

Modellierung von Abhängigkeitsstrukturen in dynamischen Systemen

Ursula Gather
Fachbereich Statistik
Universität Dortmund



Übersicht

Motivation


1. Online Monitoring Daten aus der Intensivmedizin

Methoden zur Analyse Dynamischer Strukturen

2. Graphische Modelle
3. Sliced Inverse Regression
4. Dynamische Faktorenanalyse

1) Beispiel: Intensivmedizin

11 Variablen des hämodynamischen Systems und Medikamentendosen eines Patienten über 60 Stunden




Analyse von intensivmedizinischen Online Monitoring Daten



- hochdimensionale Daten (\gg 200 Variablen)
- komplexe Datenstrukturen (Abhängigkeiten zwischen verschiedenen Variablen und Zeitabhängigkeiten)

Statistik

medizinisches
Expertenwissen



Statistische Online-Methoden zur
Mustererkennung und
Entscheidungsfindung

- individuell
- mit schnellen Algorithmen
- einfache Interpretierbarkeit

Ziele

- Dimensionsreduktion
Verständnis der dynamischen Abhängigkeitsstruktur
(mit medizinischen Experten)
- Erkennung von Mustern wie
 - Ausreißern
 - Level Shifts
 - Trends

Dimensionsreduktion und Abhängigkeitsstruktur

Sei $\mathbf{Y}(t) \in \mathbb{R}^k$, $t \in \mathbf{Z}$, (stationärer) stochastischer Prozeß

Ziel: extrahiere wenige gemeinsame „Faktoren“,
die die Zeitreihe „antreiben“

Statische Methoden zur Dimensionsreduktion:

- Graphische Modelle
- Sliced Inverse Regression
- Faktorenanalyse
- ...

Zeitreihenkontext  angemessene Adaptation
dieser Verfahren erforderlich

2) Graphische Modelle für multivariate Zeitreihen

(Brillinger 1996, Dahlhaus 2000)

Beobachtet: k-dim. Zeitreihe

$$y(t) = \left(y^1(t), \dots, y^i(t), \dots, y^j(t), \dots, y^k(t) \right), t = 1, \dots, N$$

