
Ansätze zur datengetriebenen Formulierung von Strukturhypothesen für dynamische Systeme

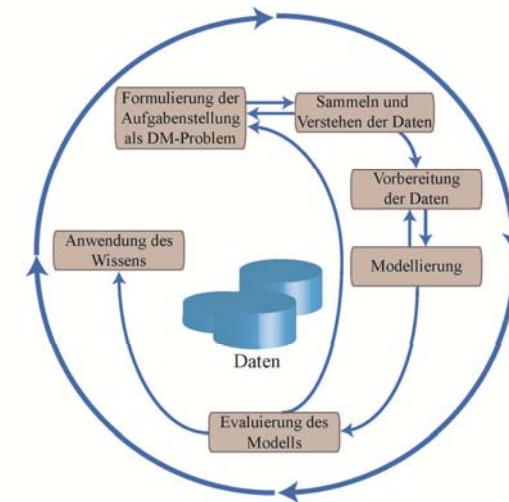
Christian Kühnert, Lutz Gröll, Michael Heizmann, Ralf Mikut
30.11.2011

Motivation

CRISP Cross-Industry Standard Process for Data Mining

„Klassisches“ Data-Mining

- Generierung von verborgenem Wissen aus vorhandenen Daten
- CRISP: Wird häufig im Produktions- und Fertigungsbereich eingesetzt
- Beispiele: Klassifikation in Gut/Schlecht-Produktionen, Online-Monitoring, ...



Eigenschaften

- Es wird von einer „natürlichen“ Prozessumgebung ausgegangen (Beobachtungsdaten)
- Lernverfahren ist oftmals eine Black-Box
- Konsequenz eines Eingriffs in den Prozess ist nicht vorhersagbar
- „Was wäre, wenn“ kann nicht beantwortet werden






Oft ist es notwendig die kausale Struktur des Prozesses zu kennen


Einleitung

Probabilistisches Kausalprinzip (statische Systeme)


- Lernen kausaler Zusammenhänge mittels Wahrscheinlichkeitstheorie
 - Die Ursache erhöht die Wahrscheinlichkeit, dass ein Effekt eintritt
 - Die Ursache wird durch eine Intervention von außen herbeigeführt




- Faithfulness Assumption
 - Erkennen kausaler Abhängigkeiten durch Beobachtungen
 - Gefundene Struktur enthält alle (un-) bedingten Unabhängigkeiten



$$x_1 \perp x_2 | x_3$$



$$x_1 \perp x_2 | x_3$$



$$x_1 \not\perp x_2 | x_3$$
$$x_1 \perp x_2$$

Einleitung

Kausalität und Zeit

- In der Regel werden dynamische Prozesse betrachtet
- Definition kausales System (Systemtheorie)
 - Werte der Eingangssignale $t > t_1$ haben keinen Einfluss auf Ausgangssignale bis $t < t_1$
 - Die Impulsantwort $t < 0$ ist 0.
 - Bei statischen Systemen liegt Kausalität vor, da das Ausgangssignal vom aktuellen Eingangssignal abhängt




Nutzen von Zeitverschiebungen zum Erkennen kausaler Abhängigkeiten in Daten

Beispiele:

- Tiefpass
- Feder-Dämpfer System
- Wachstumskurven in der Biologie
- Chemische Reaktionen

