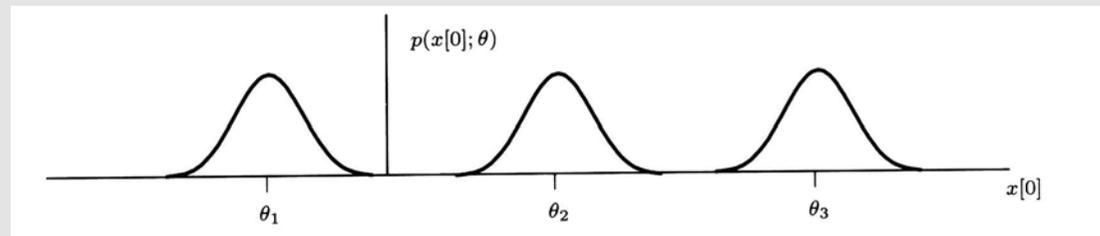


# Das Schätzproblem

Geg.: N-elementiger Datensatz  $X = \{ x[0], x[1], \dots, x[N-1] \}$ , der von einem unbekanntem Parameter  $\theta$  abhängt.

Ges.: Bestimmung von  $\theta$  mit Hilfe eines Schätzers, d.h. einer Funktion  $g$  mit

$$\hat{\theta} = g(x[0], x[1], \dots, x[N-1])$$



Grundidee: Modellierung der Wahrscheinlichkeitsdichtefunktion (WDF) der Daten in Abhängigkeit von  $\theta$

Klassische Schätztheorie:  $\theta$  ist unbekannt, aber deterministisch, d.h.  $\theta$  parametrisiert die WDF von  $x$

Bayes'sche Schätztheorie:  $\theta$  ist wie  $x$  die Realisierung einer Zufallsvariable => Modellierung über eine gemeinsame WDF  
 $p(X, \theta) = p(X/\theta) p(\theta)$

Optimale Schätzer werden über Optimalitätskriterien gesucht, z.B. Minimierung der Varianz ohne systematische Fehler (MVU), kleinste Fehlerquadrate oder **Minimierung des mittleren quadratischen Fehlers**.

# Mittlerer quadratischer Fehler

Ges.: Schätzer, der den (Bayes'schen) mittleren quadratischen Fehler

$$e(\hat{\theta}) = \iint (\theta - \hat{\theta})^2 p(X, \theta) dX d\theta \quad \text{minimiert.}$$

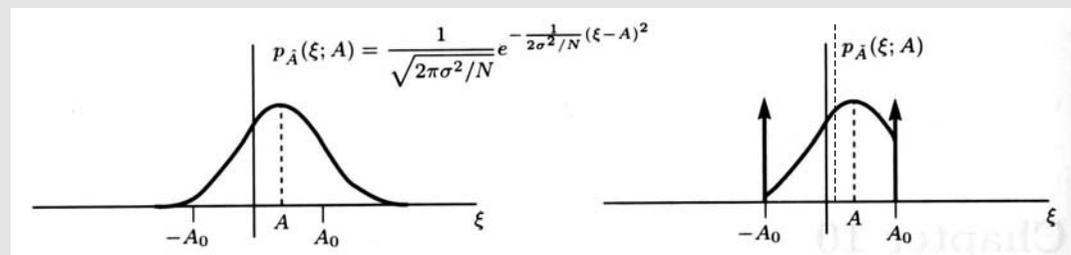
Bayes'sches Theorem:  $p(X, \theta) = p(X|\theta) p(\theta)$  ← a-priori-WDF: vor Beobachtung der Daten (Vorwissen)

$$\Rightarrow e(\hat{\theta}) = \int \left[ \int (\theta - \hat{\theta})^2 p(\theta | X) d\theta \right] p(x) dX$$

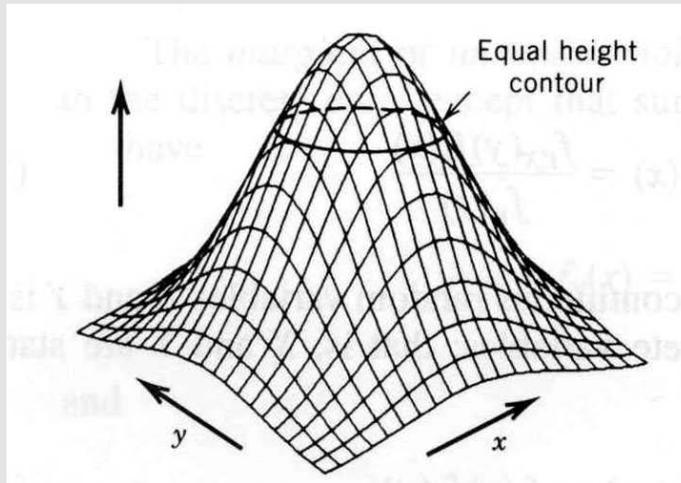
Wähle  $\hat{\theta}$  so, daß e minimiert wird:  $\frac{\partial}{\partial \hat{\theta}} \int (\theta - \hat{\theta})^2 p(\theta | X) d\theta = 0$

$$\text{Ergebnis: } \hat{\theta} = \int \theta p(\theta | X) d\theta = E(\theta | X)$$

d.h. der optimale Schätzer, der den mittleren quadratischen Fehler minimiert (MMQF-Schätzer), ist der *Mittelwert der a-posteriori-WDF* (a posteriori : nach Beobachtung der Daten).



# Multivariate Gaußverteilung



- Konturen konstanter Wahrscheinlichkeit sind Ellipsen
- Bedingte Wahrscheinlichkeiten sind wieder gaußverteilt mit

$$E(y | x) = E(y) + C_{xy} C_{xx}^{-1} (x - E(x))$$

$$C_{y|x} = C_{yy} - C_{yx} C_{xx}^{-1} C_{xy}$$

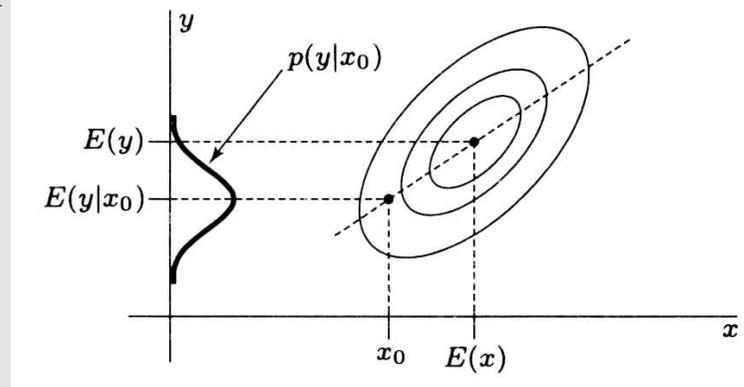
- Sind  $x_1$  und  $x_2$  unkorreliert, so gilt  
 $E(y|x_1, x_2) = E(y|x_1) + E(y|x_2)$

MMQF-Schätzer für  $y$

$$p(x) = \frac{1}{\sqrt{(2\pi)^N \det C_x}} \exp \left[ -\frac{1}{2} (x - \mu_x)^T C_x^{-1} (x - \mu_x) \right]$$

$C_x$ : Kovarianzmatrix ( $N \times N$ , symmetrisch, positiv definit  $\Rightarrow$  invertierbar) mit  $[C_x]_{ij} = E((x_i - E(x_i)) (x_j - E(x_j)))$ ,  $\mu_x$ : Mittelwert

- Ist  $C$  diagonal, dann sind die  $x_i$  unkorreliert und statistisch unabhängig,  $p$  faktorisiert in ein Produkt von 1D-Gaußfunktionen.
- Jede lineare Transformation von  $x$  mit  $y = Ax + b$  ergibt wieder eine Gaußverteilung mit  $\mu_y = A\mu_x + b$  und  $C_y = AC_x A^T$ .