Ecken: $V = \{1, \dots, k\}$

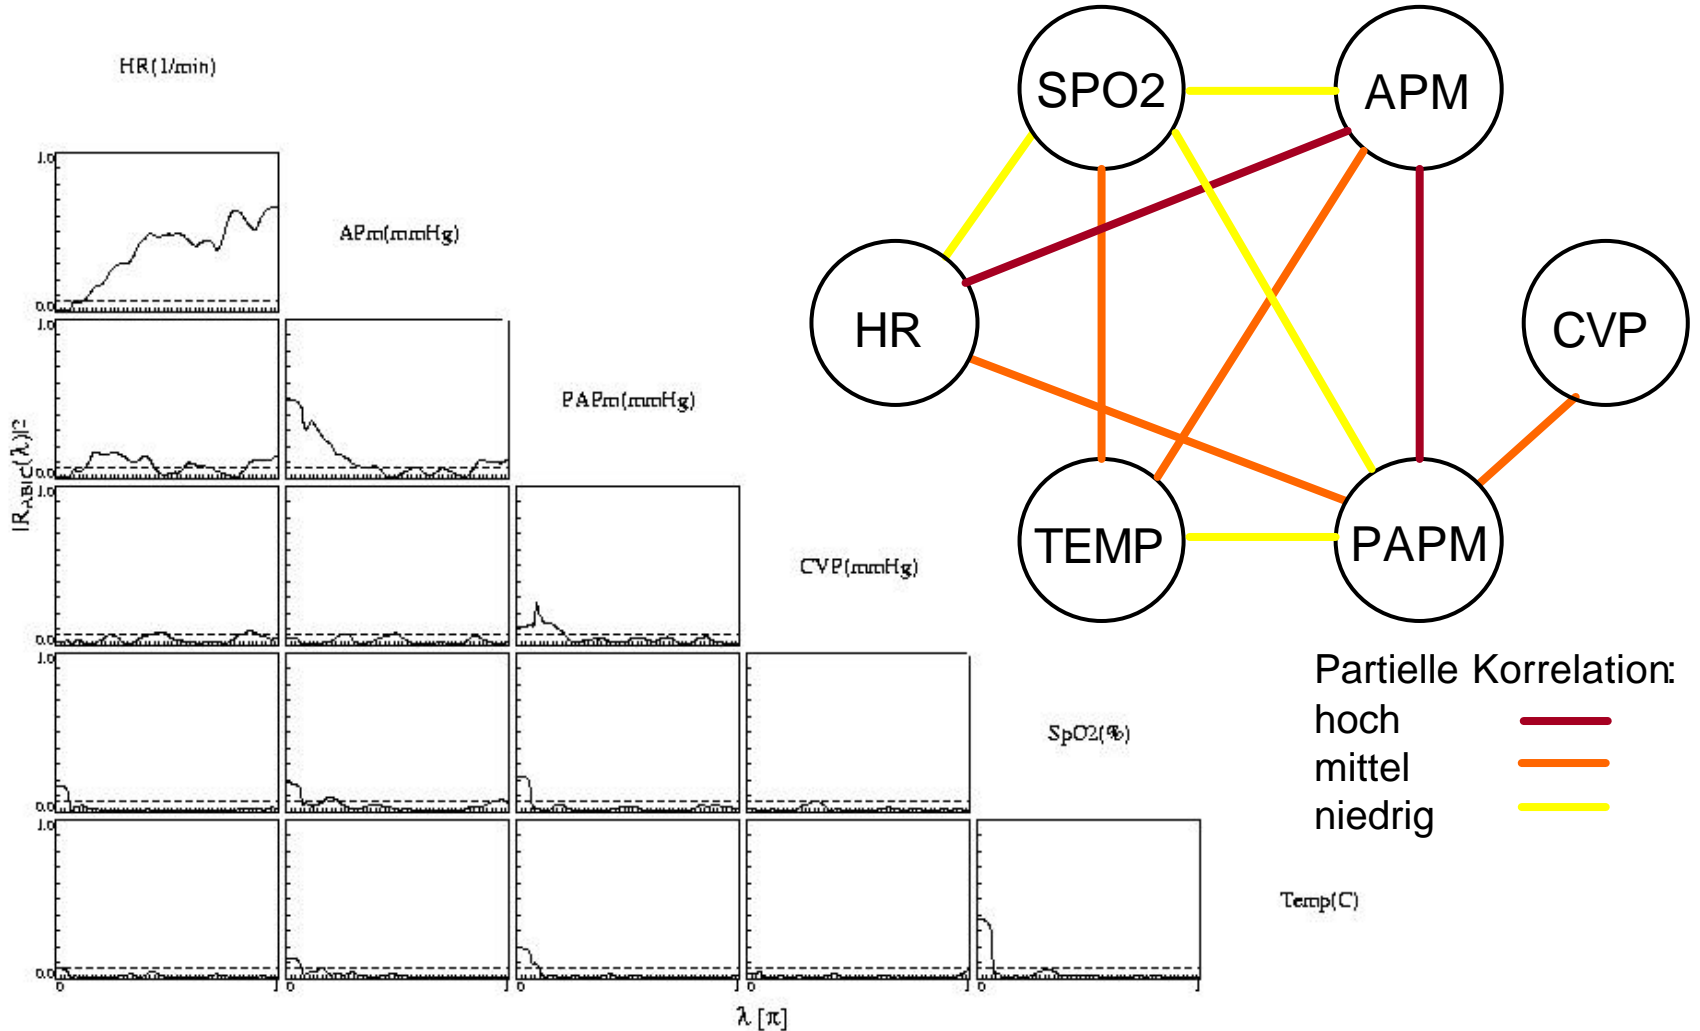
Kanten: $(i, j) \notin E \subset V \times V \iff y^i(t)$ und $y^j(t+h)$ sind unkorreliert für alle Zeitlags h gegeben die anderen Variablen