Einleitung



$$\dot{y}(t) = \frac{K}{T} u(t) - \frac{1}{T} y(t)$$



Der Datenpunkt $\dot{y}(t)$ hängt von $y(t)$ und $u(t)$ ab

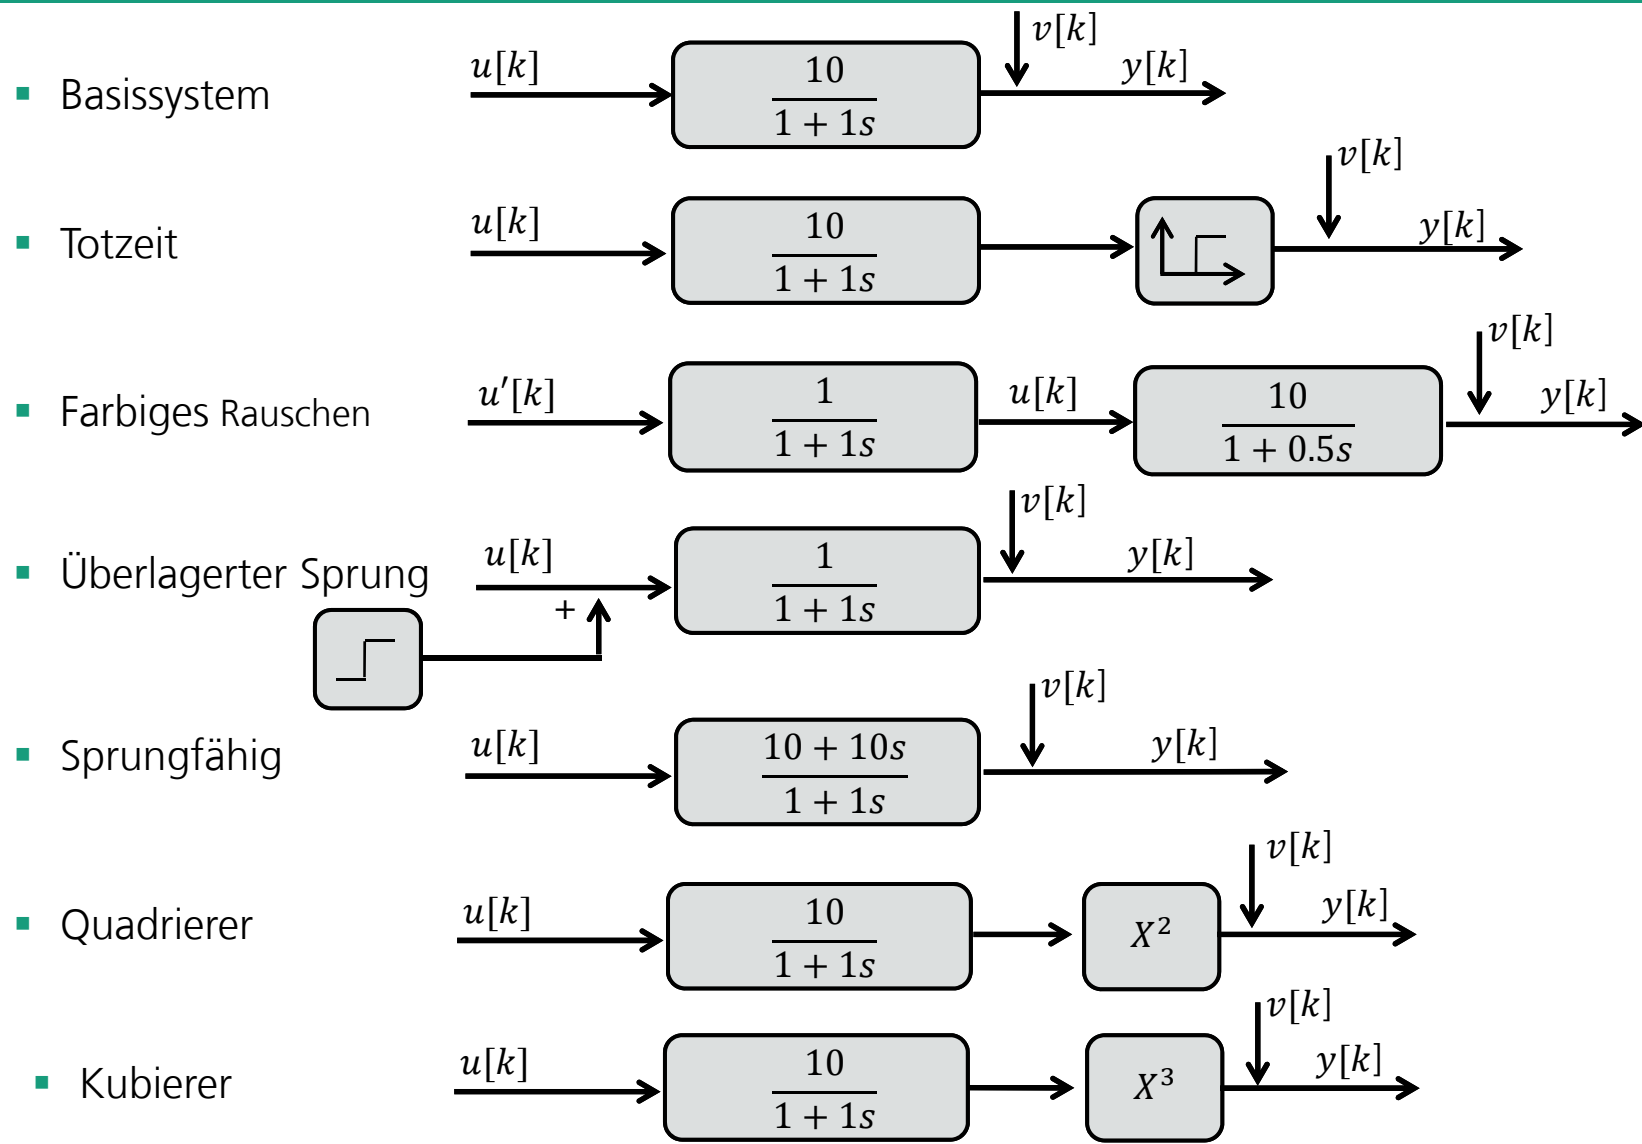
Ausgewählte Methoden:

- Kreuzkovarianzfunktion
- Granger-Kausalität
- N4SID

Benchmark: Tiefpass

- $u(t)$ ▪ Eingangssignal - Weißes Rauschen
- $y(t)$ ▪ Ausgangssignal des Systems
- $v(t)$ ▪ Überlagertes Rauschen am Ausgang mit 10% der Stärke des Eingangssignals

Untersuchte Systeme und Eingangssignale



Kreuzkovarianzfunktion

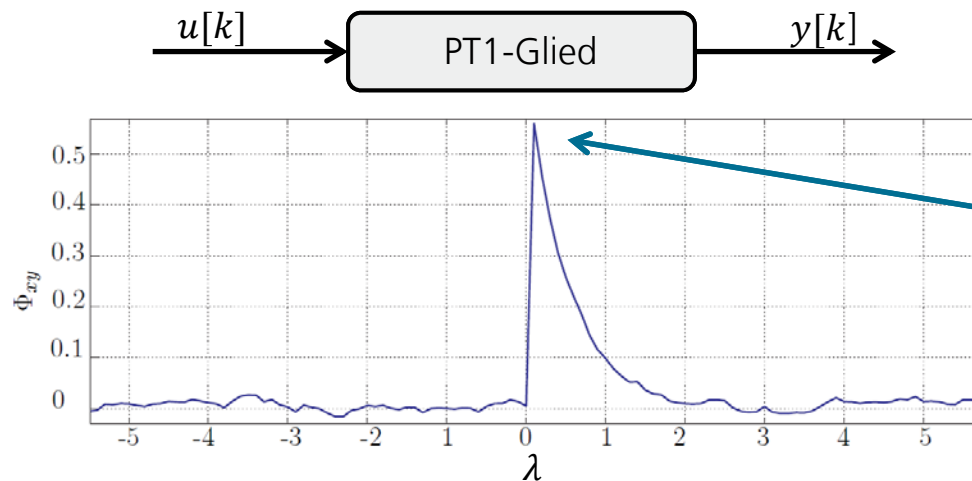
- Klassisches Maß zur Beschreibung der Abhängigkeit zweier Signale bei unterschiedlicher Zeitverschiebung
- Rein deterministisch

Voraussetzungen

- u ist eine Realisierung eines stationären weißen Rauschprozesses
- Das u und y verbindende System ist linear und stabil

Erkennen kausales Verhalten

- Betrachtung der Zeitverschiebung λ
- Höhe/Position des Maximum
- Vergleich der Flächen für $\lambda < 0$ und $\lambda > 0$




- Peak bei $\lambda = 1$
- Abfallende e-Funktion (proportional Gewichtsfunktion)