## Orthogonalitätsprinzip (gilt für jeden linearen Schätzer)

MMQF-Schätzer für Gaußverteilung:  $\hat{\theta} = E(\theta) + C_{x\theta} C_{xx}^{-1} (x - E(x))$

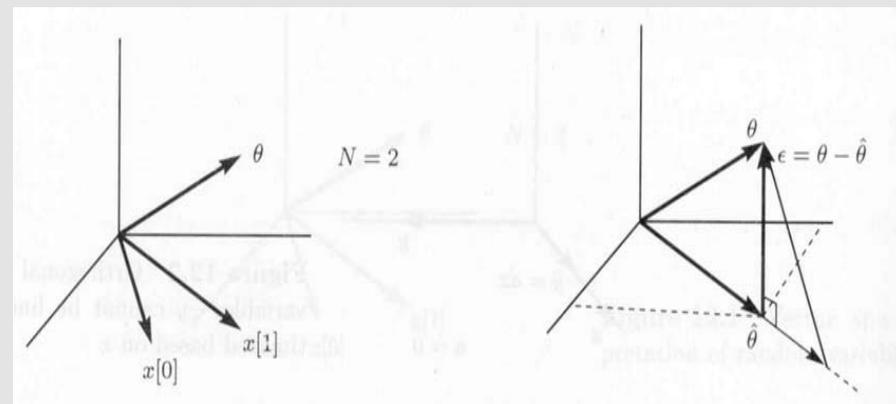
Annahme  $E(x) = E(\theta) = 0 \Rightarrow \hat{\theta} = C_{x\theta} C_{xx}^{-1} x$   
 d.h. Schätzer ist eine Linearkombination der Daten

Anwendungsfall: Geg. seien Daten  $x[1]$  bis  $x[N-1]$ , geschätzt werden soll  $x[N]$ .

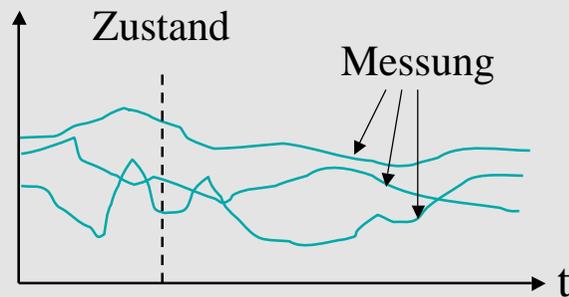
Innovation: Schätzfehler  $\tilde{x}_N = \theta - \hat{\theta} = \theta - C_{x\theta} C_{xx}^{-1} x$

Korrelation:  $E(\tilde{x}_n \cdot x) = E\left(\left(\theta - C_{x\theta} C_{xx}^{-1} x\right) \cdot x\right) = C_{x\theta} - C_{x\theta} C_{xx}^{-1} E(xx)$   
 $= C_{x\theta} - C_{x\theta} C_{xx}^{-1} C_{xx} = C_{x\theta} - C_{x\theta} = 0$

- Schätzfehler bzw. Innovation ist nicht mit den Daten korreliert, d.h. Innovation und Daten sind zueinander orthogonal
- MMQF-Schätzer nutzt die Korrelation der Daten untereinander aus bzw. „dekorreliert“ die Zeitreihe



# Stochastische Prozesse



*Zufallsvariable*: Regel, die jedem Ausgang eines Zufallexperimentes eine *Zahl* zuweist.

*Stochastischer Prozeß*: Regel, die jedem Ausgang eines Zufallexperimentes eine *Funktion* bzw. eine *Zeitreihe* zuweist (d.h. ein Ensemble von Funktionen mit Wahrscheinlichkeitsdichte  $p(x,t)$ ).

Charakterisierung:

- Mittelwert:  $\mu_x(t) = E(x(t))$
- Autokorrelation:  $R(t_1, t_2) = E(x(t_1)x(t_2))$      $R(t,t)$ : Durchschnittsleistung
- Autokovarianz:  $C(t_1, t_2) = R(t_1, t_2) - \mu(t_1)\mu(t_2)$      $C(t,t)$ : Varianz

Stationärer Prozeß (im weiteren Sinne, WSS): Mittelwert konstant, Autokorrelation hängt nur von Zeitdifferenz ab.

Diskreter WSS-Prozeß:  $R(t_1, t_2) \rightarrow r_{xx}[k] = E(x[n]x[n+1])$

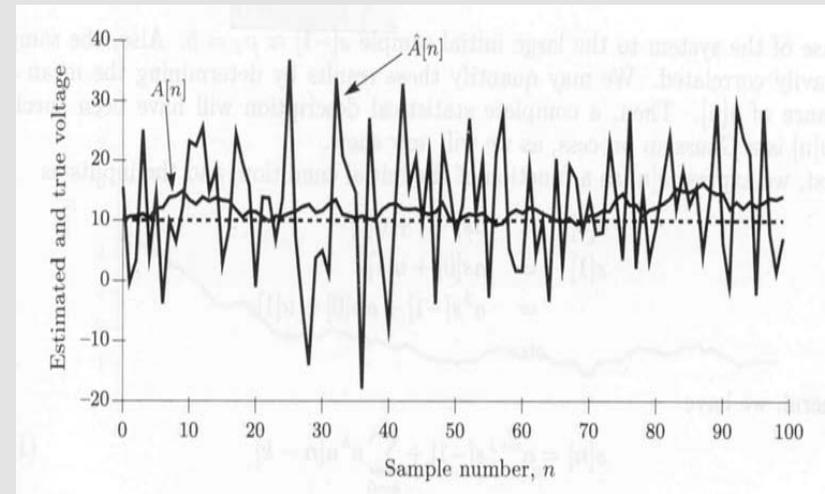
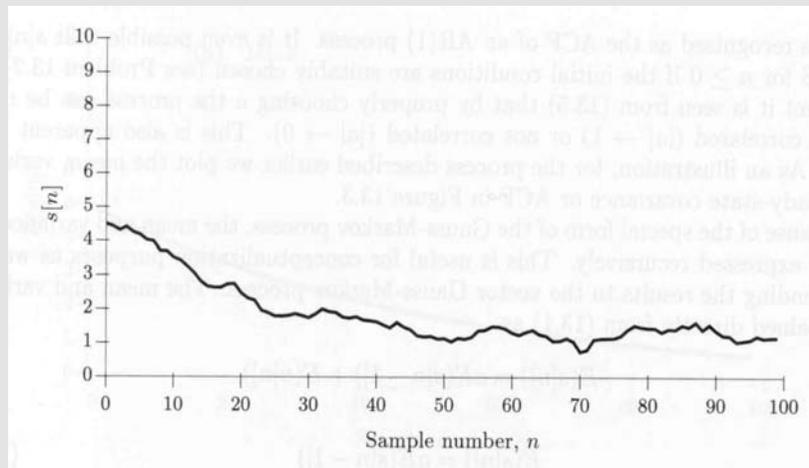
$$C(t_1, t_2) \rightarrow c_{xx}[k] = r_{xx}[k] - \mu_x^2$$

