

# Theorie des mehrdimensionalen Kalmanfilters

Markus Krug, Johannes Mühr

- 1 Zunächst benötigt man sein Modell, wie errechnet sich die Modellgröße  $x_t$  aus dem vorherigen Zustand  $x_{t-1}$

# Erinnerung an den eindimensionalen Fall

- 1 Zunächst benötigt man sein Modell, wie errechnet sich die Modellgröße  $x_t$  aus dem vorherigen Zustand  $x_{t-1}$
- 2 Bestimmen der ersten Messung  $\hat{x}(t_0)$  als beste Positionsschätzung

# Erinnerung an den eindimensionalen Fall

- 1 Zunächst benötigt man sein Modell, wie errechnet sich die Modellgröße  $x_t$  aus dem vorherigen Zustand  $x_{t-1}$
- 2 Bestimmen der ersten Messung  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}_{t+1}^-$ , kurz vor der nächsten Messung  $t + 1$

- 1 Zunächst benötigt man sein Modell, wie errechnet sich die Modellgröße  $x_t$  aus dem vorherigen Zustand  $x_{t-1}$
- 2 Bestimmen der ersten Messung  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}_{t+1}^-$ , kurz vor der nächsten Messung  $t + 1$
- 4 Bestimmen des Kalmangains  $K_{t+1}$

# Erinnerung an den eindimensionalen Fall

- 1 Zunächst benötigt man sein Modell, wie errechnet sich die Modellgröße  $x_t$  aus dem vorherigen Zustand  $x_{t-1}$
- 2 Bestimmen der ersten Messung  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}_{t+1}^-$ , kurz vor der nächsten Messung  $t + 1$
- 4 Bestimmen des Kalmangains  $K_{t+1}$
- 5 Korrektur der Prognose des aktuellen besten Zustandes  $\hat{x}_{t+1}$

- im Allgemeinen errechnet sich die Modellgröße mit Hilfe eines Zustandsraummodells, in diesem Fall einem diskreten

$$\mathbf{x}_t = \mathbf{F}_t \vec{\mathbf{x}}_{t-1} + \vec{\mathbf{w}}_t \quad (\text{Zustandsgleichung})$$

$$y_t = \mathbf{H}_t \vec{\mathbf{x}}_t + \vec{\mathbf{v}}_t \quad (\text{Ausgabegleichung})$$

- im Allgemeinen errechnet sich die Modellgröße mit Hilfe eines Zustandsraummodells, in diesem Fall einem diskreten

$$x_t = \mathbf{F}_t \vec{x}_{t-1} + \vec{w}_t \quad (\text{Zustandsgleichung})$$

$$y_t = \mathbf{H}_t \vec{x}_t + \vec{v}_t \quad (\text{Ausgabegleichung})$$

- Linearer Charakter durch Matrixmultiplikation



- im Allgemeinen errechnet sich die Modellgröße mit Hilfe eines Zustandsraummodells, in diesem Fall einem diskreten

$$x_t = \mathbf{F}_t \vec{x}_{t-1} + \vec{w}_t \quad (\text{Zustandsgleichung})$$

$$y_t = \mathbf{H}_t \vec{x}_t + \vec{v}_t \quad (\text{Ausgabegleichung})$$

- Linearer Charakter durch Matrixmultiplikation
- $\vec{w}_t$  beschreibt dabei das Rauschen oder die Störung im System

- im Allgemeinen errechnet sich die Modellgröße mit Hilfe eines Zustandsraummodells, in diesem Fall einem diskreten

$$x_t = \mathbf{F}_t \vec{x}_{t-1} + \vec{w}_t \quad (\text{Zustandsgleichung})$$

$$y_t = \mathbf{H}_t \vec{x}_t + \vec{v}_t \quad (\text{Ausgabegleichung})$$

- Linearer Charakter durch Matrixmultiplikation
- $\vec{w}_t$  beschreibt dabei das Rauschen oder die Störung im System
- $\vec{v}$  beschreibt die Messfehler der Sensoren

- Auch hier wird der Vektor  $\hat{x}_0$  der unmittelbar durch die erste Messung entsteht als beste Schätzung benutzt