Kreuzkorrelation – PT1-System




Basissystem




Totzeit




Farbiges Rauschen




Sprung




Sprungfähig




Quadrierer



Kubierer



Quadrierer mit u^2



- Eigenschaften:
 - Für lineare, nicht-sprungfähige Systeme
 - Für stationäres Eingangssignal
 - Für große Totzeiten

N4SID

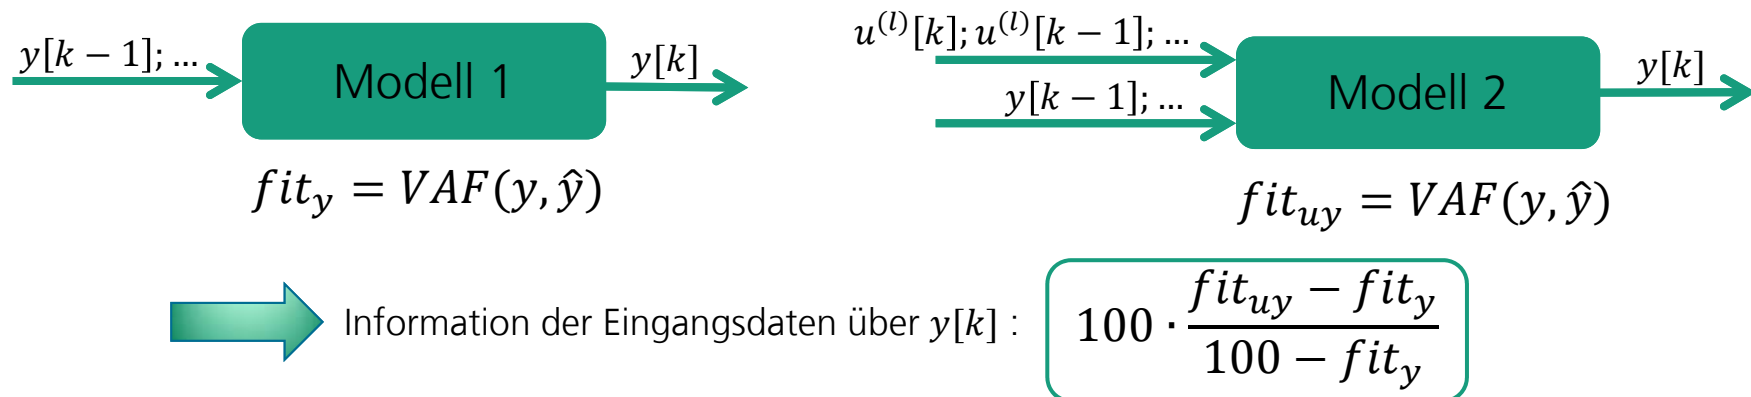
- Algorithmus gehört zur Klasse der Identifikationsverfahren im Unterraum
 - Ein-/Ausgangsdaten werden aufeinander projiziert
 - Über die Berechnung von Singulärwerten wird die Dimension des Raums geschätzt (wichtig für Totzeiten)

Störquelle (MISO-System)

- $z[k]$ ▪ Weißes Rauschen
- $z_s[k]$ ▪ Weißes Rauschen mit überlagertem Eingangssprung

Erkennen kausales Verhalten


- Hypothetische Zuordnung der Ein- Ausgangsgrößen
- Berechnung des Prognosefehlers für beide Modelle
- Ergebnis liefert Aussage darüber ob $y[k]$ Ausgangssignal ist




N4Sid




Basissystem




Totzeit




Farbiges Rauschen




Sprung




Sprungfähig




Quadrierer



Kubierer



Quadrierer mit u^2




- Für lineare Systeme
- Anwendbar für Mehrgrößensysteme
- Implizite Schätzung der Totzeit → wird möglicherweise nicht erkannt

Granger-Kausalität


- Ursprüngliche Idee stammt aus der Ökonometrie (Clive Granger)
- Ein Signal u hat kausalen Einfluss auf y , wenn u hilft Werte von y besser vorherzusagen, als nur vergangene Werte von y



- Ein Signal u hat **direkten** kausalen Einfluss auf y , wenn es kein Signal z gibt, das hilft, Werte von y besser vorherzusagen → Vergleich gegen alle weiteren Zeitreihen




