

Zustandsbewertung industrieller Prozesse mittels multivariater
Sensordatenanalyse am Beispiel hydraulischer und elektromechanischer
Antriebssysteme

Dissertation
zur Erlangung des Grades
des Doktors der Ingenieurwissenschaften
der Naturwissenschaftlich-Technischen Fakultät
der Universität des Saarlandes

von

Dipl.-Ing. Nikolai Johannes Helwig

Saarbrücken

2018

Tag des Kolloquiums: 18.12.2018
Dekan: Prof. Dr. rer. nat. Guido Kickelbick
Berichterstatter: Prof. Dr. rer. nat. Andreas Schütze
Prof. Dr.-Ing. Dirk Bähre
Vorsitz: Prof. Dr. techn. Romanus Dyczij-Edlinger
Akad. Mitarbeiter: Dr.-Ing. Paul Motzki

Zusammenfassung

In industriellen Maschinen und Anlagen werden zunehmend Sensoren zur Prozessregelung und -überwachung verwendet. Die Analyse komplexer Multisensordaten mit dem Ziel, relevante Information zu extrahieren, etwa zur Prozess- und Instandhaltungsoptimierung, ist von hoher wirtschaftlicher Bedeutung. Bei komplexen Systemen spielen hierbei datengetriebene Verfahren, insbesondere das maschinelle Lernen, eine zunehmende Rolle.

In dieser Arbeit wird ein teilautomatisierter Ansatz zur Merkmalsextraktion, -selektion und Klassifikation auf Basis heterogener Sensordaten vorgeschlagen und anhand zweier Anwendungen evaluiert.

Zum einen ist dies die Detektion und Quantifizierung von typischen Schäden eines hydraulischen Systems auf Basis von Prozesssensoren. Hierbei werden in einem Prüfstand künstliche Schadenszustände bei einem konstant und randomisiert ablaufenden Prozess emuliert. Zudem wird die Anfälligkeit der Analyse gegenüber Sensorstörungen untersucht und ein Vorgehen zur Detektion und Kompensation von letzteren vorgeschlagen und erprobt.

Die zweite Anwendung ist die Zustandsüberwachung elektromechanischer Zylinder mit dem Fokus auf der Komponente Kugelgewindetrieb. Mittels eines entwickelten Dauerlaufprüfstands erfolgt die zyklische Belastung und Charakterisierung der Zylinder vom Neuzustand bis zum Ausfall auf Basis verschiedener Messgrößen. Ziel ist es hierbei, mittels der multivariaten Sensordatenanalyse eine Verschleiß- und Lebensdauerabschätzung zu ermöglichen.

Abstract

Industrial machines and plants are increasingly equipped with sensors for process control and monitoring. The systematic analysis of complex multi sensor data aiming at extracting relevant information, e.g. to improve the process or maintenance strategy, is of great economic interest. Regarding complex industrial systems, data driven methods, especially machine learning, gain in importance.

In this work, a partially automated approach for feature extraction, selection and classification based on heterogeneous sensor data is proposed and evaluated in two scenarios.

The first application is the detection and quantification of typical faults in a hydraulic system based on process sensors. Here, artificial fault states are emulated in a test bench during cyclic and randomized processes. In addition, susceptibility of analysis in case of sensor disturbances and failures is studied proposing an approach for the detection and compensation of sensor faults.

The second application is the condition monitoring of electromechanical cylinders focusing on the ball screw drive. The lifetime characterization of cylinders from new state to failure is performed by a specifically developed endurance test system monitoring several measurands. Based on these sensor data and the multivariate approach, a statistical model for wear and residual lifetime estimation is derived.

Inhaltsverzeichnis

1	EINLEITUNG	1
2	GRUNDLAGEN	7
2.1	ZUSTANDSÜBERWACHUNG.....	7
2.2	MESSUNSICHERHEIT.....	8
2.3	SIGNALVERARBEITUNG UND MULTIVARIATE DATENANALYSE.....	9
2.3.1	<i>Signalvorverarbeitung</i>	10
2.3.2	<i>Merkmalsextraktion</i>	11
2.3.3	<i>Merkmalsselektion</i>	15
2.3.4	<i>Dimensionsreduktion</i>	19
2.3.5	<i>Abstands- und Wahrscheinlichkeitsmaße</i>	23
2.3.6	<i>Künstliche neuronale Netze</i>	25
2.3.7	<i>Support Vector Machines</i>	27
2.3.8	<i>Validierung</i>	29
3	METHODIK ZUR TEILAUTOMATISIERTEN MULTIVARIATEN SENSORDATENANALYSE	35
3.1	DATENGENERIERUNG.....	35
3.2	DATENANALYSE.....	37
3.3	REALISIERUNG	39
4	ANWENDUNGSSZENARIO HYDRAULISCHES SYSTEM	41
4.1	EINFÜHRUNG.....	41
4.2	PROBLEMSTELLUNG.....	41
4.3	STAND DER TECHNIK UND FORSCHUNG	42
4.4	KOMPONENTEN DES HYDRAULISCHES SYSTEMS UND DEREN SCHADENSMECHANISMEN	44
4.4.1	<i>Pumpe</i>	44
4.4.2	<i>Wegeventil</i>	47
4.4.3	<i>Hydrospeicher</i>	49
4.4.4	<i>Öl-Luft-Kühler</i>	52
4.4.5	<i>Hydrauliköl</i>	54
4.5	EXPERIMENTELLER AUFBAU	59

4.5.1	<i>Hydraulikaggregat</i>	59
4.5.2	<i>Schadenzustände</i>	61
4.5.3	<i>Variation der Ölparameter</i>	64
4.5.4	<i>Steuerung, Datenerfassung und Arbeitszyklus</i>	65
4.6	DETEKTION VON MASCHINENFEHLERN UND -VERSCHLEIß	72
4.6.1	<i>Erkennung und Quantifizierung isolierter Schadenstypen</i>	72
4.6.2	<i>Unterscheidung gleichzeitig auftretender Schäden</i>	75
4.6.3	<i>Auswertung über mehrere Zyklen</i>	80
4.6.4	<i>Langzeitstabilität und Übertragbarkeit</i>	82
4.6.5	<i>Einfluss der Abtastrate</i>	83
4.6.6	<i>Diskussion</i>	85
4.7	EINFLUSS VON ÖLPARAMETERN.....	86
4.7.1	<i>Öltemperatur und freie Luft</i>	86
4.7.2	<i>Partikelkontamination und Filterbeladung</i>	93
4.7.3	<i>Diskussion</i>	96
4.8	SCHWINGUNGSÜBERWACHUNG.....	96
4.8.1	<i>Auswertung auf Basis von Schwingungsmerkmalen</i>	96
4.8.2	<i>Pumpenkavitation</i>	99
4.8.3	<i>Diskussion</i>	100
4.9	UNTERSUCHUNG DER MODELLBILDUNG	101
4.9.1	<i>Signalvorverarbeitung</i>	101
4.9.2	<i>Beschaffenheit der Merkmale</i>	102
4.9.3	<i>Validierung der Merkmalsselektion</i>	103
4.9.4	<i>Berechnungsaufwand</i>	104
4.9.5	<i>Diskussion</i>	105
4.10	DETEKTION UND KOMPENSATION VON SENSORFEHLERN.....	105
4.10.1	<i>Einfluss auf die Klassifikationsrate</i>	107
4.10.2	<i>Detektion von Sensorfehlern</i>	107
4.10.3	<i>Kompensation ausgefallener Sensoren</i>	109
4.10.4	<i>Diskussion</i>	110
4.11	ZUSAMMENFASSUNG DES ANWENDUNGSSZENARIOS	111
5	ANWENDUNGSSZENARIO ELEKTROMECHANISCHER ZYLINDER	113
5.1	EINFÜHRUNG.....	113
5.2	PROBLEMSTELLUNG.....	113
5.3	STAND DER TECHNIK UND FORSCHUNG	115
5.4	KUGELGEWINDETRIEB	117
5.4.1	<i>Allgemeiner Aufbau</i>	117
5.4.2	<i>Vorspannung</i>	118

5.4.3	<i>Umlenkensystem</i>	118
5.4.4	<i>Relevante geometrische Größen</i>	119
5.4.5	<i>Kinematik und charakteristische mechanische Frequenzen</i>	121
5.5	TRIBOLOGIE UND VERSCHLEIßEFFEKTE	126
5.5.1	<i>Schädigungsformen</i>	126
5.5.2	<i>Mechanische Verschleißursachen</i>	127
5.5.3	<i>Ausfallkriterien</i>	129
5.5.4	<i>Prognosemodelle</i>	130
5.6	EXPERIMENTELLER AUFBAU	130
5.6.1	<i>Mechanik</i>	130
5.6.2	<i>Steuerung und Datenerfassung</i>	132
5.7	ERGEBNISSE	135
5.7.1	<i>Durchgeführte Lebensdauermessungen</i>	135
5.7.2	<i>Durchgeführte multivariate Auswertung</i>	137
5.7.3	<i>Lebensdauerersuch I</i>	138
5.7.4	<i>Lebensdauerersuch II</i>	142
5.7.5	<i>Lebensdauerersuch III</i>	145
5.7.6	<i>Übertragbarkeit der Prognose</i>	148
5.7.7	<i>Auswertung ohne zusätzliche Sensorik</i>	150
5.7.8	<i>Auftretende Verschleißeffekte</i>	152
5.7.9	<i>Diskussion</i>	154
5.8	ZUSAMMENFASSUNG DER ANWENDUNG	157
6	ZUSAMMENFASSUNG UND AUSBLICK	159
	LITERATURVERZEICHNIS	163
I	ANHANG	CLXXXI
I.1	DANKSAGUNG	CLXXXI
I.2	ABKÜRZUNGEN	CLXXXII
I.3	ABBILDUNGSVERZEICHNIS	CLXXXV
I.4	TABELLENVERZEICHNIS	CXCIII
I.5	EIGENE VERÖFFENTLICHUNGEN UND VORTRÄGE	CXCV

1 Einleitung

Die deutsche Industrie ist stark von der Produktion geprägt und aufgrund der globalen Wettbewerbssituation hochgradig automatisiert und rationalisiert. Mit der zunehmenden Digitalisierung von Produktionsprozessen bieten sich vielfältige Chancen, die Effizienz und Produktivität weiter zu steigern.

