

Prirodoslovno-matematički fakultet  
Matematički odsjek  
Sveučilište u Zagrebu

# UVOD U TEORIJU UPRAVLJANJA

## Predavanje 06 - Kalmanov filter

12. siječnja 2024.

Sastavio: Zvonimir Bujanović



# LTI SUSTAVI U DISKRETNOM VREMENU

# LTI sustavi u diskretnom vremenu

U mnogim primjenama, dinamika sustava se odvija u diskretnom vremenu.

- ekonomija  $\rightsquigarrow$  cijena goriva/tečaj na dnevnoj/tjednoj bazi;
- digitalni sustavi  $\rightsquigarrow$  stanja se mijenja iz takta u takt procesora;
- digitalizacija kontinuiranih procesa  $\rightsquigarrow$  lsim; digitalni zapis slike/zvuka.

## Definicija (LTI sustav u diskretnom vremenu)

Za zadane matrice  $A \in \mathbb{R}^{n \times n}$ ,  $B \in \mathbb{R}^{n \times m}$ ,  $C \in \mathbb{R}^{p \times n}$ ,  $D \in \mathbb{R}^{p \times m}$ , te za zadani ulaz  $u_0, u_1, \dots$ , formulama

$$x_{k+1} = Ax_k + Bu_k, \quad x_0 \text{ zadan}$$

$$y_k = Cx_k + Du_k.$$

za  $k = 0, 1, 2, \dots$  opisan je **LTI SUSTAV U DISKRETNOM VREMENU**, zapisan u **PROSTORU STANJA**.

Niz  $(x_k)_k$  zovemo **STANJA SUSTAVA**, a  $(y_k)_k$  zovemo **IZLAZ SUSTAVA**.

Teorija ovih sustava je posve analogna kontinuiranom slučaju, kao i pojmovi koji se pojavljuju, no karakterizacije svojstava su tipično nešto drugačije.

# LTI sustavi u diskretnom vremenu

U control toolboxu:

```
# Diskretni LTI sustav.  
# dt je vremenska razlika između susjednih koraka (realan broj).  
sys_t = ss(A, B, C, D, dt);  
  
# Slučajno generirani stabilni diskretni LTI sustav.  
sys_t = drss(n, p, m);
```

## Teorem

Stanja i izlazi diskretnog LTI sustava su dani sa:

$$x_k = A^k x_0 + \sum_{i=0}^{k-1} A^{k-1-i} B u_i,$$
$$y_k = C A^k x_0 + \left( \sum_{i=0}^{k-1} C A^{k-1-i} B u_i \right) + D u_k.$$

# Dohvatljivost, upravljivost, osmotrivost

## Definicija

Stanje  $\tilde{x}$  je **DOHVATLJIVO** ako, uz  $x_0 = 0$ , postoji  $k \in \mathbb{N}$  i niz  $u_0, u_1, \dots, u_{k-1}$  takvi da  $x_k = \tilde{x}$ .  
LTI sustav, odnosno, par  $(A, B)$  je **UPRAVLJIV** ako je  $\tilde{x}$  dohvatljivo za svaki  $x \in \mathbb{R}^n$ .

Sustav je **OSMOTRIV** ako postoji  $k$  takav da, na temelju  $u_0, \dots, u_{k-1}, y_0, \dots, y_k$  možemo jednoznačno odrediti  $x_0$ .

## Teorem

Par  $(A, B)$  je upravlјiv ako i samo ako  $\text{rank } C(A, B) = n$ , gdje je  
 $C(A, B) = [B \ AB \ A^2B \ \dots \ A^{n-1}B]$  **MATRICA UPRAVLJIVOSTI**.

Par  $(C, A)$  je osmotrov ako i samo ako je  $\text{rank } O(C, A) = n$ , gdje je  $O(C, A) =$

$$\begin{bmatrix} C \\ CA \\ \vdots \\ CA^{n-1} \end{bmatrix}$$

**MATRICA OSMOTRIVOSTI.**

Uočimo da je za osmotrvost ponovno dovoljno promatrati samo autonomni sustav

$$x_{k+1} = Ax_k,$$

$$y_k = Cx_k.$$

# Dohvatljivost, upravljivost, osmotrivost

## Teorem (PBH test)

Diskretni LTI sustav je

- *upravljiv akko*  $\text{rank} \begin{bmatrix} A - \lambda I & B \end{bmatrix} = n$ , za sve  $\lambda \in \mathbb{C}$ .
- *osmotrov akko*  $\text{rank} \begin{bmatrix} A - \lambda I \\ C \end{bmatrix} = n$ , za sve  $\lambda \in \mathbb{C}$ .

## Teorem

- 1 Neka je  $\dim \mathcal{C}(A, B) = r$ , gdje je  $\mathcal{C}(A, B) = \text{Im } C(A, B)$ . Tada postoji  $T$  takva da

$$\tilde{A} = TAT^{-1} = \begin{bmatrix} \tilde{A}_{11} & \tilde{A}_{12} \\ 0 & \tilde{A}_{22} \end{bmatrix}, \tilde{B} = TB = \begin{bmatrix} \tilde{B}_1 \\ 0 \end{bmatrix}, \text{gdje je } \tilde{A}_{11} \in \mathbb{R}^{r \times r}, \tilde{B}_1 \in \mathbb{R}^{r \times m}, \text{ te}$$

( $\tilde{A}_{11}, \tilde{B}_1$ ) je upravljiv.

↔ FORMA UPRAVLJIVOSTI.

- 2 Neka je  $\text{rank } O(C, A) = r$ . Tada postoji  $T$  takva da  $\tilde{A} = TAT^{-1} = \begin{bmatrix} \tilde{A}_{11} & 0 \\ \tilde{A}_{21} & \tilde{A}_{22} \end{bmatrix}$ ,

$$\tilde{C} = CT^{-1} = \begin{bmatrix} \tilde{C}_1 & 0 \end{bmatrix}, \text{gdje je } \tilde{A}_{11} \in \mathbb{R}^{r \times r}, \tilde{C}_1 \in \mathbb{R}^{p \times r}, \text{ te } (\tilde{C}_1, \tilde{A}_{11}) \text{ je osmotrov.}$$

↔ FORMA OSMOTRIVOSTI.

## Definicija

Za diskretni LTI sustav promotrimo pridruženi autonomni sustav

$$x_{k+1} = Ax_k,$$

tj. pretpostavimo  $u_k = 0$  za  $k \in \mathbb{N}_0$ . Sustav je **INTERNO STABILAN** ako za sve  $x_0$  vrijedi  
 $x_k \xrightarrow{k} 0$ .