# Skalarer Gauß-Markov-Prozeß

Statistische Modellierung eines Signals als korrelierter stochastischer Prozeß mit dem Zustandsmodell

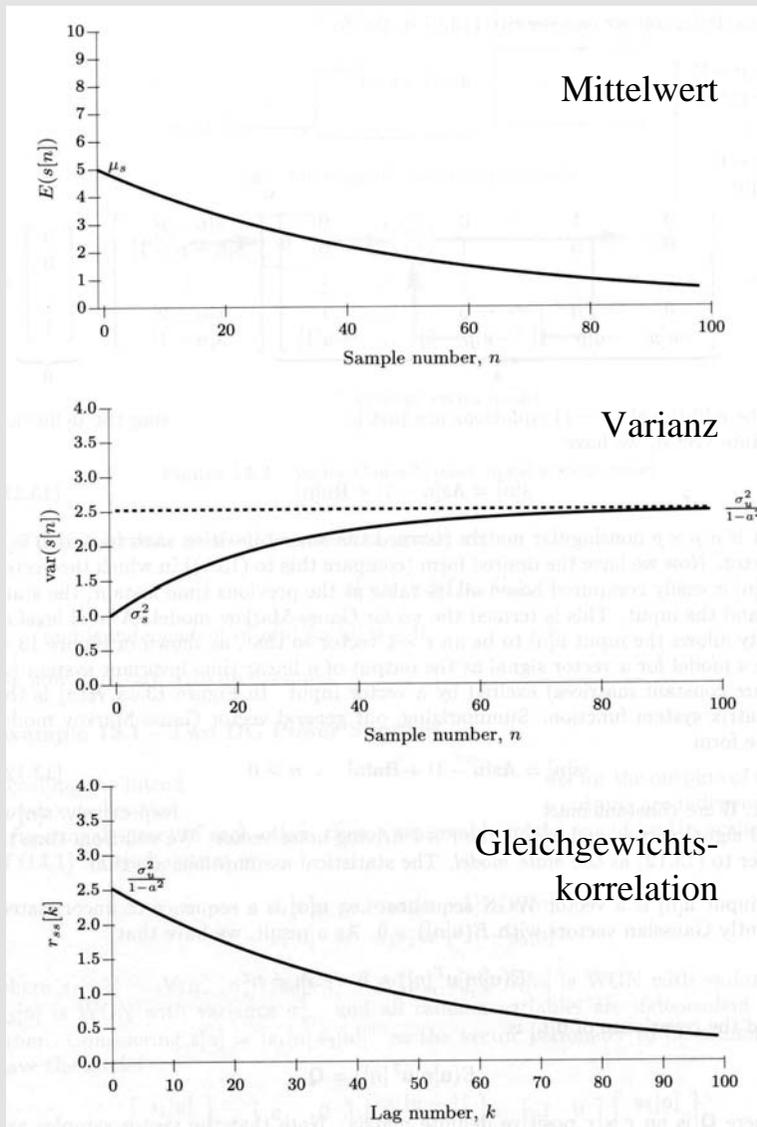
$$s[n] = as[n - 1] + u[n], \quad n \geq 0$$

mit Zustand  $s[n]$ ,  $u \sim N(0, \sigma_u^2)$ ,  $s[-1] \sim N(\mu_s, \sigma_s^2)$  und  $s[-1]$  unabhängig vom Anregungsrauschen  $u$  (Gauß-Markov-Prozeß 1. Ordnung).



- Zustand des Systems hängt nur vom vorherigen Zustand und vom Eingangswert  $u$  ab.
- Für  $|a| < 1$  ist der Prozeß stabil, d.h.  $s[n]$  bleibt beschränkt für alle  $n$ .
- Für  $|a| \rightarrow 1$  ist der Prozeß stark, für  $|a| \rightarrow 0$  schwach korreliert.
- Prozeß ist nicht stationär, wird es aber für unendliches  $n$ .
- $s[n]$  bleibt gaußverteilt für alle  $n$ .

# Statistik des Gauß-Markov-Prozesses



Fortpflanzungsgleichungen:

$$\begin{aligned}
 E(s[n]) &= aE(s[n-1]) + E(u[n]) \\
 &= aE(s[n-1]) \\
 \Rightarrow E(s[n]) &\xrightarrow{n \rightarrow \infty} 0
 \end{aligned}$$

$$\begin{aligned}
 \text{var}(s[n]) &= E\left[(s[n] - E(s[n]))^2\right] \\
 &= E\left[(as[n-1] + u[n] - aE(s[n-1]))^2\right] \\
 &= a^2 \text{var}(s[n-1]) + \sigma_u^2 \\
 \Rightarrow \text{var}(s[n]) &\xrightarrow{n \rightarrow \infty} \frac{\sigma_u^2}{1-a^2}
 \end{aligned}$$

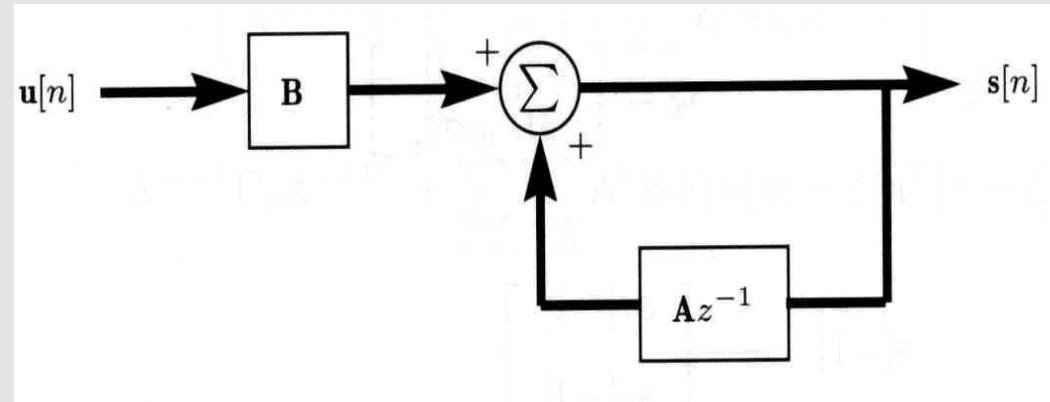
$\Rightarrow$  Für unendliches  $n$  wird der Prozeß stationär mit Autokorrelationsfunktion