Ein wichtiger Baustein ist die Instandhaltung und Wartung von Maschinen und Anlagen [1]. Hierbei sind drei Konzepte anzutreffen (Tabelle 1-1), von denen die zustandsbasierte Wartung zunehmend an Bedeutung gewinnt. Die Erwartungen der Unternehmen bei der Umsetzung sind hierbei eine erhöhte Anlagenverfügbarkeit, eine erhöhte Produkt-/Prozessqualität, eine verbesserte Planbarkeit der Service-Zyklen sowie eine höhere Lebensdauer der Anlage [2].

Tabelle 1-1. Wartungsstrategien und deren Vor- und Nachteile.

	Reaktive Wartung	Vorbeugende Wartung	Zustandsbasierte Wartung
Beschreibung	Betrieb einer Maschine bis zum Ausfall, anschließende Wiederinstandsetzung	Wartung nach festen Zeitintervallen (z.B. Ölwechsel)	Planen des Wartungsbedarfs anhand des tatsächlichen Maschinenzustands
Vorteile	(+) Keine laufenden Wartungskosten	(+) Gute Planbarkeit	(+) Gute Planbarkeit, wirtschaftlich
Nachteile	(-) Nicht wirtschaftlich, da hohe Folgekosten nach Ausfall, geringe Planbarkeit, hohe Maschinenstillstandszeiten	(-) Wenig effizient, da hohe Wartungskosten, Austausch von noch funktionsfähigen Komponenten	(-) Mit erhöhtem Aufwand (zusätzliche Sensorik und Auswertung) verbunden, zusätzliche Investitionen nötig

Die direkten Instandhaltungskosten, deren Einsparpotentiale im industriellen Sektor zu 14 Mrd. Euro in Deutschland geschätzt werden [3], sind verhältnismäßig gering im Vergleich zu den Folgekosten, die ungeplante Maschinenausfälle in der Produktion verursachen [4]. Insbesondere die Betreiber von Groß- und Fertigungsanlagen schätzen die Folgen von Störungen als ökonomisch gravierend ein [4] (Abbildung 1-1).

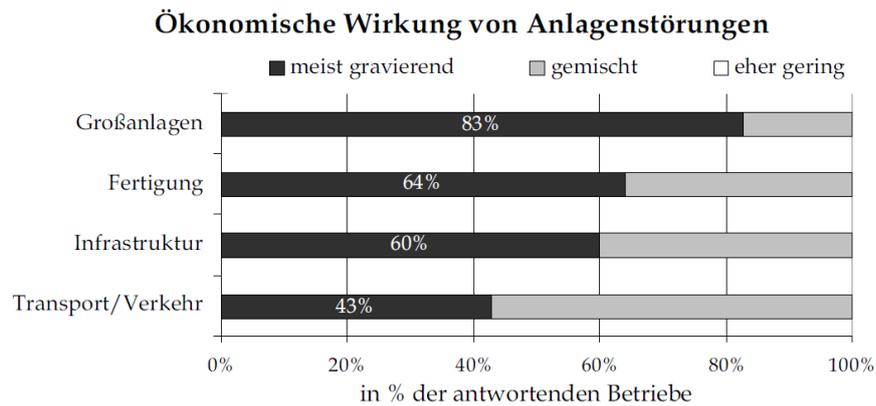


Abbildung 1-1. Ökonomische Auswirkungen von Anlagenstörungen aufgeschlüsselt nach Branchen [4].

Dennoch sollten nicht nur wirtschaftliche Aspekte betrachtet werden, auch der Schutz von Mensch und Umwelt durch die Vermeidung schwerwiegender Unfälle, die sich seit der Industrialisierung im 19. Jahrhundert wiederholt ereignet haben, sei als Argument an dieser Stelle genannt.

Die zustandsbasierte (Condition based Maintenance) und vorausschauende Wartung (Predictive Maintenance) setzen die Kenntnis über den aktuellen Maschinenzustand und somit eine geeignete Zustandsüberwachung (Condition Monitoring, CM) voraus. Die gängigen Methoden zur Zustandsüberwachung sind Schwingungsanalyse, visuelle Inspektion und zerstörungsfreie Prüfung, Performanzüberwachung auf Basis von Prozesssensoren sowie der Einsatz spezialisierter Sensorik, etwa im Bereich Schmierstoffüberwachung [5]. Die Zustandsüberwachung kann zum einen online mittels fest installierter Sensorik und kontinuierlicher Erfassung und Bewertung der Sensordaten erfolgen, zum anderen stichprobenartig mittels Offline-Analyse auf Basis konstanter oder wechselnder Zeitintervalle [6].

Die Effizienz und Qualität der Zustandsüberwachung ist maßgeblich von der Auswahl geeigneter Sensoren, Messstellen und Abtastraten abhängig. Hier existieren standardisierte Methoden, etwa die Fehlermöglichkeits-, Einfluss- und Gefährdungsanalyse (FMEA, FMECA), mit der anwendungsspezifisch aus den zu erwartenden Schäden und Symptomen die geeigneten Messgrößen abgeleitet werden können (DIN ISO 17359) [7]. Tabelle 1-2 zeigt exemplarisch eine Auflistung von Sensoren für typische Maschinen und Anlagen.

Tabelle 1-2. Exemplarische Auswahl von Messgrößen zur Zustandsüberwachung nach [5], [7].

Messgröße Anwendung	Schwingung	Luftschall	Ölqualität	Ölpartikel	Druck	Vol.-strom	Temp. / IR	VIS	Wirkungsgrad	Stromanalyse
Wälzlager	x	x					x	x		
Getriebe	x	x	x	x	x		x	x	x	
Elektromotoren	x	x					x		x	x
Verbrennungsmotor	x	x	x	x	x	x	x		x	
Turbinen	x	x	x		x	x	x	x	x	
Pumpen	x	x	x	x	x	x	x	x	x	
Kompressor	x	x	x	x	x	x	x		x	
Druckbehälter					x	x	x		x	
Ventile			x		x	x			x	
Werkzeugmaschine	x	x	x		x		x	x	x	x
Baumaschinen	x	x	x	x	x		x	x	x	

Einen besonderen Stellenwert hat die Schwingungsanalyse aufgrund ihrer universellen Anwendbarkeit und leichten Nachrüstbarkeit. Aus diesem Grund existieren vielfältige Normen zur Anwendung allgemein (DIN ISO 13373) und im Speziellen für die Bereiche rotierende Wellen (DIN ISO 10817), rotierende Maschinen (DIN ISO 22266) sowie nichtrotierende Maschinenteile (DIN ISO 10816) [8]. Unterschieden werden Kriterien auf Basis des Schwingungssignals im Zeitbereich (Effektivwert, Kurtosis, Crest-Faktor [9]) mit eingeschränkter Diagnosemöglichkeit sowie eine spektrale Auswertung, die eine selektive Identifikation von Frequenzanteilen und somit eine weiterführende Diagnose erlaubt. Letztere ist weit verbreitet etwa für die Wälzlagerdiagnose, bei der charakteristische mechanische Überrollfrequenzen ein Indikator für lokale Schädigungen sein können (vgl. Kap. 5.4.5).

Dennoch können diese Richtlinien nur einen groben Anhaltspunkt liefern, da etwa die Grenzwerte von Maschinen über große Leistungsbereiche zusammengefasst und die verfügbaren Sensordaten nur ineffizient genutzt werden. Aus diesem Grund kann eine Verbesserung des Condition Monitoring Systems (CMS) nicht alleine durch die Entwicklung und Integration von Sensorik erfolgen, sondern benötigt primär geeignete Methoden und Algorithmen zur Bewertung von Schädigungs- und Degradationsmechanismen auf Basis bestehender Sensordaten [10].

Vielversprechend sind hierbei multivariate Verfahren, die auf Basis einer Kombination von relevanten Kennwerten eine Ähnlichkeit zu zuvor aufgezeichneten Maschinenzuständen und Schadensfällen bestimmen (vgl. Kap. 2.3). Der Verband für Sensorik und Messtechnik e.V. (AMA) nennt in dem Kontext als wesentliche Entwicklungstrends die physikalische und chemische Situationserkennung auf Basis von Sensorfusion und Mustererkennung [11]. Daneben spielt in komplexen

Multisensorsystemen die Sensordatenvalidität eine zunehmende Rolle, was die Integration von Strategien zur Sensor-Selbstüberwachung und Selbst-Rekonfiguration erfordert [11].

Die systematische Analyse von Sensordaten bietet somit erhebliches Potential zur ganzheitlichen Bewertung des Maschinenzustands in Bezug auf

- das Verhalten in unterschiedlichen Betriebs- und Operationszuständen,
- die Extraktion relevanter Kennwerte/Merkmale im Zeit- oder Frequenzbereich und
- die Verknüpfung der Information von unterschiedlichen Messgrößen.

