

# Eindimensionale Applikation eines Kalmanfilters

Markus Krug, Johannes Mühr

25. Juli 2013

- Szenario

- Szenario
- Herleitung der Filtergleichungen

- Wir befinden uns mit einem Quadrocopter in einem verrauchten Gebäude, Ziel des ganzen ist es nunmehr zu vermeiden, gegen die Decke zu fliegen. Dafür wird der Kalmanfilter genutzt um eine optimale Schätzung unserer nun eindimensionalen Position durchzuführen. Zum Messen unserer Höhe haben wir Ultraschallsensoren an Board.

- Zunächst erhalten wir mit unserem Sensor eine Startmessung zum Zeitpunkt  $t_0$ .




Abbildung : Gauß-Verteilung

- Zunächst erhalten wir mit unserem Sensor eine Startmessung zum Zeitpunkt  $t_0$ .
- Messung ist nicht fehlerfrei, gaußverteilte Messung mit Mittelwert  $\mu_0$  und Varianz  $\sigma_0^2$




Abbildung : Gauß-Verteilung

- beste Positionsschätzung nach der ersten Messung  $\hat{x} = \mu_0$

- beste Positionsschätzung nach der ersten Messung  $\hat{x} = \mu_0$
- Mittelwert dabei simultan Modus, Median, und beste Schätzung gemäß kleinster Quadrate



- nun erhalten wir eine zweite Messung zum Zeitpunkt  $t_1$ . Wir haben uns der Einfachheit nicht bewegt.

# Integrieren einer zweiten Messung

- nun erhalten wir eine zweite Messung zum Zeitpunkt  $t_1$ . Wir haben uns der Einfachheit nicht bewegt.
- Der Infrarotsensor liefert dabei eine zuverlässigere Messung, also:

# Integrieren einer zweiten Messung

- nun erhalten wir eine zweite Messung zum Zeitpunkt  $t_1$ . Wir haben uns der Einfachheit nicht bewegt.
- Der Infrarotsensor liefert dabei eine zuverlässigere Messung, also:
- 

$$N(\mu_1, \sigma_1)$$

# Integrieren einer zweiten Messung

- nun erhalten wir eine zweite Messung zum Zeitpunkt  $t_1$ . Wir haben uns der Einfachheit nicht bewegt.
- Der Infrarotsensor liefert dabei eine zuverlässigere Messung, also:
- 

$$N(\mu_1, \sigma_1)$$

- dabei ist  $\sigma_1 < \sigma_0$

- nun erhalten wir eine zweite Messung zum Zeitpunkt  $t_1$ . Wir haben uns der Einfachheit nicht bewegt.
- Der Infrarotsensor liefert dabei eine zuverlässigere Messung, also:
- 

$$N(\mu_1, \sigma_1)$$

- dabei ist  $\sigma_1 < \sigma_0$
- Frage: Wie sieht unsere beste Schätzung nach nun 2 bekannten Messungen aus ?

- gesucht: resultierende Gaußverteilung mit 2 bekannten Messungen
- Annahme: Die Messungen sind unabhängig voneinander

## Aus der Stochastik:

Die resultierende Wahrscheinlichkeitsdichtefunktion  $f(x,y)$  ist gleich der Multiplikation der Randverteilungsfunktionen:

$$f(x, y) = f(x) \cdot f(y)$$

$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x-\mu_0)^2}{\sigma_0^2} \right)}$$

$$f(y) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(y-\mu_1)^2}{\sigma_1^2} \right)}$$

$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x-\mu_0)^2}{\sigma_0^2} \right)}$$

$$f(y) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(y-\mu_1)^2}{\sigma_1^2} \right)}$$

- dabei stellt  $\alpha$  eine Normalisierungskonstante dar.



$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x-\mu_0)^2}{\sigma_0^2} \right)}$$
$$f(y) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(y-\mu_1)^2}{\sigma_1^2} \right)}$$

- dabei stellt  $\alpha$  eine Normalisierungskonstante dar.
- Betrachtung des Exponenten *exp*

$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x-\mu_0)^2}{\sigma_0^2} \right)}$$

$$f(y) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(y-\mu_1)^2}{\sigma_1^2} \right)}$$

- dabei stellt  $\alpha$  eine Normalisierungskonstante dar.
- Betrachtung des Exponenten *exp*
- Da wir uns nicht bewegt haben, gilt  $x = y$

