

Condition Monitoring mit statistischen Methoden: was uns Rauschen und Kurtosis sagen können über Maschinenzustände

Prof. Dr. Andreas Schütze

Lehrstuhl für Messtechnik, FR Systems Engineering

Nikolai Helwig, Tizian Schneider

Zentrum für Mechatronik und Automatisierungstechnik GmbH



Fokus: Intelligente Sensorsysteme zur Messung chemischer Größen, sowohl für die Gasphase als auch in Flüssigkeiten.

Wir nutzen sowohl chemische als auch physikalische Effekte und verknüpfen (Mikro-)Sensoren mit Elektronik für Betrieb und Datenerfassung sowie mit angepassten Signalverarbeitungskonzepten zu komplexen Messsystemen.

Zwei sich ergänzende Bereiche

- Lehrstuhl für Messtechnik, Universität des Saarlandes
 - Grundlagenforschung
 - Schwerpunkt Gasmesstechnik, u.a. Luftgüte
- Zentrum für Mechatronik und Automatisierungstechnik
 - Angewandte F&E
 - Schwerpunkt Condition Monitoring, u.a. Ölqualität

> Warum Messung chemischer Größen?



- Sicherheitstechnik
 - Explosionsschutz, z.B. CH_4 im Bergbau (bzw. im Haushalt)
 - Vergiftungsschutz, z.B. CO im Bergbau (bzw. im Parkhaus)
- Qualitätskontrolle
 - Dichtheitsprüfung von Verpackungen
 - Prüfung von Lebensmitteln
 - Ölqualität z.B. in Flugzeughydraulik und BHKW
- Umwelttechnik
 - Abgaskontrolle und -regelung, z.B. Lambda-Sonde im Pkw
 - Erkennung von Umweltverschmutzung, Identifizierung der Verursacher
- Komfortanwendungen
 - bedarfsgerechte Lüftung in Toiletten und Küchen
 - automatische Umluftklappe im Pkw

Intelligentes Condition Monitoring – Motivation und Ziele

Motivation

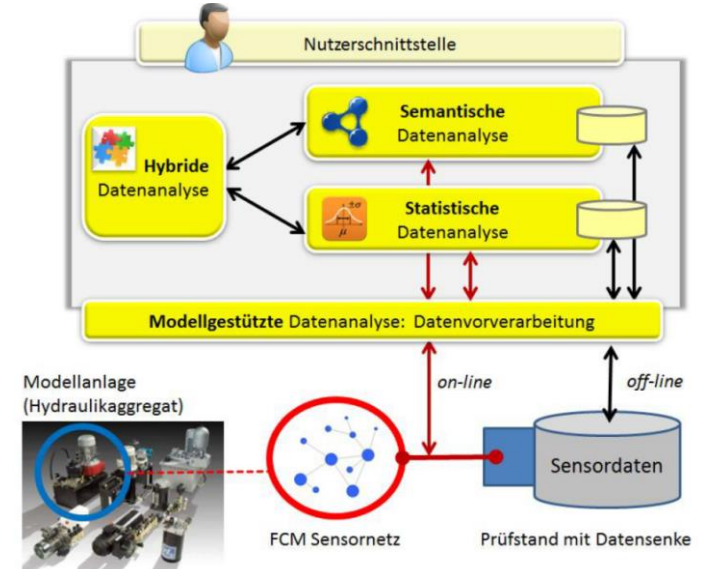
- Verfügbarkeit vieler **Sensordaten** – aber **wie** sind diese **zu deuten**?
- **Vernetzung** von Sensorinformationen zur Verbesserung der Robustheit
- Frühzeitiges **Erkennen von Anomalien** und Planbarkeit von Wartungsarbeiten

Vorgehen

- **Datenbasiert:** Merkmalsextraktion und Mustererkennung (→ ZeMA)
- **Wissensbasiert:** Semantische Modellbildung und Analyse (→ DFKI)
- **Aufbau von Prüfständen** zur **Validierung** des Systems


Ziele

- **Schadensdetektion** und **-diagnose**
- **Selbstüberwachung** auf Sensorfehler und Kompensation ausgefallener Sensoren
- **Adaptierbarkeit** auf unterschiedliche Anlagen



Intelligent Condition Monitoring

- ▶ Condition-based maintenance requires human experts to interpret complex interdependencies between measured sensor data and system conditions

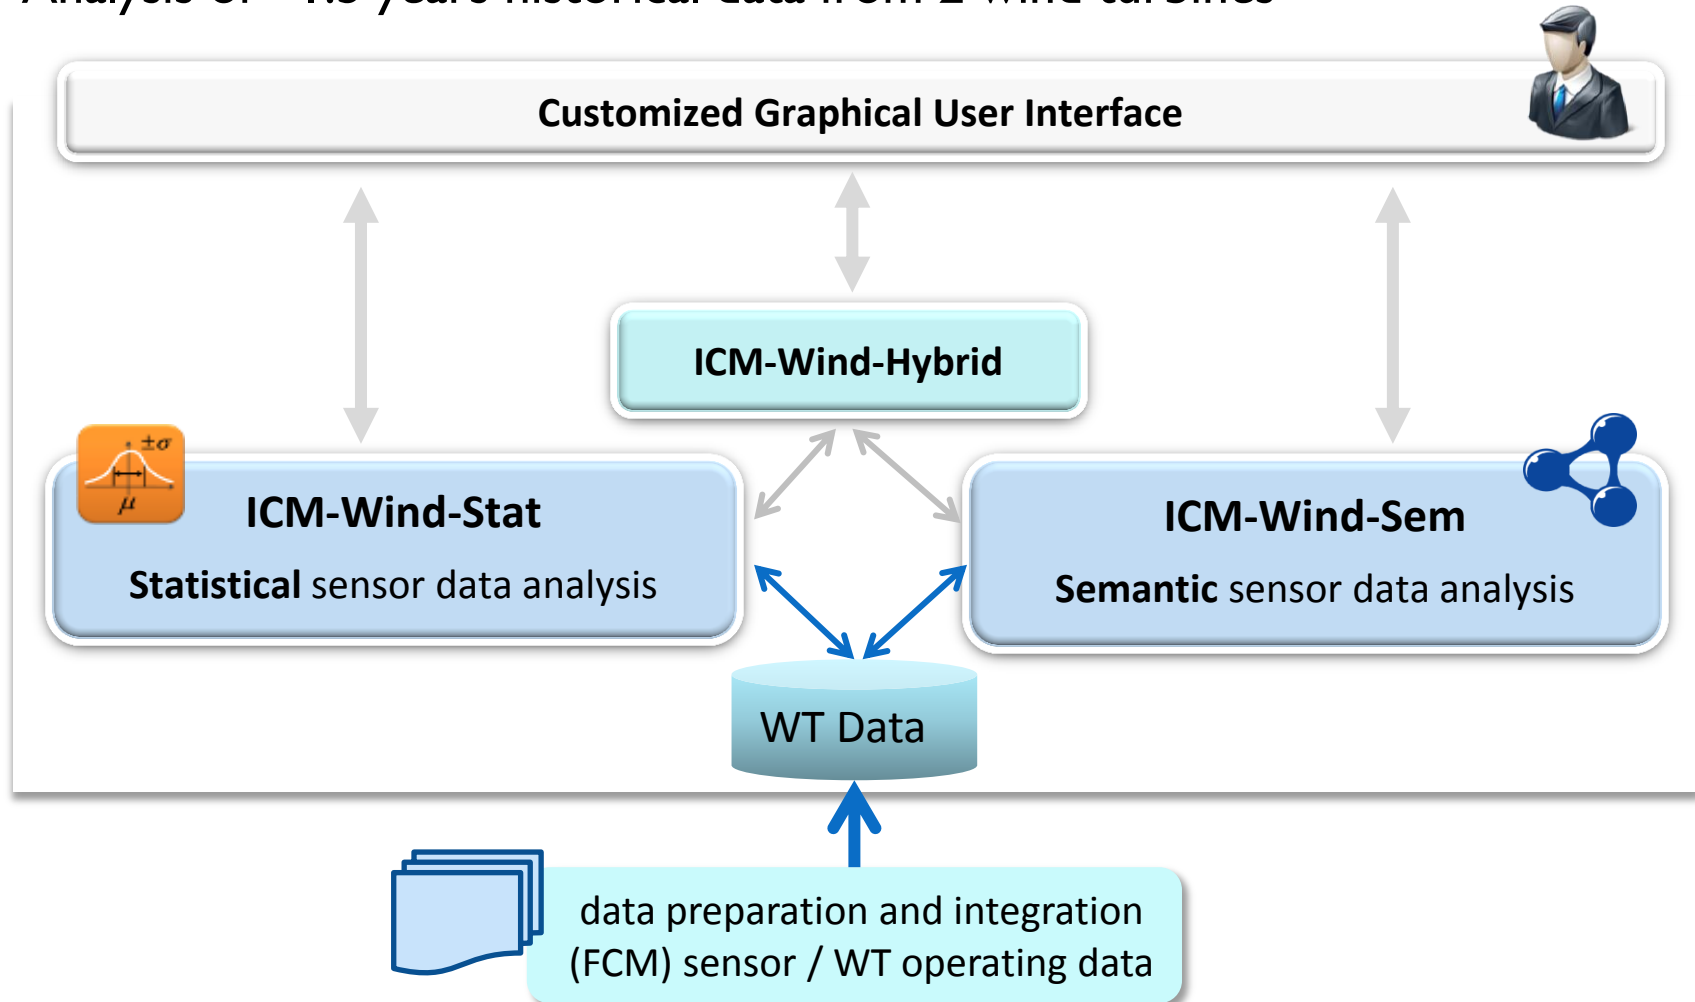


CM Automation Challenges

- Knowledge-based **explanation** of detected faults to experts and non-experts
- Fast **quantitative and qualitative reasoning** on sensor data for fault detection and diagnosis
- **Adaptation** to different hydraulic systems

Origins: iCM-Wind

- ▶ Analysis of ~1.5 years historical data from 2 wind turbines



Conclusions from iCM-Wind



- ▶ **Statistical sensor data analysis** is promising for condition monitoring and prediction of oil filters.
 - **But: data quality insufficient for in depth analysis**
- ▶ **Semantic sensor data analysis** in addition allows logical interpretation for condition monitoring.
 - **But: strongly depends of quality of domain model**
- ▶ First concept of **hybrid analysis** offers added value compared to both types of evaluation individually.


❖ **Requirements for further development:**

- ❖ **Lab model of a complex system with various components and sensors**
- ❖ **Experimental modelling of fault scenarios (degradation, component failure)**

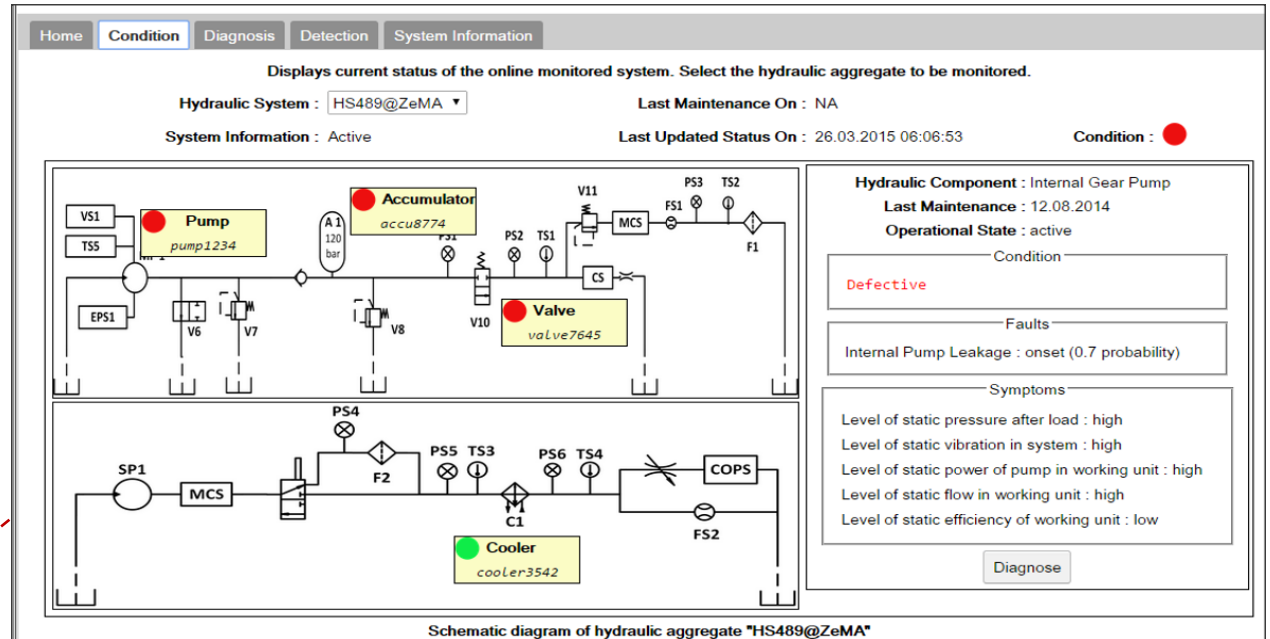
→ **Project iCM Hydraulic**

iCM-Hydraulic

- ▶ Combines statistic and semantic technologies to detect and diagnose probable faults with user understandable explanation