- Auch hier wird der Vektor  $\hat{x}_0$  der unmittelbar durch die erste Messung entsteht als beste Schätzung benutzt
- nun neu: nichtmehr durch Standardabweichung, sondern durch Kovarianzmatrizen beschrieben **P**

- Kann direkt aus dem Zustandsraummodell abgeleitet werden:

$$\mathbf{x}_t^- = \mathbf{F}_t \hat{\mathbf{x}}_{t-1}$$

- Die Systemstörung  $\vec{w}$  beeinflusst dabei die zugehörige Aposteriori Kovarianzmatrix  $\mathbf{P}_t^-$

- sehr viel Arbeit nötig, um diesen im mehrdimensionalen abzuleiten - dazu später mehr

- sehr viel Arbeit nötig, um diesen im mehrdimensionalen abzuleiten - dazu später mehr
- Erinnerung, Kalmanfilter schätzt Gleichzeitig unter anderem Mittelwert und Least Squares

- sehr viel Arbeit nötig, um diesen im mehrdimensionalen abzuleiten - dazu später mehr
- Erinnerung, Kalmanfilter schätzt Gleichzeitig unter anderem Mittelwert und Least Squares
- im eindimensionalen Fall Herleitung über Gaußgleichungen und einfaches ablesen des Mittelwerts und Standardabweichung



- sehr viel Arbeit nötig, um diesen im mehrdimensionalen abzuleiten - dazu später mehr
- Erinnerung, Kalmanfilter schätzt Gleichzeitig unter anderem Mittelwert und Least Squares
- im eindimensionalen Fall Herleitung über Gaußgleichungen und einfaches ablesen des Mittelwerts und Standardabweichung
- Auch möglich im allgemeinen Fall, aber sehr schwierig, daher dieses mal Fokus auf minimierung der Fehlerquadrate.

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [z_t - x_t^-] \text{ Mittelwertgleichung}$$

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = \underbrace{x_t^-}_{\text{bekannt durch Apriori Gleichung}} + K_t \cdot [z_t - x_t^-] \text{ Mittelwertgleichung}$$

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = x_t^- + \underbrace{K_t}_{\text{nun eine Matrix } \mathbf{K}_t} \cdot [z_t - x_t^-] \text{ Mittelwertgleichung}$$

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [ \underbrace{z_t}_{\text{Zustandsraummodell } y_t} - x_t^- ] \text{ Mittelwertgleichung}$$

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [z_t - x_t^-] \text{ Mittelwertgleichung}$$

- liefert die mehrdimensionale Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [y_t - H_t x_t^-] \text{ Mittelwertgleichung}$$

- Vergleich mit eindimensionaler Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [z_t - x_t^-] \text{ Mittelwertgleichung}$$

- liefert die mehrdimensionale Gleichung:

$$\hat{x}_t = x_t^- + K_t \cdot [y_t - H_t x_t^-] \text{ Mittelwertgleichung}$$

- $H_t$  nötig, da die Vektoren  $x_t$  und  $y_t$  keineswegs die selbe Dimension besitzen müssen!

- Bisher noch unbekannt sind zum einen die Kovarianzmatrizen zum Apriori  $\mathbf{P}_t^-$  und zum Aposteriorizustand  $\mathbf{P}_t$



- Bisher noch unbekannt sind zum einen die Kovarianzmatrizen zum Apriori  $\mathbf{P}_t^-$  und zum Aposteriorizustand  $\mathbf{P}_t$
- Sowie die Berechnung des Kalmangains  $\mathbf{K}_t$

# Das ist noch nicht alles...

- Bisher noch unbekannt sind zum einen die Kovarianzmatrizen zum Apriori  $\mathbf{P}_t^-$  und zum Aposteriorizustand  $\mathbf{P}_t$
- Sowie die Berechnung des Kalmangains  $\mathbf{K}_t$
- Berechnung über Abschätzung der kleinsten Fehlerquadrate.