- Vergleich der Residuen
 - 2 Signifikanztests




- Bewertung des kausalen Einflusses: $Res_y - Res_{uy}$

Granger-Kausalität


- Erweiterung des Benchmarks durch Hinzufügen eines zweiten Tiefpasses




- Störquelle
 - $z[k]$ ■ Weißes Rauschen
 - $z_s[k]$ ■ Weißes Rauschen mit überlagertem Eingangssprung
 - ➡ In Abbildung zusammengefasst zu einer Störgröße z
- Gesuchte Struktur




Granger Kausalität (MIMO)




Basissystem




Totzeit




Farbiges Rauschen




Sprung




Sprungfähig




Quadrierer



Kubierer




Quadrierer mit u^2



- Für lineare Systeme
- Bedingte Abhängigkeit $u \rightarrow y_1 \rightarrow y_2$ wegen Störrauschen nicht erkannt
- Implizite Schätzung der Totzeit \rightarrow wird möglicherweise nicht erkannt


Beispiel: Chemiereaktor



$$\dot{C}_A = \frac{F}{V}(C_{Af} - C_A) - k_1 C_A e^{-E_1/RT}$$

$$\dot{C}_B = k_1 C_A e^{-E_1/RT} - k_2 C_B e^{-E_2/RT} - \frac{F}{V} C_B$$

$$\dot{C}_C = k_2 C_B - \frac{F}{V} k_1 C_C$$



- Kontinuierlicher Prozess*
 - $C_{Af} \rightarrow C_A \rightarrow C_B \rightarrow C_C$
 - T_{fl} hat Einfluss auf alle Reaktionen über Exponentialfunktion
 - Anregung mit weißem Rauschen für C_{Af}, T_{fl}



Lernen der unterliegenden Reaktionsstruktur

Chemiereaktor

Kreuzkorrelationsfunktion

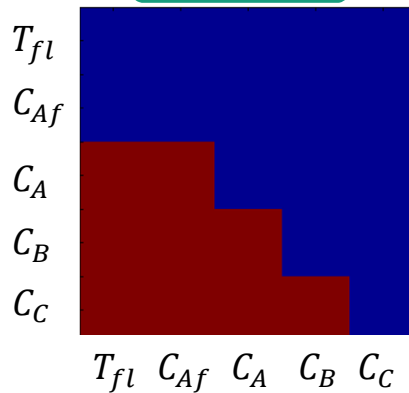
Erkennen kausales Verhalten

- Betrachtung der Zeitverschiebung λ
- Höhe des Maximum
- Vergleich der Flächen für $\lambda < 0$ und $\lambda > 0$

