



Kybernetik **Systemidentifikation**

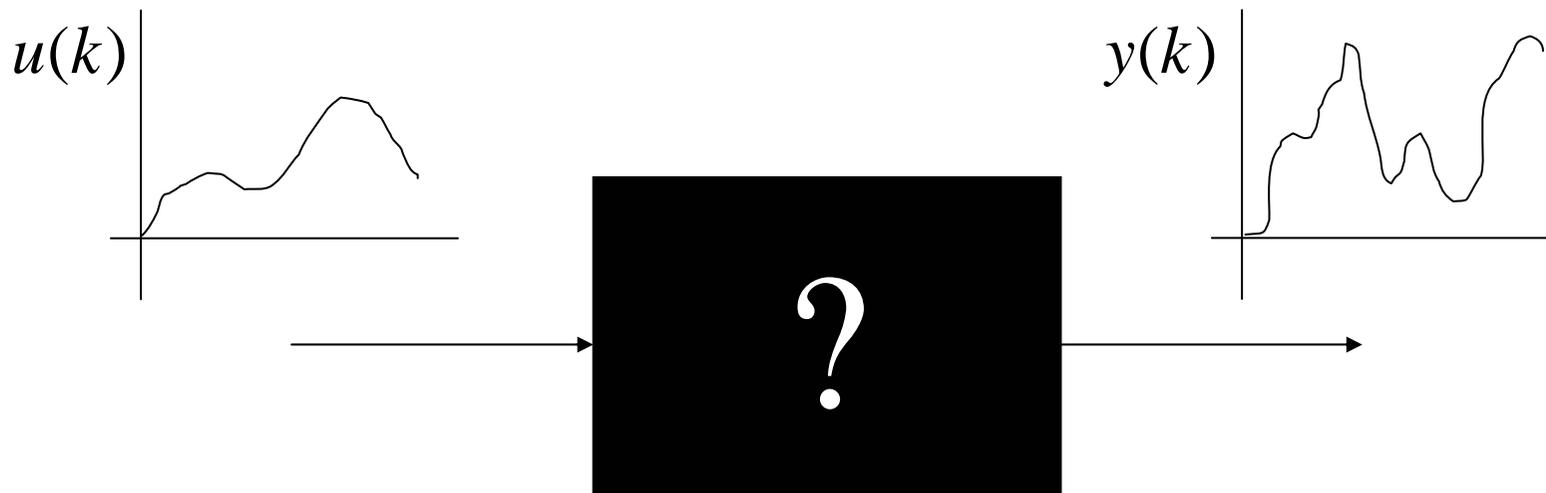
Mohamed Oubbati
Institut für Neuroinformatik

Tel.: (+49) 731 / 50 24153
mohamed.oubbati@uni-ulm.de

12. 06. 2012

Was ist Systemidentifikation?

Der Begriff **Systemidentifikation** beschreibt Methoden und Algorithmen, die aus gemessenen **Ein-/Ausgangsdaten** vom System, ein empirisches Modell des Systems erzeugen.