Aus der Stochastik:

Die Kovarianzmatrix eines Zufallsvektors berechnet sich gemäß:

$$\text{Cov}(X) = E[(X - \mu) \cdot (X - \mu)^T]$$

Aus der Stochastik:

Die Kovarianzmatrix eines Zufallsvektors berechnet sich gemäß:

$$\text{Cov}(X) = E[(X - \mu) \cdot (X - \mu)^T]$$

- In unserem Fall ist  $X$  der Vektor  $x$  und stellt die unbeobachtbaren wahren Werte unseres Systems dar

Aus der Stochastik:

Die Kovarianzmatrix eines Zufallsvektors berechnet sich gemäß:

$$\text{Cov}(X) = E[(X - \mu) \cdot (X - \mu)^T]$$

- In unserem Fall ist  $X$  der Vektor  $x$  und stellt die unbeobachtbaren wahren Werte unseres Systems dar
- $\mu$  ist die jeweilige beste Schätzung zum gegebenen Zeitpunkt

## Aus der Stochastik:

Die Kovarianzmatrix eines Zufallsvektors berechnet sich gemäß:

$$\text{Cov}(X) = E[(X - \mu) \cdot (X - \mu)^T]$$

- In unserem Fall ist  $X$  der Vektor  $x$  und stellt die unbeobachtbaren wahren Werte unseres Systems dar
- $\mu$  ist die jeweilige beste Schätzung zum gegebenen Zeitpunkt
- Wichtig: Varianzen der einzelnen Einträge des Vektors  $x$  befinden sich auf der Hauptdiagonalen!

- Wir unterscheiden daher zwei Kovarianzmatrizen:

$$\mathbf{P}_t = E[((x_t - \hat{x}_t) \cdot (x_t - \hat{x}_t)^T)] \text{ Aposteriori}$$

$$\mathbf{P}_t^- = E[((x_t - x_t^-) \cdot (x_t - x_t^-)^T)] \text{ Apriori}$$

- Einsetzen der Aposteriori Gleichung in die Definition liefert:

$$\mathbf{P}_t = E[((x_t - \hat{x}_t) \cdot (x_t - \hat{x}_t^-)^T)]$$

mit:

$$\hat{x}_t = x_t^- + \mathbf{K}_t \cdot [y_t - \mathbf{H}_t x_t^-]$$



- Einsetzen der Aposteriori Gleichung in die Definition :

$$\mathbf{P}_t = E[((x_t - \hat{x}_t) \cdot (x_t - \hat{x}_t^-)^T]$$

mit:

$$\hat{x}_t = x_t^- + \mathbf{K}_t \cdot [y_t - \mathbf{H}_t x_t^-]$$

- und anschließendem Ausklammern liefert:

$$= E[((\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \cdot (x_t - x_t^-) - \mathbf{K}_t \vec{v}_t) \cdot ((\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \cdot (x_t - x_t^-) - \mathbf{K}_t \vec{v}_t)^T]$$

$$= E[((\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \cdot (x_t - x_t^-) - \mathbf{K}_t \vec{v}_t) \cdot ((\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \cdot (x_t - x_t^-) - \mathbf{K}_t \vec{v}_t)^T]$$

- Ausmultiplizieren liefert:

$$\begin{aligned} &= E[(\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)(x_t - x_t^-)(x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &\quad - \mathbf{K}_t \vec{v}_t (x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &\quad - (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)(x_t - x_t^-)(\mathbf{K}_t \vec{v}_t)^T \\ &\quad + \mathbf{K}_t \vec{v}_t (\mathbf{K}_t \vec{v}_t)^T] \end{aligned}$$

- erster Term:

$$= E[(\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)(x_t - x_t^-)(x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) E[(x_t - x_t^-)(x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T$$

- erster Term:

$$= E[(\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)(x_t - x_t^-)(x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \underbrace{E[(x_t - x_t^-)(x_t - x_t^-)^T]}_{\mathbf{P}_t^-} (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T$$

- erster Term:

$$= E[(\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)(x_t - x_t^-)(x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\begin{aligned} \mathbf{P}_t &= (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) E[(x_t - x_t^-)(x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &= (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t^- (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \end{aligned}$$