$$r_{ss}[k] = \frac{\sigma_u^2}{1-a^2} a^k$$

# Vektorieller Gauß-Markov-Modell

Erweiterung des skalaren Modells auf  $p \times 1$ - Signalvektoren  $\mathbf{s}[n]$  und  $r \times 1$ - dimensionales Anregungsrauschen  $\mathbf{u}[n]$ :

$$\mathbf{s}[n] = \mathbf{A}\mathbf{s}[n - 1] + \mathbf{B}\mathbf{u}[n]$$



mit  $p \times p$ - Matrix  $\mathbf{A}$  und  $p \times r$ - Matrix  $\mathbf{B}$ ,  $\mathbf{u} \sim N(0, \mathbf{Q})$ ,  $\mathbf{s}[-1] \sim N(\boldsymbol{\mu}_s, \mathbf{C}_s)$  und  $\mathbf{s}[-1]$  unabhängig von der Eingangsgröße  $\mathbf{u}$ .  $\mathbf{A}$  und  $\mathbf{B}$  dürfen zeitlich variieren.

Fortpflanzungsgleichungen:

$$\mathbf{E}(\mathbf{s}[n]) = \mathbf{A}\mathbf{E}(\mathbf{s}[n - 1])$$

$$\mathbf{C}[n] = \mathbf{A}\mathbf{C}[n - 1]\mathbf{A}^T + \mathbf{B}\mathbf{Q}\mathbf{B}^T$$

$$\mathbf{E}(\mathbf{s}[n]) \xrightarrow{n \rightarrow \infty} 0$$

$$\mathbf{C}[n] \xrightarrow{n \rightarrow \infty} \sum_{k=0}^{\infty} \mathbf{A}^k \mathbf{B}\mathbf{Q}\mathbf{B}^T \mathbf{A}^{kT}$$

- für konstantes  $\mathbf{A}$  und  $\mathbf{B}$  wird der Prozeß asymptotisch stationär.
- für ein stabiles System müssen die Eigenwertbeträge von  $\mathbf{A}$  kleiner als 1 sein
- andere Eigenschaften analog zum skalaren Modell

# Skalarer Kalmanfilter - Voraussetzungen

1. „Beobachtung“: Schätzung des Zustands ohne Berücksichtigung des Meßrauschens  
„Filterung“: Schätzung des Zustands unter Berücksichtigung des Meßrauschens  
=> Kalman-“Filter“
2. Skalares Gauß-Markov-Signalmodell:  $s[n] = as[n - 1] + u[n]$ ,  $n \geq 0$   
Meßmodell (additives Gauß-Rauschen):  $x[n] = s[n] + w[n]$  mit  $w \sim N(0, \sigma_n^2[n])$   
unabh. von  $u$  und  $s[-1]$
3. Vereinfachung:  $\mu_s = 0$
4. A-priori-Wissen über den im Signalmodell gegebenen zeitlichen Zusammenhang soll verwendet werden => Bayes'scher Ansatz.
5. Optimalitätskriterium: Minimierung des mittleren quadratischen Fehlers
6. Ges.: MMQF-Schätzer für  $s[n]$  mit sequenzieller Korrektur, d.h. neue Schätzung soll sich aus der alten Schätzung  $s[n - 1]$  und der aktuellen Beobachtung  $x[n]$  berechnen.

## Skalarer Kalmanfilter\*

Vorhersage des Signals:

$$\hat{s}[n | n - 1] = a\hat{s}[n - 1 | n - 1]$$

Vorhersage des MMQF:

$$M[n | n - 1] = a^2 M[n - 1 | n - 1] + \sigma_u^2$$

Kalman-Gain:

$$K[n] = \frac{M[n | n - 1]}{\sigma_n^2 + M[n | n - 1]}$$

Korrektur der Signalschätzung:

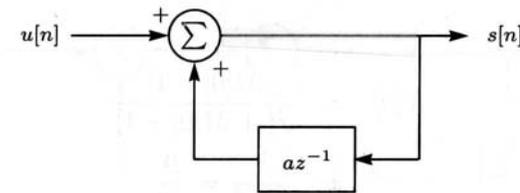
$$\hat{s}[n | n] = \hat{s}[n | n - 1] + K[n](x[n] - \hat{s}[n | n - 1])$$

Korrektur des MMQF:

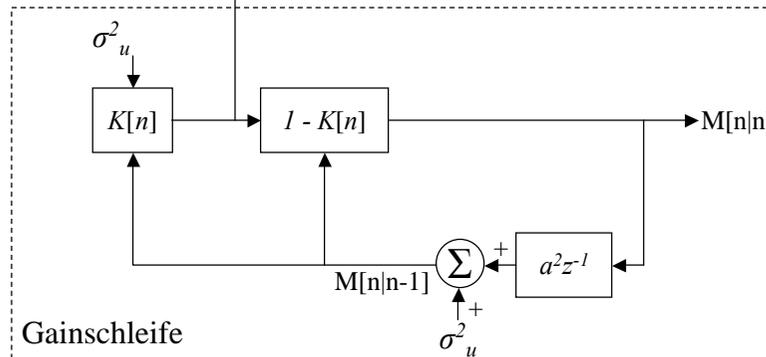
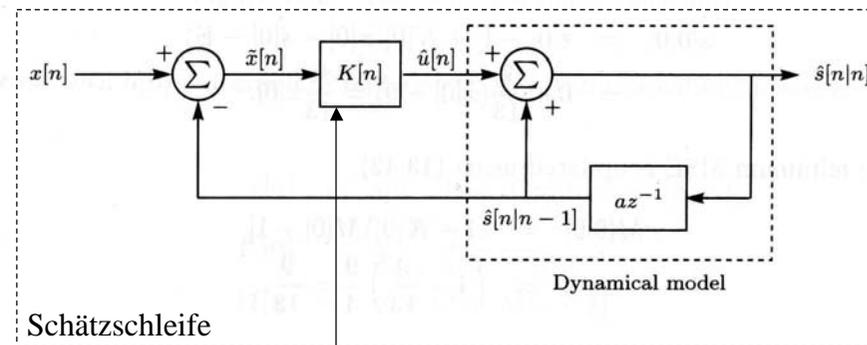
$$M[n | n] = (1 - K[n])M[n | n - 1]$$