## Teorem

Diskretni LTI sustav je interno stabilan ako i samo ako sve svojstvene vrijednosti od A leže u unutrašnjosti jedinične kružnice u  $\mathbb{C}$ .

Matrice A čiji spektar leži u unutrašnjosti jedinične kružnice zovemo **DISKRETNOSTABILNE** ili **D-STABILNE**.

## Teorem

Neka je  $M > 0$ . Tada je  $A$  d-stabilna ako i samo ako jednadžba

$$AXA^T - X + M = 0$$

ima jedinstveno rješenje  $X$  i ako za njega vrijedi  $X > 0$ .

Gornju jednadžbu zovemo **STEINOVA** ili **DISKRETNA LYAPUNOVLJEVA** jednadžba.  
Eksplicitno rješenje:

$$X = \sum_{k=0}^{\infty} A^k M (A^T)^k.$$

Python:

```
X = dlyap(A, M);
```

## Definicija

Neka je  $A$  d-stabilna matrica.

$P_D = \sum_{k=0}^{\infty} A^k BB^T (A^T)^k$  zovemo **DISKRETNI GRAMIJAN UPRAVLJIVOSTI**.

$Q_D = \sum_{k=0}^{\infty} (A^T)^k C^T CA^k$  zovemo **DISKRETNI GRAMIJAN OSMOTRIVOSTI**.

## Teorem

Neka je  $A$  d-stabilna matrica.

- 1  $P_D$  je rješenje Steinove jednadžbe  $AXA^T - X + BB^T = 0$ .

Vrijedi:  $P_D > 0$  ako i samo ako je  $(A, B)$  upravljiv.

- 2  $Q_D$  je rješenje Steinove jednadžbe  $A^T X A - X + C^T C = 0$ .

Vrijedi:  $Q_D > 0$  ako i samo ako je  $(C, A)$  osmotrov.

# Frekvencijska domena

Ulogu Fourierove transformacije preuzima tzv. Z-transformacija.

- Niz  $(u_k)_{k \in \mathbb{Z}}$  preslikava se u  $\hat{u} = Z(u)$ .
- $\hat{u} : \mathbb{C} \rightarrow \mathbb{C}$  je dan formulom

$$\hat{u}(z) = \sum_{k=-\infty}^{\infty} u_k z^{-k}.$$

- Inverzna Z-transformacija je dana formulom

$$u_k = \frac{1}{2\pi i} \int_{\Gamma} \hat{u}(z) z^{k-1} dz,$$

gdje je  $\Gamma$  zatvorena kontura oko ishodišta.

## Teorem

Za diskretni LTI sustav vrijedi:  $\hat{y}(z) = \hat{G}(z)\hat{u}(z)$ .

Ovdje je  $\hat{G}(z) = C(zI - A)^{-1}B + D$  **FUNKCIJA TRANSFERA**.

Za diskretne sustave, "frekvencijski odziv" za frekvenciju  $\omega$  odgovara funkciji transfera izračunatoj u točki  $z = e^{i\omega T}$  na jediničnoj kružnici.  $T$ =vremenski korak diskretizacije.


Python:

```
f = evalfr(sys_t, z); # Vraća funkciju transfera izračunatu u točki z.  
H = tf(broj, naz, dt); # Zadavanje LTI pomoću funkcije transfera.
```

# Sustav zatvorene petlje - Feedback kontrola

Cilj kontrole sustavom zatvorene petlje:

- Odrediti  $K$  takav da je spoj  $G$  i  $K$  interno stabilan (uz eventualnu optimizaciju).



- Sustav  $G$ :

$$x_{k+1} = Ax_k + Bu_k;$$

$$y_k = Cx_k + Du_k.$$

- Kontroler  $K$ :

$$\check{x}_{k+1} = \check{A}\check{x}_k + \check{B}\check{u}_k,$$

$$\check{y}_k = \check{C}\check{x}_k + \check{D}\check{u}_k.$$

Statički state feedback:

- $y_k = x_k = \check{u}_k$ ,
- $\check{y}_k = u_k = Kx_k \rightsquigarrow \check{A} = 0, \check{B} = 0, \check{C} = 0, K = \check{D}$ .

Spoj GK:

- $x_{k+1} = (A + BK)x_k$
- Cilj:  $A + BK$  je d-stabilna.

## Definicija

Par  $(A, B)$  je **D-STABILIZABILAN** ako postoji  $K$  takva da je  $A + BK$  d-stabilna matrica.

Par  $(C, A)$  je **D-OPAZIV** ako postoji  $L$  takva da je  $A + LC$  d-stabilna matrica.

## Teorem

Sljedeće tvrdnje su ekvivalentne:

- ① Par  $(A, B)$  je d-stabilizabilan.
- ② Za sve  $\lambda \in \mathbb{C}$  vrijedi:  $|\lambda| \geq 1 \implies \text{rank} \begin{bmatrix} A - \lambda I & B \end{bmatrix} = n$ .
- ③ Ako je  $\lambda$  svojstvena vrijednost od  $A$ ,  $|\lambda| \geq 1$ , a  $x$  lijevi svojstveni vektor za  $\lambda$ , onda  $x^* B \neq 0$ .

Slično, par  $(C, A)$  je d-opaziv ako i samo ako za sve  $\lambda \in \mathbb{C}$  vrijedi

$$|\lambda| \geq 1 \implies \text{rank} \begin{bmatrix} A - \lambda I \\ C \end{bmatrix} = n.$$

# Diskretni LQR problem

Diskretni LQR problem:

- Odrediti  $u_{\min}$  koji minimizira  $J(u) = \sum_{k=0}^{\infty} (x_k^T Q x_k + u_k^T R u_k)$  za zadane matrice  $Q, R$ , te  $x_{k+1} = Ax_k + Bu_k$ .

## Teorem

Neka je  $(A, B)$  d-stabilizabilan i  $(Q, A)$  d-opaziv.

Rješenje diskretnog LQR problema je dano sa  $u_k = Kx_k$ , gdje je

$$K = -(R + B^T X B)^{-1} B^T X A,$$

a  $X$  je jedinstveno poz. semidefinitno rješenje **DISKRETNIE RICCATIJEVE JEDNADŽBE**

$$A^T X A - X + Q - A^T X B (R + B^T X B)^{-1} B^T X A = 0.$$

Sustav zatvorene petlje

$$x_{k+1} = (A + BK)x_k$$

je d-stabilan, a  $J(u_{\min}) = x_0^T X x_0$ .