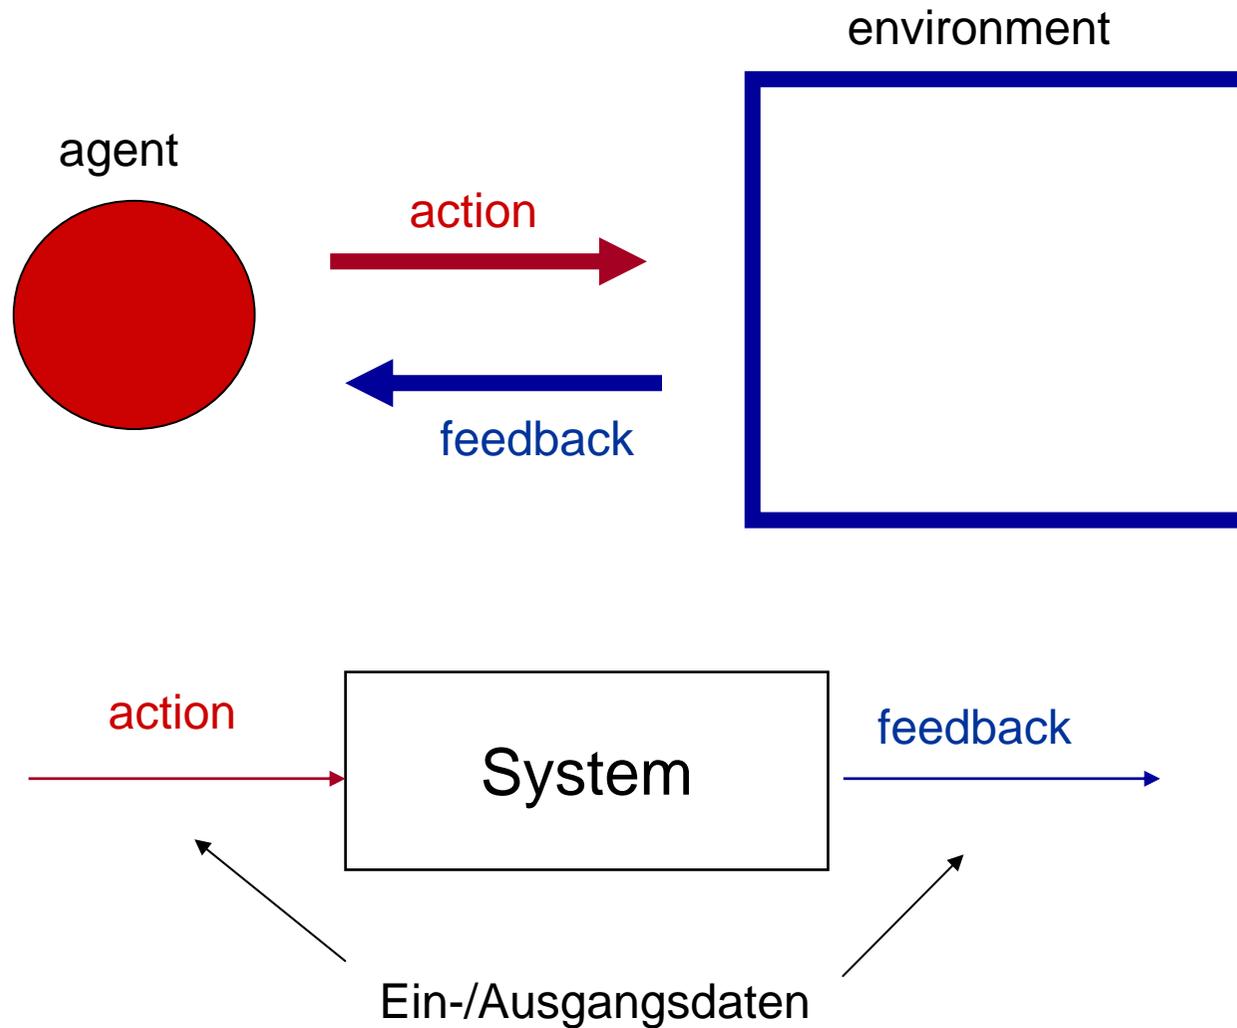
Input/output $u(n) / y(n)$ data -----> Systemidentifikation -----> empirisches Modell

Etappen der Systemidentifikation

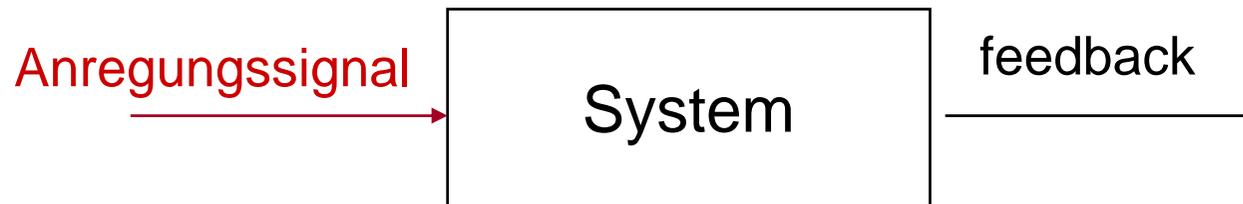
Etappen der Systemidentifikation

1. Ein-/Ausgangsdaten vom System messen.
2. Modellstruktur auswählen (AR, ARMA, ...).
3. Parameter des Modells anpassen.
4. Das gefundene Modell validieren (prüfen).

1. Ein-/Ausgangsdaten vom System messen



1. Ein-/Ausgangsdaten vom System messen



Anregungssignale, mit denen das System (agent-environment) angeregt wird, spielen eine große Rolle bei dem Identifikationsverfahren. Es ist dabei wichtig ein möglichst **breites Frequenzspektrum abzudecken**.