- zweiter Term:

$$\dots - E[\mathbf{K}_t \vec{v}_t (x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\begin{aligned} &= \mathbf{K}_t \cdot E[\vec{v}_t (x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &= \mathbf{K}_t \cdot E[(\vec{v}_t - \vec{0}) (x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \end{aligned}$$

- zweiter Term:

$$\dots - E[\mathbf{K}_t \vec{v}_t (x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\begin{aligned} &= \mathbf{K}_t \cdot E[\vec{v}_t (x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &= \mathbf{K}_t \cdot \underbrace{E[(\vec{v}_t - \vec{0})(x_t - x_t^-)^T]}_{\text{Abhängigkeit } x_t \text{ und } \vec{v}_t} (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \end{aligned}$$

- zweiter Term:

$$\dots - E[\mathbf{K}_t \vec{v}_t (x_t - x_t^-)^T (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T] + \dots$$

- Konstanten aus dem Erwartungswert nehmen bringt:

$$\begin{aligned} &= \mathbf{K}_t \cdot E[\vec{v}_t (x_t - x_t^-)^T] (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \\ &= \mathbf{K}_t \cdot \underbrace{E[(\vec{v}_t - \vec{0})(x_t - x_t^-)^T]}_{\text{Abhängigkeit } x_t \text{ und } \vec{v}_t} (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T \end{aligned}$$

- Annahme  $x_t$  und  $v_t$  sind unabhängig!  $\Rightarrow E[vx^T] = 0$



# Linearität des Erwartungswertes:

- dritter Term mit analoger Begründung zum zweiten Term = 0!

- der vierte Term:

$$\begin{aligned} & \dots + E[\mathbf{K}_t \vec{v}_t (\mathbf{K}_t \vec{v}_t)^T] \\ & = E[\mathbf{K}_t \vec{v}_t \vec{v}_t^T \mathbf{K}_t^T] \\ & = \mathbf{K}_t E[\vec{v}_t \vec{v}_t^T] \mathbf{K}_t^T \end{aligned}$$

- der vierte Term:

$$\begin{aligned} & \dots + E[\mathbf{K}_t \vec{v}_t (\mathbf{K}_t \vec{v}_t)^T] \\ & = E[\mathbf{K}_t \vec{v}_t \vec{v}_t^T \mathbf{K}_t^T] \\ & = \mathbf{K}_t \underbrace{E[\vec{v}_t \vec{v}_t^T]}_{\mathbf{V}_t} \mathbf{K}_t^T \end{aligned}$$

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t^- (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T + \mathbf{K}_t \mathbf{V}_t \mathbf{K}_t^T$$

- ausmultiplizieren und vereinfachen:

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t^- (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t)^T + \mathbf{K}_t \mathbf{V}_t \mathbf{K}_t^T$$

- ausmultiplizieren und vereinfachen:

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Erinnerung - optimaler Kalmanfilter errechnet den Gain  $\mathbf{K}_t$  so, dass die Varianzen von  $x$  in  $\mathbf{P}_t$  minimal werden

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Erinnerung - optimaler Kalmanfilter errechnet den Gain  $\mathbf{K}_t$  so, dass die Varianzen von  $x$  in  $\mathbf{P}_t$  minimal werden
- Varianzen von  $x$  befinden sich in der Spur von  $\mathbf{P}_t$ !

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Erinnerung - optimaler Kalmanfilter errechnet den Gain  $\mathbf{K}_t$  so, dass die Varianzen von  $x$  in  $\mathbf{P}_t$  minimal werden
- Varianzen von  $x$  befinden sich in der Spur von  $\mathbf{P}_t$ !
- Gefordert ist also  $\frac{\partial}{\partial \mathbf{K}} \text{Spur}(\mathbf{P}_t) \stackrel{!}{=} 0$



$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Wir benutzen folgende Ableitungsregeln:

$$\frac{\partial}{\partial \mathbf{X}} \text{Spur}(\mathbf{X} \mathbf{A} \mathbf{X}^T) = \mathbf{X}(\mathbf{A}^T + \mathbf{A})$$

$$\frac{\partial}{\partial \mathbf{X}} \text{Spur}(\mathbf{X} \mathbf{A}) = \mathbf{A}^T$$

$$\frac{\partial}{\partial \mathbf{X}} \text{Spur}(\mathbf{A} \mathbf{X}^T) = \mathbf{A}$$