Python:

```
# Vraća -K iz gornjeg teorema, tj. A-BK je d-stabilan.  
[X, Lam, K] = dare(A, B, Q, R);
```

# DISKRETNI KALMANOV FILTAR


## Nedostatak LQR:

- moramo imati pristup svim stanjima ( $y = x$ );
- jedno rješenje: dodati promatrač koji će napraviti aproksimaciju.

## Općeniti problemi kod implementacije kontrolera:

- greške u modeliranju sustava, vanjske smetnje u inputu;
- greške u mjerenuju outputu  $y$ .

## Pristupi koji uzimaju gore navedene greške u obzir:



Izdvojimo sve greške u podsustav  $\Delta$ ; sada pretpostavljamo da je modelirani sustav  $G$  savršen.

- ▶ cilj: dodati kontroler koji stabilizira  $G_\Delta$  za sve “malene”  $\Delta$ .
- ▶ obično se gleda  $\mathcal{H}_\infty$ -norma  
~~ problem  $\mathcal{H}_\infty$  sinteze.

## 2 Stohastički model

- ▶ greške i smetnje se dodaju u jednadžbe kao slučajne varijable;
- ▶ stanja sustava postaju također slučajne varijable.

Pristup 1  $\rightsquigarrow$  2. semestar

Pristup 2  $\rightsquigarrow$  Kalmanov filter

Sustav koji opisuje stanja je stohastički:

$$x_{k+1} = Ax_k + Bu_k + Fw_k, \quad F \in \mathbb{R}^{n \times n_w}, \quad w_k \in \mathbb{R}^{n_w}.$$

Ovdje:

- $w_k$  je slučajna varijabla (šum);
- opisuje npr. vanjsku smetnju i ostale elemente na koje nemamo utjecaj;
- prepostaviti ćemo da ima normalnu distribuciju.


Uz ove pretpostavke će Kalmanov filter dati optimalnu aproksimaciju stanja.

- Ako  $w_k$  nije normalna  $\rightsquigarrow$  daje najbolju linearну aproksimaciju.

Pretpostavljamo samo slučaj "bijelog šuma":

- $w_k$  je nezavisna od  $w_0, w_1, \dots, w_{k-1}$ .
- $w_k$  je nezavisna od  $x_0$ .

Sada je i stanje  $x_k$  također slučajna varijabla!



Iz jednadžbe stohastičkog LTI sustava:

- Ako znamo distribuciju od  $w_k$ , možemo ju odrediti i za  $x_k$ .
- Uz bijeli šum  $w_k$ , ovo je Markovljev proces:

$$\mathbb{P}\{x_{k+1} \mid x_0, x_1, \dots, x_k\} = \mathbb{P}\{x_{k+1} \mid x_k\}.$$

# Multivarijatna normalna razdioba

## Definicija

Slučajni vektor  $x = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n$  ima **MULTIVARIJATNU NORMALNU RAZDIOBU** ako postoji slučajni vektor  $z \in \mathbb{R}^\ell$ , matrica  $A \in \mathbb{R}^{n \times \ell}$ , te vektor  $\mu \in \mathbb{R}^n$  takva da

$$x = Az + \mu,$$

gdje je  $z = [z_1, z_2, \dots, z_\ell]^T$ , te  $z_j \sim \mathcal{N}(0, 1)$  nezavisne slučajne varijable.

Pišemo  $x \in \mathcal{N}(\mu, \Sigma)$ , gdje je  $\Sigma = AA^T$ .

Vrijedi:

- $\mathbb{E}[x] = \mu \rightsquigarrow$  očekivanje;
- $\mathbb{E}[(x - \mu)(x - \mu)^T] = \mathbb{E}\left[\left[(x_i - \mu_i)(x_j - \mu_j)\right]_{ij}\right] = \Sigma \rightsquigarrow$  kovarijacijska matrica.

## Propozicija

Neka je dan stohastički diskretni LTI sustav takav da slučajne varijable  $x_0$  i  $w_k$  imaju multivarijatnu normalnu razdiobu, za svaki  $k \in \mathbb{N}_0$ .

Tada slučajna varijabla  $x_k$  također ima multivarijatnu normalnu razdiobu, za svaki  $k \in \mathbb{N}$ .

## Problem filtriranja

Dodatno, uz jednadžbu LTI sustava imamo mjerena (output) koja daju informacije o sustavu. Mjerenja (senzori) mogu biti nepouzdani.

Scenario koji nas zanima:

- Sustav se u trenutku  $k$  ( $k = 0, 1, \dots$ ) nalazi u nepoznatom stanju  $x_k^{\text{true}}$ .
- Imamo samo indikaciju (dobru ili ne) o vjerojatnosnoj razdiobi tog stanja:  
 $x_k \sim \mathcal{N}(\mu_k, \Sigma_k)$ .
- Vjerojatnosni model sustava je:

$$x_{k+1} = Ax_k + Bu_k + Fw_k, \quad w_k \sim \mathcal{N}(0, \Sigma_w), \quad \Sigma_w = \mathbb{E}[w_k w_k^T],$$

$$y_{k+1} = Cx_{k+1} + Du_{k+1} + v_{k+1}, \quad v_{k+1} \sim \mathcal{N}(0, \Sigma_v), \quad \Sigma_v = \mathbb{E}[v_{k+1} v_{k+1}^T].$$

Ovdje slučajna varijabla  $v_{k+1}$  modelira nepouzdanost senzora.

- U trenutku  $k + 1$  imamo stvarno očitanje senzora (mjerenje)  $y_{k+1}^{\text{true}}$ , nastalo na temelju stvarnog trenutnog stanja sustava  $x_{k+1}^{\text{true}}$ .

Sada imamo dvije potencijalno konfliktnе vrijednosti za  $y_{k+1}$ :


- ① Naš model za izlaz stohastičkog LTI sustava očekuje  $\mathbb{E}[y_{k+1}]$ .
- ② Stvarno očitanje senzora je  $y_{k+1}^{\text{true}}$ .

# Problem filtriranja

Zadatak:

- Na temelju mjerena  $y_{k+1}^{\text{true}}$  prilagoditi parametre distribucije slučajne varijable  $x_{k+1}$ .
- Drugim riječima, zanima nas sljedeća funkcija gustoće:

$$f(x_{k+1} \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}}, \dots, y_{k+1} = y_{k+1}^{\text{true}}).$$



Intuicija:


- Imamo automobil koji se giba konstantnom brzinom.
- $x_k = \begin{bmatrix} \text{pozicija}_k \\ \text{brzina}_k \end{bmatrix}$
- Imamo GPS koji mjeri samo poziciju (neprecizno):  
 $y_k^{\text{true}} = \text{pozicija}_k^{\text{true}} + v_k.$
- U trenutku 0 imamo samo  $y_0^{\text{true}}$ , pa brzina može biti bilo što.
- Slika prikazuje moguću distribuciju stanja  $x_0$  (crveno).