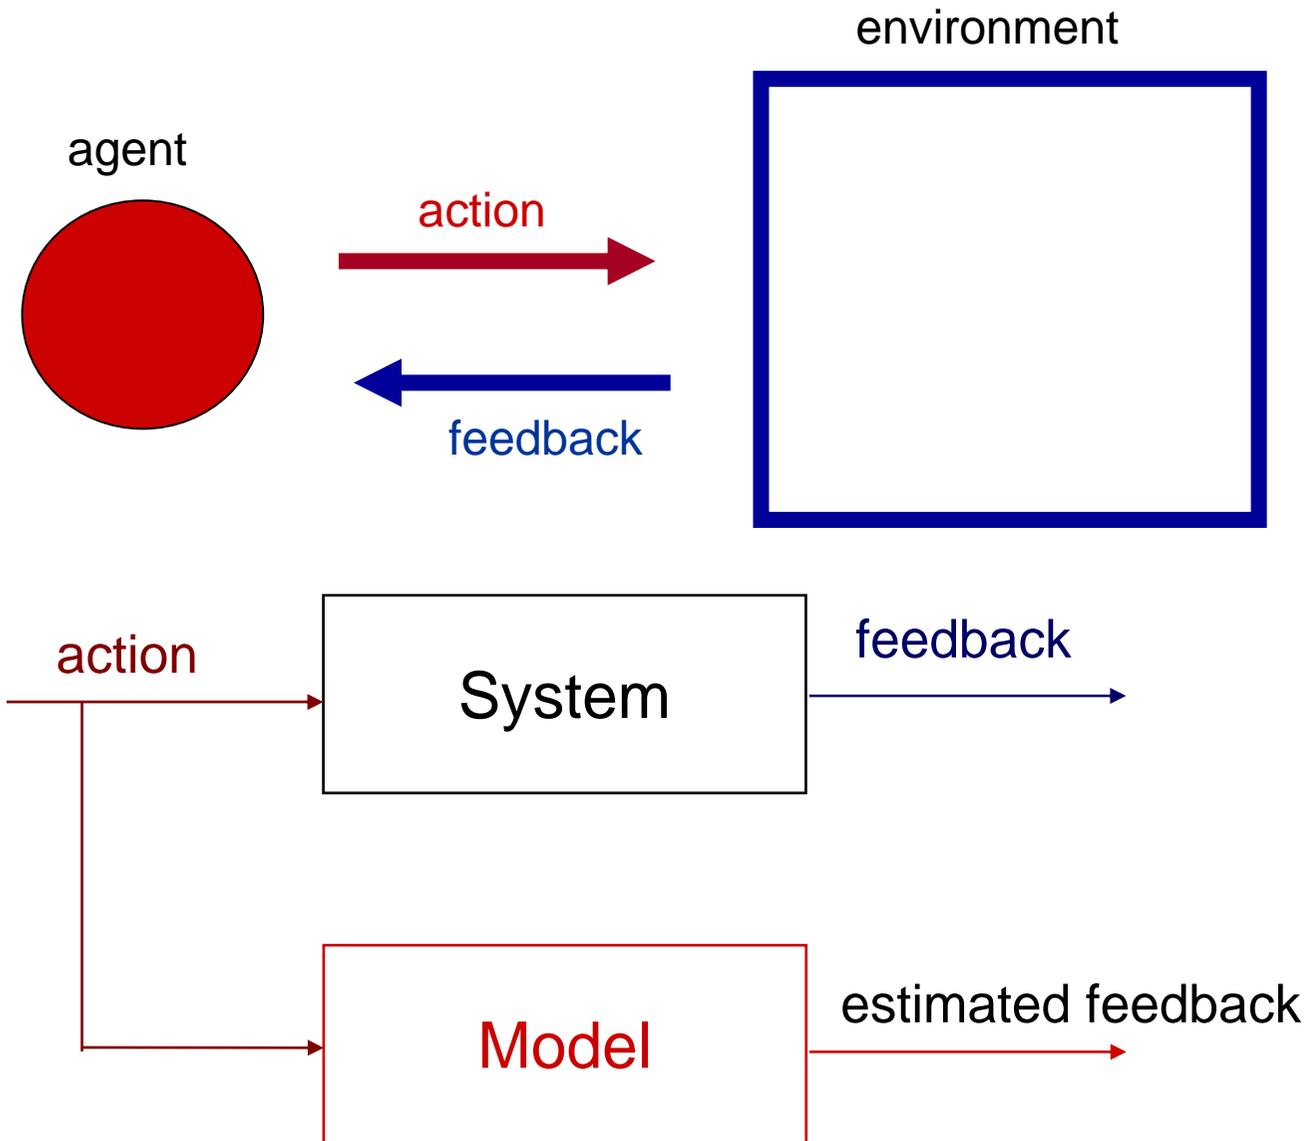
1. Ein-/Ausgangsdaten vom System messen

Anregungssignale zur Systemidentifikation

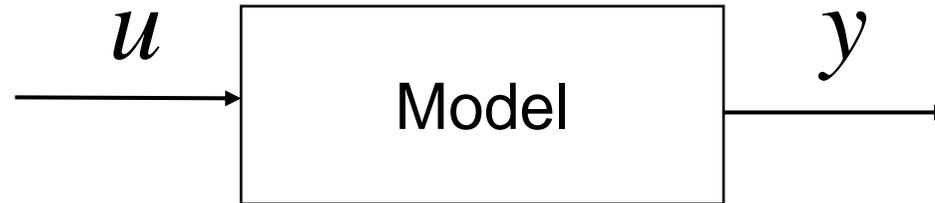
Dies kann mithilfe verschiedener Eingangssignale produziert:

- **Impuls**: eher für die theoretische Analyse hilfreich.
- **Sinus-Sweep**: Sinusschwingung mit ständig ansteigender Frequenz.
- **Rauschen**: können als regelmäßige Sprünge verschiedener Amplitude erstellt werden.