\iff die "partielle spektrale Kohärenz" ist Null

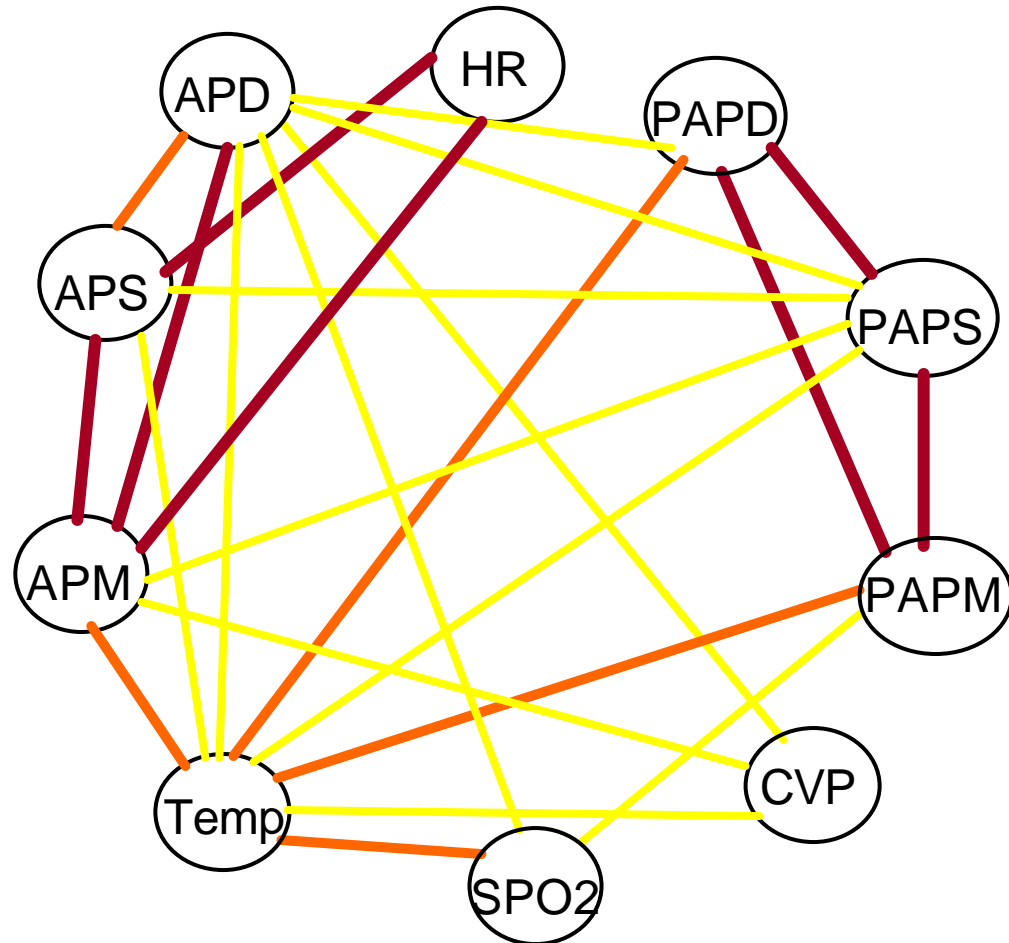
Test: $H_0 : (i, j) \notin E$
mittels Teststatistik, die auf nichtparametrischem Schätzer der Kohärenz beruht

Anwendung auf 6-dim. intensivmedizinische Zeitreihe

Graphische Darstellung der partiellen Korrelationen



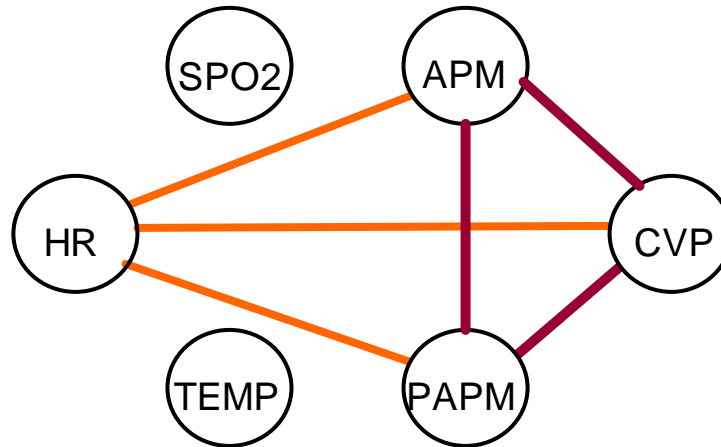
Anwendung auf 10-dimensionale Zeitreihe



Partielle Korrelation
hoch ———
mittel ———
niedrig ———

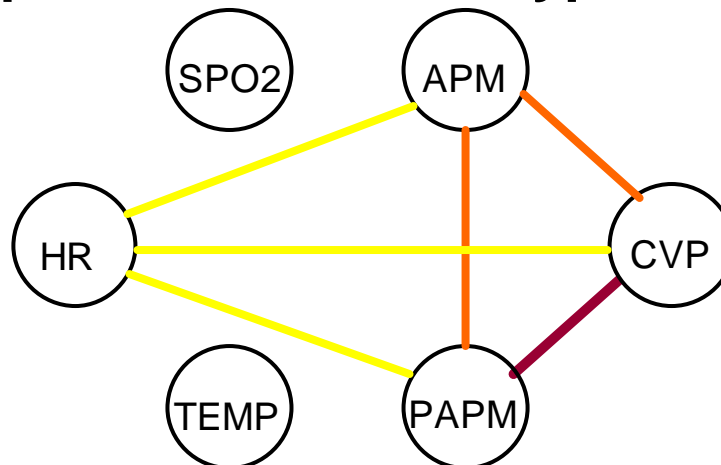
Erwarteter Graph (Normalzustand)

Partielle Korrelation:
hoch —
mittel —
niedrig —



Erwarteter Graph für Pulmonare Hypertension

Partelle Korrelation:
hoch —
mittel —
niedrig —




Partielle Korrelationen für verschiedene klinische Zustände

HR HR HR HR HR SpO2 SpO2 SpO2 SpO2 APM APM APM CVP CVP PAPM
 SPO2 APM CVP PAPMTemp APM CVP PAPMTemp CVP PAPMTemp PAPM Temp Temp