$f(x, y) = f(x) \cdot f(y)$  (Betrachtung des Exponenten)

$$\text{exp} = -\frac{1}{2} \left( \frac{(x - \mu_0)^2}{\sigma_0^2} + \frac{(x - \mu_1)^2}{\sigma_1^2} \right)$$

$$\begin{aligned} \exp &= -\frac{1}{2} \left( \frac{(x - \mu_0)^2}{\sigma_0^2} + \frac{(x - \mu_1)^2}{\sigma_1^2} \right) \\ &= -\frac{1}{2} \left( \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \end{aligned}$$

$$\begin{aligned} \exp &= -\frac{1}{2} \left( \frac{(x - \mu_0)^2}{\sigma_0^2} + \frac{(x - \mu_1)^2}{\sigma_1^2} \right) \\ &= -\frac{1}{2} \left( \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \\ &= -\frac{1}{2} \left( \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \cdot \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \right) \end{aligned}$$

$$\exp = -\frac{1}{2} \left( \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \cdot \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \right)$$

$$\exp = -\frac{1}{2} \left( \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \cdot \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \right)$$

- Vergleich mit normaler Gaußverteilung

$$\exp = -\frac{1}{2} \left( \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \cdot \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \right)$$

- Vergleich mit normaler Gaußverteilung

$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x-\mu)^2}{\sigma^2} \right)}$$



$$\exp = -\frac{1}{2} \left( \underbrace{\left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right)}_{\frac{1}{\sigma^2}} \cdot \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \right)$$

- Vergleich mit normaler Gaußverteilung

$$f(x) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{x - \mu^2}{\sigma^2} \right)}$$

- Standardabweichung der neuen Verteilung  $\hat{\sigma}$  berechnet sich aus:

- Standardabweichung der neuen Verteilung  $\hat{\sigma}$  berechnet sich aus:

$$\begin{aligned}\frac{1}{\hat{\sigma}^2} &= \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \\ &= \frac{1}{\sigma_0^2} + \frac{1}{\sigma_1^2}\end{aligned}$$

- Standardabweichung der neuen Verteilung  $\hat{\sigma}$  berechnet sich aus:

$$\begin{aligned}\frac{1}{\hat{\sigma}^2} &= \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \\ &= \frac{1}{\sigma_0^2} + \frac{1}{\sigma_1^2}\end{aligned}$$

- neue Standardabweichung kleiner als die jeweils einzelnen Standardabweichungen zuvor.

- Standardabweichung der neuen Verteilung  $\hat{\sigma}$  berechnet sich aus:

$$\begin{aligned}\frac{1}{\hat{\sigma}^2} &= \left( \frac{\sigma_0^2 + \sigma_1^2}{\sigma_0^2 \cdot \sigma_1^2} \right) \\ &= \frac{1}{\sigma_0^2} + \frac{1}{\sigma_1^2}\end{aligned}$$

- neue Standardabweichung kleiner als die jeweils einzelnen Standardabweichungen zuvor.
- Wir werden uns unserer eigenen Position „sicherer“

- Wir betrachten nun noch den Rest des Exponenten  $exp_r$  um den neuen Mittelwert  $\hat{\mu}$  zu berechnen.

$$exp_r = \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2}$$

- Wir betrachten nun noch den Rest des Exponenten  $exp_r$  um den neuen Mittelwert  $\hat{\mu}$  zu berechnen.

$$\begin{aligned} exp_r &= \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \\ &= \underbrace{\frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2}}_{=a} \cdot (x - \mu_0)^2 + \underbrace{\frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2}}_{=b} \cdot (x - \mu_1)^2 \end{aligned}$$

- Wir betrachten nun noch den Rest des Exponenten  $exp_r$  um den neuen Mittelwert  $\hat{\mu}$  zu berechnen.

$$\begin{aligned} exp_r &= \frac{\sigma_1^2(x - \mu_0)^2 + \sigma_0^2(x - \mu_1)^2}{\sigma_0^2 + \sigma_1^2} \\ &= \underbrace{\frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2}}_{=a} \cdot (x - \mu_0)^2 + \underbrace{\frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2}}_{=b} \cdot (x - \mu_1)^2 \\ &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \end{aligned}$$



$$\begin{aligned} \exp_r &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \\ &= ax^2 - 2a\mu_0x + a\mu_0^2 + bx^2 - 2b\mu_1x + b\mu_1^2 \end{aligned}$$

$$\begin{aligned} \exp_r &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \\ &= ax^2 - 2a\mu_0x + a\mu_0^2 + bx^2 - 2b\mu_1x + b\mu_1^2 \\ &= (a + b)x^2 - 2(a\mu_0 + b\mu_1)x + (a\mu_0^2 + b\mu_1^2) \end{aligned}$$