- **PRBS** (Pseudo Random Binary Signal): können als eine Folge von Rechteckimpulsen unterschiedlicher Länge erstellt werden.

2. Eine Modellstruktur auswählen



2. Eine Modellstruktur auswählen



- **AR-Modell**

Bei *AR-Modellen* benutzt man eine spezielle Regressionsgleichung die *Autoregressionsgleichung* (kurz: AR).

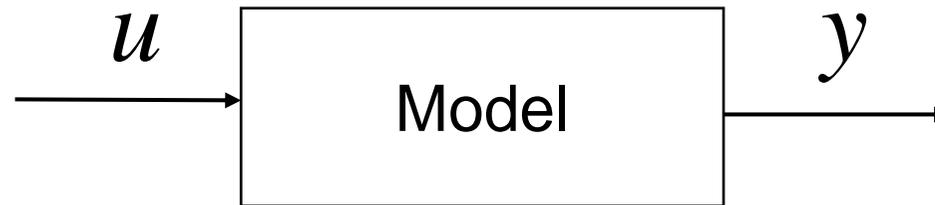
$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_n y(k-n)$$

- **MA-Modell**

Das *MA-Modell* "Moving-Average" (kurz: MA) beschreibt die Abhängigkeitsbeziehungen der Inputs wie folgt:

$$y(k) = u(k) + b_1 u(k-1) + \dots + b_m u(k-m)$$

2. Eine Modellstruktur auswählen



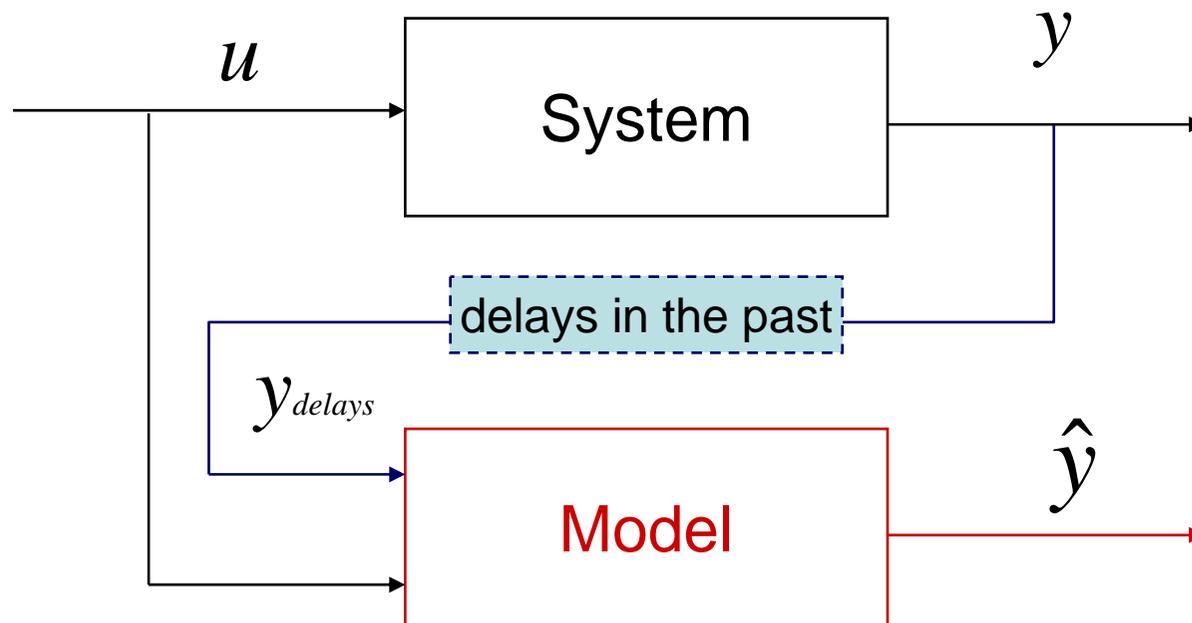
- **ARMA-Modell**

AR-Modelle und *MA-Modelle* verknüpft ergeben eine sehr nützliche Klasse von Zeitreihenmodellen, die *ARMA-Modelle*:

$$y(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_n y(k-n) \\ + u(k) + b_1 u(k-1) + \dots + b_m u(k-m)$$

2. Eine Modellstruktur auswählen

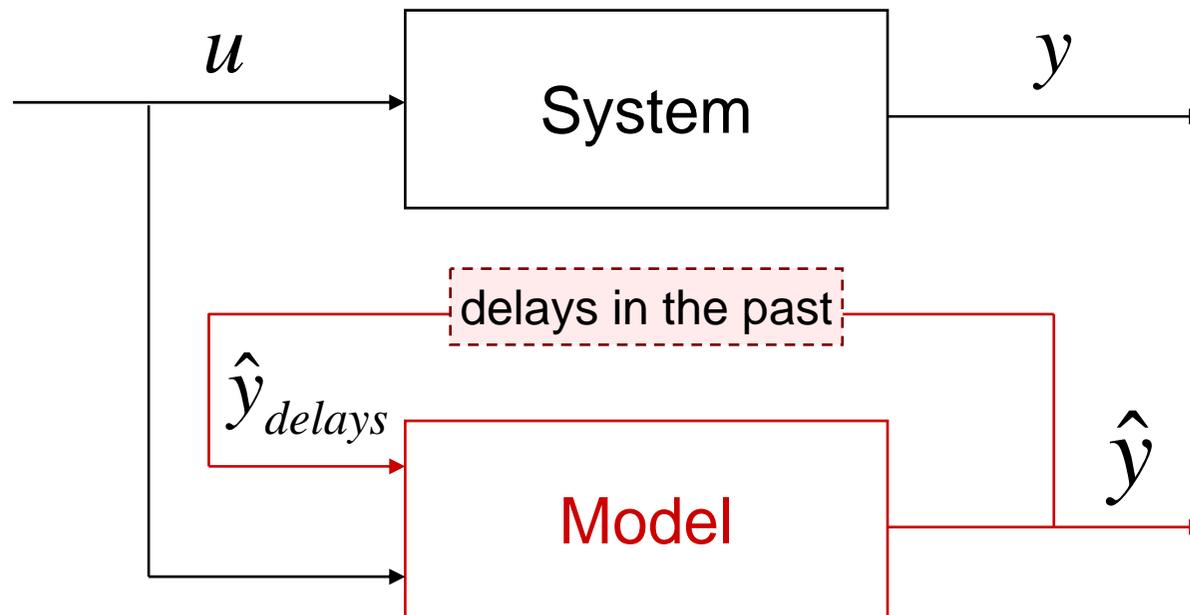
- **Series-Parallel model**: needs actual input and past output of the system as input to the model.



$$\hat{y}(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_n y(k-n) + u(k)$$