Septischer
Schock



Herzversagen



Pulmonare
Hypertension




Medikamentöse
Reanimation



Null niedrig mittel hoch

3) Sliced Inverse Regression SIR

Methode zur Dimensionsreduktion in Regressionsmodellen



Schätzung des Raums B

Schätzung der Dimension r

Anwendung auf Zeitreihen

$y_t = (y_t^1, \dots, y_t^k)$, $t = 1, \dots, N$ Beobachtungen von (Y^1, \dots, Y^k)

1. Vernachlässigen der zeitlichen Abhängigkeiten

Setze $Y = Y^i, i = 1, \dots, k$

$$\mathbf{X} = (Y^1, \dots, Y^{i-1}, Y^{i+1}, \dots, Y^k)' \in \mathbb{R}^{k-1}$$

$$Y^i = \tilde{f}(\mathbf{X}, \varepsilon) = f(\beta_1 \mathbf{X}, \dots, \beta_r \mathbf{X}, \varepsilon)$$

(Annahme: f und β_1, \dots, β_r zeitunabhängig)

Für jede Wahl von i schätze k und β_1, \dots, β_r mittels

$$\left(y_t, \left(y_t^1, \dots, y_t^{i-1}, y_t^{i+1}, \dots, y_t^k \right) \right), t = 1, \dots, N$$

2. Berücksichtigung zeitlicher Abhängigkeiten

“Künstliche” Variablen $Y^{k+1}, \dots, Y^{2k} : Y_t^{k+j} = Y_{t-1}^j, j=1, \dots, k$

Setze $Y = Y^i, i = 1, \dots, k$

$$\mathbf{X} = (Y^1, \dots, Y^{i-1}, Y^{i+1}, \dots, Y^{2k})' \in \mathbb{R}^{2k-1}$$

$$Y^i = \tilde{f}(\mathbf{X}, \varepsilon) = f(\beta_1' \mathbf{X}, \dots, \beta_r' \mathbf{X}, \varepsilon)$$

(Annahme: f und β_1, \dots, β_r zeitunabhängig)

Für jede Wahl von i schätze r und β_1, \dots, β_r mittels

$$\left(y_t, \left(y_t^1, \dots, y_t^{i-1}, y_t^{i+1}, \dots, y_t^{2k} \right) \right), t = 2, \dots, N$$

Anwendung von SIR auf hämodynamisches System

9-dim. Zeitreihe: arterielle, pulmonalarterielle (syst., diast., Mittel), Zentralvenöser Druck, Herzfrequenz, Temperatur

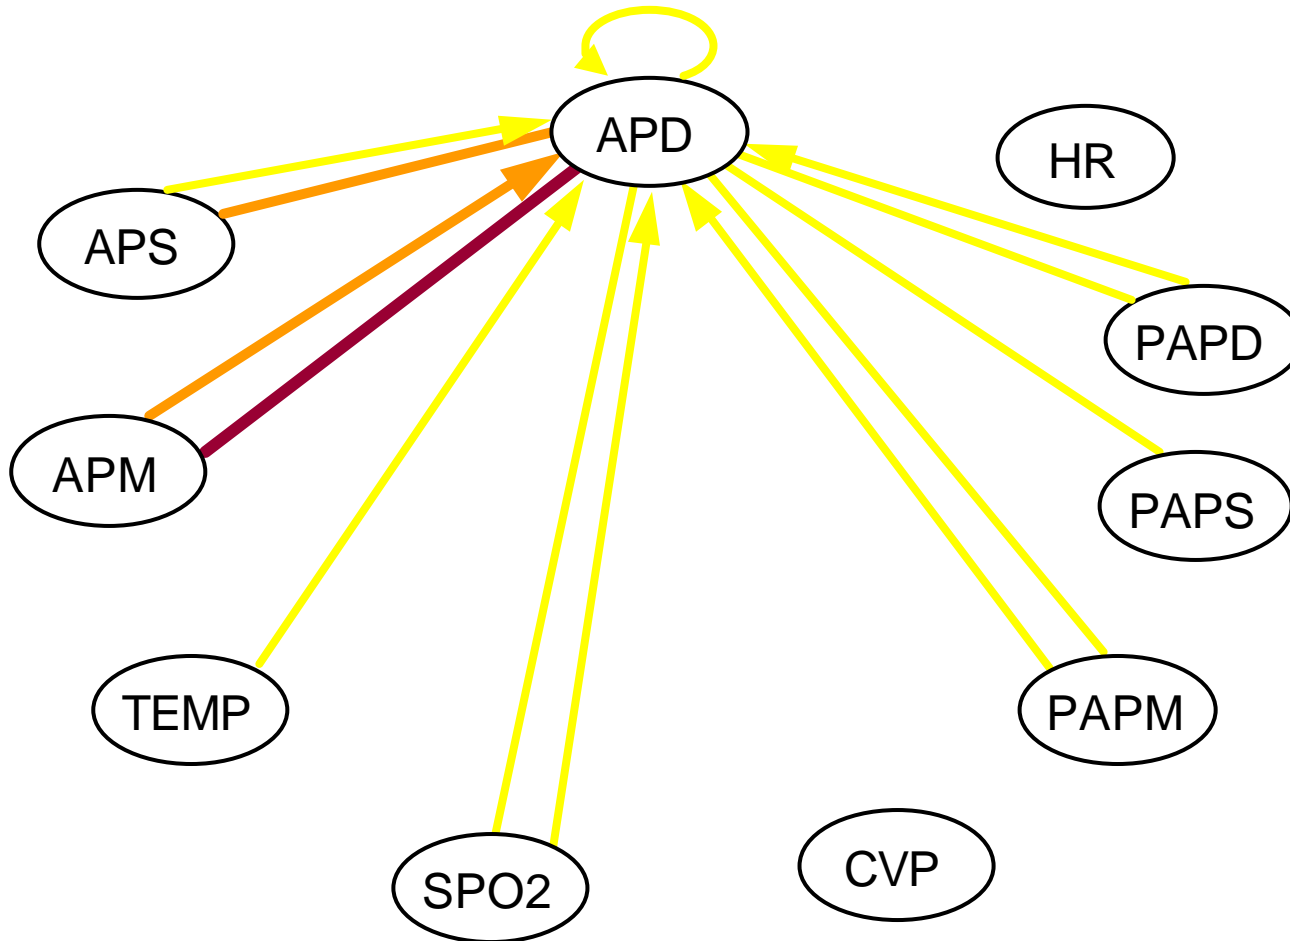
z.B. $Y = HR = f(\beta_1 X, \dots, \beta_f X)$, $X = \text{alle anderen} \setminus HR$