Mobile client for monitoring hydraulic test benches



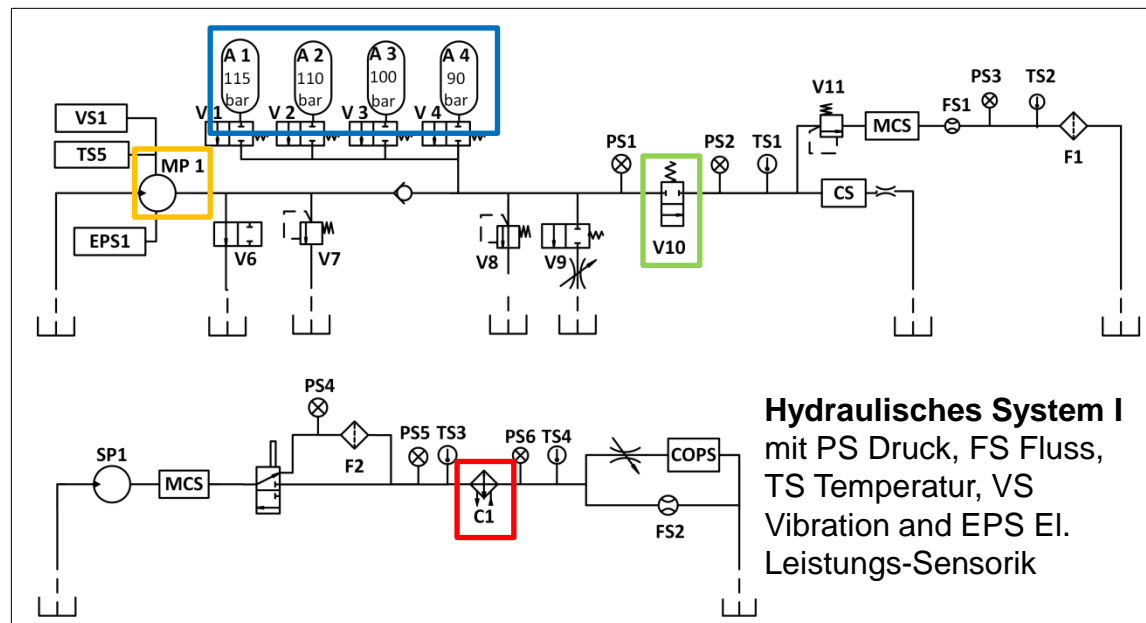
Information on probability and symptom states for Pump's 'Poor' condition. "Diagnose" details possible causes of fault and condition.

- Configuration: 2 hydraulic test benches, 17 sensors, 1 min working cycle
- Performance: 50k obs/min per bench (throughput)
- Fast offline and online analysis

Experimenteller Aufbau und Schadensszenarien

Hydraulische Prüfstände

- Arbeits- und Kühlkreislauf
- Experimentelle Schadenssimulation von Komponenten
- Zwei Systeme
 1. Charakterisierung von Schadenszuständen
 2. Langzeit- und Übertragbarkeitsanalyse





Schadensgrößen und -bereiche

Komponente	Szenario	Eingriffsgröße	Bereich
Kühler C1	Abfall Kühlleistung	Tastgrad des Lüfters	0...100 % (0.6...2.2 kW)
Wegeventil V10	Verzögertes Schaltverhalten	Ansteuerstromstärke V10	0...100 % der nomin. Stromstärke
Pumpe MP1	Interne Leckage	Bypass Blenden (V9)	3 x 0.2 mm, 3 x 0.25 mm
Hydrospeicher (A1-A4)	Gas Leckage	Speicher A1-A4 mit unters. Vordrücken	90, 100, 110, 115 bar

Schadens-Charakterisierungsmessungen

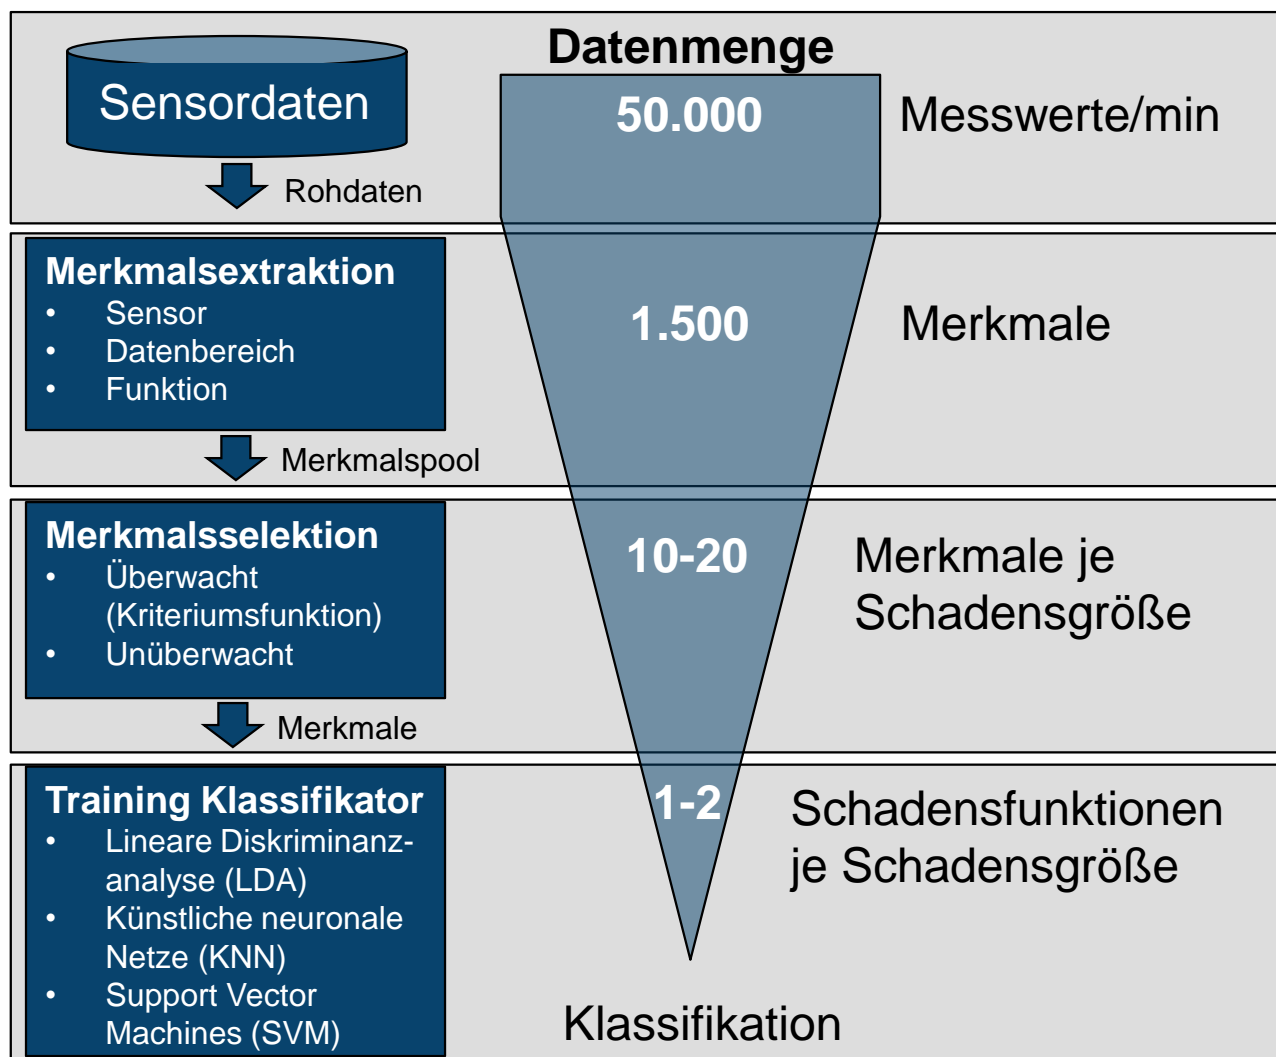
- Konfiguration von komplex verschachtelten Schadensverläufen
 - Kombinieren von Fehlertypen und Schweregraden
 - Vorteil: Berücksichtigung von Störgrößen und Quereinflüssen
- Während der Messung durchläuft das hydraulische System vordefinierte konstante Arbeitszyklen



Arbeitszyklus (Dauer 60 s, gemessen von PS1)

[Quelle: Helwig, N., Pignatelli, E., Schütze, A.: Condition Monitoring of a Complex Hydraulic System using Multivariate Statistics, 2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), May 11-14, 2015, Pisa, Italy (accepted 2015).]