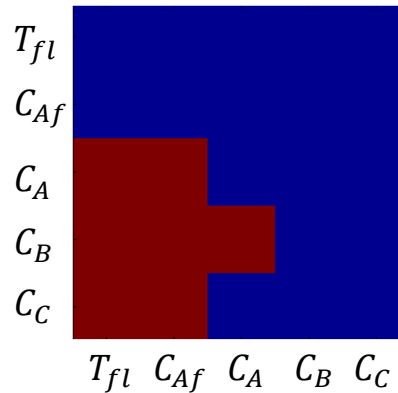


Durchführung von 2 Signifikanztests

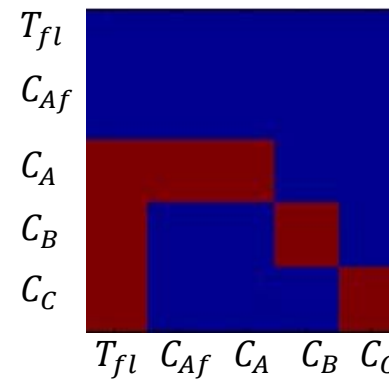
Erwartet



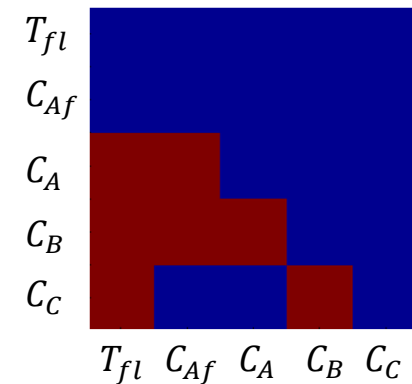
Gefunden




Erwartet



Gefunden



Grundstruktur



Granger-Kausalität

- Darstellung der bestandenen Signifikanztest

Weitere Methoden


- **Transfer Entropy**

- Messdaten sind in gewisser Weise stochastisch
- Berechnung bedingter Wahrscheinlichkeiten für zeitlich verschobene Zeitreihen.
- Vergleich des Informationsgehaltes für zeitverschobene Zeitreihen




Linear

$TE_{u \rightarrow y}$




Quadrierer

$TE_{u \rightarrow y}$




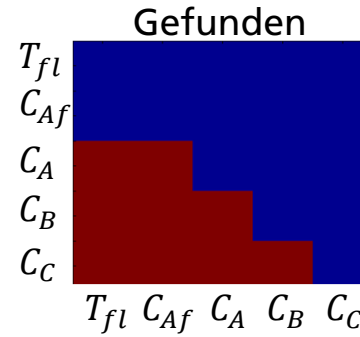

- **Dynamisches Bayes-Netz**

- Zeitreihen werden um einen Zeitschritt verschoben
→ Verdopplung der Knoten für zu lernende Netz
- Jeder Knoten bekommt eine bedingte Wahrscheinlichkeitsverteilung zugeordnet
- Berechnung des wahrscheinlichsten Netzes über „Scoring function“



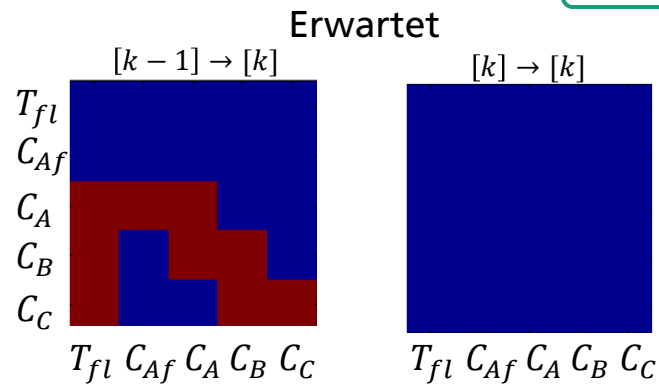


Chemiereaktor

Transfer entropy



Bayes-Netze



Zusammenfassung

- Ziel: Erkennen kausaler Abhängigkeiten in dynamischen Systemen
→ Ausnutzen von Zeitverzögerungen
- Im Detail untersucht: [Kreuzkorrelation](#), [Granger-Kausalität](#), [N4SID](#)
- Als weitere Methoden vorgestellt: [Transfer Entropy](#), [Bayes-Netze](#)
- Erstellen von Benchmarks (Tiefpass, Rührkessel) zum Vergleich und Bewerten der Verfahren
 - Je nach Aufgabenstellung bieten die einzelnen Verfahren jeweils Vor- und Nachteile

- Data-Mining kann mehr finden als reine Korrelationen!
- Es sind viele Methoden vorhanden, um kausale Strukturen in Daten dynamischer Systeme zu finden. Man muss sie nur nutzen.

Zusammenfassung

	KKF	Granger Kausalität	N4SID
Basissystem	✓	✓	✓
Zus. Totzeit	✓	✓	✓
Farbiges Eingangsrauschen	(✓)	✓	✓
Überlagerter Eingangssprung	(✓)	✓	✓
Zusätzlicher Vorhalt	(✓)	-	-
Quadrierer	-	-	-

	KKF	Granger Kausalität	N4SID
Lineare Systeme	✓	✓	✓
Integrierte Ordnungsschätzung	-	(✓) (mit AIC)	✓
Wiener/Hammerstein-Systeme	(✓)	(✓)	(✓)
Umgang mit Mehrgrößensystemen	-	✓	✓
Schätzung der Totzeit	✓	(✓) (indirekt)	(✓)(indirekt)
Einfache Parametrierung	✓	(✓)	✓