Anzahl der Dimensions-reduzierenden Richtungen:

	APS	APD	APM	Temp	CVP	HR	PAPS	PAPD	PAPM
Vernachl. zeitlicher Abhäng.	3	5	4	6	7	5	3	2	3
Berücks. zeitlicher Abhäng.	2	4	3	5	6	4	3	2	3

- Leite Zusammenhänge aus Richtungen ab
- Dimensionsreduktion durch Eliminierung von Variablen mit kleinem r

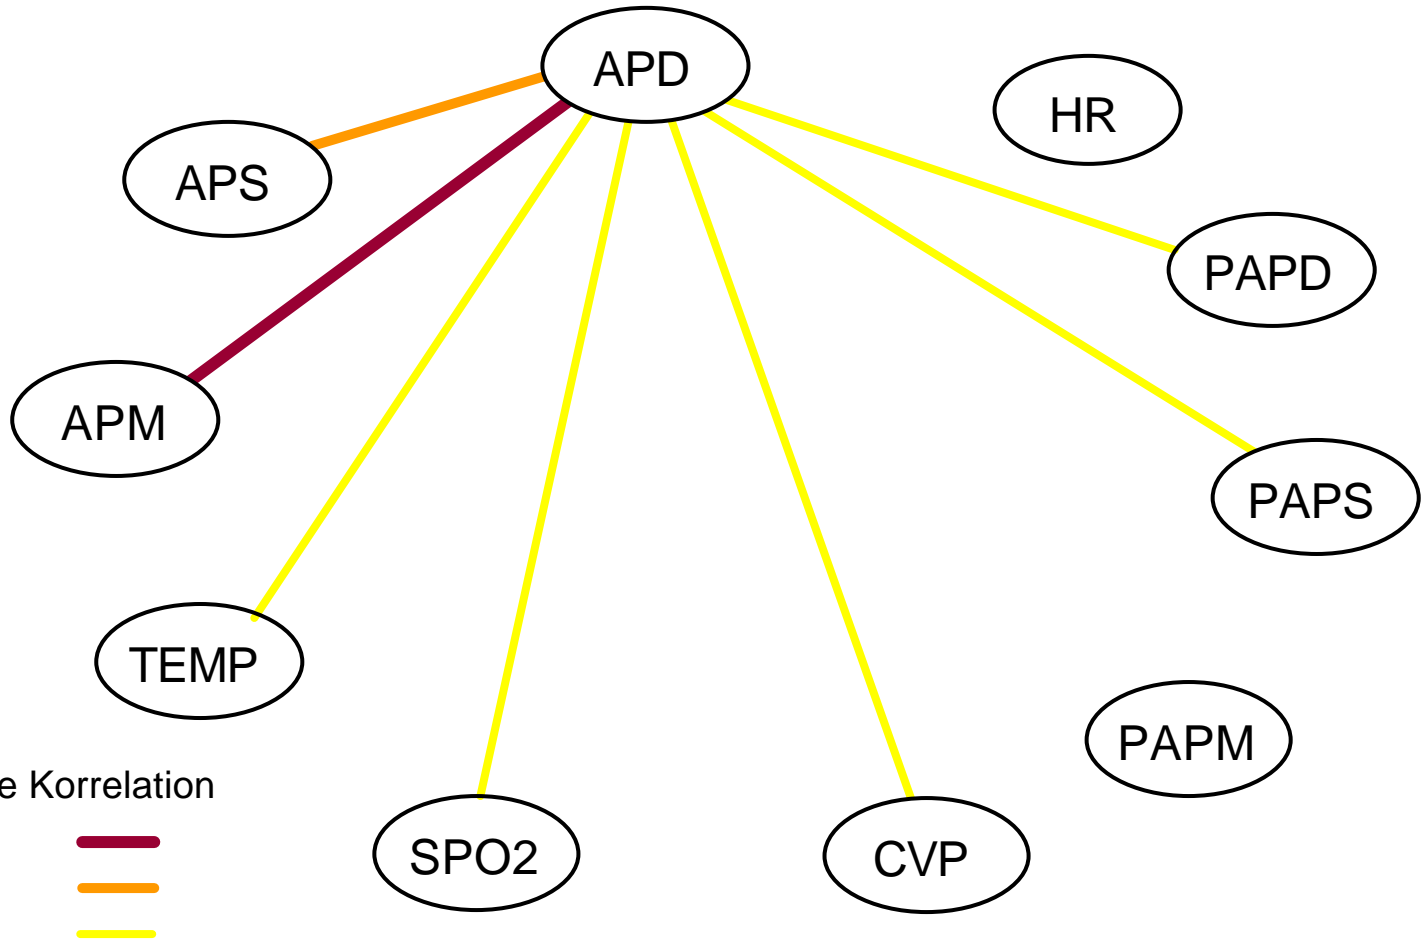
Visualisierung der Einflüsse auf APD



Linien: simultaner Einfluß

Pfeile: Zeit-versetzter Einfluß

Vergleich mit Graphischem Modell



4) Dynamische Faktorenanalyse

Definiere dynamisches Faktorenmodell für $\mathbf{Y}(t)$ durch:

$$\mathbf{Y}(t) - \mathbf{m}_Y = \sum_{s=-\infty}^{\infty} \Lambda(s) \mathbf{F}(t-s) + \mathbf{e}(t),$$

- $\mathbf{F}(t)$ — r -dim. stoch. Prozeß „Faktorreihe“, $r < k$,
- $\mathbf{e}(t)$ — k -dim. stoch. Prozeß (Fehler)
- $\Lambda(s)$ — $k \times r$ -Faktorladungs-Matrizen

plus weitere Annahmen

häufig sinnvoll:
Einsatz kausaler Filter



$$\mathbf{Y}(t) - \mathbf{m}_Y = \sum_{s=0}^m \Lambda(s) \mathbf{F}(t-s) + \mathbf{e}(t)$$

Dynamisches Faktorenmodell von Peña & Box (1987)