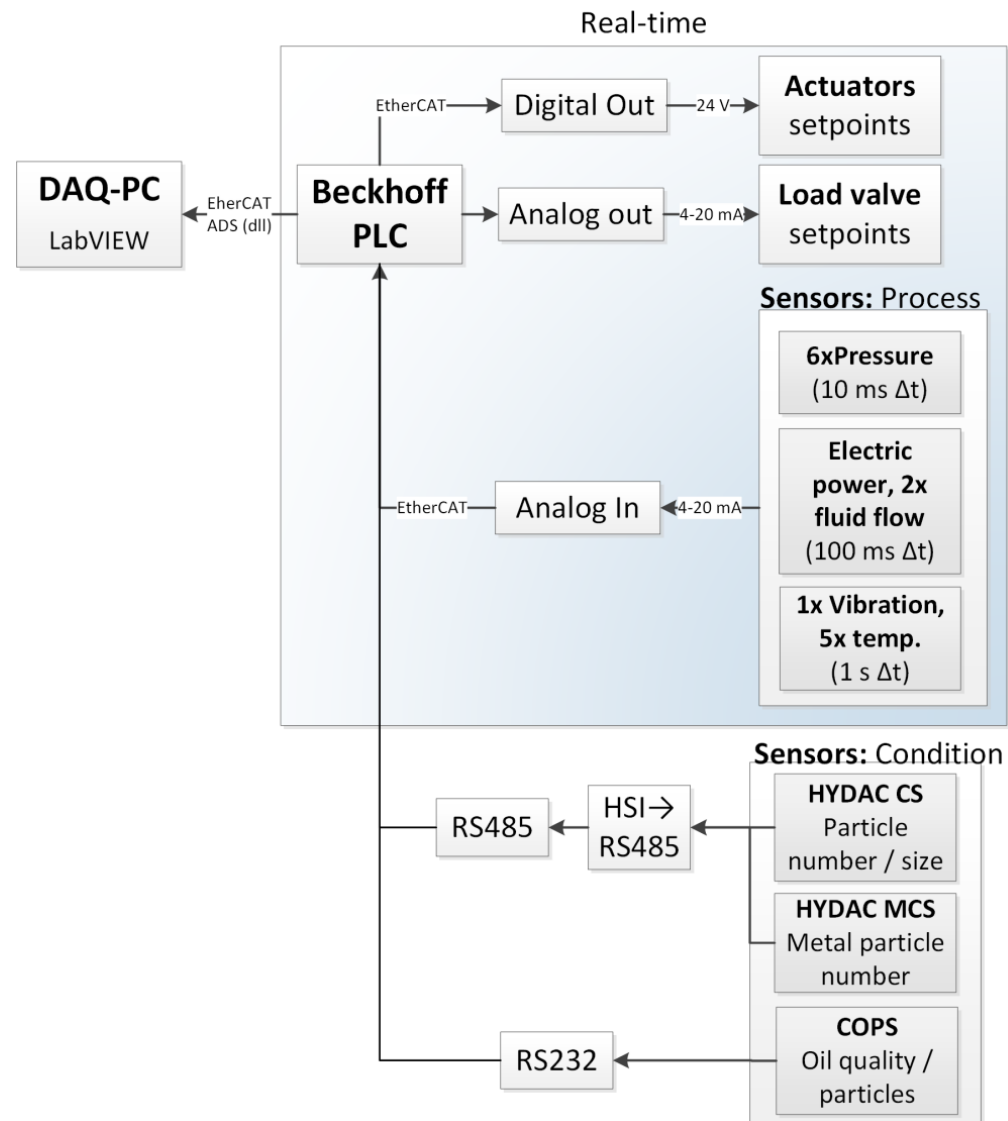
Vorgehensweise



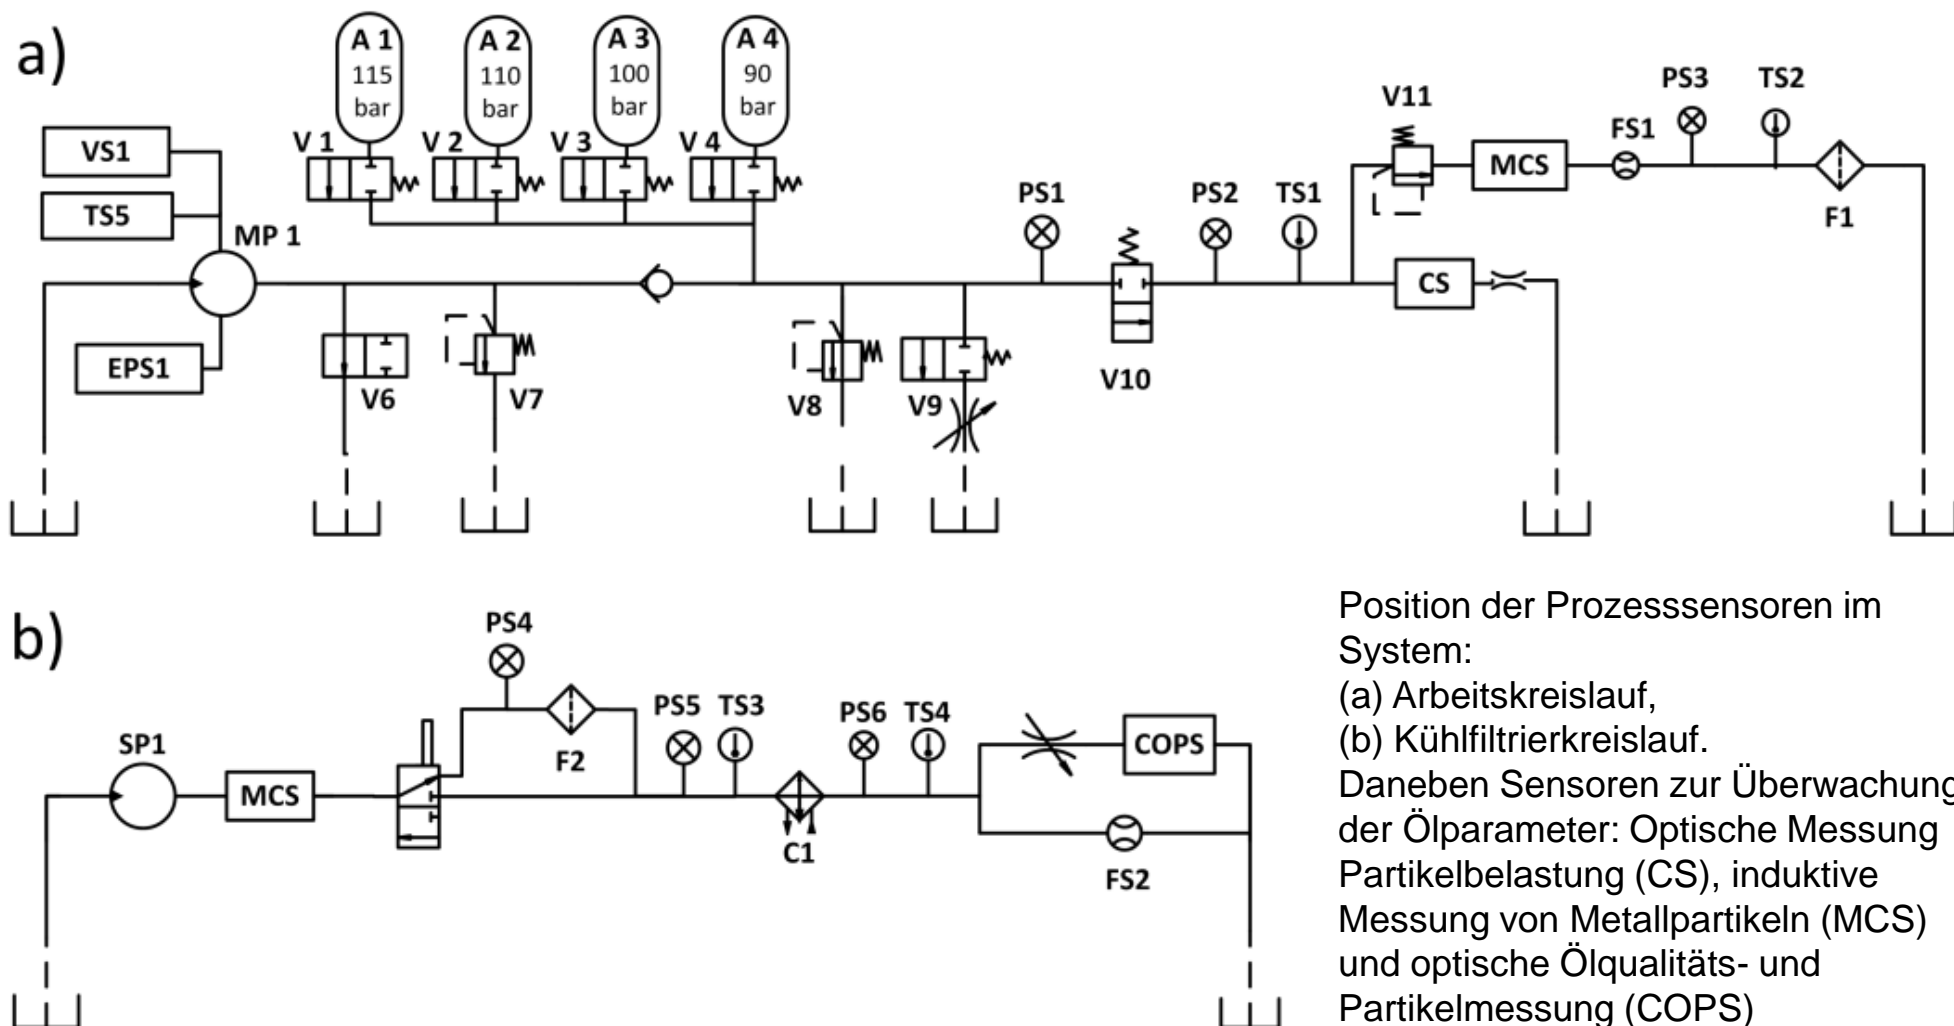
Vollständig automatisierbar!

Sensoren und Steuerung

- Ablauf des Arbeitszyklus sowie Sensordatenaufzeichnung über SPS in Echtzeit gesteuert (Beckhoff IPC)
 - Sensordaten synchron zum Prozess
 - Samplingrate an Sensortyp und zugrundeliegende Messgröße angepasst
 - Messdaten von 17 Prozesssensoren (14 physikalische und 3 virtuelle Sensoren) sowie Verlauf der Schadensgrößen werden von DAQ-PC im ASCII Format abgelegt

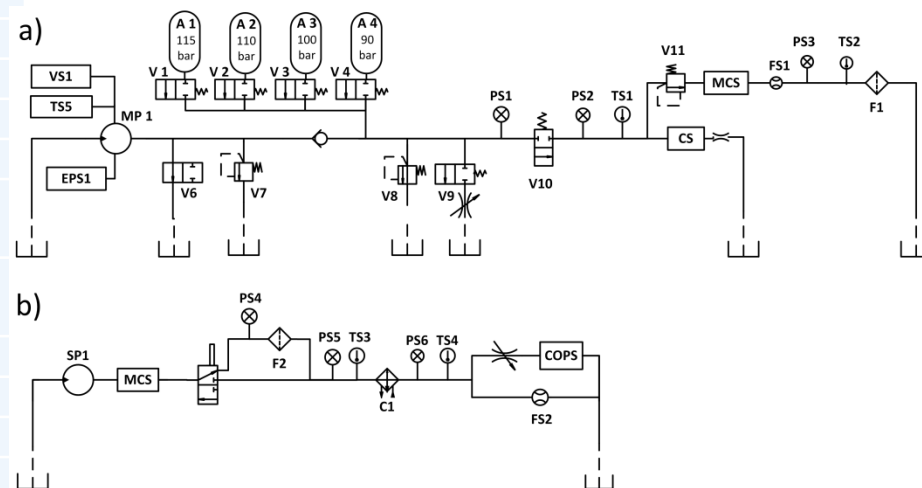


Prozesssensoren im System



Prozesssensoren im System


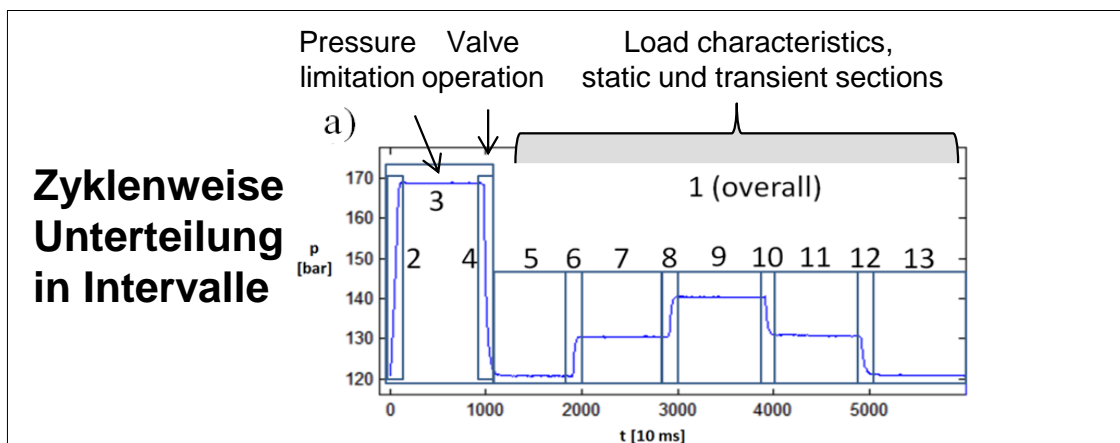

Sensor	Messgröße	Einheit	Abtastrate	Bemerkung	Typ
PS1	Druck	bar	100 Hz		Hydac HDA 4746
PS2	Druck	bar	100 Hz		Hydac HDA 4746
PS3	Druck	bar	100 Hz		Hydac HDA 4746
PS4	Druck	bar	100 Hz		Hydac HDA 4746
PS5	Druck	bar	100 Hz		Hydac HDA 4746
PS6	Druck	bar	100 Hz		Hydac HDA 4746
FS1	Volumenstrom	l/min	10 Hz	Turbinenmessprinzip	Hydac EVS 3106
FS2	Volumenstrom	l/min	10 Hz	Turbinenmessprinzip	Hydac EVS 3106
TS1	Temperatur	°C	1 Hz		Hydac ETS 7246
TS2	Temperatur	°C	1 Hz		Hydac ETS 7247
TS3	Temperatur	°C	1 Hz		Hydac ETS 7248
TS4	Temperatur	°C	1 Hz		Hydac ETS 7249
VS1	Vibration	mm/s	1 Hz	RMS Wert nach ISO10816	Hauber 6440
EPS1	Motorleistung	W	100 Hz	Dreiphasen-Leistungsmessklemme	Beckhoff EL3403
CE	Kühleffizienz	%	1 Hz	virtueller Sensor	-
CP	Kühlleistung	kW	1 Hz	virtueller Sensor	-
SE	Wirkungsgrad	%	1 Hz	virtueller Sensor	-



Position der Prozesssensoren im System: (a) Arbeitskreislauf, (b) Kühlfilterkreislauf. Daneben Sensoren zur Überwachung der Ölparameter: Optische Messung Partikelbelastung (CS), induktive Messung von Metallpartikeln (MCS) und optische Ölqualitäts- und Partikelmessung (COPS)

Merkmalsextraktion

- Berechnen von Merkmalswerten bei unters. Sensoren und Zyklusintervallen
- Genutzte Merkmale
 - Signalform (Steigung, Min, Max, Position des Maximums, ...)
 - Statistische Momente (Median, Varianz, Kurtosis, Schiefe)