In komplexen Systemen ist eine solche Analyse nur mit hohem Aufwand manuell durchführbar. Hier kann eine teil- oder vollautomatisierte Bewertung mit statistischen Verfahren die Generierung statistischer Modelle zur Zustandsüberwachung vereinfachen. Im Gegensatz zu physikalischen Modellen setzen diese zwar nicht unmittelbar Expertenwissen über Prozess und Anlage voraus, letzteres ist aber spätestens bei der Evaluierung des Systems von Bedeutung, etwa anhand der Information, welcher Betriebszustand, welcher Sensor oder welcher Frequenzbereich für die Detektion von Verschleiß- oder Schadensgrößen als statistisch signifikant bewertet wird, und ob dies in kausalem Zusammenhang zur Zielgröße stehen kann. Insofern ist der Ansatz hochgradig interdisziplinär und beinhaltet im Sinne des Systems Engineering Teilaspekte des Maschinenbaus, der Sensorik und Datenerfassung, Informationstechnologie und des maschinellen Lernens.

Die Zielsetzung dieser Arbeit ist es, das Potential einer teilweise automatisierten statistischen Modellbildung zur Zustandsüberwachung am Beispiel verschiedener Anwendungen zu erproben. Die Methodik zur multivariaten Analyse und schrittweisen Dimensions- und Datenreduktion wird in Kapitel 3 vorgestellt. Die Anforderungen können in Anlehnung an die Gassensorik [12], [13], [14] im Wesentlichen mit Sensitivität, Selektivität und Stabilität zusammengefasst werden. Im vorliegenden Fall sind dies eine möglichst frühzeitige Erkennung und Quantifizierung der Degradationszielgröße (Sensitivität), eine möglichst eindeutige und von Störgrößen unabhängige Aussage (Selektivität) sowie die Zuverlässigkeit über längere Zeiträume (Stabilität). Daneben ist die Nachvollziehbarkeit der Entscheidungsfindung ein wichtiges Kriterium für die Akzeptanz in der industriellen Anwendung, gerade bei komplexen Systemen mit vielen heterogenen Messgrößen.

Betrachtet werden im Rahmen dieser Arbeit beispielhaft zwei unterschiedliche Anwendungen aus den Bereichen Fluidtechnik und Antriebstechnik.

Erste Untersuchungen zur datengetriebenen Zustandsüberwachung von hydraulischen Systemen erfolgten am Zentrum für Mechatronik und Automatisierungstechnik (ZeMA) im Rahmen des Projektes „ICM-Wind“ [15]. Auf Basis einer multivariaten Sensordatenauswertung konnte der Filterbeladungszustand des Hydrauliksystems von mehreren Windenergieanlagen des Windparks Marpingen im Saarland überwacht werden. Dabei zeigte sich, dass die stark wechselnden Betriebs- und Umweltbedingungen sowie die undefinierten Anlagenzustände die statistische Auswertung deutlich erschwerten. Aus diesem Grund wurde das Nachfolgeprojekt „ICM-Hydraulik“ (2013-2015) initiiert, bei dem definiert eingebrachte Schäden in einem generischen hydraulischen Aggregat unter Laborbedingungen untersucht werden. Die in Kapitel 4 vorgestellten Ergebnisse wurden im Wesentlichen im Rahmen dieses Projektes erarbeitet, welches mit der Fa. Hydac Filter Systems (Sulzbach, Saar) und dem Deutschen Forschungszentrum für Künstliche Intelligenz (DFKI, Saarbrücken) durchgeführt wurde.

Die zweite Anwendung (Kapitel 5) betrifft die Antriebstechnik mit dem Fokus elektromechanische Zylinder, welche aktorseitig die Basis für verschiedenste Anwendungen im Bereich der Montage und Produktion bilden. Typische Einsatzgebiete sind Positionierungs- und Handhabungssysteme sowie Werkzeugmaschinen. Ziel dieser Anwendung ist die Zustandsüberwachung im Sinne einer Identifikation des Verschleißgrads. Die Untersuchungen wurden im Rahmen des Forschungsprojektes „MoSeS-Pro: Modulare Sensorsysteme für die Echtzeit-Prozesssteuerung und smarte Zustandsbewertung“ [16] am ZeMA u.a. in Kooperation mit den Unternehmen Festo (Werk St. Ingbert) und Sensitec GmbH (Lahnau) im Zeitraum von 2015 bis 2017 durchgeführt.

Stellt man beide Anwendungen gegenüber, so ergeben sich verschiedene Schwerpunkte (Tabelle 1-3). Während im hydraulischen Anwendungsfall (1) diskrete, bekannte Schäden emuliert werden, erfolgt in der antriebstechnischen Anwendung (2) eine unüberwachte kontinuierliche Degradation der Zylinder bei hoher Belastung im Rahmen von Dauerlauf-Tests. Zudem basiert die Analyse im ersten Fall (1) primär auf Prozesssensoren, die typischerweise in hydraulischen Systemen verwendet werden, während in (2) der Fokus der Instrumentierung auf zusätzlicher Sensorik zur Zustandsüberwachung, etwa Körper- und Luftschall sowie Motorströmen, liegt. Nicht zuletzt unterscheiden sich die Anwendungen signifikant durch die anfallenden Datenraten und -mengen.

Tabelle 1-3. Gegenüberstellung der Anwendungsszenarien.

	Hydraulikaggregat (1)	Elektromechanischer Zylinder (2)
Schadensart	Diskret simulierte, bekannte Schäden mit variablem Schweregrad	Kontinuierlicher ablaufender, unüberwachter Verschleißprozess
Sensorik	Primär Prozesssensoren (z.B. Druck, Temperatur) mit Auswertung im Zeitbereich, sekundär Vibration	Primär CM-spezifische Sensorik (Vibration, Akustik, Motorstrom) mit spektraler Merkmalsextraktion
Datenmenge	Dauer einer Charakterisierungsmessung 1-2 Tage, Sampling Rate bis 100 Hz, Datenmenge < 1 GB	Dauerlaufstest bis zu 80 Tage, Sampling Rate bis 1 MHz, Datenmenge bis zu 40 Terabyte

Die Aufgabenstellung in dieser Arbeit umfasst hierbei bei beiden Anwendungen die Entwicklung und Instrumentierung von Versuchsständen zum Generieren von geeigneten Sensordaten, anhand derer verschiedene teilautomatisierte multivariate Verfahren zur Sensordatenanalyse mit dem Ziel der Zustandsklassifikation erprobt und gegenüber gestellt werden sollen.

Das übergeordnete Ziel ist es, Erkenntnisse und Konzepte aus den exemplarischen Anwendungen, abzuleiten, die für andere industrielle Anwendungen genutzt werden können. Gleichzeitig sollen aber auch die Grenzen statistischer Verfahren aufgezeigt werden, um die Praktikabilität im industriellen Umfeld bewerten zu können.

Mithilfe der effizienten Ausnutzung der verfügbaren Daten im Produktionsprozess könnte die zustandsbasierte Instandhaltung optimiert und somit die Anlagenverfügbarkeit durch die Reduktion von ungeplanten Maschinenstillstandszeiten verbessert und die Effizienz und Wirtschaftlichkeit der Produktion weiter gesteigert werden - bei gleichzeitig verbesserter Anlagensicherheit zum Schutz von Mensch und Natur.

2 Grundlagen

Dieses Kapitel dient der Einführung von Begrifflichkeiten aus dem Bereich Zustandsüberwachung und Messunsicherheit sowie einigen verbreiteten Methoden des maschinellen Lernens, auf welche in den nachfolgenden Kapiteln zurückgegriffen wird. Die Erläuterung der technologischen Grundlagen der beiden Anwendungsszenarien erfolgt nachgelagert in den Kapiteln 4 und 5.

2.1 Zustandsüberwachung

In ISO 13372 [6] wird allgemein die Terminologie im Kontext der Zustandsüberwachung und -diagnose definiert. Demnach bezeichnet die *Zustandsüberwachung* das Aufnehmen und Detektieren von Informationen und Daten, welche den Zustand einer Maschine abbilden.

Unter einer *Maschine* wird allgemein ein mechanisches System verstanden, welches dazu entworfen wurde, eine spezifische Aufgabe, etwa die Umformung von Material oder die Transformation von Bewegung, Kraft, oder Energie, zu erfüllen.

Der Zustand einer Komponente bei abnormalem Verhalten oder im Falle der Degradation einer ihrer Teilkomponenten oder Untergruppen, welcher zu einem Ausfall der Maschine führen kann, wird als *Fehler* bezeichnet. Ein *Ausfall* hingegen bezeichnet ein Ereignis, bei dem ein System nicht mehr in der Lage ist, die geforderte Funktion zu erfüllen. Beobachtungen oder Merkmale, die die Wahrnehmung der Anwesenheit von einem oder mehreren Fehler erlauben, werden als *Symptome* bezeichnet. Eine Untersuchung der Symptome, zur Feststellung der Natur des Fehlers oder Ausfalls, etwa Typ, Ausmaß und Situation, wird laut ISO 13372 als *Diagnose* definiert.

Im Folgenden werden die genannten Begrifflichkeiten auf Basis dieser Definitionen verwendet.