2. Eine Modellstruktur auswählen

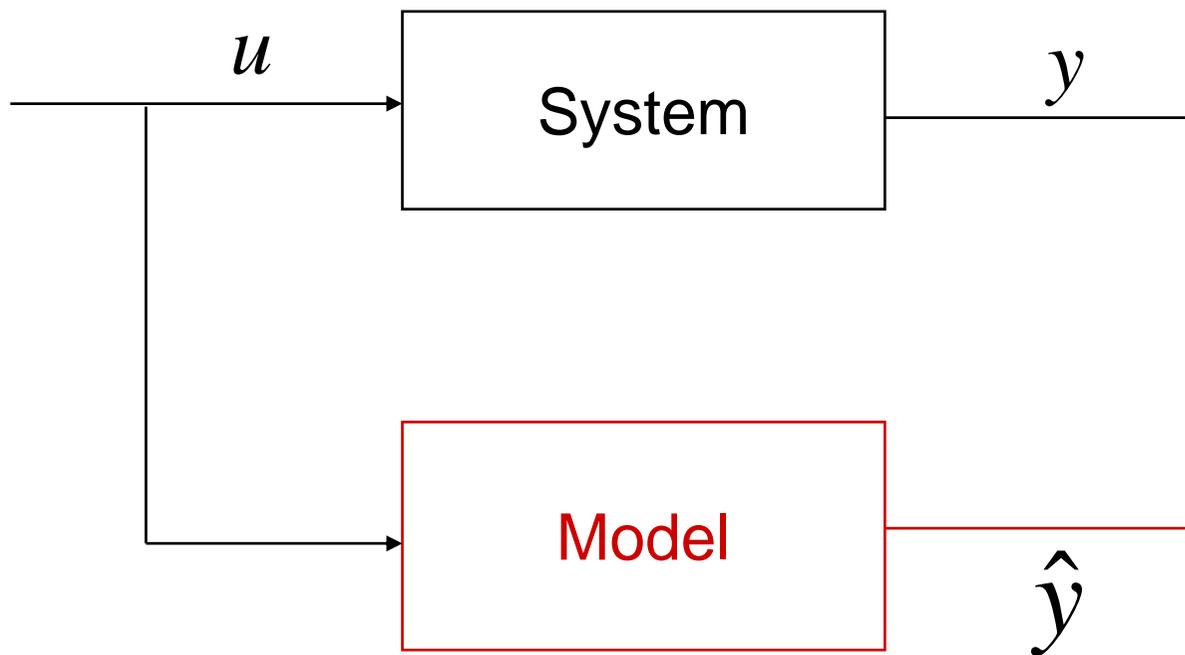
- **Parallel-Parallel model**: needs actual input and its own past outputs as the inputs.



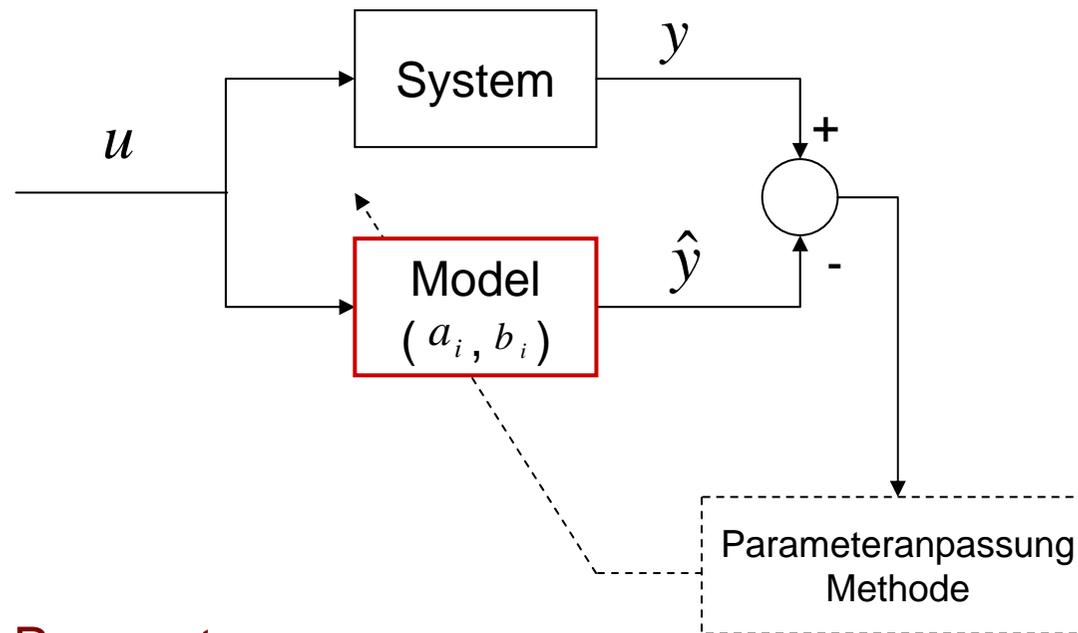
$$\hat{y}(k) = a_1 \hat{y}(k - 1) + a_2 \hat{y}(k - 2) + \dots + a_n \hat{y}(k - n) + u(k)$$

3. Parameter des Modells anpassen

Ist eine Modellstruktur gefunden, so muss noch eine **Parameteranpassung** vorgenommen werden. Dies wird erreicht, sodass die **Differenz** zwischen dem realen **System** und dem **ausgewählten Modell** so **klein** wie möglich sein soll.