Merkmals-Pool mit ~ 1500 Merkmalen

Merkmalsselektion

- Überwacht
 - Korrelation
 - Pearson
 - Spearman
 - ANOVA
- Ergebnis: Signifikante Merkmale zur Beschreibung von Schadens-/Verschleißzuständen von Komponenten

Beispiel: Liste signifikanter Merkmale (Pearson Korrelation)

Cooler features				Valve features				Pump features				Accumulator features			
Sns	Fct	Int	r	Sns	Fct	Int	r	Sns	Fct	Int	r	Sns	Fct	Int	r
CE*	Me	10	0.99	PS1	Va	4	0.98	FS1	Me	5	0.42	EPS1	Sk	12	0.69
CE*	Me	12	0.99	PS2	Me	4	0.96	SE*	Me	8	0.38	PS2	Me	3	0.66
CE*	Me	2	0.99	PS2	Va	3	0.96	FS1	Va	9	0.34	FS1	Sl	12	0.61
CE*	Me	4	0.99	PS2	Sk	3	0.95	SE*	Me	13	0.34	FS1	Va	1	0.59
CE*	Me	8	0.99	PS2	Ku	3	0.95	SE*	Me	9	0.34	FS1	Ku	12	0.59
CE*	Me	11	0.99	PS1	Sl	4	0.95	SE*	Me	1	0.34	SE*	Sk	6	0.59
CE*	Me	6	0.99	SE*	Me	4	0.93	SE*	Me	2	0.33	SE*	Sk	12	0.58
CE*	Me	1	0.99	FS1	Sk	3	0.92	SE*	Me	10	0.31	PS2	Ku	6	0.58
CE*	Me	9	0.99	PS3	Sk	3	0.92	FS1	Me	9	0.31	PS1	Ku	12	0.57
CE*	Me	13	0.99	PS2	Sk	4	0.92	PS3	Me	11	0.31	FS1	Va	6	0.56
CE*	Me	3	0.99	PS3	Ku	3	0.9	PS3	Me	9	0.3	EPS1	Sk	6	0.55
CE*	Me	5	0.99	PS1	Me	4	0.89	PS3	Me	8	0.3	FS1	Sk	12	0.55
CE*	Me	7	0.99	PS3	Me	4	0.88	FS1	Me	11	0.29	PS3	Me	3	0.54
CP*	Me	10	0.99	FS1	Ku	3	0.87	FS1	Me	10	0.29	PS1	Ku	6	0.53

Sensor description

CE: virtual sensor cooling efficiency
 CP: virtual sensor cooling power
 PS: pressur sensor
 SE: virtual sensor system efficiency
 FS: Flow sensor
 EPS: electrical power sensor pump





Feature function description

Me: Median
 Va: Variance
 Sk: Skewness
 Ku: Kurtosis
 Sl: Slope

[Quelle: Helwig, N., Pignanelli, E., Schütze, A.: Condition Monitoring of a Complex Hydraulic System using Multivariate Statistics, 2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), May 11-14, 2015, Pisa, Italy]

Aufschlüsselung signifikanter Sensoren

- Sensoren der 30 höchstkorrelierten Merkmale zu den untersuchten Schäden
- Insgesamt signifikant
 - Wirkungsgrad (SE, virtuell)
 - Motorleistung (EPS1)
 - Drücke (PS1-3)
 - Volumenstrom (FS1)
- Spezialfall Kühler-Überwachung



Weitere Dimensionsreduktion: Lineare Diskriminanzanalyse (LDA)

- Werkzeug zur überwachten Dimensionsreduktion (überwacht: benötigt Kenntnis über Zielgröße in Trainingsdaten)
- Lineare Projektion der zuvor selektierten Merkmale auf Diskriminanzfunktionen (DF), die den Schweregrad eines Schadens widerspiegeln
- Ziel: Maximieren der Klassentrennung (hier: Schadensstufen)
- Trainingsalgorithmus LDA: Identifizieren des Projektionsvektors zum Maximieren der Kriteriumsfunktion Γ

$$\Gamma = \frac{B}{W} = \frac{\sum_{g=1}^G I_g \cdot (\bar{Y}_g - \bar{Y})^2}{\sum_{g=1}^G \sum_{i=1}^{I_g} (\bar{Y}_{gi} - \bar{Y}_g)^2}$$

B: between class scattering
W: within class scattering

G : number of classes

I_g : number of elements in class g

\bar{Y}_g : mean discriminant value in

\bar{Y} : class g

\bar{Y}_{gi} : overall mean

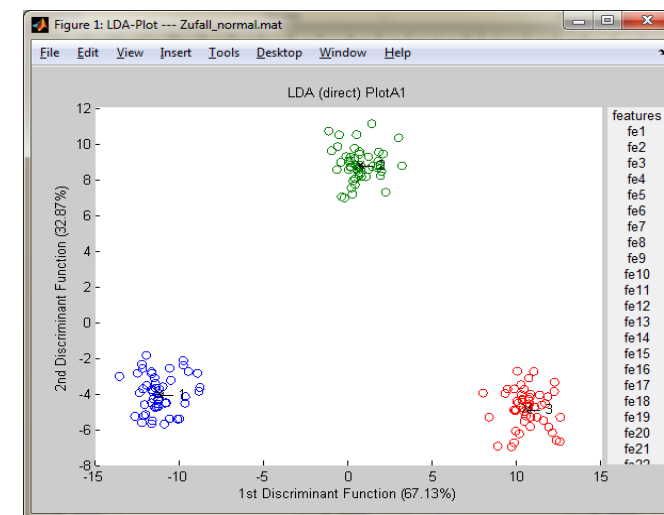




mean discriminant value of
element i of class g

Overfitting: Aufpassen bei hochdimensionalen Datensätzen!

Beispiel für Overfitting: Konstruierter Datensatz mit 150 „Messungen“ und 150 Merkmalen.

Die Merkmale stellen normalverteilte Zufallszahlen dar, also letztlich bloßes Rauschen.


Anzahl der verwendeten Merkmale: 3, 75, 125, 145



Validierungsmethoden zum Vermeiden von Overfitting

z.B. K-fold cross validation:


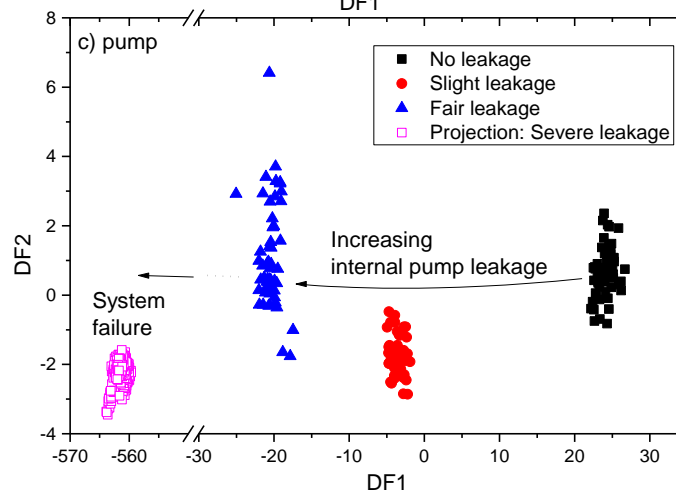
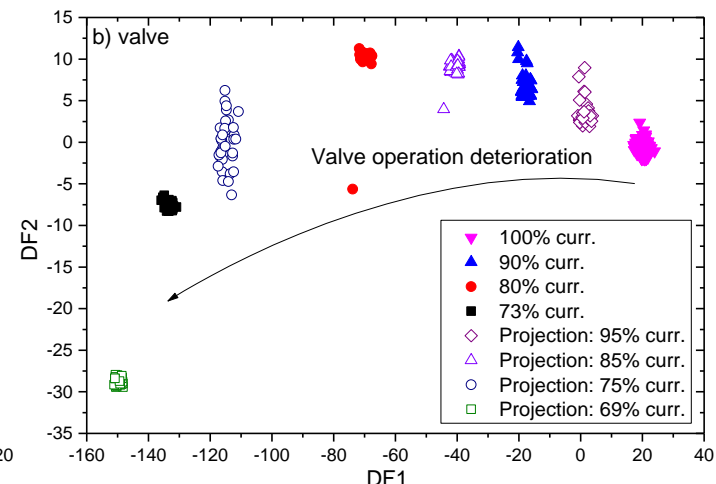
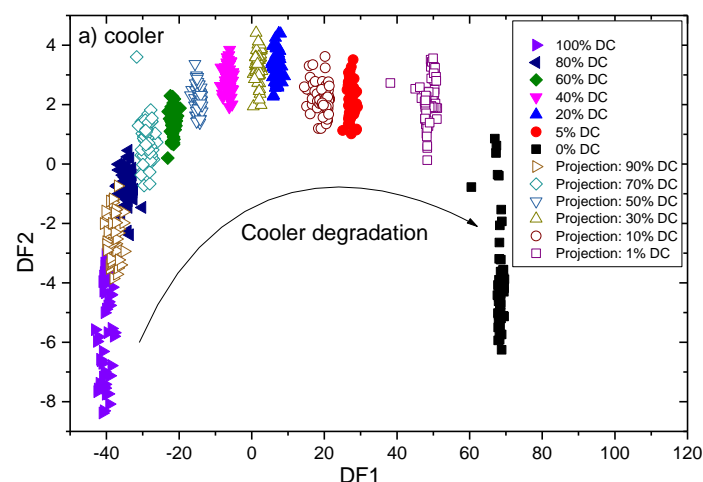
- Datensatz wird in K Gruppen aufgeteilt. Jeweils eine Gruppe wird als Test-Datensatz, der Rest als Trainings-Datensatz genutzt → K Durchläufe
- Klassifiziere gewählten Punkt an Hand der restlichen Daten mit der gewählten Signalverarbeitungsmethode (PCA/LDA, SVM, kNN, ggfs. plus Klassifikator)
- Klassifizierungserfolg wird angegeben als Prozentsatz der korrekt klassifizierten Datenpunkte
- Bei kleinem Datensatz: LOOCV oder KFCV mit großem K sinnvoll
Bei großem Datensatz: KFCV mit kleinem K sinnvoll



http://psi.cse.tamu.edu/teaching/lecture_notes/

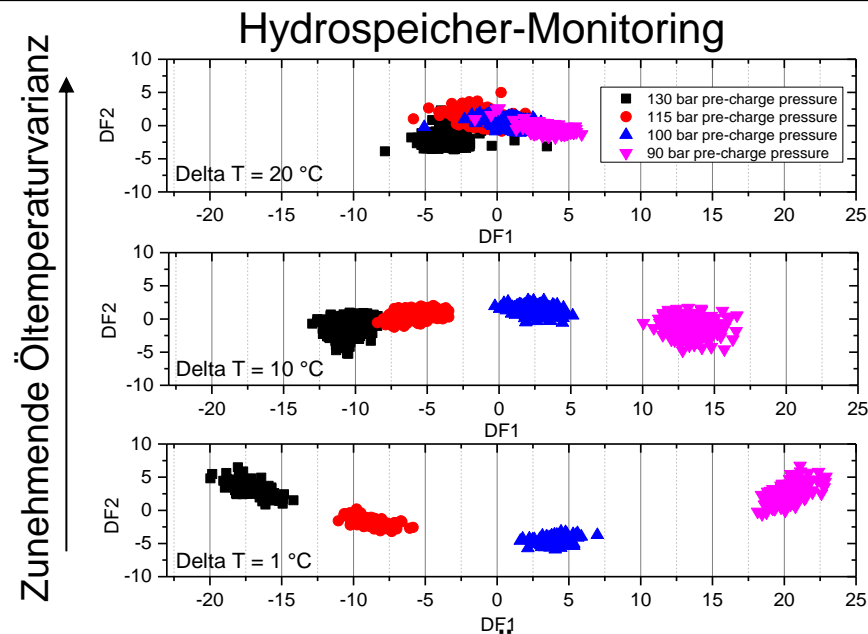
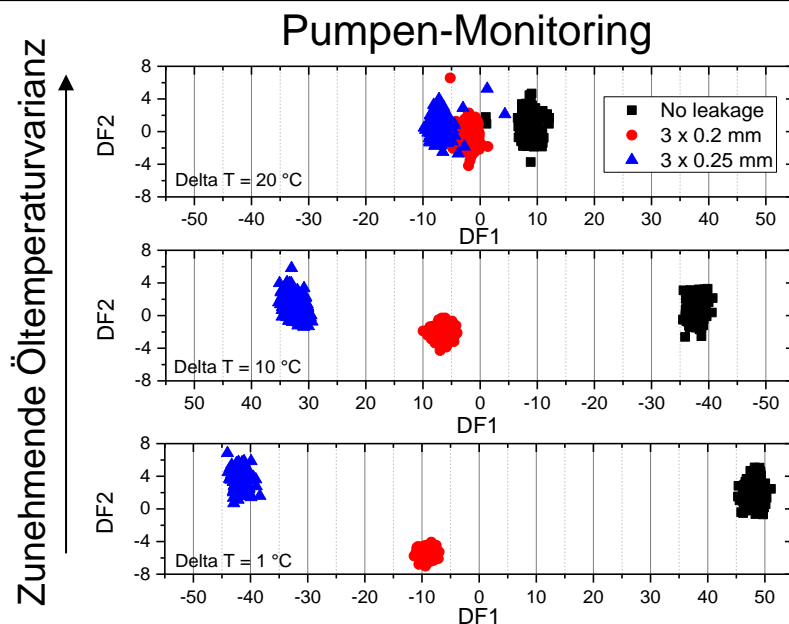
Charakteristische LDA Schadensfunktionen