2.2 Messunsicherheit

Jedes Sensor- und Messsystem unterliegt unerwünschten Abweichungen, sodass der wahre Wert der Messgröße, welcher sich bei einer idealen Messung ergeben würde, nicht mit dem realen Messergebnis übereinstimmt [17]. Gründe hierfür sind zum einen reversible Einflussgrößen, beispielsweise Umgebungstemperatur, Betriebsspannung, äußere elektrische und magnetische Felder sowie Vibrationen, zum anderen irreversible Einflussgrößen wie Alterung, elektrische Überlastung oder Überhitzung von Sensorelement und -elektronik. Die Messabweichungen lassen sich wiederum in grobe, systematische und zufällige Messabweichungen kategorisieren. Können grobe Messabweichungen, also falsche Handhabung oder offensichtliche Mängel des Messgeräts, ausgeschlossen werden, bleiben systematische Abweichungen bei wiederholten Messungen konstant oder ändern sich in vorhersagbarer Weise¹; die zufällige Messabweichung hingegen variiert bei wiederholten Messungen nicht vorhersagbar [18]. Eine Messung kann als „richtig“ angesehen werden, wenn die systematische Messabweichung (z.B. Offset, Nichtlinearität [19]) unter „Nenngebrauchsbedingungen“ des Messgeräts vernachlässigbar klein ist, was typischerweise mit einer Kalibrierung sichergestellt wird. Ist dies der Fall, kann die Messunsicherheit $\Delta\bar{y}$ bei einer indirekten Messung, also auf Basis einer aus mehreren, statistisch unabhängigen Messgrößen x_i zusammengesetzten Ergebnisgröße $y = f(x_1, \dots, x_N)$ nach der Gauß'schen Fehlerfortpflanzung berechnet werden zu

$$\Delta\bar{y} = \sqrt{\sum_{j=1}^N \left(\frac{\partial f(x_1, \dots, x_N)}{\partial x_j} \cdot \Delta x_j \right)^2} \quad (2.1)$$

mit $\Delta x_j =$ Messunsicherheiten der einzelnen Messgrößen

Letztere setzt ein hinreichend lineares Verhalten sowie Varianzhomogenität der Messgrößen im betrachteten Wertebereich voraus. Zufällige Messabweichungen liegen meist in Form einer Gauß'schen Normalverteilung vor:

$$p(x) = \frac{\exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)}{\sigma\sqrt{2\pi}} \quad (2.2)$$

mit $\mu = \frac{1}{n} \sum_{i=1}^n x_i$ dem arithmetischen Mittel der Stichprobe (2.3)

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2} \text{ der Standardabweichung der Stichprobe} \quad (2.4)$$

¹ hierzu zählen auch systematische Abweichungen, deren physikalisches Modell nicht bekannt ist, etwa Sensordrift

wobei 68,3 % der Messwerte im Konfidenzintervall $\mu \pm \sigma$ und 95 % der Werte im Konfidenzintervall $\mu \pm 1,96 \cdot \sigma$ liegen (unter der Voraussetzung einer ausreichend großen Stichprobe, $n > 100$).

Ein verallgemeinertes Vorgehen wird im Guide for the Expression of Uncertainty in Measurement (GUM) beschrieben, welcher die Bildung eines Modells vorsieht, das den Einfluss der relevanten Eingangsgrößen des Messsystems auf die Ausgangsgröße beschreibt [20]. Hierbei muss nicht notwendigerweise eine Normalverteilung der Stichprobe vorliegen, auch Rechteck-, Trapez- oder U-Verteilungen können in eine vergleichbare Standardmessunsicherheit überführt werden. Für weitere Details sei hierbei auf [20] verwiesen.

Das Ausmaß der Messunsicherheit in Relation zum Nutzsignal wird häufig auch über das Signal-Rausch-Verhältnis (oder engl. signal-to-noise ratio, SNR) beschrieben. Meist wird dieses als logarithmisches Leistungsmaß in dB angegeben:

$$SNR_{dB} = 10 \cdot \log \left(\frac{P_{Sig}}{P_{noise}} \right) \quad (2.5)$$

Rauscheffekte in einer Messkette können an unterschiedlichen Stellen entstehen, meist bestimmt jedoch das Rauschen des Sensorelements, das typischerweise durch die Sensorelektronik weiter verstärkt wird, das SNR des Gesamtsystems; daneben spielen Effekte wie Quantisierungsrauschen des Analog-Digital-Konverters (ADC) oder elektromagnetische Einstreuungen eine Rolle [21]. Bei der Rauschcharakteristik wird weißes (konstantes Leistungsdichtespektrum, z.B. bei thermischem oder Schottky-Rauschen), $1/f$ und $1/f^2$ Rauschen (mit einem Abfall der Rauschleistungsdichte um 10 bzw. 20 dB/Dekade [22]) unterschieden.

2.3 Signalverarbeitung und multivariate Datenanalyse

Abbildung 2-1 stellt eine Übersicht verbreiteter multivariater Verfahren zur Mustererkennung, Quantifizierung sowie zum Clustering dar. Im Folgenden soll insbesondere die Mustererkennung, welche Teil des überwachten Lernens ist, betrachtet werden. Typischerweise ist diese als mehrstufiger Prozess realisiert, bei dem Information, beginnend von den Sensorrohdaten, sukzessive verdichtet und gefiltert wird, um Zusammenhänge in den Daten zu erkennen und verborgene Zielgrößen zu identifizieren. Die einzelnen Schritte der Mustererkennung, also Signalvorverarbeitung, Merkmalsextraktion, -selektion, Klassifikation und Validierung werden nachfolgend erläutert.

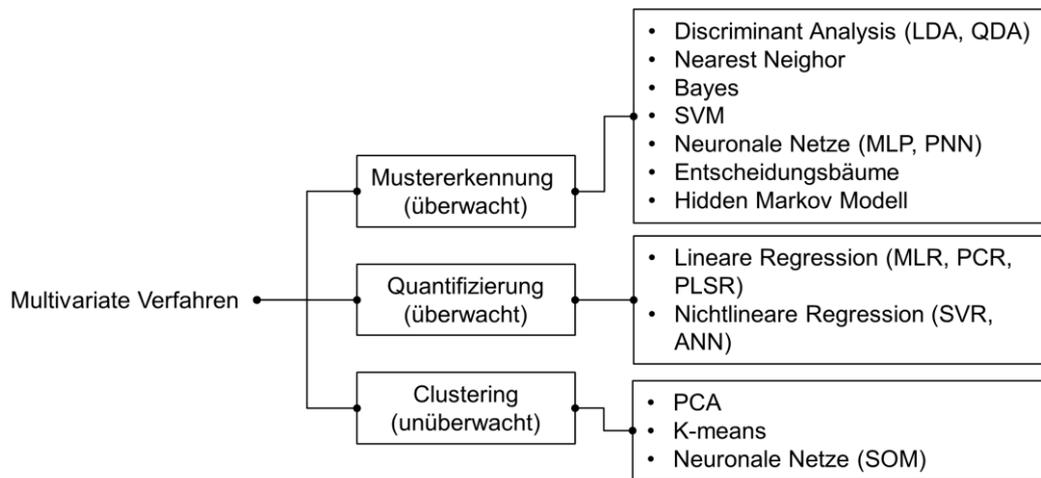


Abbildung 2-1. Multivariate Methoden, zusammengefasst aus [23], [24], [25].

Die Voraussetzung für eine effektive multivariate Datenanalyse ist das Vorliegen von zyklisch strukturierten Daten eines Sensors oder Sensorarrays, etwa in Form einer Matrix von Messwerten $x_{i,j}$

$$\mathbf{X} = (x_{i,j}) = \begin{pmatrix} x_{1,1} & \dots & x_{1,N} \\ \vdots & \ddots & \vdots \\ x_{M,1} & \dots & x_{M,N} \end{pmatrix} \quad (2.6)$$

Der Index i bestimmt hierbei die Zyklusnummer von insgesamt M identisch strukturierten Zyklen, während der Index j den Zeitpunkt innerhalb eines Zyklus jeweils bestehend aus N Datenpunkten beschreibt, sodass eine Prozess-synchronisierte Datenerfassung notwendig ist.

Des Weiteren wird für überwachte Lernverfahren ein Zielgrößenvektor \mathbf{y} definiert, der die bekannte Gruppenzugehörigkeit, beispielsweise den Maschinenzustand, für jeden Zyklus i abbildet:

$$\mathbf{y} = (y_i) = \begin{pmatrix} y_1 \\ \vdots \\ y_M \end{pmatrix} \quad (2.7)$$

Manche der nachfolgend eingeführten Methoden setzen bei y_i numerische Daten (Pearson-/Spearman-Korrelation) oder kategorische Daten (Varianzanalyse, LDA) voraus, wobei numerische Daten auch gruppiert und somit kategorisch gedeutet werden können.

2.3.1 Signalvorverarbeitung

Der Merkmalsextraktion vorangestellt ist vielfach eine Signalvorverarbeitung, mit der die Sensorsignale konditioniert (z.B. geglättet oder standardisiert) werden. Ziel ist es, die Signalqualität zu verbessern und intrinsische Störeffekte und Defizite von Sensoren, etwa im Bereich Stabilität, zu reduzieren [12], [26]. Daneben kann die

Vorverarbeitung bei heterogenen Sensornetzen genutzt werden, um unterschiedliche Skalen und Amplituden anzugleichen, sodass der nachfolgende Klassifikator, sofern dieser nicht implizit eine Standardisierung durchführt (z.B. k-NN, vgl. Kap. 2.3.5.1), nicht durch Skaleneffekte verfälscht wird. In der Literatur finden sich hierbei verschiedene Verfahren [27], [28], von denen exemplarisch drei gängige Standardisierungsverfahren herausgegriffen werden.

