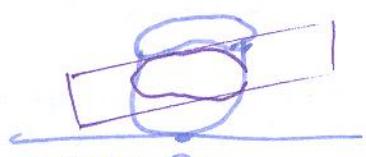
\uparrow
x kovariancia matrix
(atlagol vald ceteris
négyzetesen)

A négyzetes uiba függvénye az x rtok. foly.
kovarianciamatrixnak es a még mindig ismeretlen
 φ báziselemeknek...

Minimumis négyzetes uibát alapul véve hogyan
vadászunk meg φ -t? \Rightarrow 2. lépés.

$\varphi_i \quad i=0,1,2,\dots,N-1$ feltételes normálizálási probléma
 $\hookrightarrow \varphi_i^T \varphi_j = \delta_{ij}$

illusztráció: paraboloid



gradus 0.

\rightarrow itt egyidejű feltétel: b_i es r_e lehet ír elő.

\rightarrow nem a r_e es, hanem a b_i es r_e közötti szoros kapcsolat
keresni $\Rightarrow \hat{\varepsilon}$

Laplace multiplikatív módszer alkalmazása. -119.

$$\hat{\epsilon} = \epsilon - \sum_{i=M}^{N-1} \beta_i [\psi_i^T \psi_i - 1]$$

a β értéket beleválasztjuk!

\Rightarrow ennek keressük a minimumát.

\Rightarrow visszefelül bevezetjük a Lagrange szorzókat.

$$\frac{\partial \hat{\epsilon}}{\partial \psi_i} = 2 C_{xx} \psi_i - 2 \beta_i \psi_i$$

itt a deriváltak
lejjutnak,
és éppen
0.

ϵ feletti értéket használjuk
 $\epsilon = \sum_{i=M}^{N-1} \psi_i^T C_{xx} \psi_i$ } itt deriválva (vesszük le)
 multiplikatív tényező

$$C_{xx} \psi_i = \beta_i \psi_i \quad \text{az eredmény.$$

↑ sajátvektor ↑ sajátérték.

Ezt visszahelyettesítjük:

$$\epsilon_{min} = \sum_{i=M}^{N-1} \beta_i$$

Meghatározzuk az állapotos végső értékekben legyártott vektorokat

Eov. mátrix \Rightarrow sajátvektor, sajátérték \Rightarrow opt. beállítás.

γ Kovariancia mátrixa:

$$C_{yy} = T C_{xx} T^T = \text{diag} \langle \beta_0, \beta_1, \dots, \beta_{N-1} \rangle$$

diagonalmátrix, elemek a sajátértékek.

A T transformációt olyan egyenletrendszerrel oldjuk meg, ami diagonalmátrix; azaz a keresztmátrixok nulla, $\gamma_i - \gamma_j$ korrelálatlanok.

Σ : arra oldjuk fel a minimumot, hogy vektorunk ψ_i az első N sajátvektorok, vagyis nemcsak az első M-et, hanem az első N-1-et is figyelembe vesszük (M...N-1)

\Rightarrow periodikus jelölés, pl. EKG tömörítése.

\Rightarrow az EKG M olyan vektorból áll fel, ami a fő jellegzetességeit megadja, az elhagyott kiegészítő pedig kiegészíthető.

Utdord: a sajátoelet / sajátoelet problémával már nembehalde-
kor kothul, mielő a Wiener- kopt kareldio felübeten
akartuk jöl magogni => teufelyiducyok, met kard-reudner,
(kiciktekiesen yzaukz a megeldes)

meg pdr az a rdttekyüdt.

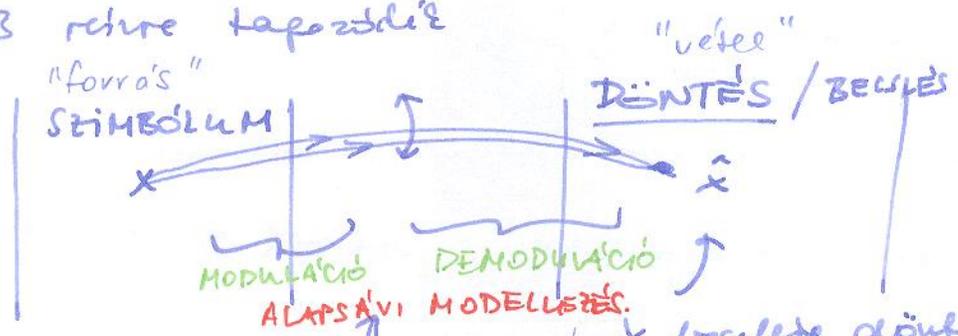
- adott srtodr foly => azououtata: x
emdr van egy kov. matnixa
Sajátoelet, sajátoelet-adottak

? :ha elspöndemk emzi elmet, manzi
ler a nögyetes lita minimuma
=> isreadat, keiz.