- Schadensverlauf wird in 2-D LDA-Raum dargestellt
- DF1 erlaubt die Quantifizierung des Schweregrades
- Evaluierung des statistischen Modells durch die Projektion von Zwischengruppen (→ Interpolation) erfolgreich



[Quelle: Helwig, N., Pignanelli, E., Schütze, A.: Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System, SENSOR 2015 - 17th International Conference on Sensors and Measurement Technology, May 19-21, 2015, Nuremberg, Germany]

Öltemperatur als Einflussgröße



Erkennungsraten [%] mit knn-Klassifikator (k=3) bei unterschiedlichen Öltemperatur-Bereichen

	$\Delta T=1\text{ °C}$, (n=489)				$\Delta T=10\text{ °C}$, (n=969)				$\Delta T=20\text{ °C}$, (n=1449)			
	Cool	Valve	Pump	Acc	Cool	Valve	Pump	Acc	Cool	Valve	Pump	Acc
Pearson	100	100	100	100	100	100	100	100	100	100	99	83.25
Spearm.	100	100	100	100	100	100	100	99.75	100	100	98.5	84.75
ANOVA	100	100	100	100	100	100	100	99.5	100	100	98.75	88.25

- Schadenserkennung stark durch Öltemperaturbereich beeinflusst
- Trainingsdaten sollten Variationen der Öltemperatur beinhalten um Quereinflüsse gezielt unterdrücken zu können

Vergleich periodische und zufälliger Arbeitsprozesse

- Szenario I - industrielle Applikation: vordefinierte und konstante Arbeitszyklen (Presse)
- Szenario II - Mobilhydraulik: stark variierende Arbeitsabläufe (Radlader)
 - Simuliert mit pseudo-zufälligen Lastniveaus

Klassifikationsraten [%] in Abh. vom Szenario (LDA, 20 Merkm.)

Arbeitszyklus		konstant		zufällig	
Corr.-Koeffizient		r	ρ	r	ρ
Zeitbereichsmerkmale	Kühler	100.0	100.0	100.0	100.0
	Ventil	100.0	100.0	100.0	100.0
	Pumpe	97.9	98.0	72.3	73.6
	Speich.	90.4	88.8	54.2	54.0


Vergleich der Klassifikationsraten [%] zwischen typischen Klassifikationsmethoden

	LDA	ANN	SVM (linear)	SVM (RBF)
Kühler	100	100	100	100
Ventil	100	100	100	95.7
Pumpe	73.6	80.0	72.4	64.2
Speicher	54.0	50.4	51.6	65.7
∅	81.9	82.6	81.0	81.4

→ Keine deutliche Verbesserung mit ANN/SVM





Idee: Zeitreihenanalyse über mehrere Zyklen mit anschließender Merkmalsextraktion

→ Deutliche Verbesserung der Fehlererkennungsrate für die pseudo-zufälligen Arbeitszyklen



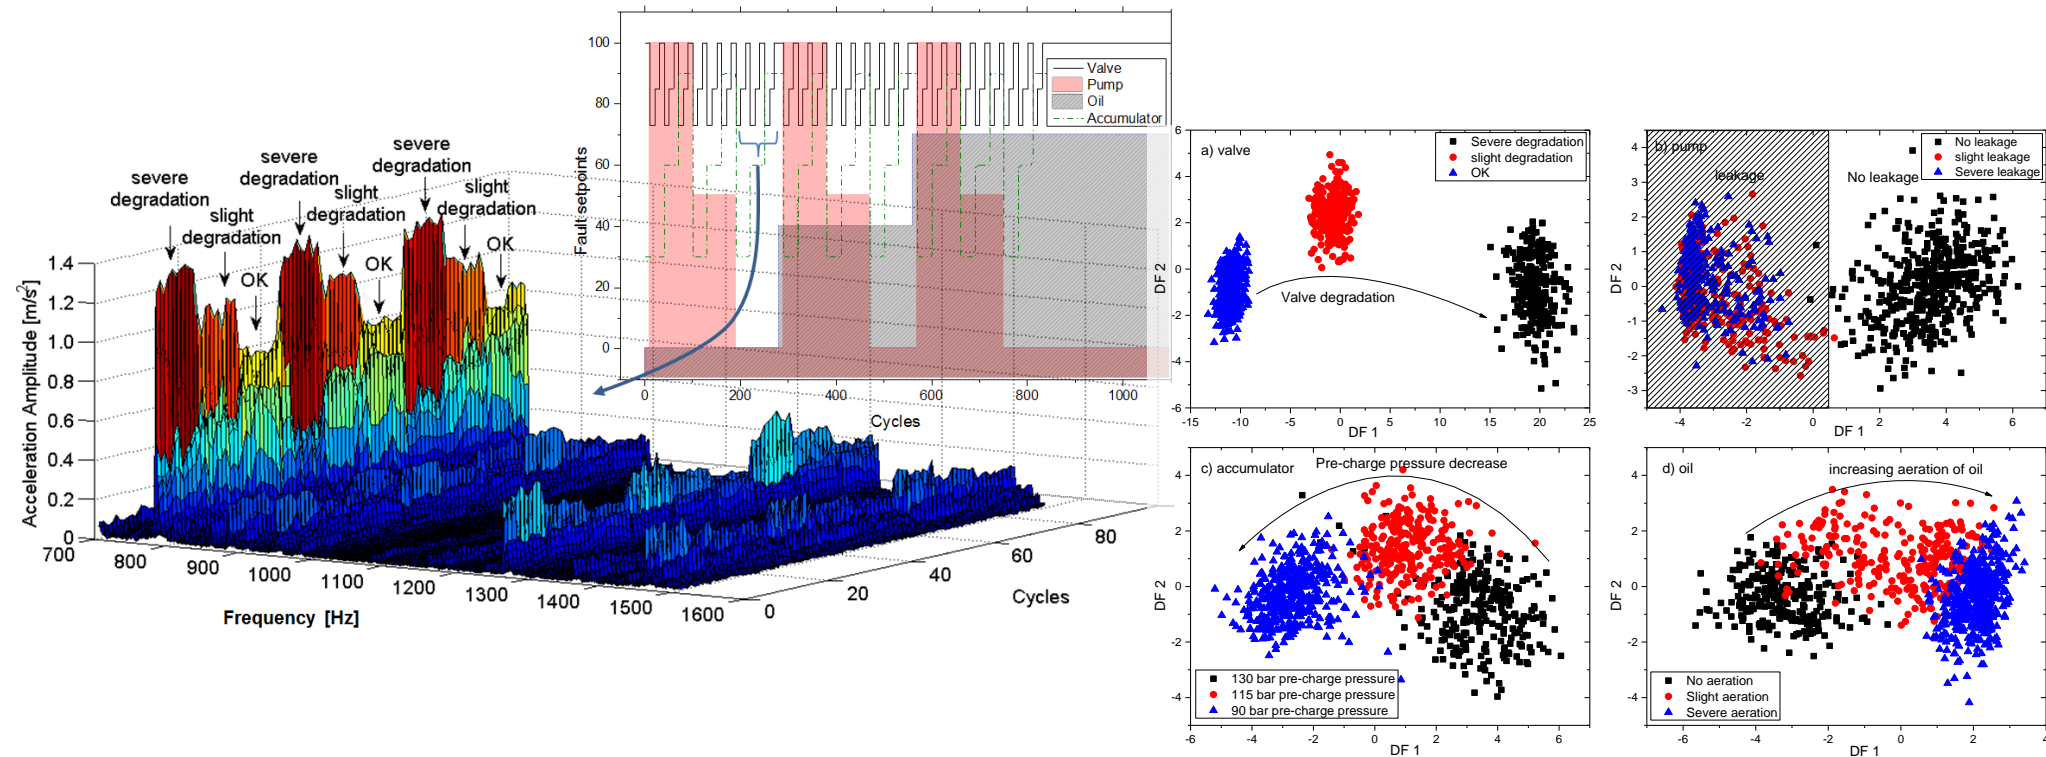
Stabilität und Übertragbarkeit

- Trainingsdaten mit Schadensinformation von System I (~ 1 Tag)
- Merkmalsextraktion, -selektion und Berechnung der LDA
- Projektion von Langzeitdaten (1 Monat) von System II nach Offset-Abgleich



→ Das angelernte statistische Modell ist übertragbar mit geringen Anpassungen
 → Langzeit-Stabilität

Übertragen des Konzepts auf spektrale Schwingungsdaten




	Valve switching				Internal pump leakage				Accumulator pressure				Oil aeration			
	Sns	Int	Freq [Hz]	Fct	Sns	Int	Freq [Hz]	Fct	Sns	Int	Freq [Hz]	Fct	Sns	Int	Freq [Hz]	Fct
1	2	4	1536 - 1792	Sk	2	12	1536 - 1792	Va	2	1	3328 - 3584	Ku	2	8	2816 - 3072	Va
2	2	4	3328 - 3584	Sk	2	6	1536 - 1792	Va	3	1	3328 - 3584	Ku	2	9	2816 - 3072	Va
3	2	4	768 - 1024	Max	2	10	1536 - 1792	Va	4	8	256 - 512	Va	1	3	256 - 512	Me
4	3	4	768 - 1024	Max	2	13	1536 - 1792	Va	2	1	3328 - 3584	Sk	1	1	256 - 512	Me
5	3	4	3328 - 3584	Sk	2	9	1536 - 1792	Va	3	1	3328 - 3584	Sk	1	4	256 - 512	Me
6	2	4	1536 - 1792	Ku	2	7	1536 - 1792	Va	4	11	256 - 512	Va	5	12	3584 - 3840	Va


[Quelle: N. Helwig, S. Klein, A. Schütze: Identification and Quantification of Hydraulic System Faults based on Multivariate Statistics using Spectral Vibration Features, Eurosensors 2015]

Mögliches Problem: Sensorfehler und deren Einfluss

a) Konstanter Offset




b) Drift




Drift & Rauschen


c) Rauschen




d) Signal-Ausreißer



Detektionsrate [%]
Pumpen-Monitoring



Detektionsrate [%]
Speicher-Monitoring



- Pumpen- und Speicherüberwachung sehr anfällig gegenüber leichter Drift- und Rauschüberlagerung
- Selbstüberwachung der Sensoren erhöht Robustheit des CMS

[Quelle: Helwig, N., Pignanelli, E., Schütze, A.: Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System, SENSOR 2015 - 17th International Conference on Sensors and Measurement Technology, May 19-21, 2015, Nuremberg, Germany]




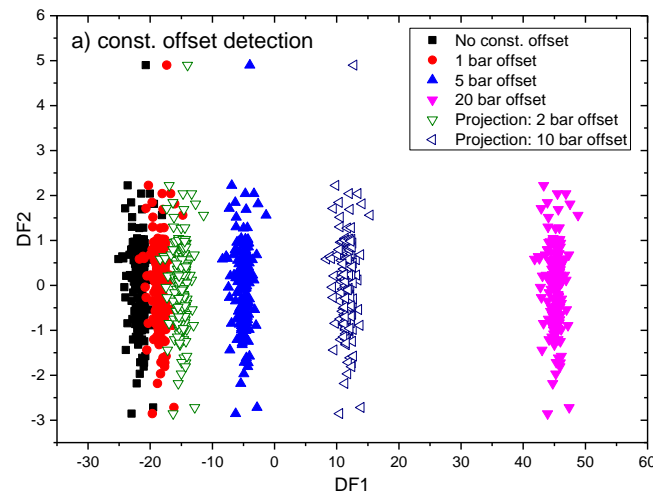
Übertragen des Konzepts zum Erkennen von Sensorfehlern