Die z-Score $\tilde{x}_{z|i,j}$, auch als z-Transformation bezeichnet, zentriert die Stichprobe um den Wert 0 skaliert mit einer Standardabweichung von 1.

$$\tilde{x}_{z|i,j} = \frac{x_{i,j} - \bar{x}_i}{\sigma_i} \quad (2.8)$$

Hierbei beschreibt $x_{i,j}$ den j-ten Datenpunkt und \bar{x}_i des Mittelwert des Zyklus i.

Häufig verwendet wird zudem die Minimum-Maximum-Skalierung $\tilde{x}_{minmax|i,j}$, die den Wertebereich des Zyklus zwischen 0 und 1 abbildet. Dieses Verfahren ist deutlich empfindlicher gegenüber Signalausreißern.

$$\tilde{x}_{minmax|i,j} = \frac{x_{i,j} - x_{min|i}}{x_{max|i} - x_{min|i}} \quad (2.9)$$

Speziell im Bereich der Gassensorik wird die Mittelwert-Skalierung verwendet, wie in [14], [26], [29] beschrieben, um überlagerte Drifteffekte zu kompensieren.

$$\tilde{x}_{mittel|i,j} = \frac{x_{i,j}}{\bar{x}_i} \quad (2.10)$$

Daneben werden Glättungsverfahren (z.B. Moving-Average- oder Savitzky-Golay-Filter) verwendet, primär um das SNR bei rauschbehafteten Signalen zu verbessern.

Die Signalvorverarbeitung ist prinzipiell ein optionaler Schritt, kann jedoch ein vielversprechender Ansatzpunkt sein, wenn die nachfolgenden Schritte der Dimensionsreduktion keine hinreichende Klassifizierungsgenauigkeit erzielen [30].

2.3.2 Merkmalsextraktion

Ziel der Merkmalsextraktion ist es, die relevante Information der hoch abgetasteten Sensorsignale in möglichst wenigen Merkmalen zusammenzufassen und so zu verdichten. In der Literatur findet sich eine Vielzahl von Methoden zur Merkmalsextraktion, die sich in automatisierte und (teil-)manuelle Verfahren unterteilen lassen. Bei den automatisierten Verfahren ist das Ziel, den Signalverlauf mit einem möglichst geringen Approximationsfehler über den gesamten Datensatz abzubilden. Die adaptive lineare Approximation [31] beispielsweise identifiziert automatisiert die Zyklenabschnitte, mit denen der Kurvenverlauf über die gesamte Messung optimal linear angenähert werden kann. Die manuelle Merkmalsextraktion beschreibt in dem Kontext, dass wesentliche Vorgaben, etwa die

Zyklussegmentierung, durch den Benutzer auf Basis von Expertenwissen oder vorangegangener händischer Analyse der Rohdaten vorgegeben werden. Typischerweise werden hierbei im Zeitbereich Merkmale der deskriptiven Statistik und zur Signalformbeschreibung eingesetzt, auf die nachfolgend näher eingegangen wird.

2.3.2.1 Deskriptive Statistik

Betrachtet man die abgetasteten Messwerte eines Sensors in einem definierten Zeitraum als Stichprobe, kann deren Häufigkeitsverteilung mittels statistischer Parameter beschrieben werden.

Der Median \tilde{x} ist bei einer der Größe nach geordneten Stichprobe aus n Messwerten der Wert, bei dem mindestens die Hälfte der Messwerte $\leq \tilde{x}$ und $\geq \tilde{x}$ sind:

$$\tilde{x} = \begin{cases} x_{\frac{n+1}{2}} & \text{für } n \text{ ungerade} \\ \frac{1}{2}(x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & \text{für } n \text{ gerade} \end{cases} \quad (2.11)$$

Die höheren zentralen Momente dienen der Beschreibung der Verteilung mit den Aspekten Varianz (2. Ordnung), Schiefe (3. Ordnung) und Kurtosis (4. Ordnung):

$$\text{var}(x) = \sigma^2(x) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2.12)$$

$$\text{skew}(x) = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{\sigma} \right)^3 \quad (2.13)$$

$$\text{kurtosis}(x) = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{\sigma} \right)^4 \quad (2.14)$$

Hierbei beschreibt x_i den i -ten von insgesamt n Datenpunkten, \bar{x} den Mittelwert und σ die Standardabweichung der Verteilung. Die Schiefe ist ein Maß für die Asymmetrie der Häufigkeitsverteilung, während die Kurtosis deren Wölbungsform beschreibt. Sie quantifiziert somit, ob die Messwerte der Stichprobe sich um den Mittelwert konzentrieren oder gleichmäßig bis in den Randbereich der Verteilung auftreten (Abbildung 2-2).

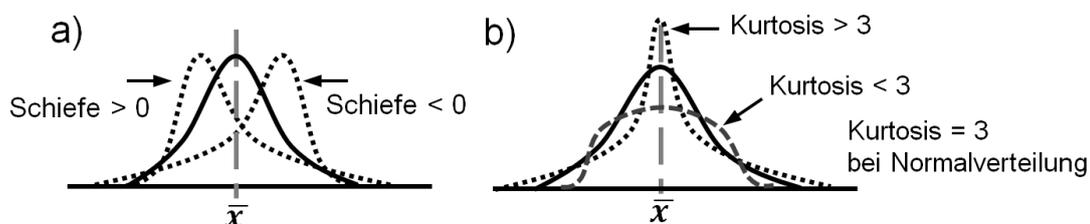


Abbildung 2-2. Verteilungsfunktionen bei verschiedenen Werten von a) statistischer Schiefe (3. Moment) und b) Kurtosis (4. Moment).

2.3.2.2 Formbeschreibend

Ein weiterer Ansatz ist die Beschreibung der Signalform, etwa auf Basis der Extremwerte und deren zeitliche Positionierung im Zeitbereich bzw. der maximalen Amplitude und deren Frequenz bei einer Auswertung im Frequenzbereich.

Daneben spielt insbesondere bei transienten Vorgängen die Steigungsform von rampenförmigen Signalen eine Rolle. Diese kann über die Koeffizienten β_k des polynomiellen Regressionsmodells m -ter Ordnung abgebildet werden.

$$y_j = \beta_0 + \beta_1 x_j + \beta_2 x_j^2 + \dots + \beta_m x_j^m + \varepsilon_j \quad (2.15)$$

Hierbei beschreibt y_j das gefittete Sensorsignal, x_j den Zeitpunkt innerhalb des Zyklusintervalls und ε_j den Approximationsfehler der Regression. Das Optimierungsproblem zur Bestimmung von β_k kann mit der Bildung der Vandermonde Matrix als lineares Gleichungssystem formuliert und effizient gelöst werden [32]:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^m \\ 1 & x_2 & x_2^2 & \dots & x_2^m \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^m \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad (2.16)$$

Die Berechnung von Polynomen höheren Grades ist aufwändig und kann zu numerischer Instabilität führen [32]. Aus diesem Grund wird nachfolgend nur ein einfaches Modell erster Ordnung verwendet.

2.3.2.3 Frequenz- und Frequenz-Zeit-Bereich

Im Bereich des Condition Monitoring ist die spektrale Merkmalsextraktion im Frequenz- bzw. Frequenz-Zeit-Bereich weit verbreitet, da vielfach periodische Messgrößen (z.B. Luft- und Körperschall) verwendet werden.

Die Fouriertransformation ist das übliche Verfahren zur Überführung von Signalen aus dem Zeit- in den Frequenzbereich, das im Folgenden in Anlehnung an [33] beschrieben wird. Ihr liegt die Überlegung zu Grunde, dass sich jede periodische Funktion $f(t)$ als eine Überlagerung von Sinus- und Cosinus-Funktionen geeigneter Amplitude darstellen lässt:

$$f(t) = \sum_{k=0}^{\infty} (a_k \cos(\omega_k t) + b_k \sin(\omega_k t)) \quad (2.17)$$

Die Fourierkoeffizienten werden mittels Integration über einen Zeitabschnitt mit der Periode T ermittelt:

$$a_k = \frac{2}{T} \int_{-T/2}^{T/2} f(t) \cos(\omega_k t) dt, k \neq 0 \quad (2.18)$$

$$a_0 = \frac{1}{T} \int_{-T/2}^{T/2} f(t) dt \quad (2.19)$$

$$b_k = \frac{2}{T} \int_{-T/2}^{T/2} f(t) \sin(\omega_k t) dt, \text{ für alle } k \quad (2.20)$$

Auf Basis der Eulerschen Identität lässt sich Formel in die komplexe Schreibweise überführen. Man erhält analog:

$$f(t) = \sum_{k=-\infty}^{\infty} c_k e^{i\omega_k t}, \text{ mit } \omega_k = \frac{2\pi k}{T} \quad (2.21)$$

$$\text{mit } c_k = \frac{1}{T} \int_{-T/2}^{T/2} f(t) e^{-i\omega_k t} dt \quad (2.22)$$

Die kontinuierliche Fouriertransformation ist wie folgt definiert:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-i\omega t} dt \quad (2.23)$$

Liegt statt einer kontinuierlichen Funktion $f(t)$ ein zeitdiskretes Sensorsignal vor, ergibt sich für die diskrete Fouriertransformation (DFT):

$$F_j = \frac{1}{N} \sum_{k=0}^{N-1} f_k W_N^{-kj}, \text{ mit } W_N = e^{\frac{2\pi i}{N}} \quad (2.24)$$

mit der Anzahl von Abtastwerten N . Effizient berechnen lässt sich die DFT mit dem FFT-Algorithmus, bei dem sich die Komplexität von N^2 komplexen Multiplikationen auf $N \cdot \log(N)$ reduziert [34], unter der Voraussetzung, dass N einer Zweierpotenz entspricht.