einfache Identifikation latenter Faktoren in multivariaten Zeitreihen

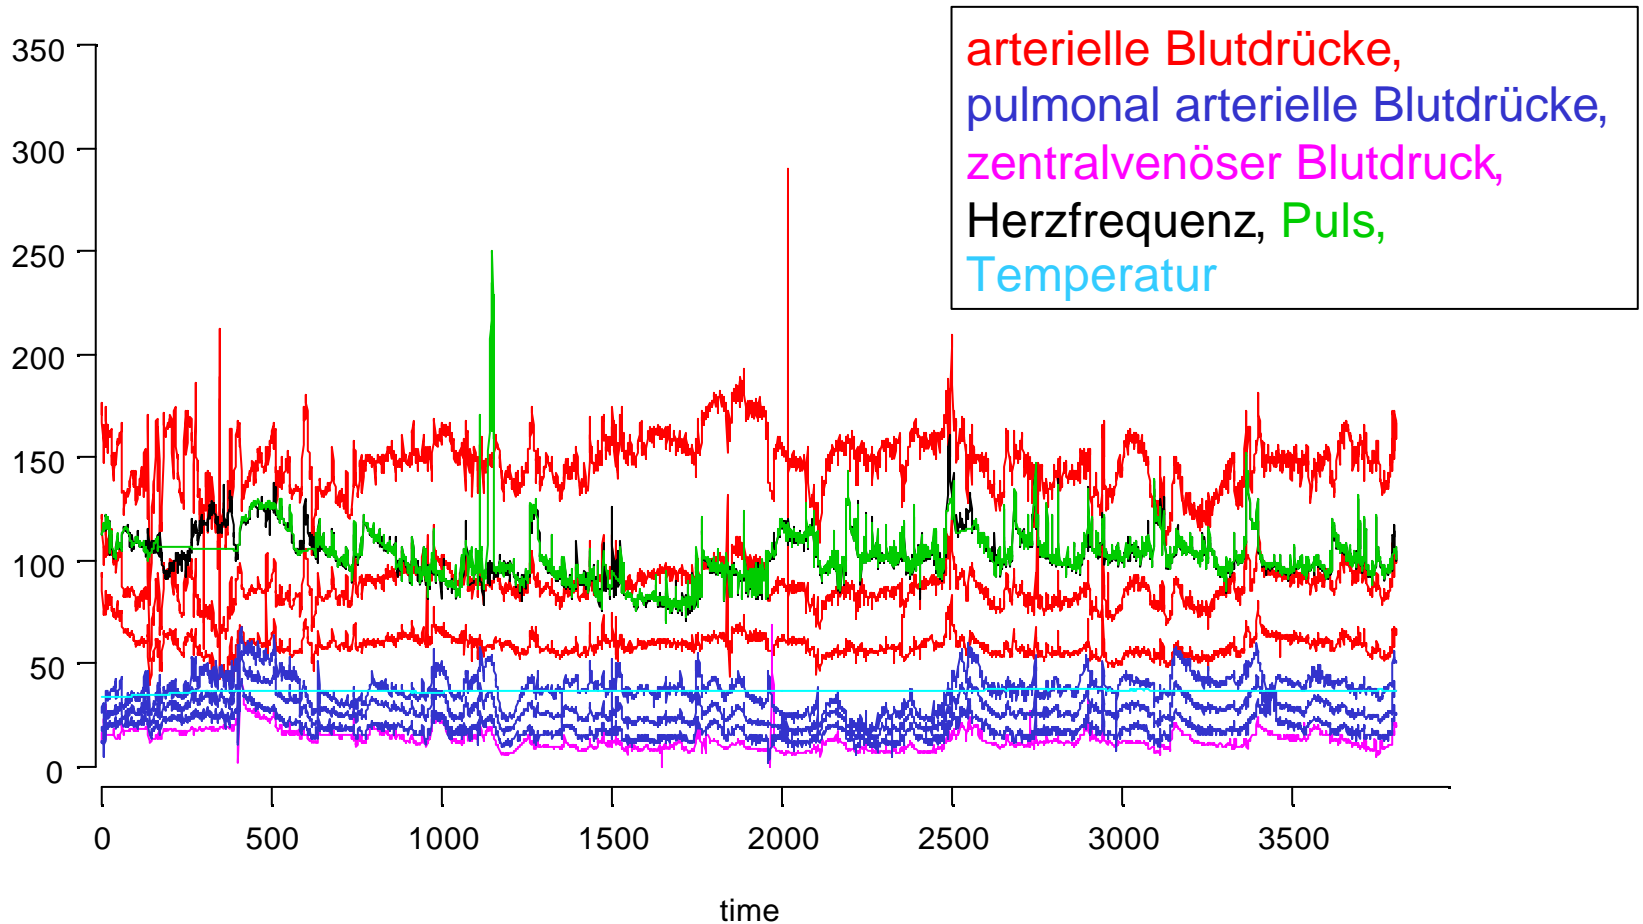
Modell mit unabhängigen Faktoren:

$$\mathbf{Y}(t) - \mathbf{m}_Y = \Lambda \mathbf{F}(t) + \mathbf{e}(t)$$

Annahmen:

- $\mathbf{F}(t)$ — r -dim., stationärer, invertierbarer VARMA(p, q)-Prozeß $\Phi_F(\mathbf{B}) \mathbf{F}(t) = \Theta_F(\mathbf{B}) \mathbf{u}(t)$
- Unabhängigkeit der r Faktoren $F_1(t), \dots, F_r(t)$
mit diagonalen Matrizen der Filter Φ_F und Θ_F
- Kovarianzmatrix $\Sigma_{\mathbf{u}}$ diagonal
- $\Lambda' \Lambda = \mathbf{I}_r$

Beispiel: Zeitreihe von 10 Variablen des hämodynamischen Systems eines Patienten auf der Intensivstation



Beispiel: Analyse der standard. Zeitreihe nach Peña und Box

erklärte Varianz

3 Faktoren 0.7883


4 Faktoren 0.8931

geschätzte Ladungsmatrix nach Varimax-Rotation durch Analyse der geschätzten Kreuzkovarianzmatrizen


Geschätzte Ladungs- matrix	APDIA	0.0076	0.4538	0.0629	-0.1978
	APM	0.0336	0.6032	-0.0512	-0.0053
	APSYS	-0.0418	0.6528	-0.0030	0.1684
	CVP	0.4339	-0.0336	0.0330	-0.2340
	HR	0.0082	-0.0208	0.7031	0.0128
	PAPDIA	0.4882	0.0104	0.0302	-0.0960
	PAPM	0.5389	0.0039	0.0199	0.0752
	PAPSYS	0.5301	0.0213	-0.0858	0.2141
	TEMP	0.0034	-0.0315	0.0360	0.9038
	PULS	0.0015	0.0320	0.6985	-0.0020