3. Parameter des Modells anpassen



$a_i, b_i ?$
 sodass
 $\hat{y} \approx y$

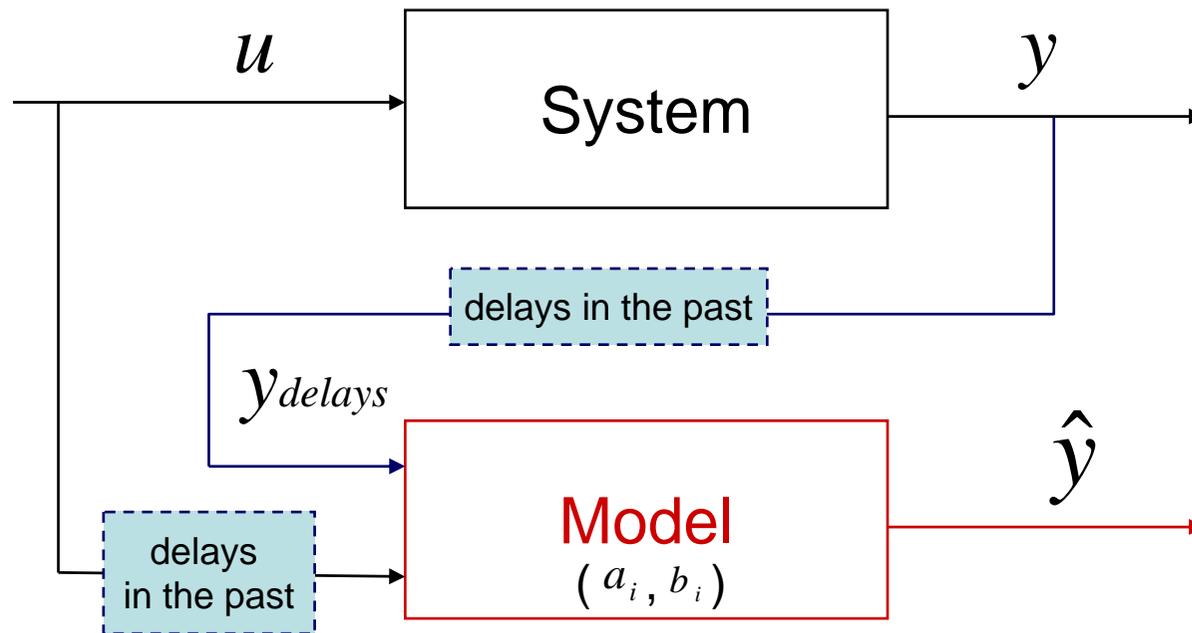
Methoden zur Parameteranpassung

- Least Squares (LS)
- Recursive Least Squares (RLS)
- Prediction Error Method (PEM)
- Recursive Prediction Error Method (RPE)
- Artificial Neural Networks
- ...

Methode der kleinsten Quadrate (Least Squares Method)

Methode der kleinsten Quadrate

Die Modellstruktur des Systems wird als **ARMA-Modell** in **Serie-Parallel** Form ausgewählt.



$$\hat{y}(k) = a_1 y(k-1) + a_2 y(k-2) + \dots + a_n y(k-n) + u(k) + b_1 u(k-1) + \dots + b_m u(k-m)$$

Methode der kleinsten Quadrate

• Messdaten

$$U^T = (u(k-1), u(k-2), \dots, u(k-m))$$

$$Y^T = (y(k-1), y(k-2), \dots, y(k-n))$$

$$k = 1, 2, \dots, N$$

$$\varphi(k) = \begin{pmatrix} Y \\ U \end{pmatrix}$$

• Parameter

$$a^T = (a_1, a_2, \dots, a_n)$$

$$b^T = (b_1, b_2, \dots, b_m)$$

$$\rightarrow \theta = \begin{pmatrix} a \\ b \end{pmatrix} \quad \text{Unbekannt!}$$