Kitekinet's jellegi ügyde.

1. FELÁTVITELI ZENSZERE K

- felettebb novos :) ; analogia jöl kizpítkehd.
- itt is 3 reire tapoztdie



csatama, mi szelafkand
rajos! => ut kell
vissradellitau.

x belete döntöten alapmit
amiat, u. detaldban
rix kizreletből vallesittdiek.

az attriteli csatama is a vétel oldalra is vannak specialitatal :
moduláció és demoduláció fajaiban

- hatékonyabb növelete
- jobbnor frekvenciátranszponció (vöröre riltetel)

=> a csatama modellere sokkal rdelebb kint, mint
az itt taljallak; a körkörösmodellben a csatama
modellere a rafebb fajndel.

=> mind jobb csatamihamudtsok is fontos; megredelmedelben
ez mastepp jleeri? megf.

modellerei: jelszítési rendszerre kell kiemelni az
alapsívi modelleket; a mod/demod.
részelt valóságszámú sereget.

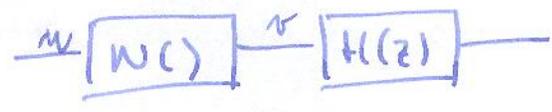
2. NEMLINEARIS

- > a vald vilds nemlin.
- > Eves a gyakorlati probléma, aled megmaradhatunk
a lineáris követések mellett.
- > szakasos lineáris.
- > a mérés. leideges a nemlin. dolga deude udli.
- > Söt dra, aled uelidegy ~~(dogy)~~ tárgy.
- > csak egy-két dologra feniük ki.
- a szuperpozíció lényeg. => szüntűgő.
a probléma nem dekomponálható.
=> semmi nem működik.

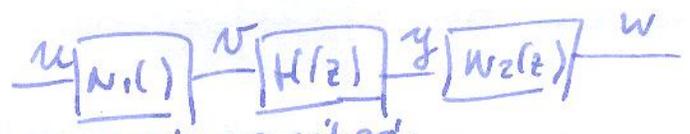
=> miúren jd, dehdudus cludlet!

• modellreható: (Specidlis beuud jilet alkalmasa
múuud, leud fignuduel
=> pl. aidda - folepadi dram.

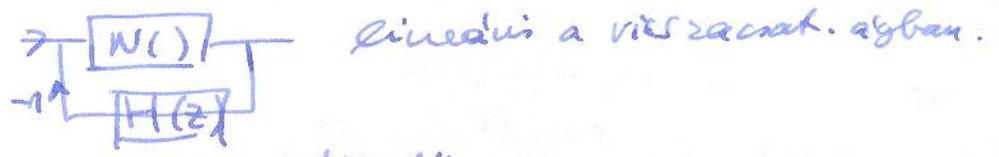
(Specidlis stultirale => stat es din. réhdudantata,
nemlin. => lin.



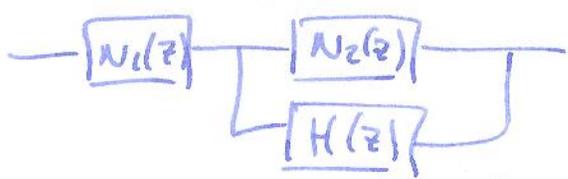
valtoratai:



Ett nemlineáris.
lelt visszacabca i

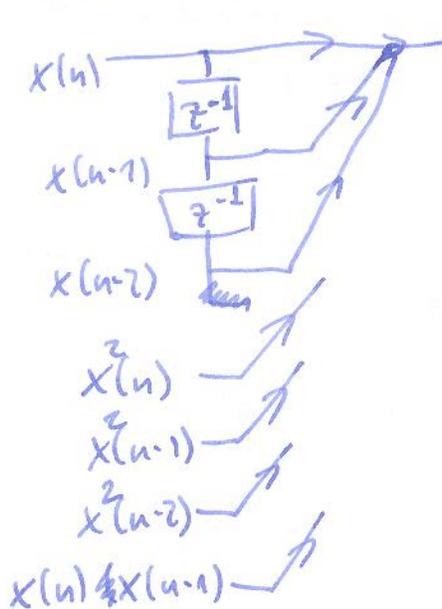


=> a leud fignuduel:



(Sofestetek => unkapanti lineárislet.
=> szakasos lineáris megafalala.

konvulció dehdudantata => Volterra - sorok.



„bővíthető” típus, hogy nem csak
 lin. elem.-ot, hanem nemlineáris
 elemeket is alkalmazhatunk.
 → együttesen látszik
 a mintfüggőség.