Beispiel (Fs.): Analyse der standard. Zeitreihe n. Peña und Box

Schätzung der vier extrahierten
Faktorzeitreihen nach Glättung
durch Kalman-Filter



Approximationsfehler



Interpretation

pulmonal arterielle Blutdrücke


arterielle Blutdrücke

Herzfrequenz / Puls


Temperatur

Beispiel (Fs.): Analyse der Median-geglätteten Zeitreihe mit „gleitender“ Analyse

Schätzung der vier extrahierten „gleitenden“ Faktorenreihen



Approximationsfehler



Interpretation

pulmonal arterielle Blutdrücke

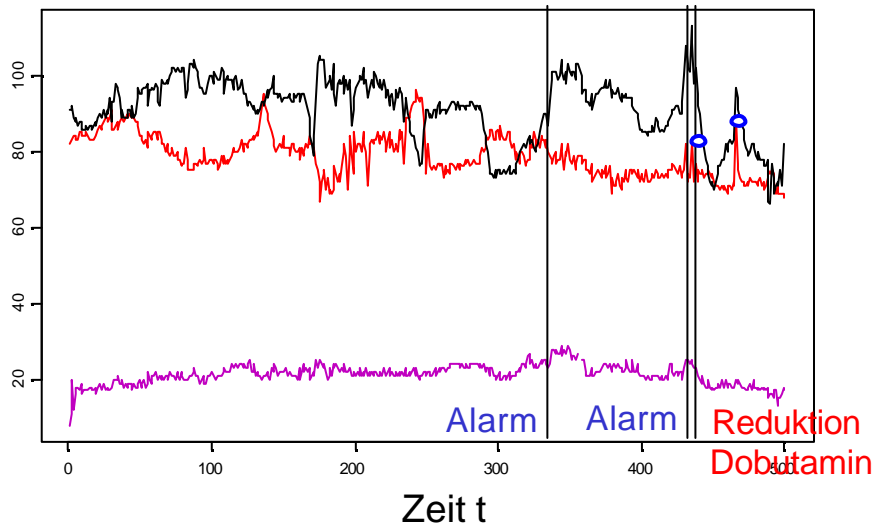
arterielle Blutdrücke

Herzfrequenz / Puls


Temperatur

Alarmsystem basierend auf Mustererkennung

Beobachtete Zeitreihe



Differenzierte Zeitreihe, 400-450



Arterieller Druck



Pulmonalarterieller Druck



Herzfrequenz



Zur Anwendung

Besondere Anforderungen auf der Intensivstation wie in der Prozeßkontrolle:

- ⇒ automatische Verfahren und schnelle Algorithmen
- ⇒ einfache Interpretation (→ Arzt)
der Faktoren bzw. der Ursache eines Alarms
- ⇒ Berücksichtigung von Änderungen in der
Abhängigkeitsstruktur
- ⇒ Umgang mit Ausreißern

Literatur

- Becker, C., Fried, R. (2001). Sliced Inverse Regression for High-dimensional Time Series. Technical Report 14/2001, SFB 475, University of Dortmund, Germany.
- Brillinger, D.R. (1981). *Time Series. Data Analysis and Theory*. San-Francisco: Holden-Day.
- Brillinger, D.R. (1996). Remarks Concerning Graphical Models for Time Series and Point Processes. *Revista de Econometria* **16**, 1-23.
- Cox, D.R., Wermuth, N. (1996). *Multivariate Dependencies*. London: Chapman & Hall.
- Dahlhaus, R. (2000). Graphical Interaction Models for Multivariate Time Series. *Metrika*, **51**, 157-172
- Dahlhaus, R., Eichler, M. (2002). SPECTRUM. C-programme available at <http://www.statlab.uni-heidelberg.de/projects>
- Fried, R., Didelez, V. (2002). Decomposability and Selection of Graphical Models for Multivariate Time Series. Technical Report 17/2002, SFB 475, University of Dortmund, Germany.
- Gather, U., Fried, R., Imhoff, M., Becker, C. (2002). Patterns of Dependencies in Dynamic Multivariate Data. Preprint, Department of Statistics, University of Dortmund, Germany.
- Gather, U., Fried, R., Lanius, V., Imhoff, M. (2002). Online Monitoring of High-dimensional Physiological Time Series - a Case-study. *Estadística*, in press.
- Gather, U., Imhoff, M., Fried, R. (2002). Graphical Models for Multivariate Time Series From Intensive Care Monitoring. *Statistics in Medicine*, in press.
- Peña, D., Box, G.E.P. (1987). Identifying a Simplifying Structure in Time Series. *JASA* **82**, 836-843.