$$\begin{aligned} \exp_r &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \\ &= ax^2 - 2a\mu_0x + a\mu_0^2 + bx^2 - 2b\mu_1x + b\mu_1^2 \\ &= \underbrace{(a + b)}_{=1} x^2 - 2(a\mu_0 + b\mu_1)x + (a\mu_0^2 + b\mu_1^2) \end{aligned}$$

$$\begin{aligned} \exp_r &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \\ &= ax^2 - 2a\mu_0x + a\mu_0^2 + bx^2 - 2b\mu_1x + b\mu_1^2 \\ &= \underbrace{(a + b)}_{=1} x^2 - 2(a\mu_0 + b\mu_1)x + (a\mu_0^2 + b\mu_1^2) \\ &= (x - (a\mu_0 + b\mu_1))^2 - (a\mu_0 + b\mu_1)^2 + (a\mu_0^2 + b\mu_1^2) \end{aligned}$$

$$\begin{aligned} \exp_r &= a(x - \mu_0)^2 + b(x - \mu_1)^2 \\ &= ax^2 - 2a\mu_0x + a\mu_0^2 + bx^2 - 2b\mu_1x + b\mu_1^2 \\ &= \underbrace{(a + b)}_{=1} x^2 - 2(a\mu_0 + b\mu_1)x + (a\mu_0^2 + b\mu_1^2) \\ &= (x - \underbrace{(a\mu_0 + b\mu_1)}_{=\hat{\mu}})^2 - \underbrace{(a\mu_0 + b\mu_1)^2 + (a\mu_0^2 + b\mu_1^2)}_{\text{unabhängig von } x \text{ fließt in Konstante } \alpha} \end{aligned}$$

$$\hat{\mu} = (a\mu_0 + b\mu_1)$$

$$= \frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_0 + \frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_1$$

$$\hat{\mu} = (a\mu_0 + b\mu_1)$$

$$= \frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_0 + \frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_1$$

- Spezialfall: beide Messungen gleiche Verteilungen  $\Rightarrow$  Durchschnitt als neue Position

- die nun erhaltenen Gleichungen müssen noch in die von Kalman vorgeschlagene Form gebracht werden



- Varianz:

$$\hat{\sigma}^2 = \frac{\sigma_0^2 \cdot \sigma_1^2}{\sigma_0^2 + \sigma_1^2}$$

- Varianz:

$$\hat{\sigma}^2 = \frac{\sigma_0^2 \cdot \sigma_1^2}{\sigma_0^2 + \sigma_1^2}$$

- Einführung der Konstante K (Kalmangain)

$$K = \frac{\sigma_0^2}{\sigma_0^2 + \sigma_1^2}$$

- Varianz:

$$\hat{\sigma} = K \cdot \sigma_1^2$$

- Varianz:

$$\begin{aligned}\hat{\sigma} &= K \cdot \sigma_1^2 \\ &= (1 - K) \cdot \sigma_0^2\end{aligned}$$

- Varianzgleichung:

$$\begin{aligned}\hat{\sigma} &= K \cdot \sigma_1^2 \\ &= (1 - K) \cdot \sigma_0^2 \\ &= \sigma_0^2 - K\sigma_0^2\end{aligned}$$

- Mittelwertgleichung:

$$\begin{aligned}\hat{\mu} &= \frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_0 + \frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_1 \\ &= K\mu_1 + (1 - K)\mu_0\end{aligned}$$

- Mittelwertgleichung:

$$\begin{aligned}\hat{\mu} &= \frac{\sigma_1^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_0 + \frac{\sigma_0^2}{\sigma_1^2 + \sigma_0^2} \cdot \mu_1 \\ &= K\mu_1 + (1 - K)\mu_0 \\ &= \mu_0 + K(\mu_1 - \mu_0)\end{aligned}$$

- Wir haben nun gelernt wie wir zwei Gaußverteilungen zu einer resultierenden Gaußverteilung aktualisieren



- Wir haben nun gelernt wie wir zwei Gaußverteilungen zu einer resultierenden Gaußverteilung aktualisieren
- Allerdings: Einschränkung auf eine Bewegungslosigkeit zwischen den Messungen.