Initialisierung:

$$\hat{s}[-1 | -1] = \mu_s, \quad M[-1 | -1] = \sigma_s^2$$



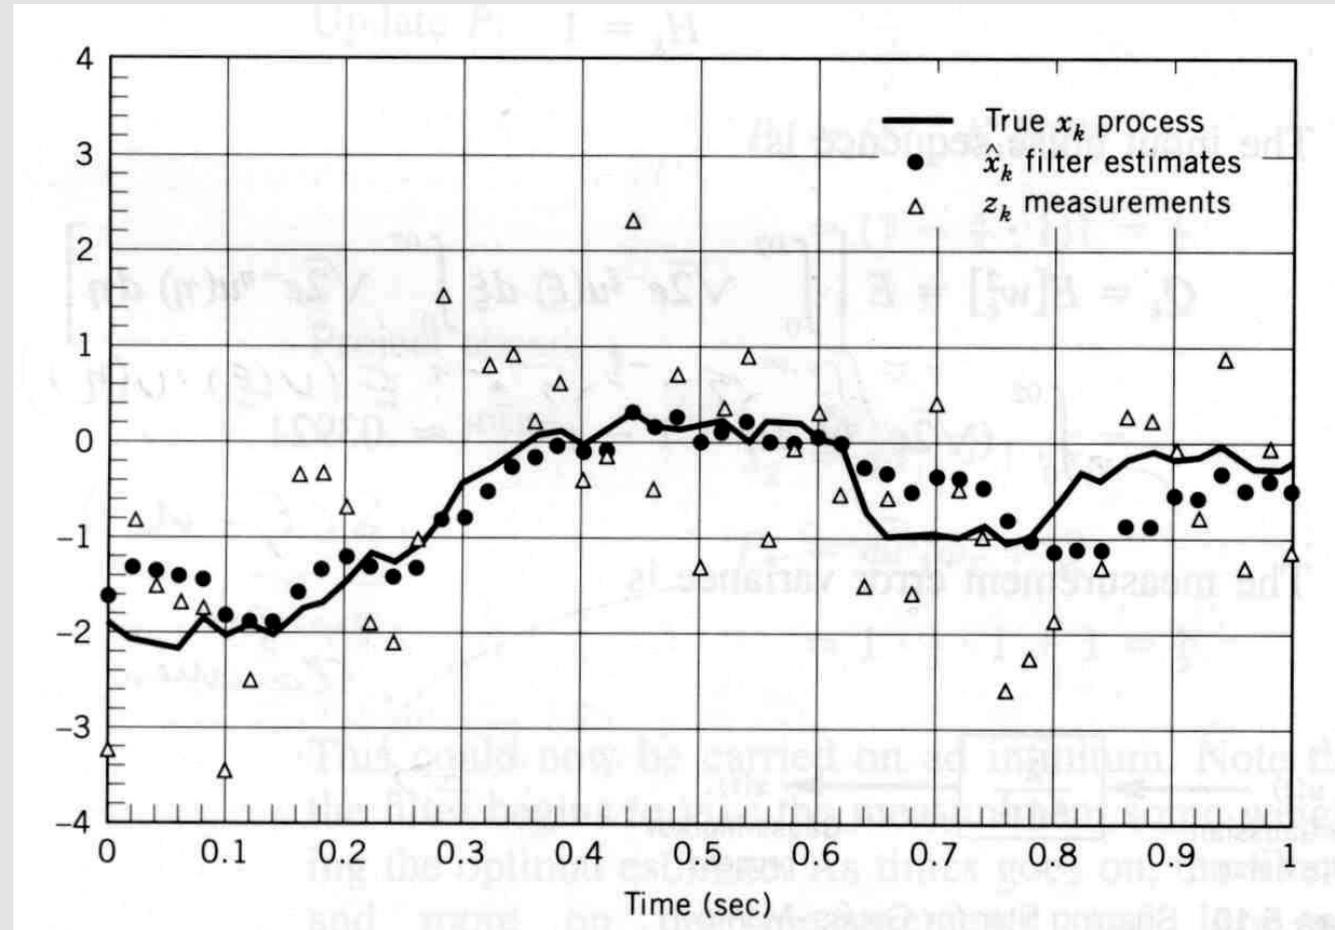
(a) Dynamical model



\*identische Gleichungen für  $\mu_s \neq 0$

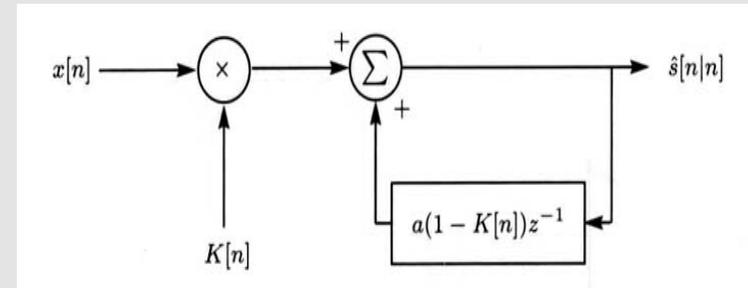
## Beispiel

$$\begin{aligned} a &= 0.9802 \\ \sigma_u^2 &= 0.039 \\ \sigma_n^2 &= 1 \\ \mu_s &= 0 \\ \sigma_s^2 &= 1 \end{aligned}$$

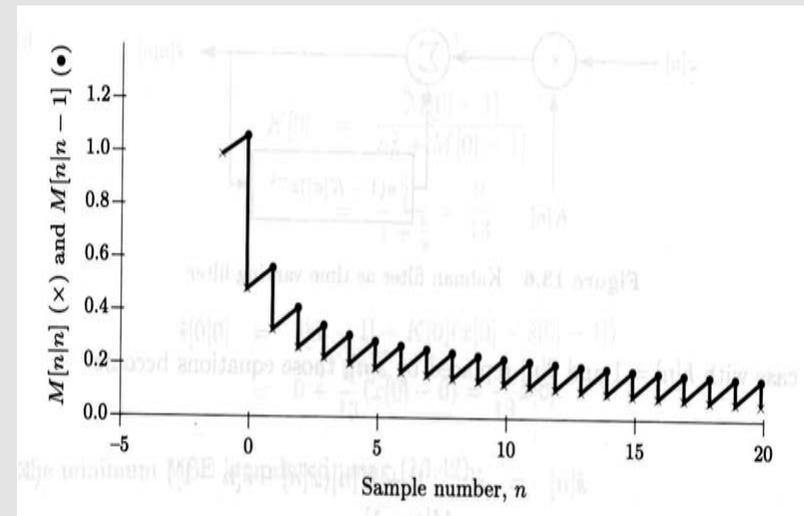


# Kalmanfilter - Eigenschaften

- Gainberechnung läuft ohne Rückkopplung der Daten in einer unabhängigen Schleife
- Gain kann schon im voraus berechnet werden
- Gainschleife kann instabil werden
- Kalmanfilter ist ein rekursiver linearer Filter erster Ordnung mit zeitvarianten Koeffizienten
- Keine Matrixinversion notwendig
- Kalmanfilter liefert gleichzeitig sein eigenes Konfidenzmaß, den MMQF  $M[n|n]$
- MMQF steigt im Vorhersageschritt und sinkt im Korrekturschritt.
- Kalmanfilter ist der bestmögliche lineare Filter, selbst wenn Gauß'sche Annahme nicht zutrifft.
- kann auf Vektorzustände und -messungen verallgemeinert werden.



$$\begin{aligned}\hat{s}[n | n] &= a\hat{s}[n - 1 | n - 1] + \\ &K[n](x[n] - a\hat{s}[n - 1 | n - 1]) \\ &= a(1 - K[n])\hat{s}[n - 1 | n - 1] + K[n]x[n]\end{aligned}$$



# Vektorieller Zustand - skalare Messung

Signalmodell:

Vektorieller Gauß-Markov-Modell

$$\mathbf{s}[n] = A\mathbf{s}[n-1] + B\mathbf{u}[n]$$

mit Zusatzannahme  $Q$  diagonal.