Áramlási rács

áramlási rács → pt. hosszúság: $N=2K-1$

↳ a bejövő mintákat napjainkban
 nemit vendég sorba, és a kimenetet
 adja ki a kimenetnek.

multiplikatív rendszer: $a \cdot b \Rightarrow \log a + \log b$
 nemlineáris → lineáris.

$$\frac{a(\omega)}{b(\omega)} \Rightarrow \log a(\omega) - \log b(\omega)$$

logaritmusos érv. alkalmazása;

3. VÁLTOZÁSDETEKTÁLÁS, FELTÁRÁS FELÜGYELETI HIBOK

technológiai felismerés; ugrás mértékén halad előre; környék vált. ugrás.

→ hibajelenség

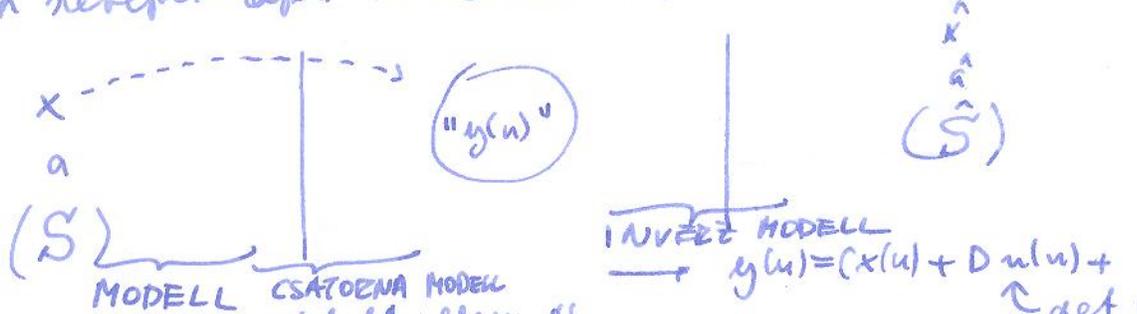
→ kimenet megváltozása.

felismerés egy ÁBRÁT.



Összefoglalás.

Körponti nevezet kapott a hirtelen tapasztalat.



következő nem mérhető jellemzők.
→ kellett előzetes ismeretek.

$$x(u+1) = Ax(u) + Bu(u)$$

↑ állapotátmeneti mátrix
↖ külső gerjesztés.

→ determinisztikus + stochasztikus.

⇒ egyszerűsített, diszkrét, lineáris modell.

$$x(u+1) = f(x(u), u(u))$$

PERTURBÁCIÓ → ahhoz, hogy a lineáris infó kelő mélységű legyen, alapsan meg kell vizsgálni a rendszert; olyan gerjesztést kell találni, ami a rendszer összes tulajdonságát feltérképezi.

⇒ a vizsgálati komplexitás a rendszer komplexitásával kell összemérhető legyen.

"trükkös játék"

pl. másodrendű jellet olyan gerjesztéssel is lehet feloldani, ami elsőrendű rendszert mutat.

KORRELÁCIÓS MÉRÉSTECH

⇒ névből is látszik, hogy folyamatosan nem volt szabad perturbációt belevinni!

Az $y(u)$ értékek a ravaság hatására követelményben nem elegendőek → többrétegű mérés.

⇒ az ismeretanyag birtokában próbáljuk visszahatározni: (y -ből x ; inverz modell)

↓ MEGFIGYELŐ SÉMA

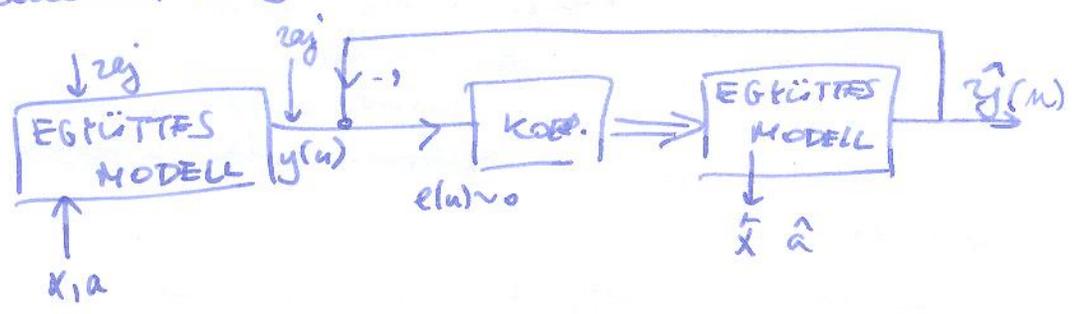
KALMAN PREDIKTOR
PARAMÉTER ADAPTÁCIÓ

} $a \cdot x$
(constant) (állandó)
par.=? állapot (representáció vektor)

} ha ilyen a struktúra, mindig szükséglet érzésem!