# Problem filtriranja

Zadatak:

- Na temelju mjerenja  $y_{k+1}^{\text{true}}$  prilagoditi parametre distribucije slučajne varijable  $x_{k+1}$ .
- Drugim riječima, zanima nas sljedeća funkcija gustoće:

$$f(x_{k+1} \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}}, \dots, y_{k+1} = y_{k+1}^{\text{true}}).$$




Intuicija:

- Pomoću modela (konstantna brzina) u idućem koraku imamo:  
$$x_{k+1} = \begin{bmatrix} \text{pozicija}_k + dt \cdot \text{brzina}_k \\ \text{brzina}_k \end{bmatrix} + w_{k+1}.$$
- Na temelju modela možemo izračunati distribuciju stanja  $x_{k+1}$ .
- Slika prikazuje moguću distribuciju stanja  $x_1$  (plavo).

# Problem filtriranja

Zadatak:

- Na temelju mjerena  $y_{k+1}^{\text{true}}$  prilagoditi parametre distribucije slučajne varijable  $x_{k+1}$ .
- Drugim riječima, zanima nas sljedeća funkcija gustoće:  
 $f(x_{k+1} \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}}, \dots, y_{k+1} = y_{k+1}^{\text{true}}).$



Intuicija:


- No u trenutku 1 imamo novo (nepouzdano) mjerjenje  $y_1^{\text{true}}$ .
- Slika prikazuje:
  - ▶ moguću distribuciju stanja  $x_1$  dobivenu pomoću modela (plavo);
  - ▶ moguću distribuciju stanja  $x_1$  temeljem mjerena (zeleno).
- Nakon mjerena vidimo da se stanje  $x_1$  nalazi u presjeku plavog i zelenog!

# Problem filtriranja

Zadatak:

- Na temelju mjerjenja  $y_{k+1}^{\text{true}}$  prilagoditi parametre distribucije slučajne varijable  $x_{k+1}$ .
- Drugim riječima, zanima nas sljedeća funkcija gustoće:

$$f(x_{k+1} \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}}, \dots, y_{k+1} = y_{k+1}^{\text{true}}).$$



Intuicija:

- Uzimajući u obzir i stanje dobiveno modelom i mjerjenje, možemo dobiti puno bolju informaciju o mogućoj distribuciji stanja!
- Slika prikazuje distribuciju  $f(x_1 \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}})$  (crveno).

# Izvod Kalmanovog filtra

Cilj:

- Odrediti PDF  $f(x_{k+1} \mid y_0 = y_0^{\text{true}}, y_1 = y_1^{\text{true}}, \dots, y_{k+1} = y_{k+1}^{\text{true}})$ .
  - Pokazuje se da je to ponovno multivarijatna normalna razdioba (bez dokaza)!
  - Sa  $x_k \sim \mathcal{N}(\mu_k, \Sigma_k)$  označimo sluč. varijablu s tom razdiobom koraku  $k$ .
  - Sada moramo odrediti parametre  $\mu_{k+1}, \Sigma_{k+1}$  za  $x_{k+1} \sim \mathcal{N}(\mu_{k+1}, \Sigma_{k+1})$ .
- 1 Predikcija: što jednadžbe sustava daju za stanje u idućem koraku?

Stavimo:

$$\tilde{x}_{k+1} = Ax_k + Bu_k + Fw_k, \quad \tilde{x}_{k+1} \sim \mathcal{N}(\tilde{\mu}_{k+1}, \tilde{\Sigma}_{k+1}), \quad \tilde{\mu}_{k+1}, \tilde{\Sigma}_{k+1} = ?$$

Zasad ne uzimamo mjerjenje  $y_{k+1}^{\text{true}}$  u obzir.

Očekivanje:

$$\begin{aligned}\tilde{\mu}_{k+1} &= \mathbb{E}[Ax_k + Bu_k + Fw_k] = \mathbb{E}[Ax_k] + \mathbb{E}[Bu_k] + \mathbb{E}[Fw_k] \\ &= A\mathbb{E}[x_k] + Bu_k + F\mathbb{E}[w_k] \\ &= A\mu_k + Bu_k.\end{aligned}$$

# Izvod Kalmanovog filtra

- 1 Predikcija: što jednadžbe sustava daju za stanje u idućem koraku?

$$\tilde{x}_{k+1} = Ax_k + Bu_k + Fw_k, \quad \tilde{x}_{k+1} \sim \mathcal{N}(\tilde{\mu}_{k+1}, \tilde{\Sigma}_{k+1}), \quad \tilde{\mu}_{k+1}, \tilde{\Sigma}_{k+1} = ?$$

Zasad ne uzimamo mjerenoje  $y_{k+1}^{\text{true}}$  u obzir.

Očekivanje:  $\tilde{\mu}_{k+1} = A\mu_k + Bu_k$ .

Uvedimo odstupanje:

$$\tilde{e}_{k+1} := \tilde{x}_{k+1} - \tilde{\mu}_{k+1} = Ax_k + Bu_k + Fw_k - A\mu_k - Bu_k = Ae_k + Fw_k,$$

gdje je  $e_k = x_k - \mu_k$ .

Matrica kovarijacije:

$$\begin{aligned}\tilde{\Sigma}_{k+1} &= \mathbb{E}[(\tilde{x}_{k+1} - \tilde{\mu}_{k+1})(\tilde{x}_{k+1} - \tilde{\mu}_{k+1})^T] = \mathbb{E}[\tilde{e}_{k+1}\tilde{e}_{k+1}^T] \\ &= \mathbb{E}[(Ae_k + Fw_k)(Ae_k + Fw_k)^T] \\ &= \mathbb{E}[Ae_k e_k^T A^T + Fw_k e_k^T A^T + A e_k w_k^T F^T + F w_k w_k^T F^T] \\ &= A \mathbb{E}[e_k e_k^T] A^T + F \mathbb{E}[w_k e_k^T] A^T + A \mathbb{E}[e_k w_k^T] F^T + F \mathbb{E}[w_k w_k^T] F^T \\ &= \left[ w_k, e_k \text{ nezavisne } \Rightarrow \mathbb{E}[w_k e_k^T] = \mathbb{E}[w_k] \mathbb{E}[e_k^T] = 0 \right] \\ &= A \Sigma_k A^T + F \Sigma_w F^T.\end{aligned}$$

# Izvod Kalmanovog filtra

- 2 Procjena mjerena: što jednadžbe sustava daju za izlaz u idućem koraku?

$$\tilde{y}_{k+1} = C\tilde{x}_{k+1} + Du_{k+1} + v_{k+1}, \quad \tilde{y}_{k+1} \sim \mathcal{N}(\tilde{\mu}_{k+1}^Y, \tilde{\Sigma}_{k+1}^Y), \quad \tilde{\mu}_{k+1}^Y, \tilde{\Sigma}_{k+1}^Y = ?$$

Zasad ne uzimamo mjereno  $y_{k+1}^{\text{true}}$  u obzir.