In der Signalverarbeitung und somit auch für die DFT gilt die Unschärferelation zwischen Zeit- und Frequenzauflösung:

$$\Delta t \Delta \omega \geq \frac{1}{2} \quad (2.25)$$

Demzufolge wird bei der DFT mit größerer zeitlicher Fensterbreite die Frequenzauflösung erhöht, gleichzeitig reduziert sich aber die zeitliche Lokalisierbarkeit. In der Praxis muss somit eine Abwägung zwischen den beiden Parametern getroffen werden. Ein Ansatz, der Frequenz- und Zeitlokalisierung vereint, ist die Wavelet-Transformation (WT), die in integraler Form definiert ist als [35]

$$W_\psi f(x, s) = \int_{\mathbb{R}} f(t) \frac{1}{\sqrt{s}} \psi\left(\frac{t-x}{s}\right) dt \text{ mit } x \in \mathbb{R}, s \in \mathbb{R}_+ \quad (2.26)$$

Die WT kann als Korrelation zwischen der Funktion $f(t)$ und einer gestauchten und verschobenen Basis-Wavelet-Funktion ψ interpretiert werden [35]. Hierbei ist s der Skalenparameter, der das Verhältnis zwischen Zeit- und Frequenzauflösung bestimmt und x der Translationsparameter. Für ψ gilt:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (2.27)$$

Die einfachste Basisfunktion, das Haar-Wavelet ist definiert als

$$\psi(t) = \begin{cases} 1, & \text{für } 0 \leq t < \frac{1}{2} \\ -1, & \text{für } \frac{1}{2} \leq t < 1 \\ 0 & \text{sonst} \end{cases} \quad (2.28)$$

Häufig werden jedoch in der Praxis komplexere Wavelet-Funktionen wie die Daubechies-4 Basisfunktion [31] verwendet. In der diskreten Formulierung ist die Komplexität der schnellen Wavelet-Transformation (Fast Wavelet Transformation, FWT) $O(N)$ und somit geringer als bei der FFT [36].

Wavelet-basierte Merkmalsextraktionsmethoden konnten sehr gute Ergebnisse bei der Früherkennung von Schäden in verschiedensten Anwendungsbereichen erzielen, etwa der Überwachung von Helikopter-Getrieben [37] oder rotatorisch betriebenen Maschinen [38], [39], da sie sowohl zeit- und frequenzlokalisierte Ereignisse detektieren können. Nachteile der Wavelet-Transformation sind die Verzerrung der Signal-Randbereiche, Energieleckage [40] und eine Störanfälligkeit gegenüber Rauschen [41].

2.3.3 Merkmalsselektion

Bei der Merkmalsextraktion kann eine beliebige Vielzahl von Merkmalen generiert werden, die sich allerdings nicht gleichermaßen für die statistische Modellbildung eignen. Ziel der Merkmalsselektion ist es, aus dem vorhandenen Merkmalspool diejenigen auszuwählen, die eine möglichst gute Separierung und Klassifizierung der Daten in Bezug zur Zielgröße erreichen. Aufgrund zweier unerwünschter Effekte sollte die Anzahl der Merkmale und somit die Dimension des Merkmalsvektors begrenzt werden. Zum einen ist dies „Overfitting“, welches eine Überanpassung an die Trainingsdaten und eine geringe Generalisierbarkeit des statistischen Modells in Bezug auf unbekannte Testdaten beschreibt (vgl. Abbildung 2-3). Zum anderen der sogenannte „Curse of dimensionality“ (Fluch der Dimensionalität), welcher sich dadurch auswirkt, dass die Distanzen von hochdimensionalen Merkmalsvektoren zueinander, auf denen multivariate Klassifikatoren im Allgemeinen beruhen, bei Verwendung vieler irrelevanter, d.h. rauschbehafteter Merkmale immer ähnlicher werden. Die Distanzmaße verlieren somit an Kontrast und die Klassifikation wird erschwert. Weitere Vorteile einer geringeren Merkmalsanzahl sind die bessere Nachvollziehbarkeit der Ergebnisse sowie eine geringere Berechnungskomplexität [42].

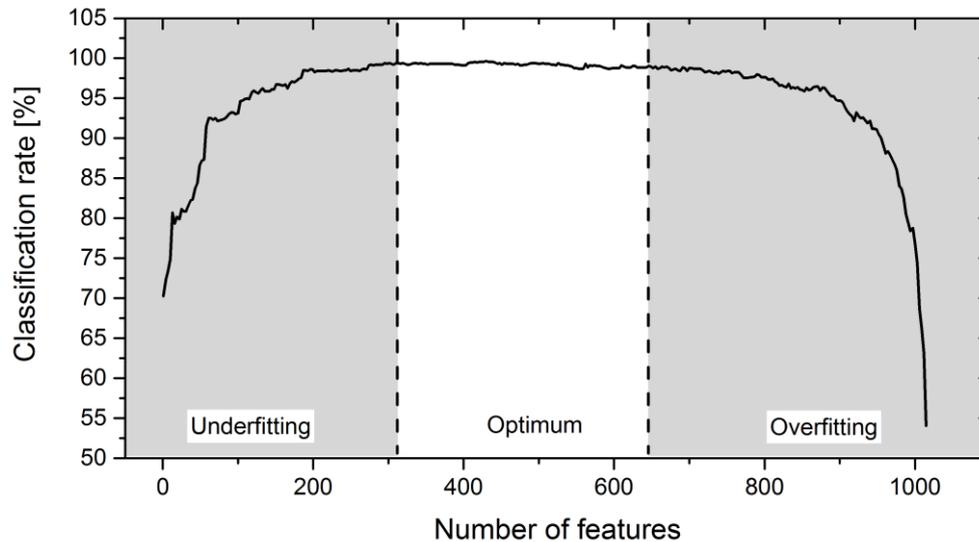


Abbildung 2-3. Under- und Overfitting am Beispiel der Performanz in Abhängigkeit der Merkmalsanzahl (10-fold CV, $n=1134$). Underfitting (linker Bereich) beschreibt hierbei die Verwendung einer zu geringen Anzahl von Merkmalen, welche die Klassifikation in Kombination nur unzureichend zuverlässig ermöglichen. Overfitting (rechter Bereich) hingegen entsteht bei einer Überanpassung an die Trainingsdaten, etwa bei Verwendung einer zu großen Anzahl von Merkmalen.

Abbildung 2-4 zeigt eine Übersicht von gängigen Merkmalsselektionsverfahren. Die manuelle Selektion kann auf spezifischem Prozesswissen, einer Modellbildung oder einer händischen Inspektion der Daten, etwa über einen Vergleich der individuellen Gruppen-Box-Plots oder der Merkmalsverläufe über die Zeit, wie von Bur [14] vorgeschlagen, erfolgen. Die manuelle Auswahl hat den Vorteil, dass tendenziell eine geringere Merkmalsanzahl gewählt wird, die zudem typischerweise auf Plausibilität geprüft wird. Automatisierte und rein datengetriebene Verfahren hingegen weisen einen Blackbox-Charakter auf, d.h. bei manchen Methoden (Wrapper, Embedded) kann die Entscheidungsfindung nur schwer nachvollzogen werden. Zudem muss strikt zwischen den Begriffen Kausalität und Korrelation unterschieden werden. Ist beispielsweise eine nicht annotierte dominante Störgröße der Zielgröße korreliert überlagert, wird das automatisierte Verfahren eher diejenigen Merkmale selektieren, die die Störgröße möglichst gut abbilden (vgl. Kap. 4.7). Dies zeigt die Notwendigkeit zu einem „sauberen“ Design-of-Experiment bei der Generierung von Trainingsdaten, einer Überprüfung der Merkmalsauswahl und einer hinreichenden Modellvalidierung. Guyon [43] empfiehlt aus diesem Grund, eine sinnvolle Vorauswahl der Merkmale auf Basis von Prozess- und Expertenwissen der automatisierten Selektion voranzustellen.

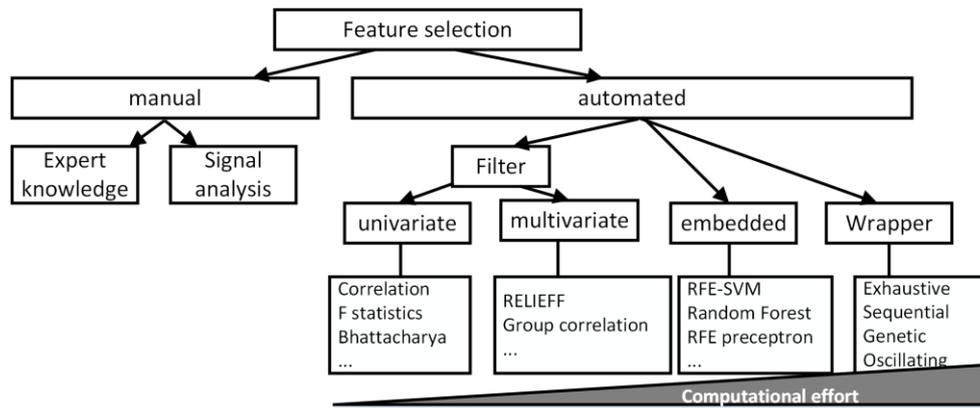


Abbildung 2-4. Methoden der Merkmalsselektion basierend auf [44].