- Idee: Nutzen der Signalrelationen des Sensornetzes
- Merkmalsextraktion anhand Mittelwertquotienten (a, b), paarweisen Sensorsignal-Korrelationen (c) und statistischen Parametern (d)

- Erkennungslimit:

- Konstanter Offset
 - 0.4 % Full Scale
- Driftrate
 - 0.5 ‰ pro Stunde
- Rauschen
 - 20 dB SNR
- Signal-Ausreißer
 - Einzelnes Event


→ Einzelne Sensorfehler können erkannt werden, bevor sie zu Fehlklassifizierungen führen



[Quelle: Helwig, N., Pignanelli, E., Schütze, A.: Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System, SENSOR 2015 - 17th International Conference on Sensors and Measurement Technology, May 19-21, 2015, Nuremberg, Germany]

Kompensation ausgefallener Sensoren

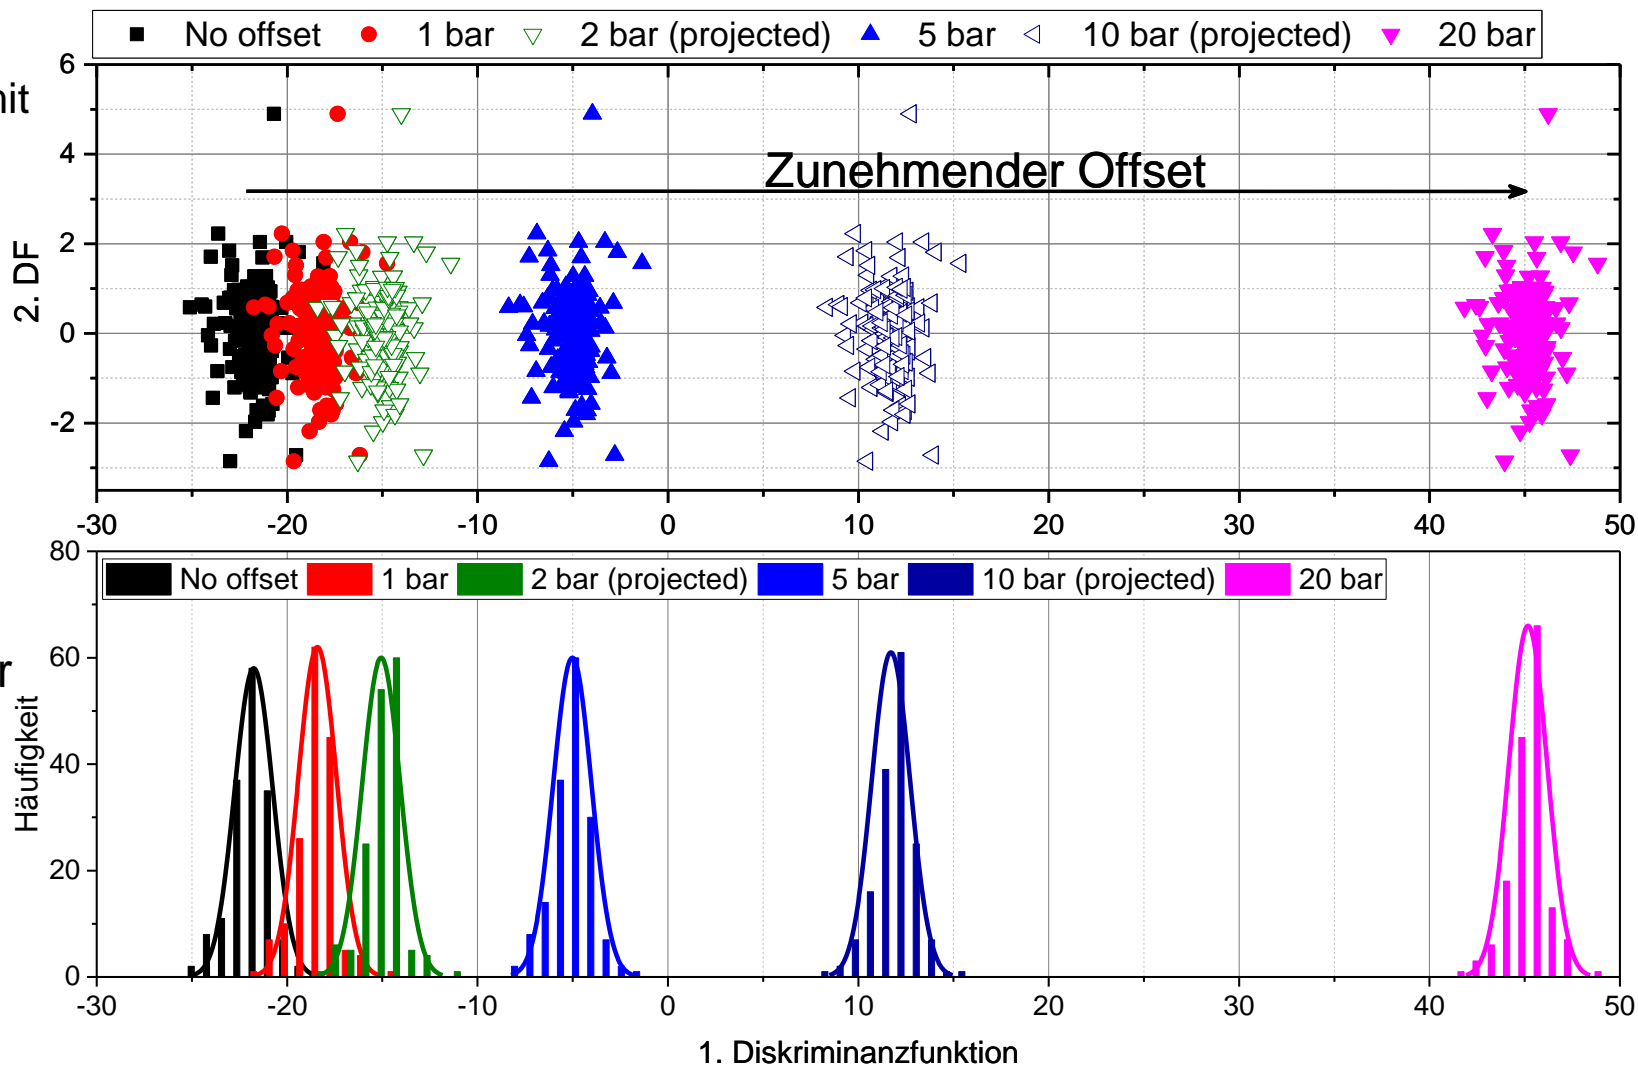
- Um Fehlalarme zu vermeiden, müssen die Daten von ausgefallenen Sensoren ausgeschlossen und das System neu antrainiert werden
 - Die „nächstbesten“ Merkmale werden automatisch ausgewählt
- Bis zu fünf ausgefallene Sensoren können im Testsystem ohne signifikante Verschlechterung der Erkennungsrate kompensiert werden
- LDA im Vergleich zu anderen State-of-the-Art Methoden (ANN, SVM) konkurrenzfähig



[Quelle: Helwig, N., Pignanelli, E., Schütze, A.: Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System, SENSOR 2015 - 17th International Conference on Sensors and Measurement Technology, May 19-21, 2015, Nuremberg, Germany]


Sensorfehler: Offset-Klassifizierung mit gleichbleibender Messunsicherheit

- **Fehlerszenario**
Drucksensor 1 mit konst. Offset
- **Kalibrierung**
0, 1, 5, 20 bar Offset
- **Evaluierung**
2, 10 bar Offset
- **Merkmale:**
Mittelwert-
verhältnisse der
Sensoren
- **N = 966**
- DF1 ist „Messwert“ für Offset



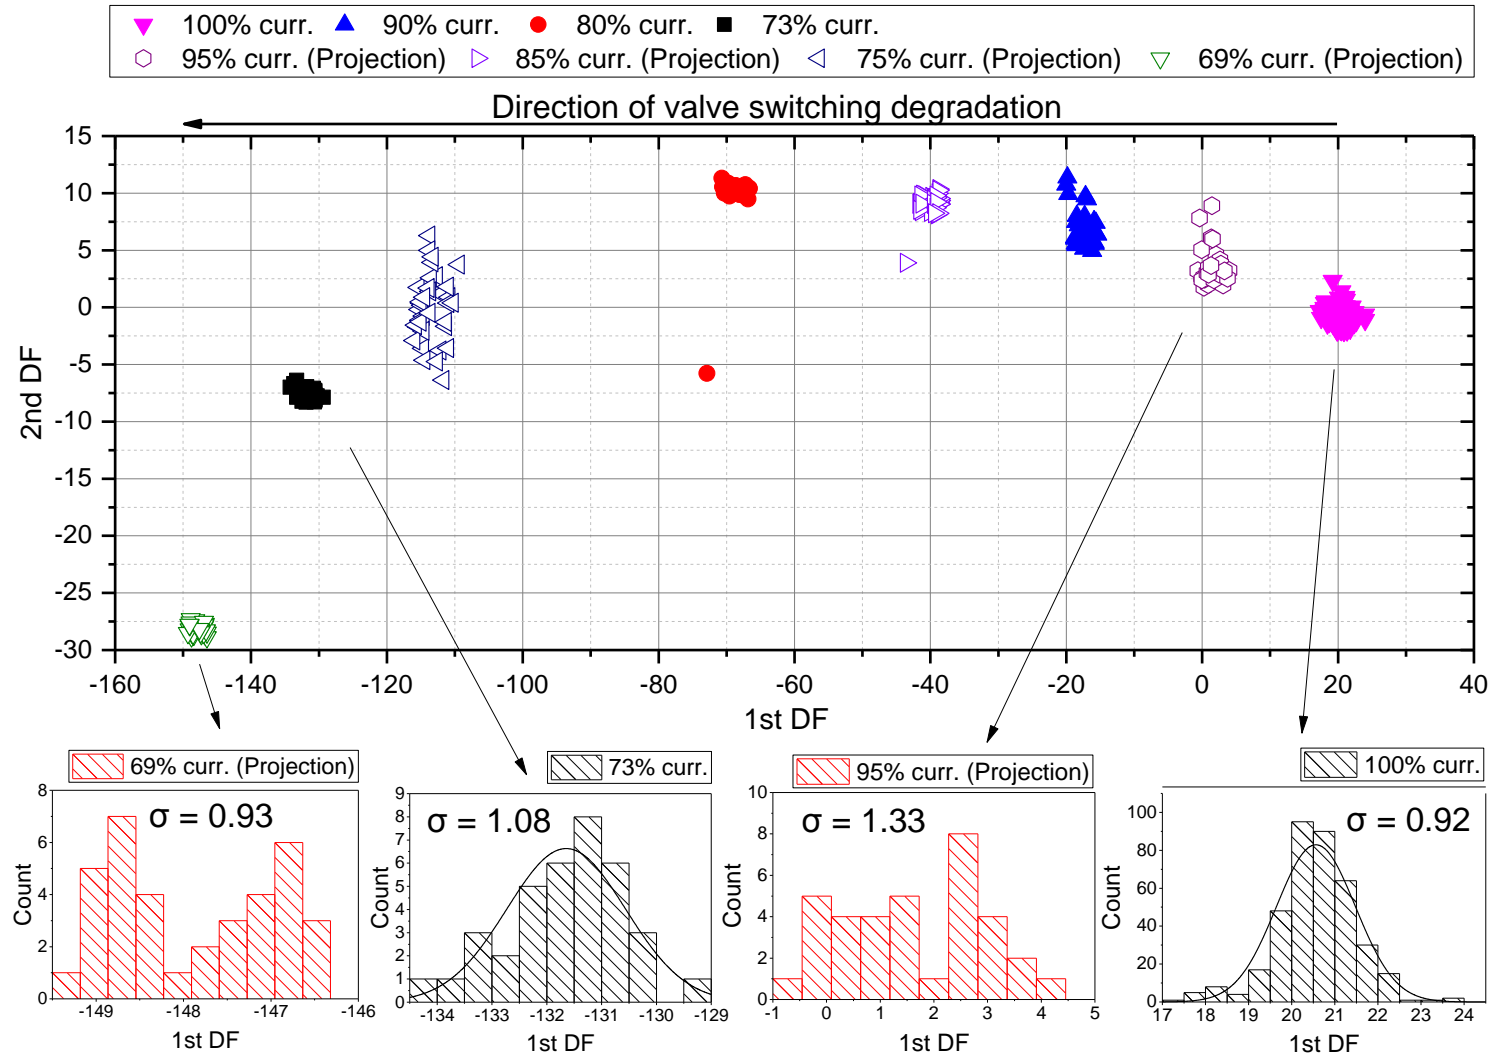
Klassifizierung des Speichervordrucks: Einfluss der Umgebungstemperatur auf die Messunsicherheit