Očekivanje:

$$\begin{aligned}\tilde{\mu}_{k+1}^Y &= \mathbb{E}[\tilde{y}_{k+1}] = \mathbb{E}[C\tilde{x}_{k+1} + Du_{k+1} + v_{k+1}] = C\mathbb{E}[\tilde{x}_{k+1}] + Du_{k+1} + \mathbb{E}[v_{k+1}] \\ &= C\tilde{\mu}_{k+1} + Du_{k+1}.\end{aligned}$$

Uvedimo odstupanje:

$$\tilde{e}_{k+1}^Y = \tilde{y}_{k+1} - \tilde{\mu}_{k+1}^Y = C(\tilde{x}_{k+1} - \tilde{\mu}_{k+1}) + v_{k+1} = C\tilde{e}_{k+1} + v_{k+1}.$$

Matrica kovarijacije:

$$\begin{aligned}\tilde{\Sigma}_{k+1}^Y &= \mathbb{E}[\tilde{e}_{k+1}^Y (\tilde{e}_{k+1}^Y)^T] = \mathbb{E}[(C\tilde{e}_{k+1} + v_{k+1})(C\tilde{e}_{k+1} + v_{k+1})^T] \\ &= [\tilde{e}_{k+1}, v_{k+1} \text{ nezavisne}] \\ &= C\mathbb{E}[\tilde{e}_{k+1} \tilde{e}_{k+1}^T] C^T + \mathbb{E}[v_{k+1} v_{k+1}^T] \\ &= C \tilde{\Sigma}_{k+1} C^T + \Sigma_v.\end{aligned}$$

## 3 Filtriranje

- ▶ Sada tražimo razdiobu za  $x_{k+1}$  koja uzima u obzir i ono što daje model sustava  $(\tilde{x}_{k+1}, \tilde{y}_{k+1})$  i ono što daje mjerenje  $y_{k+1}^{\text{true}}$ , tj. uvjet  $\tilde{y}_{k+1} = y_{k+1}^{\text{true}}$ .
- ▶ Ranije smo spomenuli da će tražena razdioba biti normalna:  
 $x_{k+1} \sim \mathcal{N}(\mu_{k+1}, \Sigma_{k+1})$ .
- ▶ Vrijedi:

$$x_{k+1} = \tilde{x}_{k+1} + \underbrace{K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})}_{\text{korekcija}}.$$

Ovdje je  $K_{k+1}$  tzv. **KALMANOV GAIN**. Određujemo ga iz uvjeta

$$\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min.$$

To daje optimalni estimator stanja uz naše prepostavke (Gaussov šum).

- ▶ Ako  $w_k, v_k$  nisu Gaussove, ova procedura daje tzv. najbolji linearni estimator za  $x_{k+1}$ .

# Izvod Kalmanovog filtra

③ Filtriranje:  $x_{k+1} = \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})$ ,  $\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min.$

Očekivanje:

$$\begin{aligned}\mu_{k+1} &= \mathbb{E}[x_{k+1}] \\ &= \mathbb{E}[\tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})] \\ &= \tilde{\mu}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \mathbb{E}[\tilde{y}_{k+1}]) \\ &= \tilde{\mu}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{\mu}_{k+1}^Y) \\ &= \tilde{\mu}_{k+1} + K_{k+1}e_{k+1}^Y,\end{aligned}$$

gdje je  $e_{k+1}^Y = y_{k+1}^{\text{true}} - \tilde{\mu}_{k+1}^Y$ .

Odstupanje:

$$\begin{aligned}e_{k+1} &:= x_{k+1} - \mu_{k+1} \\ &= \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1}) - \tilde{\mu}_{k+1} - K_{k+1}(y_{k+1}^{\text{true}} - \tilde{\mu}_{k+1}^Y) \\ &= \tilde{x}_{k+1} - K_{k+1}\tilde{y}_{k+1} - \tilde{\mu}_{k+1} + K_{k+1}\tilde{\mu}_{k+1}^Y \\ &= \tilde{e}_{k+1} - K_{k+1}\tilde{e}_{k+1}^Y \\ &= \tilde{e}_{k+1} - K_{k+1}(C\tilde{e}_{k+1} + v_{k+1}) \\ &= (I - K_{k+1}C)\tilde{e}_{k+1} - K_{k+1}v_{k+1}.\end{aligned}$$

3) Filtriranje:  $x_{k+1} = \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})$ ,  $\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min.$

Očekivanje:  $\mu_{k+1} = \tilde{\mu}_{k+1} + K_{k+1}e_{k+1}^\gamma$ .

Odstupanje:  $e_{k+1} = (I - K_{k+1}C)\tilde{e}_{k+1} - K_{k+1}v_{k+1}$ .

Matrica kovarijacije:

$$\begin{aligned}\Sigma_{k+1} &= \mathbb{E}[e_{k+1}e_{k+1}^T] \\ &= \mathbb{E}[((I - K_{k+1}C)\tilde{e}_{k+1} - K_{k+1}v_{k+1})((I - K_{k+1}C)\tilde{e}_{k+1} - K_{k+1}v_{k+1})^T] \\ &= [\tilde{e}_{k+1}, v_{k+1} \text{ nezavisne}] \\ &= (I - K_{k+1}C)\mathbb{E}[\tilde{e}_{k+1}\tilde{e}_{k+1}^T](I - K_{k+1}C)^T + K_{k+1}\mathbb{E}[v_{k+1}v_{k+1}^T]K_{k+1}^T \\ &= (I - K_{k+1}C)\tilde{\Sigma}_{k+1}(I - K_{k+1}C)^T + K_{k+1}\Sigma_v K_{k+1}^T \\ &= \tilde{\Sigma}_{k+1} - K_{k+1}C\tilde{\Sigma}_{k+1} - \tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}C\tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}\Sigma_v K_{k+1}^T.\end{aligned}$$

③ Filtriranje:  $x_{k+1} = \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})$ ,  $\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min.$

Očekivanje:  $\mu_{k+1} = \tilde{\mu}_{k+1} + K_{k+1}e_{k+1}^\gamma$ .