Die automatisierten Selektionsverfahren lassen sich in Filter-, Embedded- und Wrapper-Methoden unterteilen, die sich jeweils deutlich von ihrem Ansatz und ihrer Komplexität unterscheiden und nachfolgend erläutert werden.

2.3.3.1 Filter

Filter basieren auf statistischen Kenngrößen, die die Relation zwischen Merkmalen und Zielgröße bewerten. Im univariaten Fall werden hierbei die Merkmale isoliert betrachtet, während bei multivariaten Filtern deren Wechselwirkung berücksichtigt und das gesamte Merkmals-Subset bewertet wird. Der Fokus liegt im Folgenden auf den univariaten Methoden.

Eine häufig verwendete Filterfunktion ist der Pearson Korrelationskoeffizient r , der über die Kovarianz und Standardabweichung zweier Variablen X und Y bestimmt wird:

$$r = \frac{\text{cov}(X,Y)}{\sqrt{\text{var}(X)\text{var}(Y)}} = \frac{\sum_{i=1}^M (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^M (x_i - \bar{x})^2 \sum_{i=1}^M (y_i - \bar{y})^2}} \quad (2.29)$$

Mit r werden lineare Abhängigkeiten zwischen zwei Variablen abgebildet; eine einfache Möglichkeit, diese Restriktion zu umgehen, ist ein nichtlinearer Fit der Zielfunktion oder alternativ eine geeignete nichtlineare Signalvorverarbeitung (Inverse, Logarithmus, etc.) [43].

Die Einschränkung auf lineare Zusammenhänge wird vom Spearman Korrelationskoeffizient ρ überwunden, welcher die Korrelation auf Basis des Rangs bestimmt:

$$\rho = \frac{\text{cov}(rg(X),rg(Y))}{\sqrt{\text{var}(rg(X))\text{var}(rg(Y))}} = \frac{\sum_{i=1}^M (rg(x_i) - \overline{rg(x)})(rg(y_i) - \overline{rg(y)})}{\sqrt{\sum_{i=1}^M (rg(x_i) - \overline{rg(x)})^2 \sum_{i=1}^M (rg(y_i) - \overline{rg(y)})^2}} \quad (2.30)$$

$rg(x_i)$ beschreibt den Rang des Merkmalswerts x_i des Zyklus i und $\overline{rg(x)}$ den Mittelwert der Ränge des Merkmals über alle Zyklen, gleiches gilt für die Zielgröße

Y. Hierbei werden die einzelnen Merkmalswerte zunächst in deren Ränge konvertiert, mit den Rängen der Zielgröße Y verglichen und darauf basierend die Korrelation bestimmt. Beide Korrelationskoeffizienten, r und ρ , sind geeignet für kontinuierliche Zielgrößen, wobei ρ robuster gegenüber Ausreißern ist [45].

Ein weiteres Verfahren zur Überprüfung der statistischen Signifikanz eines Merkmals ist die Varianzanalyse (ANOVA). In der betrachteten einfaktoriellen Varianzanalyse wird der Einfluss einer einzelnen unabhängigen Variable auf die abhängige Variable untersucht. Konkret wird gruppenspezifisch das Streuverhalten untersucht und in eine systematische (Streuung der Mittelwerte der Gruppen, SS_b^2) und eine stochastische Komponente (Streuung innerhalb der Gruppen, SS_w^3) unterteilt [46]. Die Signifikanz wird auf Basis der F-Statistik berechnet:

$$F = \frac{SS_b/df_b}{SS_w/df_w} = \frac{\sum_{g=1}^G N_g (\bar{x}_g - \bar{x})^2 / (G-1)}{\sum_{g=1}^G \sum_{n=1}^{N_g} (x_{gn} - \bar{x}_g)^2 / (G(N_g-1))} \quad (2.31)$$

\bar{x}_g ist der Mittelwert des Merkmalswertes der Gruppe g , \bar{x} der Gesamtmittelwert und x_{gn} der Merkmalswert n der Gruppe g . Die Freiheitsgrade df_b , df_w ergeben sich aus der Anzahl der Gruppen G und den Datenpunkten pro Gruppe N_g . Die Abbildung auf die Zielgröße erfolgt in diesem Fall kategorisch über die Gruppenzuordnung. Voraussetzungen zur Verwendung der ANOVA sind normalverteilte unabhängige Stichproben mit vergleichbarer Standardabweichung [47]. Angestrebt wird ein möglichst großer Wert von F , sodass sich der Merkmalswert zwischen unterschiedlichen Klassen möglichst stark unterscheidet, innerhalb der Klassen aber nur eine minimale Streuung aufweist. Damit ist der ANOVA F-Wert verwandt mit der Fisher'schen Kriteriumsfunktion des Dimensionsreduktionsverfahrens LDA (s. Kap. 2.3.4.2).

Die genannten Parameter r , ρ und F können jeweils als Vergleichskriterium für die Signifikanz der individuellen Merkmale in Bezug zur Zielgröße verwendet, anhand ihres Betrags sortiert und somit für die Erstellung einer Rangliste der zu selektierenden Merkmale genutzt werden.

2.3.3.2 Selektion mit Klassifikator-Interaktion

Wrapper-Methoden sind iterative Verfahren zum Identifizieren des optimalen Merkmal-Subsets. Diese verwenden als Kriteriumsfunktion typischerweise den kreuzvalidierten Klassifikationsfehler oder multivariate Filter [44]. Intuitiv naheliegend ist eine erschöpfende Suche des Subsets mit k Elementen aus einem

² Sum of squares between the group

³ Sum of squares within the group

Pool von n Merkmalen, die jedoch aufgrund ihrer Komplexität von $O\left(\frac{n!}{k!(n-k)!}\right)$ selbst bei vermeintlich überschaubaren Problemstellungen an ihre Grenzen stößt (z.B. 184.756 mögliche Kombinationen im Fall $\binom{n=20}{k=10}$). Sequentielle Suchalgorithmen (SBE, SFS⁴) [48] reduzieren zwar den Berechnungsaufwand, können aber aufgrund von Verschachtelungseffekten zu suboptimaler Merkmalsauswahl führen [49]. Dies versuchen genetische Suchalgorithmen durch das Einbeziehen einer randomisierten Komponente (in Anlehnung an die natürliche Mutation in der biologischen Evolution) zu umgehen [50]. Dennoch werden Wrapper-Methoden, obwohl in der Theorie vielversprechend, aufgrund ihres hohen Berechnungsaufwands nur selten in der Praxis eingesetzt. Von Vorteil ist, dass sie im Gegensatz zu univariaten Filtermethoden die Interaktionen der Merkmale untereinander und zum Klassifikationsverfahren mit abbilden.

Bei Embedded-Methoden ist die Selektion Teil des Trainingsprozesses des Klassifikators und nutzt interne Parameter des Mustererkennungsverfahrens (z.B. Decision Trees, SVM, LDA) als Selektionskriterium. Ähnlich wie bei den Wrapper-Methoden kann das Suchproblem sequentiell (Vorwärts- und Rückwärts-Methoden) formuliert werden. Eine typische Rückwärtsmethode sind die RFESVM⁵, die eine one-vs-one Klassentrennung auf Basis aller standardisierten Merkmale und einer linearen SVM durchführt [44]. Die Gewichtung der einzelnen Merkmale bei der Trennung kann über den jeweiligen Eintrag des Normalenvektors der Hyperebene abgelesen werden, welches in diesem Fall als Signifikanzmaß verwendet wird. Iterativ wird die SVM trainiert und das Merkmal mit der geringsten Gewichtung verworfen, bis eine optimale Auswahl erreicht wird, bei der das Fehlermaß minimiert wird (vgl. Abbildung 2-3). Daneben existieren weitere Embedded-Ansätze, die die Formulierung des maschinellen Lernverfahrens ausweiten, etwa mit der Optimierung von Skalierungsfaktoren oder der Einführung eines Reduktionsterms; hierbei sei auf [44] verwiesen. Embedded-Methoden besitzen ähnliche Vorteile wie die Wrapper-Methoden (Berücksichtigung Merkmals-/Klassifikatorinteraktion), sind jedoch wesentlich effizienter. Inhärenter Nachteil ist die Beschränkung auf kleine Merkmalspools, was diese Methoden insbesondere in Kombination mit einer Vorselektion auf Basis von Filter-Methoden interessant macht.

2.3.4 Dimensionsreduktion

Nachfolgend werden die zwei bekanntesten Vertreter zur unüberwachten (PCA) und überwachten (LDA) Dimensionsreduktion vorgestellt. Ziel der Verfahren es, den

⁴ Sequential backward elimination / forward selection

⁵ Recursive feature elimination support vector machine

hochdimensionalen Merkmalsraum in eine niedrigdimensionale Darstellung zu überführen, um in dieser eine Klassifizierung bzw. Visualisierung durchzuführen.