- LDA Berechnung mit 20 Merkmalen
- 4 Blasenspeicherdruckniveaus: 130, 115, 100, 90 bar
- 3 Öltemperaturbereiche (ΔT): 1°C, 10°C, 20°C
- Größerer Temperaturbereich führt zu deutlich steigender Messunsicherheit (gleichmäßig für alle Druckniveaus, aber nicht linear mit ΔT)



Verschlechtertes Ventilschaltverhalten: Evaluierung zeigt andere Verteilung als Kalibrierdaten


- LDA Berechnung mit 10 Merkmalen
- N = 488 (Kalibrierung)
- Kalibrierzustände: 100%, 90%, 80%, 73%
- normalverteilt
- Evaluierung durch Projektion der nicht für die Berechnung genutzten Zustände: 95%, 85%, 75%, 69%
- nicht normalverteilt



Zusammenfassung zur Multiparameter-Signalverarbeitung

- Klassifikationsraten von oder nahe 100% bei betrachteten Schadensfällen auf Basis installierter Prozesssensordaten
 - Transfer des statistischen Modells erfolgreich
 - Ansatz übertragbar auf spektral ausgewertete Schwingungsdaten
 - Detektion typischer Sensorfehler und Kompensation von bis zu 5 ausgefallenen signifikanten Sensoren im Testsystem
 - Berechnungsdauer von ~120 Mio. Rohdatenpunkten (~ 1 Tag)
(17 Sensoren, 6000 Werte pro Zyklus, 1250 cycles) @ Intel Core i5 CPU, 8 GB RAM
 - Merkmalsextraktion: ~ 5 min
 - Merkmalsselektion: 0,2 s pro Zielgröße
 - LDA: 0,1 s pro Zielgröße
 - Klassifikation eines neuen Zyklus: < 0,1 s pro Zielgröße
- Technisch umsetzbar
- Momentan Ausweitung des Ansatzes auf weitere Anwendungsgebiete
(Antriebstechnik, Werkzeugmaschinen, Fertigungs- und Produktionsanlagen)

iCM-Hydraulic @ Hannover Messe 2015




Automatisierte Merkmalsextraktion und -selektion

Masterarbeit Tizian Schneider

Anwendungsbeispiele


1. Temperaturzyklischer Betrieb



[Dipl.-Ing. Martin Leidinger]

Gassensarik:


2. Impedanzspektroskopie



[Dipl.-Ing Marco Schüler]

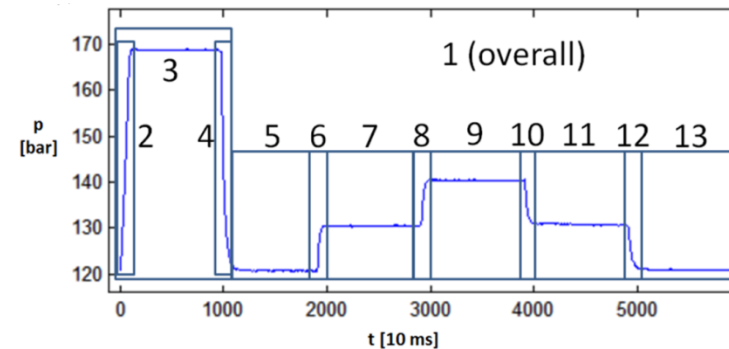
Zustandsüberwachung:

3. Vibrationsanalyse



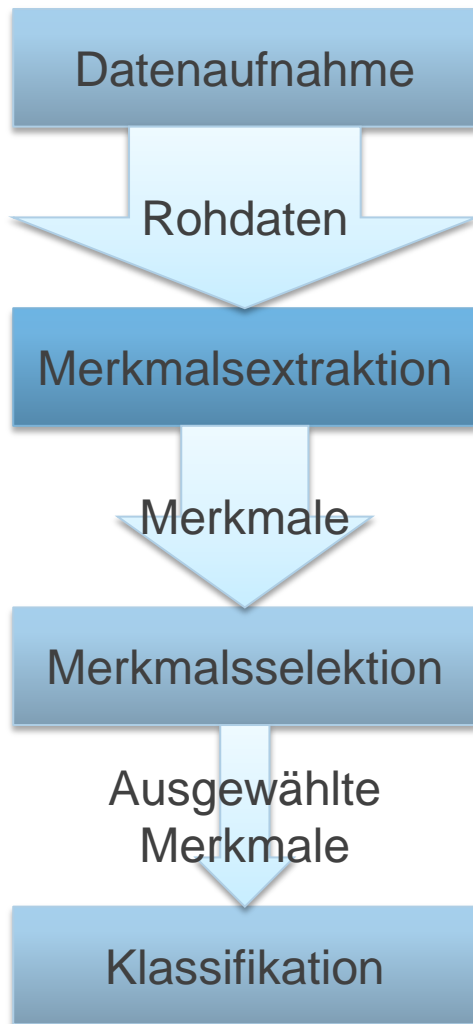
[S. Klein, "Multivariate Auswertung spektraler Beschleunigungsdaten für das Condition Monitoring," Bachelor-Arbeit, Universität des Saarlandes, 2015]

4. Prozesssensoren



[N. Helwig, E. Pignatelli, and A. Schütze, "Condition Monitoring of a Complex Hydraulic System using Multivariate Statistics," in *Instrumentation and Measurement Technology Conference (I2MTC)*, 2015, pp. 210–215]



Merkmalsextraktion



- Extrahiere fundamentale Merkmale des Zyklus
- Unüberwachter Schritt ohne Kenntnis des Gruppenzugehörigkeiten
- Keine Methode kann optimale Leistung garantieren
- Ziele:
 - Konzentriere Information in wenigen Merkmalen
 - Skalierbarkeit
 - Bewahre natürliche Strukturen im Datensatz



Merkmalsextraktion: Adaptive lineare Approximation

- Automatische Unterteilung in lineare Abschnitte
- Rauschunterdrückung
- Gut für Ecken, Kanten und im Zeitbereich lokalisierte Information




Merkmalsextraktion: Hauptkomponentenanalyse

- Erste Hauptkomponenten beschreiben die Zyklusform
- Bartlett`s Test ermittelt die Anzahl benötigter Komponenten
- Beste lineare Transformation im Hinblick auf Approximationsfehler




Merkmalsextraktion: Beste Fourier Koeffizienten

- Transformation in den Frequenz-Bereich
- Für maximale Signalenergie extrahiere Koeffizienten mit größtem durchschnittlichen Betrag




Messpunktnummer im Zyklus




Messpunktnummer im Zyklus

Merkmalsextraktion: Beste Wavelet Koeffizienten

- Transformation in den Zeit-Frequenz-Bereich
- Daubechies-4-Wavelet zur Kompression linearer Signalbereiche
- Erste Koeffizienten für globale Merkmale und letzte für lokale Details







Messpunktnummer im Zyklus



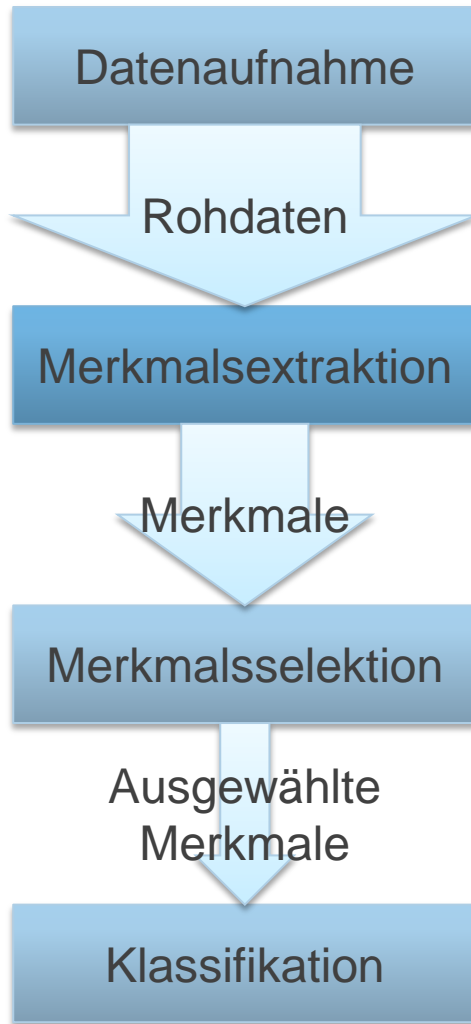
Messpunktnummer im Zyklus

Merkmalsextraktion: Evaluation

■ 4-Fach Plot zur Qualität der Approximation



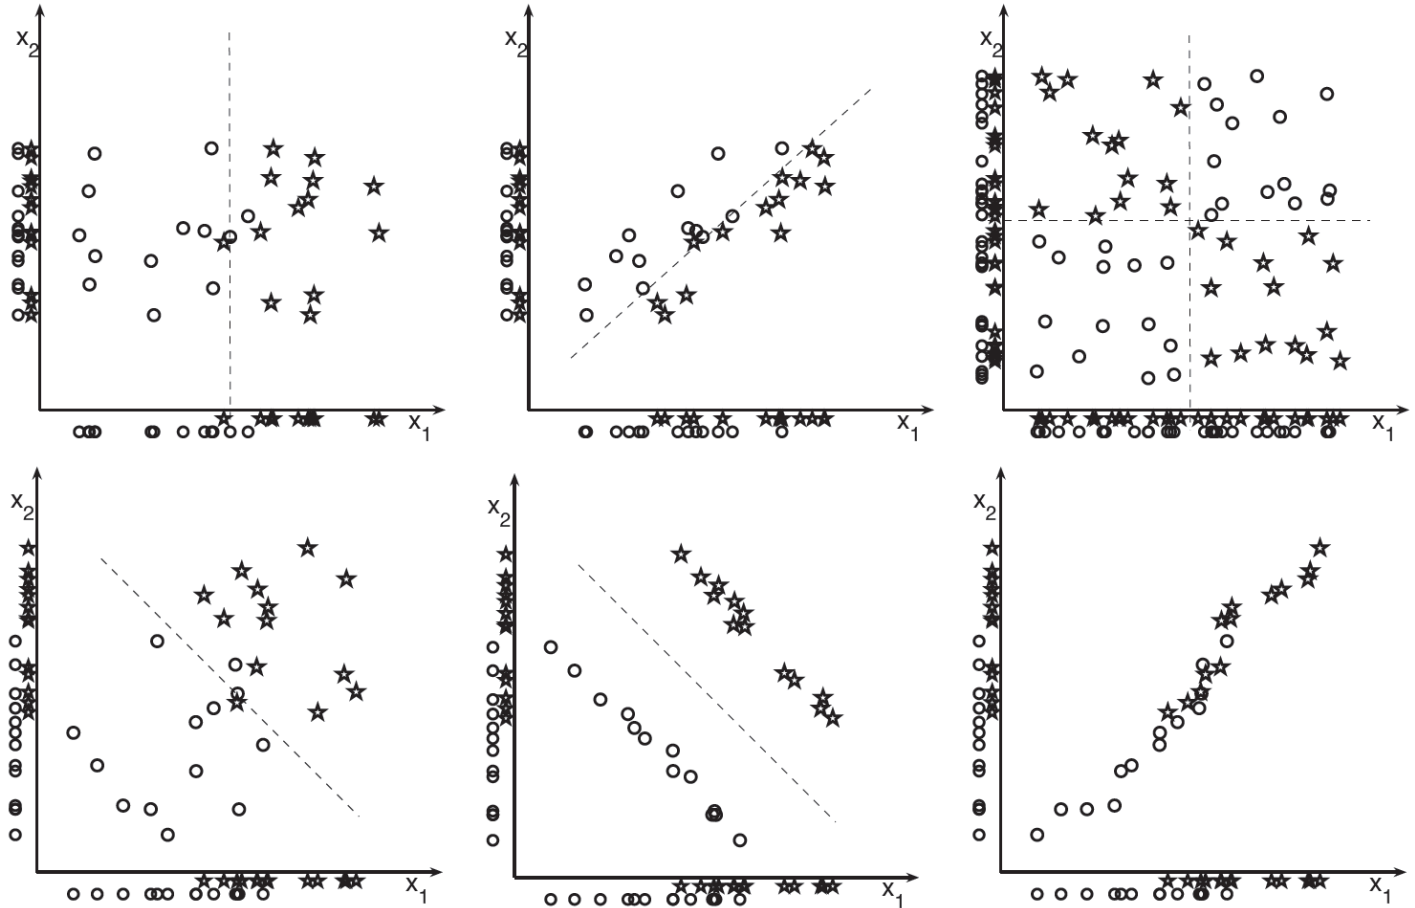
Merkmalsselektion



- Auswahl der besten Merkmale für maschinelles Lernen
- Überwachter Schritt → Validierung notwendig!
- Keine Methode kann optimale Leistung garantieren
- Ziele:
 - Konzentriere Information in wenigen Merkmalen
 - Skalierbarkeit