Meßmodell:

$$x[n] = \mathbf{h}^T[n]\mathbf{s}[n] + w[n]$$

mit  $w \sim N(0, \sigma_n^2[n])$  unabh. von  $\mathbf{u}$  und  $\mathbf{s}[-1]$

- Kalman-Gain ist jetzt ein Vektor, MMQF eine Matrix
- Es müssen genügend Messungen vorhanden sein
- $A$  und  $\mathbf{h}$  müssen bestimmten Bedingungen genügen (Beobachtbarkeit)

Vorhersage des Signals:

$$\hat{\mathbf{s}}[n | n-1] = A\hat{\mathbf{s}}[n-1 | n-1]$$

Vorhersage des MMQF ( $p \times p$  - Matrix):

$$M[n | n-1] = AM[n-1 | n-1]A^T + BQB^T$$

Kalman-Gain-Vektor ( $p \times 1$ ):

$$\mathbf{K}[n] = \frac{M[n | n-1]\mathbf{h}[n]}{\sigma_n^2 + \mathbf{h}^T[n]M[n | n-1]\mathbf{h}[n]}$$

Korrektur der Signalschätzung:

$$\hat{\mathbf{s}}[n | n] = \hat{\mathbf{s}}[n | n-1] + \mathbf{K}[n](x[n] - \mathbf{h}^T[n]\hat{\mathbf{s}}[n | n-1])$$

Korrektur des MMQF:

$$M[n | n] = (1 - \mathbf{K}[n]\mathbf{h}^T[n])M[n | n-1]$$

Initialisierung:

$$\hat{\mathbf{s}}[-1 | -1] = \hat{\mathbf{i}}_s, \quad M[-1 | -1] = C_s$$

# Vektorieller Zustand - vektorielle Messung

Signalmodell: wie vorher.

Lineares Meßmodell: Messungen sind  $m \times 1$ - Vektoren

$$\mathbf{x}[n] = \mathbf{H}[n]\mathbf{s}[n] + \mathbf{w}[n]$$

mit  $\mathbf{w} \sim N(0, \mathbf{C}[n])$  unabh. von  $\mathbf{u}$  und  $\mathbf{s}[-1]$

- Kalman-Gain und MMQF sind Matrizen
- Achtung: Matrixinversion für Berechnung der Gainmatrix erforderlich.
- Erweiterungen:
  - $A, B, Q$  zeitvariant  $\Rightarrow$  identische Gleichungen
  - zeitliche Korrelationen in  $\mathbf{w}$
  - deterministisches  $\mathbf{u}$

Vorhersage des Signals:

$$\hat{\mathbf{s}}[n | n - 1] = \mathbf{A}\hat{\mathbf{s}}[n - 1 | n - 1]$$

Vorhersage des MMQF ( $p \times p$  - Matrix):

$$\mathbf{M}[n | n - 1] = \mathbf{A}\mathbf{M}[n - 1 | n - 1]\mathbf{A}^T + \mathbf{B}\mathbf{Q}\mathbf{B}^T$$

Kalman-Gain-Matrix ( $p \times m$ ):

$$\mathbf{K}[n] = \mathbf{M}[n | n - 1]\mathbf{H}^T[n] \left( \mathbf{C}[n] + \mathbf{H}[n]\mathbf{M}[n | n - 1]\mathbf{H}^T[n] \right)^{-1}$$

Korrektur der Signalschätzung:

$$\hat{\mathbf{s}}[n | n] = \hat{\mathbf{s}}[n | n - 1] + \mathbf{K}[n](x[n] - \mathbf{H}[n]\hat{\mathbf{s}}[n | n - 1])$$

Korrektur des MMQF:

$$\mathbf{M}[n | n] = (\mathbf{I} - \mathbf{K}[n]\mathbf{H}[n])\mathbf{M}[n | n - 1]$$

Initialisierung:

$$\hat{\mathbf{s}}[-1 | -1] = \hat{\mathbf{i}}_s, \quad \mathbf{M}[-1 | -1] = \mathbf{C}_s$$

# Erweiterter Kalmanfilter (EKF)

Erweiterung auf nichtlineares Signal- und Meßmodell mit additiven Rauschtermen:

$$\mathbf{s}[n] = \mathbf{a}(\mathbf{s}[n-1]) + \mathbf{B}\mathbf{u}[n] \quad \text{und} \quad x[n] = \mathbf{h}(\mathbf{s}[n]) + \mathbf{w}[n]$$

mit nichtlinearen Funktionen  $\mathbf{a}$  und  $\mathbf{h}$ . Geschlossene Lösung für MMQF-Schätzer ist nicht bekannt  $\Rightarrow$  Näherungslösung durch Linearisierung um  $\hat{\mathbf{s}}[n-1|n-1]$  und  $\hat{\mathbf{s}}[n|n-1]$

$$\mathbf{a}(\mathbf{s}[n-1]) \approx \mathbf{a}(\hat{\mathbf{s}}[n-1|n-1]) + \left. \frac{\partial \mathbf{a}}{\partial \mathbf{s}[n-1]} \right|_{\substack{\mathbf{s}[n-1]= \\ \hat{\mathbf{s}}[n-1|n-1]}} (\mathbf{s}[n-1] - \hat{\mathbf{s}}[n-1|n-1]) \quad \Rightarrow \quad A[n-1] = \left. \frac{\partial \mathbf{a}}{\partial \mathbf{s}[n-1]} \right|_{\substack{\mathbf{s}[n-1]= \\ \hat{\mathbf{s}}[n-1|n-1]}}$$

$$\mathbf{h}(\mathbf{s}[n]) \approx \mathbf{h}(\hat{\mathbf{s}}[n|n-1]) + \left. \frac{\partial \mathbf{h}}{\partial \mathbf{s}[n]} \right|_{\substack{\mathbf{s}[n]= \\ \hat{\mathbf{s}}[n|n-1]}} (\mathbf{s}[n] - \hat{\mathbf{s}}[n|n-1]) \quad \Rightarrow \quad H[n] = \left. \frac{\partial \mathbf{h}}{\partial \mathbf{s}[n]} \right|_{\substack{\mathbf{s}[n]= \\ \hat{\mathbf{s}}[n|n-1]}}$$