⇒ közös séma.

A feldolított egjttes modell valaminymen $y(u)$ -t
 modelled \Rightarrow megcinaldjud a valmunkigeben: $\hat{y}(u)$
 \Rightarrow ddall a lltajcl, ami addig ngydona az egjttes
 modellet, meg az ellet lltaj Eb. \neq nem len.



lea van ngydntkcs katas, nem az $e(u)$ minimalizalcs,
 hanem az $E[e^2(u)]$ minimalizalcs a cel.

feltetelent, hogy valaminymen z(u) ngydntkcsidit kap az
 egjttes modellet is a ngyfzclcs
 \Rightarrow Kalman-predictor

alstruktura: Kalman-nnd.
 \rightarrow az $x(u)$ -et ddltotta eld az
 $x(u-1)$ cs $u(u)$ ngyfzclcsvel.

$$x(u) = f[x(u-1); u(u)]$$

\hookrightarrow Ertelbi becsles finomítása.

Specialis dcljcl:

- rekurziv transformacids.
- \rightarrow ngyfzclcs filardfidval jclreprezentacids
- \rightarrow komponensclktcl lin. Eomb.-bal jcl ddallltata
- \rightarrow transformacids: Sltelydnyzcl ddallltata
- \rightarrow mndclnt rekurziv!
- \rightarrow (ngyfzclcs sdma)

- adaptiv dclrtclcs
- \rightarrow ngyfzclcsdmdbe LMS eljclrtcl.
- \rightarrow lltajreudner analclzclt utclclt.

$$x(u+1) - \hat{x}(u+1) = (A - GC) (x(u) - \hat{x}(u))$$

parametclrdclcs:

$$V(u+1) = \begin{pmatrix} & \end{pmatrix} V(u)$$

→ blokkos feldolgozó

→ differenciák és ut transzformáció. (jeltranszformáció)

• Wiener-műnd. ⇒ adaptív lineáris kombinációval kapni.

→ az a FIR-sűrűvel is

kapcsolatba hozható a regressziós vektor megfelelő lefolytatása után (tesztelés)

→ rekurzív előállítók

→ lényege mindig az, hogy a tén. időpillanat az aktuálisnak bizonyos divék/súlyozott értéke.

v. korrekció, új mérték figyelmeztetésre

$$x(n+1) = () x(n) + KORR. (új mérték)$$

→ optimális műnd alkalmazásai mindig

(Kalman-műnd, Kalman-predictor)

ZH: • jelreprezentáció, Wiener-Hopf módszer új!

• adaptív algoritmusok tulajdonságai; leibarcendések

μ megválasztása, stabilitáselméleti megközelítés.

↙ belső energia csökkenése

$$V^T(n+1)V(n+1) = (\mu) V^T(n)V(n)$$

$$\mu \neq 0 \quad 0 < \mu < \frac{1}{x^T(n)x(n)} \text{ minden } n\text{-re!}$$

• Kalman-predictor jellemzői

→ a lemezek komplekt volt, de adatok megadással működtetve viselkedésük.

• döntéshozatali összefoglaló.

→ határolás, kiadástechnika alapfeladat

→ igen/nem; 0/1

→ döntési rajos Eövillemények zörött

→ likelihood-ardny számítás zello' adattal

→ döntési Eöszöb meghatározás.

• becslésműnd.

→ Bayes-becslési világ; 3 esetben adható.

- négyzetes krit.
- abszolút
- "csörög"

} a-posteriori valószínűségvis. re alapra adtuk optimális becslést. f. (a/z)

→ ha az a-pertinens meghatározható...

- 1.) $E[]$
 - 2.) median
 - 3.) maximum
- } adja az optimális becsült paramétert

⇒ egyenlítőérték / median / maximum a becsléshez

⇒ egyenlítőérték alapján viselkedés, de az

⇒ max likelihood → jól követhető a valószínűségi paramétert

a ~~max~~ likelihood: szelvény - lépés

⇒ Bayes módszer. ⇒ valószínűségi

→ négyes

⇒ 3. szint. négyes becsül.

pl. lépés, egyenlítő

becsülés a-pertinens-ből kiindulva

⇒ $E()$, median, max. likelihood.

ha nincs, a 3. egyenlítő;

ha nem, a 3. nem egyenlítő egybe

→ korrelációs mértékszámok

• stochasztikus jelölés optimális reprezentációja (falkonváltás)

⇒ convex sajátérték / sajátvektor probléma!

⇒ értékes mérések adatfeldolgozás, opt. értékelés.

• értékelés 2H - példát new general

(relaxáció / analógia; változókészlet)