Merkmalsselektion: Typische Probleme

- Theoretisch nur Aussagen über „wahrscheinlich annähernd irrelevante“ Merkmale möglich
- Typische Probleme:



[I. Guyon, "An Introduction to Variable and Feature Selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157–1182, 2003]

66 Algorithmen betrachtet, 45 implementiert und getestet

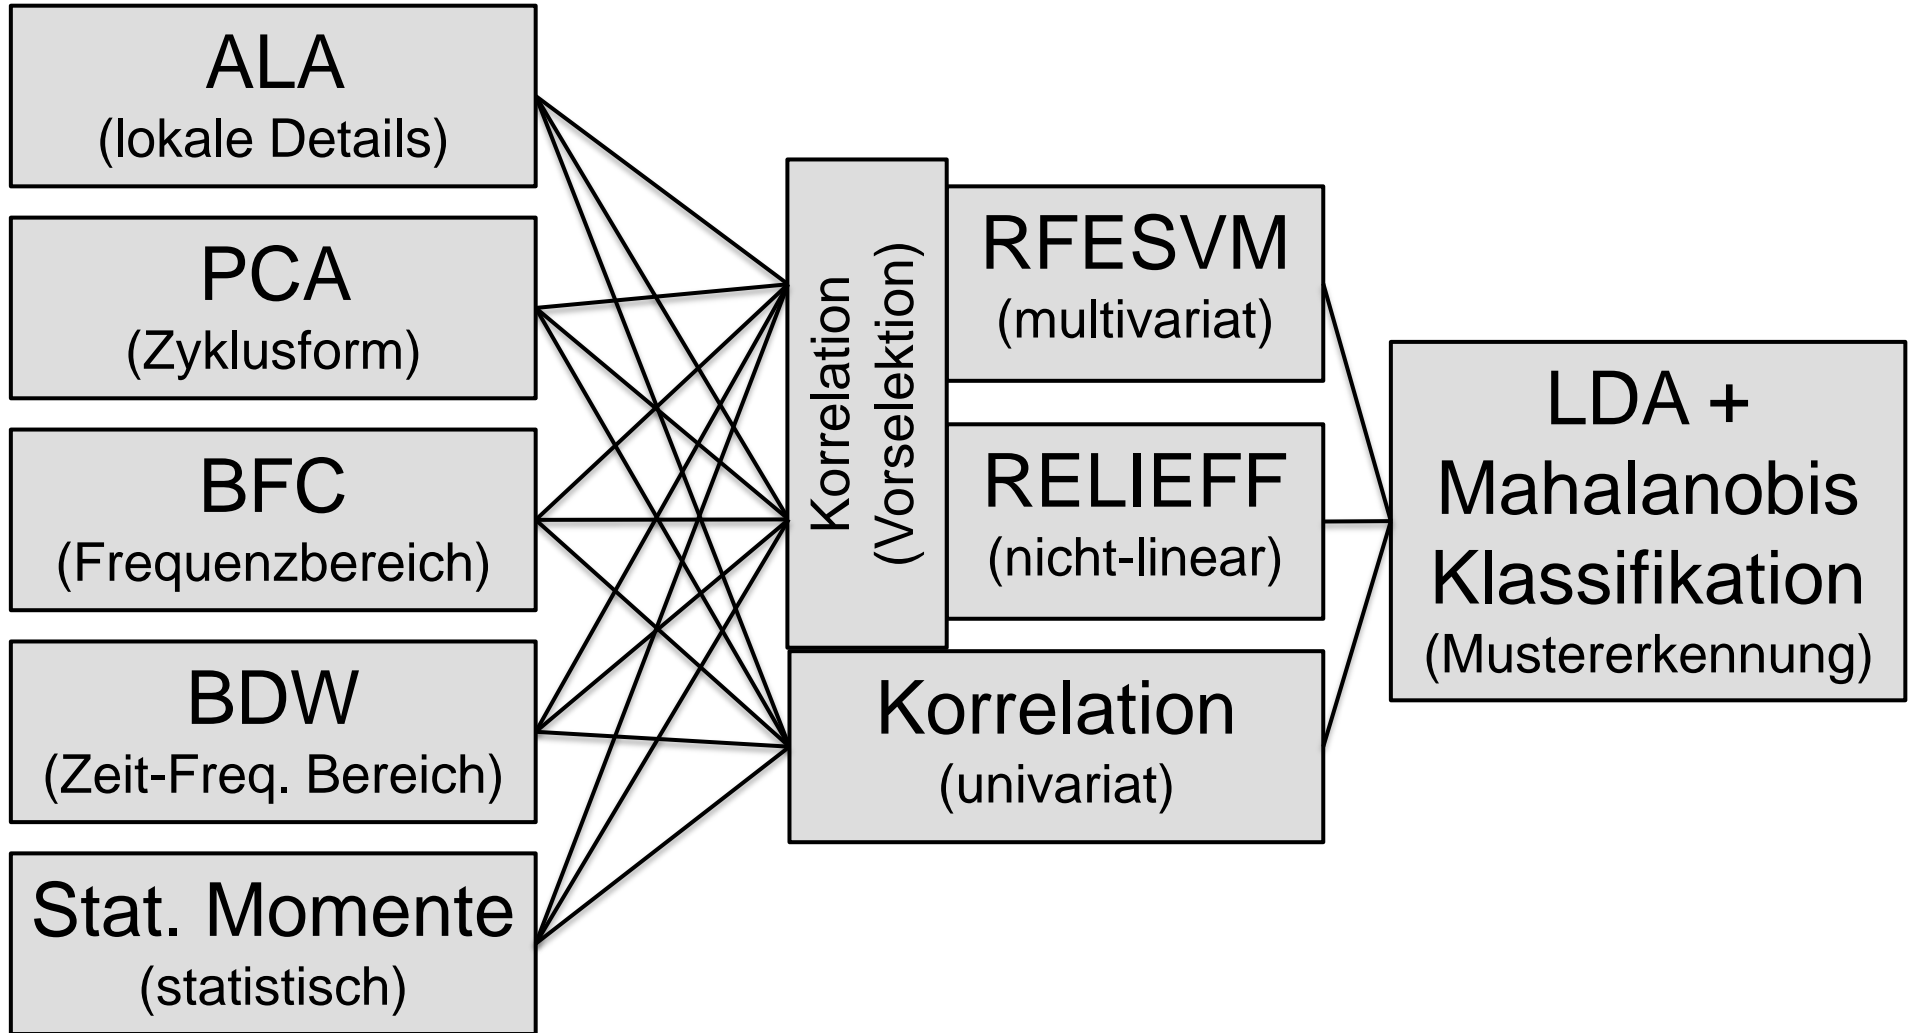
Filter Methods		Wrapper Methods		Embedded Methods
Univariate		Multivariate		
Parametric	Model-free			
<ul style="list-style-type: none"> • <u>t-test</u> • <u>Bayesian measure</u> • <u>Regression</u> • <u>Goodman and Kruskal's Gamma</u> • <u>Pearson correlation coefficient</u> • <u>Fisher criterion</u> • <u>Bhattacharya distance</u> 	<ul style="list-style-type: none"> • <u>Wilcoxon rank sum</u> • <u>BSS/WSS</u> • <u>Rank products</u> • <u>Threshold number of missclassification TNoM</u> • <u>Spearman's rank correlation coefficient</u> • <u>Kendall tau rank correlation coefficient</u> • <u>Signal to noise ratio</u> • <u>Kolmogorov-Smirnov test</u> • <u>Pearson's Chi-squared test</u> • <u>G-test</u> • <u>Kolmogorov distance</u> • <u>Kullbak-Leibler divergence / mutual information</u> • <u>Jeffreys-Matusita distance</u> • <u>Vajda entropy / Bayes measure</u> • <u>Memory based reasoning</u> • <u>Information and Entropy</u> • <u>J-measure</u> • <u>Average weight of evidence</u> • <u>Minimum description length MDL</u> 	<ul style="list-style-type: none"> • <u>Bivariate</u> • <u>Minimum redundancy, maximum relevance mRMR</u> • <u>USC</u> • <u>Markov blanket</u> • <u>Relief Algorithm</u> • <u>Partial Least Squares (PLS)</u> • <u>Group correlation Coefficient</u> • <u>1R decision tree</u> • <u>C4.5 tree</u> • <u>CHAIS decision tree</u> • <u>CART decision trees</u> 	<ul style="list-style-type: none"> • <u>Sequential forward selection</u> • <u>Sequential backward selection</u> • <u>Generalized sequential search</u> • <u>Plus I-take away r</u> • <u>Beam-Search</u> • <u>Floating Search</u> • <u>Oscillating search</u> • <u>Genetic algorithms</u> • <u>Rapid randomized pruning</u> • <u>Simulated annealing</u> • <u>Estimation of distribution algorithms</u> • <u>Exhaustive search</u> • <u>Branch and Bound</u> • <u>BABM</u> 	<ul style="list-style-type: none"> • <u>Random forest</u> • <u>Recursive feature elimination SVM (RFE-SVM)</u> • <u>Weights of logistic regression</u> • <u>Optimal Brain Damage (OBD)</u> • <u>Automatic Relevance Determination (ARD)</u> • <u>Sensitivity of output</u> • <u>Forward selection with least squares</u> • <u>Decision trees</u> • <u>Gram Schmidt orthogonalisation procedure</u> • <u>RFE perceptron</u> • <u>Bounds for Support Vector Machines</u> • <u>Gradient Descent on the R²w² Bound</u> • <u>Variable scaling with maximum entropy discrimination</u> • <u>Joint Classifier and Feature Optimization</u> • <u>Sparsity-term</u>

Automatische Merkmalsselektion - Ergebnisse

dataset	LDA, standard.	LDA	1NN, standard.	1NN	SVM linear	SVM RBF- Kernel
UST/20	RELIEFF filter 0.72/5.41	RELIEFF filter 0.72/5.24	RFESVM 0.12/0.55	Goodman Gamma 0.12/0.22	Bhattacharyya distance 0.55/0.72	Sensitivity to Output 0.12/0.28
UST/210	RFESVM 0.72/-	RFESVM 0.72/-	mRmR 0.06/1.66	GCC forward 0.12/28.6	RFESVM 0.28/1.90	RFESVM 0.12/3.11
WO3/20	Linear regression 0.70/4.65	Genetic Mutation 0.64/4.53	GCC forward 0.06/0.51	Bhattacharyya distance 0.13/0.25	GCC forward 0.32/0.83	Linear regression 0.06/0.45
WO3/210	GCC forward 0.51/-	GCC forward 0.45/-	Kolmogorov- Smirnov test 0.19/8.86	RELIEFF filter 0.13/34.0	RFESVM 0.25/1.28	RFESVM 0.06/1.66
WO3/840	mRmR 0.51/-	mRmR 0.57/-	RELIEFF filter 0.13/9.24	RFESVM 0.19/32.2	RFESVM 0.06/0.89	RFESVM 0.06/1.79
HYD/1079 pump	RFESVM 0/-	RFESVM 0/-	RFESVM 0/30.3	Kendall Tau 0.28/16.9	RFESVM 0/0.97	RFESVM 0/10.5

Ausgewählt: RFESVM (lineare Klassifikation) und RELIEFF (nicht-lineare Klass.)

Methoden zur automatisierten Datenauswertung



Fazit automatisierte Auswertung

- Die vorgeschlagenen Methoden wurden auf sehr unterschiedliche, reale Datensätze angewandt.
- Trotz des relativ simplen Lernalgorithmus wurden auf allen Datensätzen hervorragende Ergebnisse erzielt.
- Ansatz liefert zwar keine Garantie für optimale, aber eine hohe Wahrscheinlichkeit für sehr gute Ergebnisse