Filtergleichungen ändern sich nicht, bis auf

Vorhersage:  $\hat{\mathbf{s}}[n|n-1] = \mathbf{a}(\hat{\mathbf{s}}[n-1|n-1])$

und Korrektur:

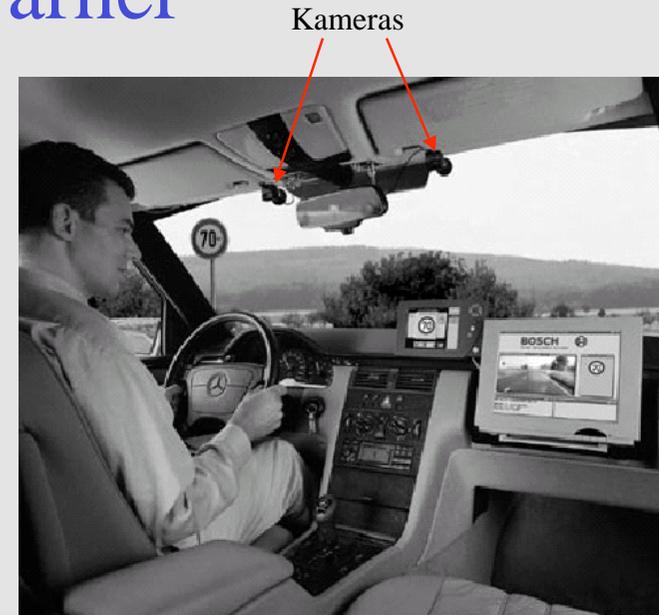
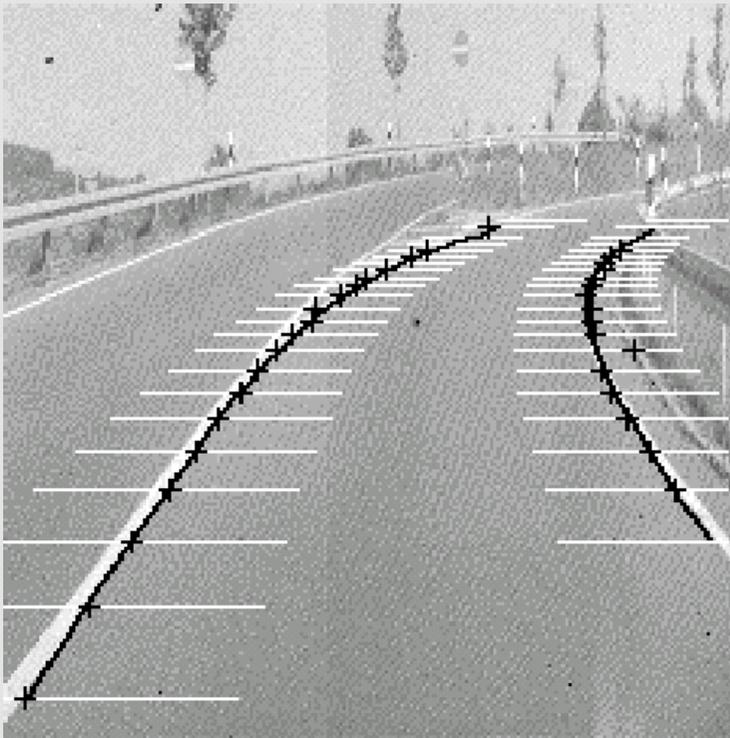
$$\hat{\mathbf{s}}[n|n] = \hat{\mathbf{s}}[n|n-1] + K[n](x[n] - \mathbf{h}(\hat{\mathbf{s}}[n|n-1]))$$

Achtung:

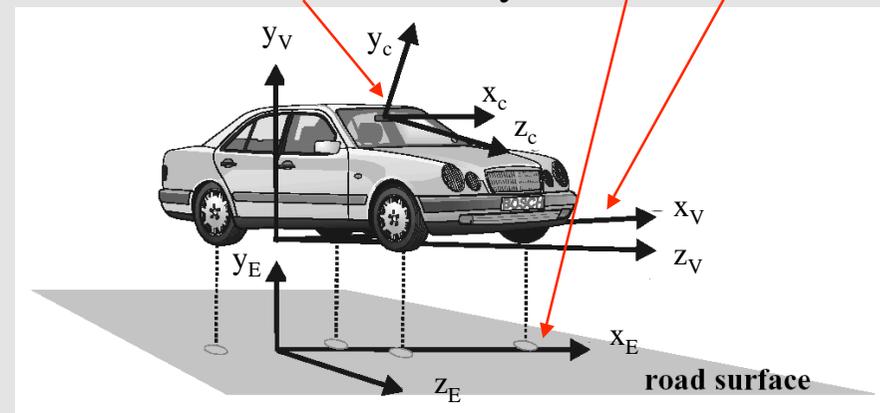
- keine Optimalitätseigenschaften
- M ist hier kein verlässliches Konfidenzmaß
- $A[n-1] H[n]$  müssen in jedem Zeitschritt neu berechnet werden.
- K und M können nicht im voraus berechnet werden.

# Anwendungsbeispiel Spurwarner

Aufgabe: Detektion der Fahrbahnrandmarkierungen im Kamerabild, daraus Schätzung der Fahrzeugposition innerhalb des Spurverlaufs mit einem erweiterten Kalmanfilter und ggf. Warnung bei Verlassen der Spur.



3 Koordinatensysteme: Fahrbahn-, Fahrzeug- und Kamerakoordinatensystem:



# Modellierung eines Zeitschritts

- Spurverlauf wird als Polynom 3. Grades beschrieben:

$$x_E(z_E) = \Delta x + \frac{c_0}{2} z_E^2 + \frac{c_1}{6} z_E^3$$

mit Krümmung

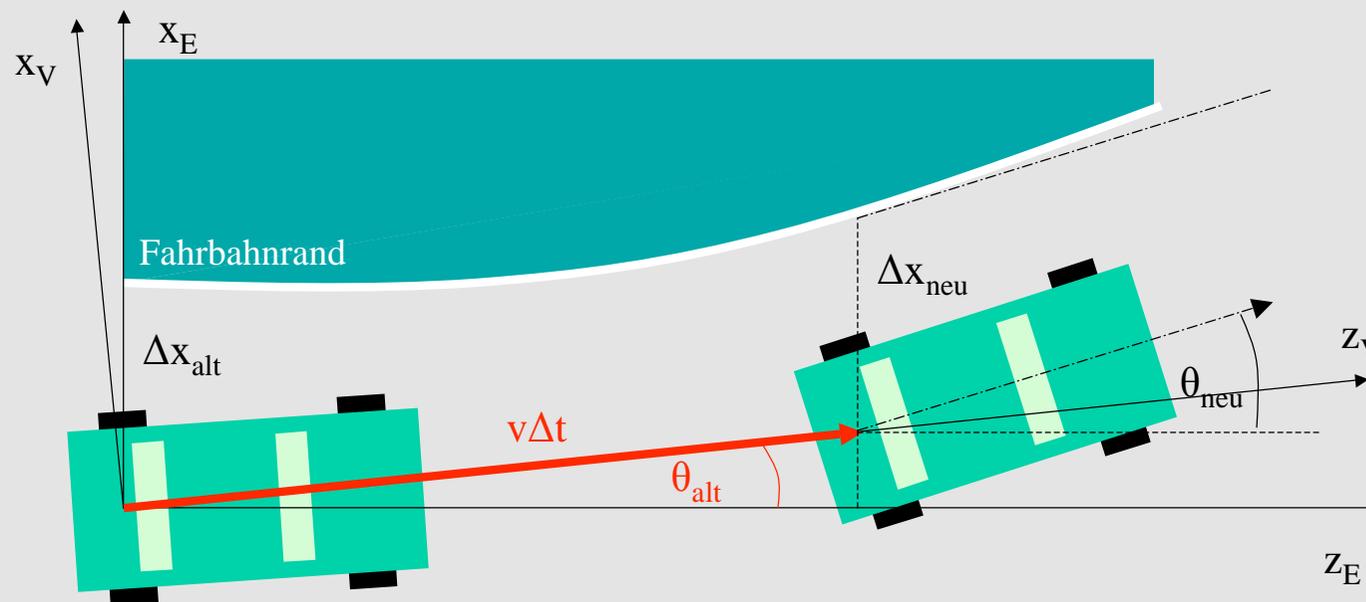
mit Krümmungsänderung

und Abstand zum Fahrbahnrand  $\Delta x$

$$c_0 = \frac{d^2 x_E}{dz_E^2}$$

$$c_1 = \frac{d^3 x_E}{dz_E^3}$$

- Bewegung im Zeitschritt  $\Delta t$  sei stückweise konstant, d.h. erst Translation um  $v \Delta t$  in Richtung  $\theta$ , dann Drehung parallel zum Spurverlauf.
- Straßen-KS ist tangential zur Spur.
- $v$  und  $\Delta t$  sei bekannt.



# Aufstellen des Signalmodells

1. Spurposition:

$$\Delta x_{neu} = \Delta x_{alt} + \frac{c_0}{2} z_E^2 + \frac{c_1}{6} z_E^3 - v\Delta t \tan \theta$$

Annahme: Kleine Gierwinkel und Krümmungen

$$\xrightarrow{\theta \ll 1} z_E \approx v\Delta t, \quad \tan \theta \approx \theta \quad \Rightarrow$$

$$\Delta x_{neu} = \Delta x_{alt} + \frac{c_0^{alt}}{2} (v\Delta t)^2 + \frac{c_1^{alt}}{6} (v\Delta t)^3 - \theta v_{alt} \Delta t$$

2. Krümmung und Krümmungsänderung:

$$c_0^{neu} = c_0^{alt} + \left. \frac{\partial c_0}{\partial z_E} \right|_{z_E=0} \Delta z_E \quad \Rightarrow$$

$$c_0^{neu} = c_0^{alt} + c_1^{alt} v\Delta t$$

$$c_1^{neu} = c_1^{alt}$$

3. Gierwinkel:  $\theta_{neu} = \theta_{alt} + \tan \frac{dx_E}{dz_E} \approx \theta_{alt} + \frac{dx_E}{dz_E} =$

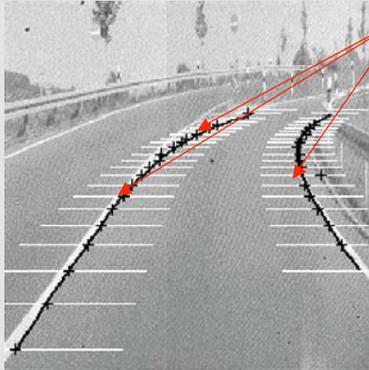
$$\theta_{alt} + c_0 z_E + \frac{c_1}{2} z_E^2 \quad \Rightarrow$$

$$\theta_{neu} = \theta_{alt} + c_0^{alt} v\Delta t + \frac{c_1^{alt}}{2} (v\Delta t)^2$$

=> Signalmodell:  $\mathbf{s}[n] = \mathbf{A}\mathbf{s}[n-1] + \mathbf{u}[n]$  mit  $\mathbf{s}[n] = (\Delta x, c_0, c_1, \theta)^T$  und

$$\mathbf{A} = \begin{pmatrix} 1 & \frac{1}{2}(v\Delta t)^2 & \frac{1}{6}(v\Delta t)^3 & -v\Delta t \\ 0 & 1 & v\Delta t & 0 \\ 0 & 0 & 1 & 0 \\ 0 & v\Delta t & \frac{1}{2}(v\Delta t)^2 & 1 \end{pmatrix}, \quad \mathbf{Q} = \begin{pmatrix} \sigma_{\Delta x}^2 & 0 & 0 & 0 \\ 0 & \sigma_{c_0}^2 & 0 & 0 \\ 0 & 0 & \sigma_{c_1}^2 & 0 \\ 0 & 0 & 0 & \sigma_{\theta}^2 \end{pmatrix}$$

# Aufstellen des Meßmodells



1.  $N$  Beobachtungen pro Frame  
mit

$$\mathbf{x}[n] = \begin{pmatrix} x_b(\mathbf{s}[n], y_{b,1}) + w_1 \\ x_b(\mathbf{s}[n], y_{b,2}) + w_2 \\ \vdots \\ x_b(\mathbf{s}[n], y_{b,N}) + w_N \end{pmatrix}$$

2. Transformation Welt-Kamera:

$$x_C = \cos \theta x_E - \sin \theta z_E$$

$$y_C = y_E - h$$

$$z_C = \sin \theta x_E + \cos \theta z_E - d$$

mit Montagehöhe  $h$  und Entfernung zur Hinterachse  $d$

3. Perspektivische Abbildung  
für  $\theta \ll 1$ :

$$x_b = f \frac{x_E - \theta z_E}{\theta x_E + z_E - d}$$

$$y_b = f \frac{y_E - h}{\theta x_E + z_E - d}$$

4. Auflösen nach  $z_E$   
für  $\theta z_E \ll z_E$ :

$$z_E \approx d - \frac{fh}{y_b} \quad \text{einsetzen}$$

$$x_b = f \frac{\Delta x + \frac{c_0}{2} z_E^2 + \frac{c_1}{6} z_E^3 - \theta z_E}{\theta \left( \Delta x + \frac{c_0}{2} z_E^2 + \frac{c_1}{6} z_E^3 \right) + z_E - d}$$

=> erweiterter Kalmanfilter benötigt linearisierte Meßgleichung mit den Ableitungen  $\frac{\partial x_b}{\partial(\Delta x)}$ ,  $\frac{\partial x_b}{\partial \theta}$ ,  $\frac{\partial x_b}{\partial c_0}$ ,  $\frac{\partial x_b}{\partial c_1}$

# Beispiele