Matrica kovarijacije:

$$\Sigma_{k+1} = \tilde{\Sigma}_{k+1} - K_{k+1}C\tilde{\Sigma}_{k+1} - \tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}C\tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}\Sigma_v K_{k+1}^T.$$

Cilj optimizacije:

$$\begin{aligned}\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] &= \mathbb{E}[(x_{k+1} - \mu_{k+1})^T(x_{k+1} - \mu_{k+1})] \\ &= \mathbb{E}[\text{trace}((x_{k+1} - \mu_{k+1})^T(x_{k+1} - \mu_{k+1}))] \\ &= \mathbb{E}[\text{trace}((x_{k+1} - \mu_{k+1})(x_{k+1} - \mu_{k+1})^T)] \\ &= [\text{trag je linearna funkcija}] \\ &= \text{trace } \Sigma_{k+1} \rightarrow \min.\end{aligned}$$

# Izvod Kalmanovog filtra

- 3 Filtriranje:  $x_{k+1} = \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})$ ,  $\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min$ .

Cilj optimizacije:  $\min_{K_{k+1}} \text{trace } \Sigma_{k+1}$ .

Trebat će izračunati  $\frac{\partial \text{trace } \Sigma_{k+1}}{\partial K_{k+1}}$ . Vrijedi ( $\partial_{ij} = \text{derivacija po } X_{ij}$ ):

$$\frac{\partial \text{trace}(AX)}{\partial X} = [\partial_{ij} \text{trace}(AX)]_{ij} = [\partial_{ij} \sum_{\ell=1}^n (AX)_{\ell\ell}]_{ij}$$

$$= [\partial_{ij} \sum_{\ell=1}^n \sum_{k=1}^n A_{\ell k} X_{k\ell}]_{ij} = [A_{ji}]_{ij} = A^T,$$

$$\frac{\partial \text{trace}(XA)}{\partial X} = A^T,$$

$$\frac{\partial \text{trace}(AX^T)}{\partial X} = \frac{\partial \text{trace}(XA^T)}{\partial X} = A,$$

$$\frac{\partial \text{trace}(XAX^T)}{\partial X} = 2XA, \text{ A simetrična.}$$

Vidi i Wikipedia: Matrix calculus.

# Izvod Kalmanovog filtra

- ③ Filtriranje:  $x_{k+1} = \tilde{x}_{k+1} + K_{k+1}(y_{k+1}^{\text{true}} - \tilde{y}_{k+1})$ ,  $\mathbb{E}[\|x_{k+1} - \mu_{k+1}\|^2] \rightarrow \min.$

Matrica kovarijacije:

$$\Sigma_{k+1} = \tilde{\Sigma}_{k+1} - K_{k+1}C\tilde{\Sigma}_{k+1} - \tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}C\tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}\Sigma_v K_{k+1}^T.$$

Imamo:

$$\begin{aligned}\frac{\partial \text{trace } \Sigma_{k+1}}{\partial K_{k+1}} &= -\tilde{\Sigma}_{k+1}C^T - \tilde{\Sigma}_{k+1}C^T + 2K_{k+1}C\tilde{\Sigma}_{k+1}C^T + 2K_{k+1}\Sigma_v \\ &= -2\tilde{\Sigma}_{k+1}C^T + 2K_{k+1}(C\tilde{\Sigma}_{k+1}C^T + \Sigma_v) \\ &= 0,\end{aligned}$$

pa slijedi

$$K_{k+1} = \tilde{\Sigma}_{k+1}C^T(C\tilde{\Sigma}_{k+1}C^T + \Sigma_v)^{-1}.$$

Jednostavniji izraz za matricu kovarijacije:

$$\begin{aligned}\Sigma_{k+1} &= (I - K_{k+1}C)\tilde{\Sigma}_{k+1}(I - K_{k+1}C)^T + K_{k+1}\Sigma_v K_{k+1}^T \\ &= (I - K_{k+1}C)\tilde{\Sigma}_{k+1} - (I - K_{k+1}C)\tilde{\Sigma}_{k+1}C^T K_{k+1}^T + K_{k+1}\Sigma_v K_{k+1}^T \\ &= (I - K_{k+1}C)\tilde{\Sigma}_{k+1} + \underbrace{(-\tilde{\Sigma}_{k+1}C^T + K_{k+1}(C\tilde{\Sigma}_{k+1}C^T + \Sigma_v))K_{k+1}^T}_0 \\ &= (I - K_{k+1}C)\tilde{\Sigma}_{k+1}.\end{aligned}$$

## Algoritam (Kalmanov filter za diskretne sustave)

Neka je  $x_0 \sim \mathcal{N}(\mu_0, \Sigma_0)$ .

for  $k = 0, 1, 2, \dots$

- 1 Propagacija stanja:

$$\begin{aligned}\tilde{\mu}_{k+1} &= A\mu_k + Bu_k \\ \tilde{\Sigma}_{k+1} &= A\Sigma_k A^T + F\Sigma_w F^T\end{aligned}\left.\right\} \tilde{x}_{k+1} \sim \mathcal{N}(\tilde{\mu}_{k+1}, \tilde{\Sigma}_{k+1})$$

- 2 Inkorporiranje mjerjenja  $y_{k+1}^{true}$ :

$$\begin{aligned}\tilde{\mu}_{k+1}^Y &= C\tilde{\mu}_{k+1} + Du_{k+1} \\ e_{k+1}^Y &= y_{k+1}^{true} - \tilde{\mu}_{k+1}^Y \\ K_{k+1} &= \tilde{\Sigma}_{k+1} C^T (C\tilde{\Sigma}_{k+1} C^T + \Sigma_v)^{-1} \\ \mu_{k+1} &= \tilde{\mu}_{k+1} + K_{k+1} e_{k+1}^Y \\ \Sigma_{k+1} &= (I - K_{k+1} C) \tilde{\Sigma}_{k+1}\end{aligned}\left.\right\} x_{k+1} \sim \mathcal{N}(\mu_{k+1}, \Sigma_{k+1})$$

Stvarno stanje sustava aproksimiramo sa  $x_{k+1}^{true} \approx \mu_{k+1}$ .

end

KONTINUIRANI KALMANOV FILTAR

Direktni izvod Kalmanovog filtra za kontinuirane LTI?

- Zahtijeva napredna znanja iz statistike.
- Naš izvod: diskretni KF + limes kada vremenski korak  $T \rightarrow 0$ .

