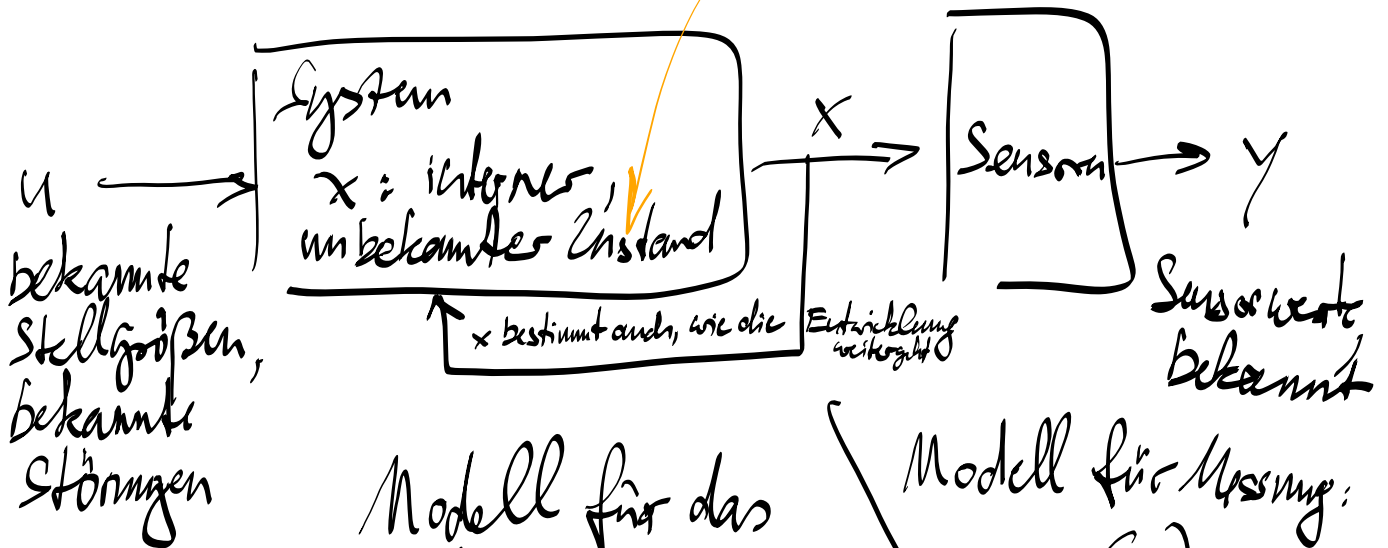


# EKF: Extended Kalman Filter

Job: Den schätzen!



Modell für das System:

$$x(k+1) = f(x(k), u(k)) + \epsilon_x$$

modelliert Entwicklung des Systems

Modell für Messung:

$$y = g(x) + \epsilon_y$$

Rauschen

$x_p$ : vorhergesagter Zustand

$x_c$ : korrigierter vorhergesagter Zustand

$x_c$  als Schätzung angeben!

$$x_c(k+1) = f(x_c(k), u(k))$$

Rechenschritt  
①

$y_p$  : vorhergesagte Sensorwerte

$$y_p = g(x_p) \quad \textcircled{2}$$

Was messe ich jetzt wirklich?

Was habe ich tbun für jetzt vorge sagt?

$$x_c \oplus = x_p + K \cdot (y - y_p) \quad \textcircled{5}$$

für nächsten Schritt

„Innovation“

Kalman Gain :  
Wie wählt man K optimal?

Dann hat man den Kalman-Filter!

• Vertrauen wir der Vorhersage? Dann  $K=0$ !

• Vertrauen wir den Sensor?

Dann soll  $x_c$  komplett aus  $y$  kommen!

$$\text{Also } x_c \stackrel{!}{=} g^{-1}(y)$$

Was für K einsetzen, damit diese Gleichung stimmt?

$$\left( x_p + K \cdot (y - y_p) \right) \quad \underbrace{\hspace{10em}}_{g(x_p)}$$

$$\Rightarrow g^{-1}(y) = x_p + K \cdot (y - g(x_p)) \quad // \text{glf}$$

$$\Rightarrow y = g(x_p + K \cdot (y - g(x_p)))$$

$$= g(x_p) + g'(x_p) \cdot K \cdot (y - g(x_p))$$

Klein 2,1,? Lineare Näherung!

offiziell:

Jacobi-Matrix

Wähle in diesem Fall also:  
 $K = g'^{-1}$

Um zwischen diesen beiden Fällen abzuwägen, müssen wir die Unsicherheiten beschreiben:

$$\sigma^2 = \text{Var}(X) = E[(X - E[X])^2] = \text{mittlere quadratische Abweichung}$$

$\uparrow$  Standardabweichung       $\uparrow$  Zufallsgröße

$\vec{X}$  ein Vektor von Zufallsgrößen. Transposition

$$\text{Kovarianzmatrix} = E[(\vec{X} - E[\vec{X}])(\vec{X} - E[\vec{X}])^T]$$

$\text{Cov}_x$ : Kovarianzmatrix von  $\epsilon_x$

$\text{Cov}_y$ : " " "  $\epsilon_y$

$\text{Cov}_p$ : geschätzte Kovarianzmatrix für die Unsicherheit von  $x_p$

Vergleiche :  
 Unsicherheit  
 des Sensorwerte  $\longleftrightarrow$  Unsicherheit  
 der Vorhersage  
 der Sensorwerte

$Cov_y$

$g' \cdot Cov_p \cdot g'^T$

Transposition

Intuition muss also gelten:  
 $\hat{x}$  und berechenbar optimal

$$K = g'^{-1} \cdot \frac{\Lambda}{\Lambda + \frac{Cov_y}{g' Cov_p g'^T}}$$

4

Korrekt wäre:  $\hat{x}^{-1}$ , weil Matrizen

$$= Cov_p g'^T (g' Cov_p g'^T + Cov_y)^{-1}$$

Noch zu bestimmen!

$\text{Cov}_c$ : geschätzte Unsicherheit von  $x_c$

$$\text{Cov}_p(k+1) \stackrel{**}{=} f' \text{Cov}_c(k) f'^T + \text{Cov}_x$$

Noch zu bestimmen!

3

Zwischenschritt:

$$x - x_c = x - (x_p + k \cdot (y - y_p))$$

$$g(x) + \varepsilon_y \quad g(x_p)$$

$$= x - x_p - k \cdot (g(x) + \varepsilon_y - g(x_p))$$

$$\approx g'(x_p) \cdot (x - x_p)$$

Linear Näherung!  
Kein??

$$\approx \underline{x - x_p} - k \cdot (\underline{g'(x_p)} \cdot \underline{(x - x_p)} + \varepsilon_y)$$

$$= (\mathbb{1} - K \cdot g') (x - x_p) - K \epsilon_y$$

Annahme:  
unkorreliert

$$\Rightarrow \text{Cov}_c =$$

$$\textcircled{6} (\mathbb{1} - K \cdot g') \text{Cov}_p (\mathbb{1} - K \cdot g')^T + K \cdot \text{Cov}_y \cdot K^T$$

lange Formel, aber robust  
zu rechnen

↙ K voroben  
einsetzen

$$= \dots = (\mathbb{1} - K \cdot g') \text{Cov}_p$$

Also dies merken:

- $x_c$
- $\text{Cov}_c$

Und das Schritt für Schritt weiterpflegen,  
mit Hilfe der Sensorwerte,

Vorsicht: Die verwendeten linearen Näherungen gelten  
nur, wenn die Unsicherheiten klein genug sind.