• Die Vorhersage des Modells im Zeitpunkt k

$$\hat{y}(k) = \varphi^T(k) \theta \quad k = 1, 2, \dots, N$$

Methode der kleinsten Quadrate

- Die Differenz zwischen den gemessenen Ausgangswerten $y(k)$ und den Ausgangswerten des Modells $\hat{y}(k)$ ist

$$\xi(k, \theta) = y(k) - \hat{y}(k) = y(k) - \varphi^T(k)\theta$$

- Die Aufgabe der systemidentifikation ist es, der Vektor $\hat{\theta}$ (eine Approximation von θ) zu finden, sodass

$$\xi(k, \hat{\theta}) = \hat{y}(k) - \varphi^T(k)\hat{\theta} \approx 0$$

Methode der kleinsten Quadrate

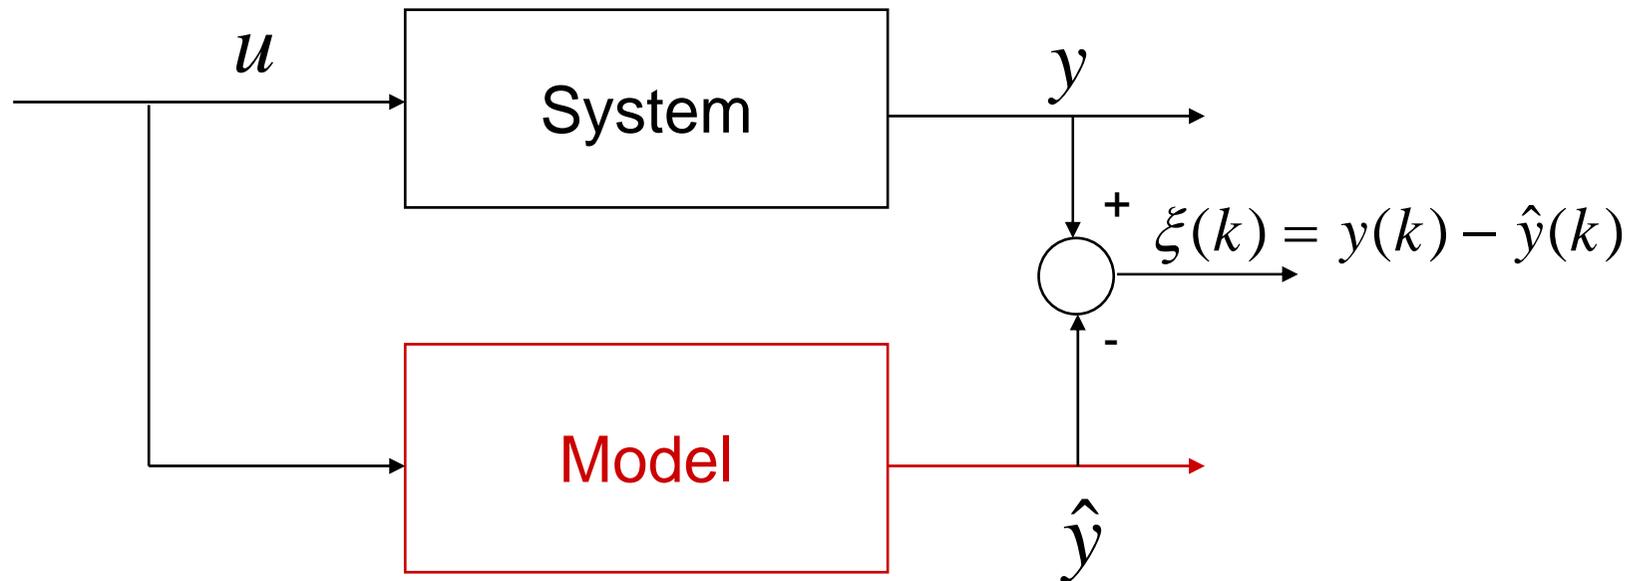
Das Least-Square Algorithm versucht eine Approximation $\hat{\theta}$ zu finden, durch die Minimierung der Funktion $V_N(\theta)$

$$V_N(\theta) = \frac{1}{2} \sum_{k=1}^N \xi^2(k, \theta)$$

$$\hat{\theta} = \arg \min_{\theta} V_N(\theta)$$

$$\rightarrow \hat{\theta} = \left[\sum_{k=1}^N \varphi(k) \varphi^T(k) \right]^{-1} \left[\sum_{k=1}^N \varphi(k) y(k) \right]$$

4. Das gefundene Modell validieren (prüfen).



Following statistics are often used for model validation

- mean error: $m_N = \frac{1}{N} \sum_{k=1}^N \xi(k)$
- variance: $Var_N = \frac{1}{N} \sum_{k=1}^N (\xi(k) - m_N)^2$
- mean square error: $MSE_N = \frac{1}{N} \sum_{k=1}^N \xi^2(k)$