Model stohastičkog kontinuiranog LTI:

$$\begin{aligned}\dot{x}(t) &= Ax(t) + Bu(t) + Fw(t), & w(t) &\sim \mathcal{N}(0, \Sigma_w), \\ y(t) &= Cx(t) + Du(t) + v(t), & v(t) &\sim \mathcal{N}(0, \Sigma_v),\end{aligned}$$

gdje su  $w(t), v(t)$  nezavisne.

Diskretna varijjanta ovog sustava (za "male"  $T$ ):

$$\left. \begin{array}{rcl} x_k & \approx & x(T \cdot k), \quad k = 0, 1, \dots \\ \dot{x}(T \cdot k) & \approx & \frac{x_{k+1} - x_k}{T} \\ u_k & := & u(T \cdot k) \end{array} \right\} \Rightarrow \begin{array}{rcl} x_{k+1} & = & (I + AT)x_k + BTu_k + Fw_k \\ y_k & = & Cx_k + Du_k + v_k, \\ w_k & \sim & \mathcal{N}(0, T \cdot \Sigma_w), \quad v_k \sim \mathcal{N}(0, \frac{1}{T} \Sigma_v). \end{array}$$

$$x_{k+1} = (I + AT)x_k + BTu_k + Fw_k, \quad w_k \sim \mathcal{N}(0, T \cdot \Sigma_w),$$

$$y_k = Cx_k + Du_k + v_k, \quad v_k \sim \mathcal{N}(0, \frac{1}{T} \Sigma_v).$$

Sada uvrstimo ovaj sustav u formule za diskretni KF:

1)  $K_{k+1} = \tilde{\Sigma}_{k+1} C^T (C \tilde{\Sigma}_{k+1} C^T + \frac{1}{T} \Sigma_v)^{-1}$  povlači

$\frac{1}{T} K_{k+1} = \tilde{\Sigma}_{k+1} C^T (TC \tilde{\Sigma}_{k+1} C^T + \Sigma_v)^{-1}$  pa imamo:

$$\lim_{T \rightarrow 0} \left( \frac{1}{T} K_{k+1} \right) = \tilde{\Sigma}_{k+1} C^T \Sigma_v^{-1}, \quad \lim_{T \rightarrow 0} K_{k+1} = 0.$$

2) Matrica kovarijacije za propagaciju stanja:

$$\begin{aligned} \tilde{\Sigma}_{k+1} &= (I + AT)\Sigma_k(I + AT)^T + FT\Sigma_wF^T \\ &= \Sigma_k + T(A\Sigma_k + \Sigma_k A^T + F\Sigma_w F^T) + \mathcal{O}(T^2) \\ &= \left[ \text{iz prethodnog koraka: } \Sigma_k = (I - K_k C)\tilde{\Sigma}_k \right] \\ &= (I - K_k C)\tilde{\Sigma}_k + T(A(I - K_k C)\tilde{\Sigma}_k + (I - K_k C)\tilde{\Sigma}_k A^T + F\Sigma_w F^T) + \mathcal{O}(T^2). \end{aligned}$$

Slijedi:

$$\frac{1}{T} (\tilde{\Sigma}_{k+1} - \tilde{\Sigma}_k) = \frac{-1}{T} K_k C \tilde{\Sigma}_k + (A(I - K_k C)\tilde{\Sigma}_k + (I - K_k C)\tilde{\Sigma}_k A^T + F\Sigma_w F^T) + \mathcal{O}(T),$$

$$\dot{\tilde{\Sigma}}_k := \lim_{T \rightarrow 0} \frac{1}{T} (\tilde{\Sigma}_{k+1} - \tilde{\Sigma}_k) = -\tilde{\Sigma}_k C^T \Sigma_v^{-1} C \tilde{\Sigma}_k + (A\tilde{\Sigma}_k + \tilde{\Sigma}_k A^T + F\Sigma_w F^T).$$

Dakle, uz  $T \rightarrow 0$ , možemo definirati funkciju  $\Sigma$  takvu da je  $\Sigma(T \cdot k) \approx \tilde{\Sigma}_k$  za koju vrijedi

$$\dot{\Sigma}(t) = -\Sigma(t) \cdot C^T \Sigma_v^{-1} C \cdot \Sigma(t) + A\Sigma(t) + \Sigma(t)A^T + F\Sigma_w F^T,$$

uz početni uvjet  $\Sigma(0) = \Sigma_0$ , gdje je  $x(0) \sim \mathcal{N}(\mu_0, \Sigma_0)$ .

Ovo je tzv. **DIFERENCIJALNA RICCATIJEVA JEDNADŽBA**.

- Samo  $\Sigma$  ovisi o  $t$ , sve ostalo su konstante.
- Očekujemo  $\Sigma(t) \xrightarrow{t \rightarrow \infty} \text{const}$ , tj. da se rješenje  $\Sigma(t)$  stabilizira, pa  $\dot{\Sigma}(t) \xrightarrow{t \rightarrow \infty} 0$ .
- Uz  $\Sigma(t) = \Sigma = \text{const}$  se gornja jednadžba svodi na

$$A\Sigma + \Sigma A^T - \Sigma \cdot C^T \Sigma_v^{-1} C \cdot \Sigma + F\Sigma_w F^T = 0.$$

- Ovo je obična algebarska Riccatijeva jednadžba s nepoznanim  $\Sigma$ .

Inkorporiranje mjerenja za diskretizirani sustav iz diskretnog KF:

$$\begin{aligned}\mu_{k+1} &= \tilde{\mu}_{k+1} + K_{k+1} e_{k+1}^Y \\ &= \tilde{\mu}_{k+1} + K_{k+1} (y_{k+1}^{\text{true}} - C\tilde{\mu}_{k+1} - Du_{k+1}) \\ &= (I + AT)\mu_k + BTu_k + K_{k+1} (y_{k+1}^{\text{true}} - C(I + AT)\mu_k - CBTu_k - Du_{k+1}).\end{aligned}$$

Slijedi:

$$\frac{1}{T}(\mu_{k+1} - \mu_k) = A\mu_k + Bu_k + \frac{1}{T}K_{k+1}(y_{k+1}^{\text{true}} - C\mu_k - Du_{k+1} - CT(A\mu_k + Bu_k)),$$

pa puštanjem  $T \rightarrow 0$  imamo:

$$\begin{aligned}\dot{\mu}(t) &= A\mu(t) + Bu(t) + \Sigma(t)C^T\Sigma_v^{-1}(y^{\text{true}}(t) - C\mu(t) - Du(t)) \\ &= A\mu(t) + Bu(t) + K(t)(y^{\text{true}}(t) - \tilde{\mu}^Y(t)).\end{aligned}$$

Ovdje je  $K(t) := \Sigma(t)C^T\Sigma_v^{-1}$  Kalmanov gain, te  $\tilde{\mu}^Y(t) := C\mu(t) + Du(t)$  očekivanje vrijednosti mjerenja nakon faze propagacije.

