



---

# Estimación de estados

Prof. Cesar de Prada

Dpt. Ingeniería de Sistemas y Automática

[prada@autom.uva.es](mailto:prada@autom.uva.es)

ISA-UVA



# Modelo discretizado

$$\frac{dx}{dt} = Ax + Bu$$
$$y = Cx + Du$$




$$x((k + 1)T) = \Phi x(kT) + \Gamma u(kT)$$

$$y(kT) = Cx(kT)$$

$$\Phi = e^{AT} \quad \Gamma = \int_0^T e^{A\tau} d\tau B$$

Matlab c2d

Ecuación en diferencias



Para este tipo de entradas, el modelo discretizado da los mismos valores en los instantes  $t = kT$  que el modelo continuo. (Partiendo del mismo estado inicial y aplicando las mismas entradas)



# Estimación de estados: Observadores





Muchas veces el estado no es medible y se desea estimar su valor para aplicar una ley de control del tipo  $u = -Lx$ .

Caso sin ruido:

Observador de estados:

$$\hat{x}(t|t) = \hat{x}(t|t-1) + K[y(t) - C\hat{x}(t|t-1)]$$

Fórmula recursiva de estimación (predicción- corrección) con un término de corrección proporcional al error de estimación



K matriz de ganancia del observador



# Errores de estimación

$$x(t+1) = \Phi x(t) + \Gamma u(t)$$

$$y(t) = Cx(t)$$

$$x(t) = \Phi x(t-1) + \Gamma u(t-1)$$

$$\begin{aligned}\hat{x}(t|t) &= \hat{x}(t|t-1) + K[y(t) - C\hat{x}(t|t-1)] = \\ &= [\Phi\hat{x}(t-1|t-1) + \Gamma u(t-1)] + K[Cx(t) - C\hat{x}(t|t-1)]\end{aligned}$$

restando

$$\begin{aligned}e(t) &= x(t) - \hat{x}(t|t) = \Phi e(t-1) - KC[x(t) - \hat{x}(t|t-1)] = \\ &= \Phi e(t-1) - KC[(\Phi x(t-1) + \Gamma u(t-1)) - (\Phi\hat{x}(t-1|t-1) + \Gamma u(t-1))] = \\ &= \Phi e(t-1) - KC\Phi e(t-1) = [\Phi - KC\Phi]e(t-1)\end{aligned}$$

$$e(t) = [I - KC]\Phi e(t-1)$$

Para que el error de estimación tienda a cero: los autovalores de  $(I-KC)\Phi$  deben estar dentro del círculo unidad (Criterio de selección de  $K$ , se fija la dinámica del error)




# Filtro de Kalman

Problema de estimación de estados con perturbaciones gaussianas

$$x(t+1) = \Phi x(t) + \Gamma u(t) + v(t)$$

$$y(t) = Cx(t) + e(t)$$

Filtro de Kalman: Elección óptima de la matriz de ganancias del observador para minimizar la varianza del error




$$\hat{x}(t|t) = \hat{x}(t|t-1) + K(t)[y(t) - C\hat{x}(t|t-1)]$$

$$\hat{x}(t|t-1) = \Phi \hat{x}(t-1|t-1) + \Gamma u(t-1)$$

Dos formulaciones:

Filtro y predictor



$K(t)$  matriz de Kalman: ganancia del filtro



# Filtro de Kalman (KF)

---

$$\mathbf{x}(t+1) = \Phi\mathbf{x}(t) + \Gamma\mathbf{u}(t) + \mathbf{v}(t)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{e}(t)$$

La ganancia  $\mathbf{K}$  se escoge para minimizar la varianza del error

$$\hat{\mathbf{x}}(t|t) = \hat{\mathbf{x}}(t|t-1) + \mathbf{K}(t)[\mathbf{y}(t) - \mathbf{C}\hat{\mathbf{x}}(t|t-1)]$$

$$\hat{\mathbf{x}}(t|t-1) = \Phi\hat{\mathbf{x}}(t-1|t-1) + \Gamma\mathbf{u}(t-1)$$

$$\mathbf{K}(t) = \mathbf{P}(t)\mathbf{C}'[\mathbf{C}\mathbf{P}(t)\mathbf{C}' + \mathbf{R}_{ee}]^{-1}$$

$$\mathbf{P}(t) = \Phi[\mathbf{I} - \mathbf{K}(t-1)\mathbf{C}]\mathbf{P}(t-1)\Phi' + \mathbf{R}_{vv}$$

$\mathbf{P}$  es la varianza del error de predicción que se calcula recursivamente

$\mathbf{R}_{ee}$  y  $\mathbf{R}_{vv}$  son respectivamente las covarianzas de las perturbaciones de la salida y del estado que se suponen conocidas



# Extended Kalman Filter (EKF)

$$\mathbf{x}(t+1) = \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t)) + \mathbf{v}(t)$$

$$\mathbf{y}(t) = \mathbf{g}(\mathbf{x}(t), \mathbf{u}(t)) + \mathbf{e}(t)$$

Si el sistema dinámico es no-lineal, se puede usar el mismo enfoque haciendo una linealización sobre el punto de operación y calculando las predicciones “a priori” con el modelo no lineal, dando lugar al EKF

$$\hat{\mathbf{x}}(t|t) = \mathbf{f}(\hat{\mathbf{x}}(t-1|t-1), \mathbf{u}(t-1)) + \mathbf{K}(t)[\mathbf{y}(t) - \mathbf{C}\mathbf{g}(\hat{\mathbf{x}}(t|t-1), \mathbf{u}(t-1))]$$