- Wir haben nun gelernt wie wir zwei Gaußverteilungen zu einer resultierenden Gaußverteilung aktualisieren
- Allerdings: Einschränkung auf eine Bewegungslosigkeit zwischen den Messungen.
- Jetzt: Bewegung zwischen den Messungen

- Unser Quadrocopter bleibt nun nicht mehr zwischen den Messungen am selben Ort, sondern er bewegt sich mit der Geschwindigkeit  $u$

- Unser Quadrocopter bleibt nun nicht mehr zwischen den Messungen am selben Ort, sondern er bewegt sich mit der Geschwindigkeit  $u$
- Daher muss sich der Glaube an unsere wahrscheinlichste Position bereits **zwischen den Messungen** ändern

- Unser Quadrocopter bleibt nun nicht mehr zwischen den Messungen am selben Ort, sondern er bewegt sich mit der Geschwindigkeit  $u$
- Daher muss sich der Glaube an unsere wahrscheinlichste Position bereits **zwischen den Messungen** ändern
- Da auch die Geschwindigkeit in der Regel mit einem Fehler  $w$  behaftet ist, sind wir uns unserer Position immer unsicherer

- Unser Quadrocopter bleibt nun nicht mehr zwischen den Messungen am selben Ort, sondern er bewegt sich mit der Geschwindigkeit  $u$
- Daher muss sich der Glaube an unsere wahrscheinlichste Position bereits **zwischen den Messungen** ändern
- Da auch die Geschwindigkeit in der Regel mit einem Fehler  $w$  behaftet ist, sind wir uns unserer Position immer unsicherer
- $\Rightarrow$  die Gaußverteilung muss breiter werden,  $\Rightarrow$  die Varianz daher wachsen

- Unser Quadrocopter bleibt nun nicht mehr zwischen den Messungen am selben Ort, sondern er bewegt sich mit der Geschwindigkeit  $u$
- Daher muss sich der Glaube an unsere wahrscheinlichste Position bereits **zwischen den Messungen** ändern
- Da auch die Geschwindigkeit in der Regel mit einem Fehler  $w$  behaftet ist, sind wir uns unserer Position immer unsicherer
- $\Rightarrow$  die Gaußverteilung muss breiter werden,  $\Rightarrow$  die Varianz daher wachsen
- Uns interessiert nun die Gaußverteilung kurz vor der nächsten Messung  $x_2$  unter Berücksichtigung der Geschwindigkeit

$$P(x_2) = \int_{-\infty}^{\infty} P(x_2|x_1)P(x_1) dx_1 \text{ (Gesetz der totalen Wahrscheinlichkeit)}$$



$$P(x_2) = \int_{-\infty}^{\infty} P(x_2|x_1)P(x_1) dx_1 \text{ (Gesetz der totalen Wahrscheinlichkeit)}$$

- $P(x_2|x_1)$  bezeichnet das Übergangsmodell, also die Änderung zwischen den Messungen
- $P(x_1)$  ist die Gaußverteilung, die sich nach der letzten Messung ergeben hat

- Das Übergangsmodell  $P(x_2|x_1)$  ist wieder eine Gaußverteilung, die den Zusammenhang zwischen  $x_2$  und  $x_1$  beschreibt, hier also:

$$P(x_2|x_1) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x_2 - x_1)^2}{\sigma_w^2} \right)}$$

- Das Übergangsmodell  $P(x_2|x_1)$  ist wieder eine Gaußverteilung, die den Zusammenhang zwischen  $x_2$  und  $x_1$  beschreibt, hier also:

$$P(x_2|x_1) = \alpha \cdot e^{-\frac{1}{2} \left( \frac{(x_2 - x_1)^2}{\sigma_w^2} \right)}$$

- Dabei errechnet sich  $x_2$  aus  $x_1$  in diesem Fall sehr simpel:

$$x_2 = x_1 + u \cdot \Delta t$$

- der Fehlervektor  $w$  trägt seine Standardabweichung  $\sigma_w$  bei.

- insgesamt erhalten wir folgendes Integral

$$\begin{aligned} P(x_2) &= \int_{-\infty}^{\infty} P(x_2|x_1)P(x_1)dx_1 \\ &= \int_{-\infty}^{\infty} \alpha \cdot e^{-\frac{1}{2}\left(\frac{(x_2-x_1)^2}{\sigma_w^2}\right)} \cdot \alpha \cdot e^{-\frac{1}{2}\left(\frac{(x_1-\mu_1)^2}{\sigma_1^2}\right)} dx_1 \end{aligned}$$

- mit  $x_2 = x_1 + u \cdot \Delta t + w$

- dem Aufmerksamen Zuhörer fällt auf, dass wir alles unabhängig von  $x_1$  vor das Integral ziehen können, sowie

- dem Aufmerksamen Zuhörer fällt auf, dass wir alles unabhängig von  $x_1$  vor das Integral ziehen können, sowie
- eine neue Normalisierungskonstante  $\alpha'$  einführen können, und