Uoči:  $K(t)$  je moguće izračunati unaprijed, prije bilo kojeg mjerenja!

Sada stanje aproksimiramo očekivanjem:

$$x^{\text{true}}(t) \approx x_{KF}(t) := \mu(x),$$

a vrijednost izlaza očekivanom vrijednosti mjerena:  $y_{KF}(t) := \tilde{\mu}^Y(t)$ .

**KONTINUIRANI KALMANOV FILTER** je dan sa:

$$\begin{aligned}\dot{x}_{KF}(t) &= Ax_{KF}(t) + Bu(t) + K(t)(y^{\text{true}}(t) - y_{KF}(t)), \\ y_{KF}(t) &= Cx_{KF}(t) + Du(t).\end{aligned}$$

Ovdje je:

- $K(t) = \Sigma(t)C^T\Sigma_v^{-1}$  Kalmanov gain.
- $\Sigma(t)$  je rješenje diferencijalne Riccatijeve jednadžbe.

Najčešće u praksi uzimamo:

- $K(t) = K = \Sigma C^T \Sigma_v^{-1}$ .
- $\Sigma = \text{care}(A^T, C^T, F \Sigma_w F^T, \Sigma_v)$  je rješenje algebarske Riccatijeve jednadžbe.


# LQG kontrola

Problem linearno-kvadratično-Gaussove (LQG) kontrole:

- Želimo stabilizirati sustav za koji nemamo dostupno očitanje njegovog stanja (nego samo mjerena izlaza) i pritom minimizirati zadani kvadratični funkcional  $J(u)$ .
- Mjerenja sustava su podložna Gaussovom šumu  $v \sim \mathcal{N}(0, \Sigma_v)$ ; model sustava je također stohastički s Gausovim vanjskim smetnjama  $w \sim \mathcal{N}(0, \Sigma_w)$ .
- Početno stanje sustava je opisano očekivanjem i matricom kovarijacije normalne distribucije:  $x_0 = x_{KF}(0) \sim \mathcal{N}(\mu_0, \Sigma_0)$ .

Rješenje:

- 1 Estimaciju stanja sustava na temelju mjerena radimo pomoću Kalmanovog filtera.
- 2 Dobivenu estimaciju stanja zatim koristimo u LQR kontroli za minimizaciju  $J(u)$ .



# Zadatak

Nastavljamo s primjerom stabilizacije invertiranog njihala pomoću LQR kontrole.

Realnija situacija:

- LQR-kontroler nema pristup svim stanjima  $x$ , nego samo nekom izlazu  $y$   
~~> LQR-kontroler može dobiti samo aproksimaciju stanja  $\tilde{x} \approx x$  na temelju  $u, y$ .
- Kod njihala:  $y(t) = [x(t), \theta(t)]^T$ .
- Dodatno: šum "u modelu"  $w \sim \mathcal{N}(0, 0.04I_4)$ , šum u mjerenuju  $v \sim \mathcal{N}(0, 0.01I_2)$ .  
(tj.  $w(t)$  generiramo sa  $w = 0.2 * \text{randn}(4)$ , a  $v(t)$  sa  $v = 0.1 * \text{randn}(2)$ )

- 1 Ugradite Luenbergerov promatrač  $P$  u sustav [s dijagrama](#) (uz zamjenu  $P$  umjesto  $KF$ ):

$$\dot{x}_P(t) = (A + LC)x_P(t) + Bu(t) - Ly(t).$$

Ovdje smo pretpostavili  $D = 0$  u jednadžbi sustava  $G$ .

$A + LC$  treba biti Hurwitzova ~~> smjestite joj polove u  $\{-0.4, -0.5, -0.6, -0.7\}$ .

Napravite simulaciju koja uključuje šum  $v, w$ :

- Isim nema tu mogućnost;
- Zbog toga sami radimo diskretizaciju LTI sustava i manualno simuliramo.

## 1 Diskretizacija LTI sustava

$$\dot{x}(t) = Ax(t) + Bu(t) + Fw(t), \quad x_k \approx x(dt \cdot k), u_k, w_k$$

$$y(t) = Cx(t) + Du(t) + v(w), \quad y_k \approx y(dt \cdot k), v_k.$$

Uoči:  $u_k = u_k^{\text{ext}} - u_k^K$ .

Koristimo aproksimaciju derivacije podijeljenom razlikom unaprijed:

$$\frac{x_{k+1} - x_k}{dt} = Ax_k + Bu_k + Fw_k.$$

Diskretizirani sustav  $G$ :

$$x_{k+1} = x_k + dt \cdot (Ax_k + Bu_k + Fw_k)$$

$$y_{k+1} = Cx_{k+1} + Du_{k+1} + v_{k+1}.$$

Promatrač i kontroler daju, analogno:

$$x_{k+1}^P = x_k^P + dt \cdot ((A + LC)x_k^P + Bu_k - Ly_k)$$

$$u_{k+1}^K = K_{LQR} \cdot x_{k+1}^P.$$

Ovdje feedback  $K_{LQR}$  izračunamo s parametrima originalnog, kontinuiranog modela sustava  $G$ .

- 2 Zamijenimo Luenbergerov promatrač Kalmanovim filterom, tj. napravimo LQG kontrolu:

$$\dot{x}_{KF}(t) = Ax_{KF}(t) + Bu(t) + K(y^{\text{true}}(t) - y_{KF}(t))$$

$$y_{KF}(t) = Cx_{KF}(t) + Du(t)$$

$$u_K(t) = K_{LQR}x_{KF}(t)$$

Nakon diskretizacije:

$$x_{k+1}^{KF} = x_k^{KF} + dt \cdot (Ax_k^{KF} + Bu_k + K(y_k^{\text{true}} - y_k^{KF})),$$

$$y_{k+1}^{KF} = Cx_{k+1}^{KF} + Du_{k+1},$$

$$u_{k+1}^K = K_{LQR}x_{k+1}^{KF}.$$

Usporedite rezultat dobiven Luenbergerovim promatračem i Kalmanovim filterom:

- Je li sustav stabiliziran u oba slučaja?
- Kakve su performanse kontrole (koliko su “velika” stanja)?
- Koliko  $x_P, x_{KF}$  odstupaju od stvarnog stanja  $x$ ?