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Und erhalten:

$$0 = \mathbf{K}_t [\mathbf{H}_t (\mathbf{P}_t^-)^T \mathbf{H}_t^T + \mathbf{V}_t^T + \mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t] - \mathbf{P}_t^- \mathbf{H}_t^T - (\mathbf{P}_t^-)^T \mathbf{H}_t^T$$

$$0 = \mathbf{K}_t[\mathbf{H}_t(\mathbf{P}_t^-)^T \mathbf{H}_t^T + \mathbf{V}_t^T + \mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t] - \mathbf{P}_t^- \mathbf{H}_t^T - (\mathbf{P}_t^-)^T \mathbf{H}_t^T$$

- mit der Eigenschaft der symmetrischen Kovarianzmatrizen  $(\mathbf{P}_t^-)^T = \mathbf{P}_t^-$  und  $\mathbf{V}_t^T = \mathbf{V}_t$  gilt:

$$0 = \mathbf{K}_t[2\mathbf{H}_t(\mathbf{P}_t^-) \mathbf{H}_t^T + 2\mathbf{V}_t] - 2\mathbf{P}_t^- \mathbf{H}_t^T$$

- Wir erhalten also für den allgemeinen Fall den Kalmangain gemäß:

## Der Kalmangain

$$K_t = \frac{P_t^- H_t^T}{H_t P_t^- H_t^T + V_t}$$

- Wir erhalten also für den allgemeinen Fall den Kalmangain gemäß:

## Der Kalmangain

$$K_t = \frac{P_t^- H_t^T}{H_t P_t^- H_t^T + V_t}$$

- Es bleibt die Berechnung von  $P_t$  und von  $P_t^-$

- Einsetzen des Kalmangains in die nicht abgeleitete Formel für  $\mathbf{P}_t$ :

$$\mathbf{K}_t = \frac{\mathbf{P}_t^- \mathbf{H}_t^T}{\mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t}$$

- in:

$$\mathbf{P}_t = \mathbf{P}_t^- - \mathbf{P}_t^- \mathbf{H}_t^T \mathbf{K}_t^T - \mathbf{K}_t \mathbf{H}_t \mathbf{P}_t^- + \mathbf{K}_t (\mathbf{H}_t \mathbf{P}_t^- \mathbf{H}_t^T + \mathbf{V}_t) \mathbf{K}_t^T$$

- Liefert letztenendes:

## Die Aposteriori Kovarianzmatrix

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t^-$$

- Liefert letztenendes:

## Die Aposteriori Kovarianzmatrix

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t^-$$

- gleich geschafft es fehlt nur noch  $\mathbf{P}_t^-$



# Die Apriori Kovarianzmatrix $\mathbf{P}_t$

$$\mathbf{P}_{t+1}^- = E\left[\left(x_t - \underbrace{x_t^-}_{\mathbf{F}_{t+1}\hat{x}_t}\right) \cdot \left(x_t - x_t^-\right)^T\right]$$

⋮

## Die Aposteriori Kovarianzmatrix $\mathbf{P}_t^-$

$$\mathbf{P}_t^- = \mathbf{F}_t \mathbf{P}_{t-1} \mathbf{F}_t^T + \mathbf{W}_t$$

# Der Zyklus ist geschlossen!

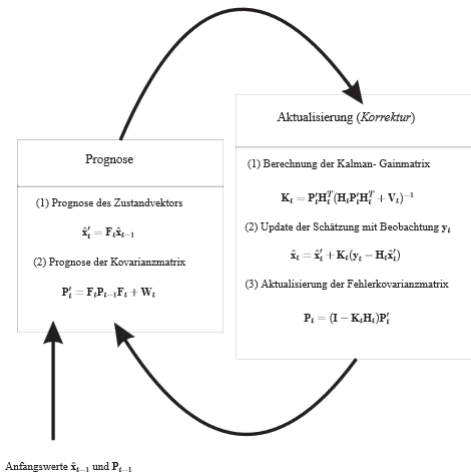


Abbildung : Der Kalman-Zyklus