- dem Aufmerksamen Zuhörer fällt auf, dass wir alles unabhängig von  $x_1$  vor das Integral ziehen können, sowie
- eine neue Normalisierungskonstante  $\alpha'$  einführen können, und
- wieder mit Hilfe der quadratischen Ergänzung die e-Funktion in einen Term abhängig von  $x_1$  und einen unabhängig davon zerlegen können

- dem Aufmerksamen Zuhörer fällt auf, dass wir alles unabhängig von  $x_1$  vor das Integral ziehen können, sowie
- eine neue Normalisierungskonstante  $\alpha'$  einführen können, und
- wieder mit Hilfe der quadratischen Ergänzung die e-Funktion in einen Term abhängig von  $x_1$  und einen unabhängig davon zerlegen können
- Letztendlich bleibt ein konstanter Term vor dem Integral und ein Integral über den gesamten Wertebereich der e-Funktion der 1 ergibt



- es ergibt sich letztendlich folgender Zusammenhang direkt nach der letzten Messung und der Parameter  $(\mu, \sigma)$  direkt vor der nächsten Messung:

$$\hat{\mu}_2 = \hat{\mu}_1 + u\Delta t$$

$$\sigma_2^2 = \sigma_1^2 + \sigma_w^2 \Delta t$$

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

# Zusammenführen der bisherigen Ergebnisse

- 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  $\Rightarrow N(\mu_0, \sigma_0)$ ,  $\hat{x}(t_0)$  als beste Positionsschätzung

# Zusammenführen der bisherigen Ergebnisse

- 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  $\Rightarrow N(\mu_0, \sigma_0)$ ,  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}^-(t+1)$ , kurz vor der nächsten Messung  $t+1 \Rightarrow N(\hat{\mu}^-(t), \sigma_t^2 + \Delta t \cdot \sigma_w)$

# Zusammenführen der bisherigen Ergebnisse

- 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  $\Rightarrow N(\mu_0, \sigma_0)$ ,  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}^-(t+1)$ , kurz vor der nächsten Messung  $t+1 \Rightarrow N(\hat{\mu}^-(t), \sigma_t^2 + \Delta t \cdot \sigma_w)$
- 4 Bestimmen des Kalmangains  $K(t+1) = \frac{\sigma_t^2 + \Delta t \cdot \sigma_w}{(\sigma_t^2 + \Delta t \cdot \sigma_w)^2 + \sigma_{t+1}^2}$

# Zusammenführen der bisherigen Ergebnisse

- 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  $\Rightarrow N(\mu_0, \sigma_0)$ ,  $\hat{x}(t_0)$  als beste Positionsschätzung
- 3 Errechnen der Prognose  $\hat{x}^-(t+1)$ , kurz vor der nächsten Messung  $t+1 \Rightarrow N(\hat{\mu}^-(t), \sigma_t^2 + \Delta t \cdot \sigma_w)$
- 4 Bestimmen des Kalmangains  $K(t+1) = \frac{\sigma_t^2 + \Delta t \cdot \sigma_w}{(\sigma_t^2 + \Delta t \cdot \sigma_w)^2 + \sigma_{t+1}^2}$
- 5 Korrektur der Prognose des aktuellen besten Zustandes  $\hat{x}(t+1)$

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

$$x_2 = x_1 + u \cdot \Delta t + w$$

- Bestimmen der ersten Messung als beste Positionsschätzung

$\hat{x}_0 = z_0$  Sei  $z_0$  hier die erste Messung



- Bestimmen der besten Vorhersage kurz vor der Messung zur Zeit  $t + 1$

$$\begin{aligned}x_{t+1}^- &= \hat{x}(t) + u\Delta t \\ (\sigma_{t+1}^-)^2 &= \sigma_t^2 + \sigma_w^2\Delta t\end{aligned}$$

- Bestimmen des Kalmangains  $K(t + 1)$  bei nun bekannter Messung zum Zeitpunkt  $t + 1$

$$K_{t+1} = \frac{(\sigma_{t+1}^-)^2}{(\sigma_{t+1}^-)^2 + \sigma_{z_{t+1}}^2}$$

- Korrektur der Prognose des aktuellen besten Zustandes  $\hat{x}(t+1)$  mit neuer Messung  $z_{t+1}$

$$\hat{x}_{t+1} = x_{t+1}^- + K_{t+1} \cdot [z_{t+1} - x_{t+1}^-] \text{ Mittelwertgleichung}$$

$$\sigma_{t+1}^2 = (\sigma_{t+1}^-)^2 - K_{t+1} \cdot (\sigma_{t+1}^-)^2 \text{ Varianzgleichung}$$