$$\mathbf{K}(t) = \mathbf{P}(t|t-1)\mathbf{C}(t)'[\mathbf{C}(t)\mathbf{P}(t|t-1)\mathbf{C}(t)' + \mathbf{R}_{ee}]^{-1}$$

$$\mathbf{P}(t|t-1) = \mathbf{A}(t)\mathbf{P}(t-1|t-1)\mathbf{A}(t)' + \mathbf{R}_{vv}$$

$$\mathbf{P}(t|t) = (\mathbf{I} - \mathbf{K}(t)\mathbf{C}(t))\mathbf{P}(t|t-1)$$

$$\mathbf{A}(t) = \left. \frac{\partial \mathbf{f}}{\partial \mathbf{x}} \right|_{t-1} \quad \mathbf{C}(t) = \left. \frac{\partial \mathbf{g}}{\partial \mathbf{x}} \right|_{t-1}$$

$$\hat{\mathbf{x}}(t|t-1) = \mathbf{f}(\hat{\mathbf{x}}(t-1|t-1), \mathbf{u}(t-1))$$

$\mathbf{P}$  es la varianza del error de predicción que se calcula recursivamente

$\mathbf{R}_{ee}$  y  $\mathbf{R}_{vv}$  son respectivamente las covarianzas de las perturbaciones de la salida y del estado que se suponen conocidas



# Estimación conjunta de estados y parámetros con el EKF



$$x(t+1) = f(x(t), u(t), p) + v(t)$$

$$y(t) = g(x(t), u(t), p) + e(t)$$

$p$  parámetros desconocidos  
del modelo

El EKF se puede utilizar para también para  
estimar simultáneamente estados y  
parámetros desconocidos sin mas que  
considerer el sistema ampliado:

$$x(t+1) = f(x(t), u(t), p) + v(t)$$

$$p(t+1) = p(t)$$

$$y(t) = g(x(t), u(t), p) + e(t)$$

$$z(t+1) = \begin{bmatrix} x(t+1) \\ p(t+1) \end{bmatrix} = \begin{bmatrix} f(x(t), u(t)) \\ p(t) \end{bmatrix} + \begin{bmatrix} v(t) \\ 0 \end{bmatrix} = F(z(t), u(t)) + \begin{bmatrix} v(t) \\ 0 \end{bmatrix}$$

$$\hat{z}(t|t) = F(\hat{z}(t-1|t-1), u(t-1)) + K(t)[y(t) - Cg(\hat{z}(t|t-1), u(t-1))]$$

$$\hat{z}(t|t-1) = \begin{bmatrix} f(\hat{x}(t-1|t-1), u(t-1)) \\ \hat{p}(t-1) \end{bmatrix}$$



# Moving Horizon Estimation (MHE)

$$\min_{x_{t-N}, d_i} \sum_{i=0}^N [y(t-i) - y_m(t-i)]^2 + \gamma d(t-i)^2$$


$$\dot{x}(t) = f(x(t), u(t), d(t))$$

$$y(t) = g(x(t), u(t))$$

$$L_v \leq d(t-i) \leq L_v$$

Facilmente inicializable

Tiene la misma estructura que el problema de optimización del control



Qué estado inicial en  $t-N$  and  $y$  perturbaciones mínimas  $d(t-i)$  llevarían al proceso a evolucionar de la forma más cercana a los valores medidos  $y(t-i)$  en el intervalo  $[t-N, t]$  si se aplicaran las acciones de control  $u(t-i)$  realmente aplicadas en dicho intervalo?




# Moving Horizon Estimation (MHE)

$$\min_{x_{t-N}, d_i} \sum_{i=0}^N [y(t-i) - y_m(t-i)]^2 + \gamma d(t-i)^2$$

$$\dot{x}(t) = f(x(t), u(t), d(t))$$

$$y(t) = g(x(t), u(t))$$

$$L_v \leq d(t-i) \leq L_v$$



Una vez que se han calculado los  $x(t-N)$  y  $d(t-N), d(t-N+1), \dots$  óptimos,  $x(t)$  se puede estimar por simulación del modelo comenzando en  $x(t-N)$  y aplicando los controles  $u(t-N), u(t-N+1), \dots$  y perturbaciones  $d(t-N), d(t-N+1), \dots$  hasta el tiempo  $t$



# Moving Horizon Estimation (MHE)




## Formulación discreta

$$\min_{x_{t-N}, d_i} \sum_{i=0}^N [y(t-i) - y_m(t-i)]^2 + \gamma d(t-i)^2$$

$$x(t+1) = f(x(t), u(t), d(t))$$

$$y(t) = g(x(t), u(t))$$

$$L_v \leq d(t-i) \leq L_v$$



Qué estado inicial en  $t-N$  and  $y$  perturbaciones mínimas  $d(t-i)$  llevarían al proceso a evolucionar de la forma más cercana a los valores medidos  $y(t-i)$  en el intervalo  $[t-N, t]$  si se aplicaran las acciones de control  $u(t-i)$  realmente aplicadas en dicho intervalo?




# Moving Horizon Estimation (MHE)

$$\min_{x_{t-N}, d_i} \sum_{i=0}^N [y(t-i) - y_m(t-i)]^2 + \gamma d(t-i)^2$$

$$x(t+1) = f(x(t), u(t), d(t))$$

$$y(t) = g(x(t), u(t))$$

$$L_v \leq d(t-i) \leq L_v$$



Una vez que se han calculado los  $x(t-N)$  y  $d(t-N), d(t-N+1), \dots$  óptimos,  $x(t)$  se puede estimar por simulación del modelo comenzando en  $x(t-N)$  y aplicando los controles  $u(t-N), u(t-N+1), \dots$  y perturbaciones  $d(t-N), d(t-N+1), \dots$  hasta el tiempo  $t$