2.3.4.1 Hauptkomponentenanalyse

Die Hauptkomponentenanalyse (engl. principal component analysis, PCA) ist ein unüberwachtes Verfahren zur Dimensionsreduktion. Ziel ist es, den Informationsgehalt eines hochdimensionalen Merkmalsvektors, der in diesem Fall mit der Varianz gleichgesetzt wird, in möglichst wenigen Dimensionen, den sogenannten Hauptkomponenten (PCs), abzubilden. Die PCs sind orthogonal zueinander und nach ihrem Informationsgehalt sortiert; so beinhalten die ersten beiden PCs typischerweise schon den wesentlichen Teil (> 80 %) der Streuinformation [24]. Gleichzeitig ist die PCA anfällig für Skaleneffekte der Eingangsmerkmale, weswegen für eine homogene Gewichtung und somit höhere Stabilität vorab eine Standardisierung durchgeführt werden sollte. Die verlustbehaftete Dimensionsreduktion kann durch das Verwerfen der höheren Hauptkomponenten realisiert werden und eignet sich damit für die Visualisierung mehrdimensionaler Daten. Bei nichtlinearen hochdimensionalen Datenstrukturen sollten jedoch deutlich komplexere Verfahren, wie selbstorganisierende Karten (SOM) [24] auf Basis künstlicher neuronaler Netze (Kap. 2.3.6), verwendet werden. Neben der explorativen Datenanalyse wird die PCA auch zur Anomalie-Detektion genutzt: Hierbei wird der Approximationsfehler zwischen den ersten PCs und den Originaldaten verglichen; eine deutliche Erhöhung ist ein Indiz für ein geändertes Systemverhalten [51]. Daneben wird in dieser Arbeit die PCA auch als unüberwachtes Verfahren zur Merkmalsreduktion betrachtet, bei der ein umfangreicher Merkmalspool auf wenige unkorrelierte Hauptkomponenten-Merkmale abgebildet wird.

Die folgende mathematische Beschreibung ist [46] entnommen. Die Grundgleichung der PCA lautet

$$\tilde{\mathbf{X}} = \mathbf{A} \cdot \mathbf{P} \quad (2.32)$$

mit den standardisierten Merkmalsdaten $\tilde{\mathbf{X}}$, den Faktorladungen \mathbf{A} und den Faktorwerten \mathbf{P} . Aufgrund deren Orthogonalität gilt

$$\mathbf{P} = \mathbf{A}^{-1} \cdot \tilde{\mathbf{X}} = \mathbf{A}^T \cdot \tilde{\mathbf{X}} \quad (2.33)$$

$$p_q = \sum_k a_{kq} \cdot \tilde{x}_k = \mathbf{a}_q^T \tilde{\mathbf{x}}_k \quad (2.34)$$

Jeder Faktor $q=1,\dots,Q$ bildet eine Linearkombination der Merkmale $\tilde{\mathbf{x}}_k$ mit $k=1,\dots,K$, somit gilt für die Varianz von q :

$$s_q^2 = \sum_{k=1}^K \sum_{l=1}^K a_{kq} \cdot a_{lq} \cdot r_{kl} = \mathbf{a}_q^T \mathbf{R} \mathbf{a}_q \quad (2.35)$$

Da die Korrelationsmatrix \mathbf{R} bereits vorgegeben ist, ist die Varianz demzufolge nur abhängig von den Faktorenladungen \mathbf{a}_q . Wie zuvor beschrieben, soll ein Faktor möglichst viel Varianz der Eingangsvariablen enthalten, womit sich das Optimierungsproblem ergibt:

$$\max_{\mathbf{a}_q} \{s_q^2\}, \text{ unter der Nebenbedingung } \mathbf{a}_q^T \mathbf{a}_q = 1 \quad (2.36)$$

Unter Verwendung des Lagrange-Ansatzes lassen sich die Ladungen von Faktor 1 über das homogene Gleichungssystem bestimmen:

$$(\mathbf{R} - \lambda_1 \mathbf{E}) \mathbf{a}_1 = \mathbf{0} \quad (2.37)$$

mit dem Eigenwert λ_1 , dem Eigenvektor \mathbf{a}_1 und der Einheitsmatrix \mathbf{E} .

$$\text{da } \mathbf{a}_1^T \mathbf{a}_1 = 1, \text{ gilt } \lambda_1 = \mathbf{a}_1^T \mathbf{R} \mathbf{a}_1 = s_1^2 \quad (2.38)$$

Da das Ziel die Maximierung von s_1^2 ist, muss λ_1 der größte Eigenwert von \mathbf{R} sein. Der Eigenvektor ist gleichzeitig der Projektionsvektor zu Faktor 1, sprich der ersten Hauptkomponente. Mit den höheren Komponenten können sukzessive nun immer kleiner werdende Anteile der Gesamtvarianz abgebildet werden:

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_Q \quad (2.39)$$

Die Dimensionalität Q bleibt somit identisch zu derjenigen der Ausgangsdaten und wird erst durch Verwerfen der höheren (wenig informationsbehafteten) Faktoren q reduziert.

2.3.4.2 Lineare Diskriminanzanalyse

Die Lineare Diskriminanzanalyse (LDA) nach Fisher ist ein überwachtes Dimensionsreduktionsverfahren, welches einen hochdimensionalen Merkmalsraum in eine niedrigdimensionale Darstellung auf Basis von orthogonalen Diskriminanzfunktionen (DF) überführt [46]. Hierbei wird typischerweise eine zweidimensionale Darstellung zur intuitiven graphischen Repräsentation gewählt. Wie auch die PCA setzt sich die Transformation aus einer Translation und einer Rotation zusammen.

Ziel der LDA ist eine maximale Separierung der bekannten Klassen, indem sie die Streuung der Klassenmittelpunkte unterschiedlicher Klassen maximiert und dabei gleichzeitig die Streuung innerhalb einzelner Klassen minimiert. Dies erfolgt über die Maximierung der Kriteriumsfunktion $J(\mathbf{w})$ [52]:

$$J(\mathbf{w}) = \frac{\mathbf{w}^T S_b \mathbf{w}}{\mathbf{w}^T S_w \mathbf{w}} \quad (2.40)$$

Hierbei beschreibt \mathbf{w} den Projektionsvektor, S_b die Streu-Matrix zwischen den Klassen und S_w die Streu-Matrix innerhalb der Klassen. Letztere sind folgendermaßen definiert:

$$S_b = \sum_{g=1}^G N_g (\bar{\mathbf{x}}_g - \bar{\mathbf{x}})(\bar{\mathbf{x}}_g - \bar{\mathbf{x}})^T \quad (2.41)$$

$$S_w = \sum_{g=1}^G \sum_{n=1}^{N_g} (\mathbf{x}_{gn} - \bar{\mathbf{x}}_g)(\mathbf{x}_{gn} - \bar{\mathbf{x}}_g)^T \quad (2.42)$$

Hierbei ist G die Anzahl der Klassen, N_g die Anzahl der Beobachtungen pro Klasse g , $\bar{\mathbf{x}}_g$ der Mittelwertvektor der Klasse g , $\bar{\mathbf{x}}$ der globale Mittelwert und \mathbf{x}_{gn} der Merkmalsvektor n der Klasse g . Die Problemstellung kann in ein Eigenwert-Problem überführt und effizient gelöst werden [53]. Die Klassenanzahl G bestimmt hierbei die maximal verfügbare Anzahl $G - 1$ der Diskriminanzfunktionen.

Die Projektion in die dimensionsreduzierte Darstellung erfolgt durch eine einfache Linearkombination [46] analog zur PCA:

$$DF_i = w_{i,0} + \sum_{k=1}^K w_{i,k} x_k \quad (2.43)$$

mit der i -ten Diskriminanzfunktion DF_i , dem Diskriminanzkoeffizienten $w_{i,k}$ von DF_i und Merkmal x_k mit insgesamt K verwendeten Merkmalen.

Mit der Optimierung des Diskriminanzkriteriums wird nur das Verhältnis der Diskriminanzkoeffizienten bestimmt und nicht die absolute Lage und Skalierung der DFs. Um diese Uneindeutigkeit aufzuheben, ist die Konvention entstanden, eine Normierung der Diskriminanzkoeffizienten durchzuführen, sodass die Varianz innerhalb der Gruppen Eins ergibt [46]. Die absolute Position der Abbildung ($w_{i,0}$) wird nachfolgend so gewählt, dass der Gesamtmittelwert aller Diskriminanzwerte zu Null wird. Im Gegensatz zur PCA ist die LDA unempfindlich gegenüber heterogenen Skalierungen der Merkmale, sie beeinflussen weder die Klassentrennung noch die relative Lage der Klassen zueinander [54].

Zur Anwendung der LDA werden einige Annahmen vorausgesetzt, etwa die multivariate Normalverteilung (Verifikation z.B. durch Roy's Test), ein ähnliches Streuverhalten (Homoskedastizität, überprüfbar z.B. mit dem Goldfeld-Quandt-, White- oder Levene-Test) sowie die Unkorreliertheit und Unabhängigkeit der Merkmale [54]. Tatsächlich ist die LDA aber relativ robust gegen eine leichte Verletzung dieser Annahmen, wohingegen unter bestimmten Bedingungen, etwa bei Verwendung von kombinierten binären und kontinuierlichen Variablen, ein instabiles Verhalten entstehen kann [25]. Als problematisch ist eine hohe positive oder negative Korrelation von Merkmalen untereinander nahe ± 1 zu bewerten, da dies zu einer Singularität bei der Berechnung der inversen Kovarianzmatrix führen kann [55]. Die Frage, in welchem Ausmaß eine Verletzungen der Annahmen tolerabel ist und inwieweit die Ergebnisse in dem Fall interpretierbar sind, ist nicht pauschal

beantwortbar [54]. Ein praktikables Vorgehen ist hierbei die Untersuchung der Kreuzvalidierungs-Klassifikationsrate; signifikante Verstöße der Annahmen führen mit hoher Wahrscheinlichkeit zu einem schlechten Ergebnis. In dem Kontext ist es ratsam, der LDA alternative, nicht-parametrische Klassifikatoren gegenüberzustellen.

Abbildung 2-5 zeigt exemplarisch die Projektionsrichtungen von LDA und PCA zur Verdeutlichung der beiden verschiedenen Optimierungsziele Gesamtstreuung und Klassentrennung.

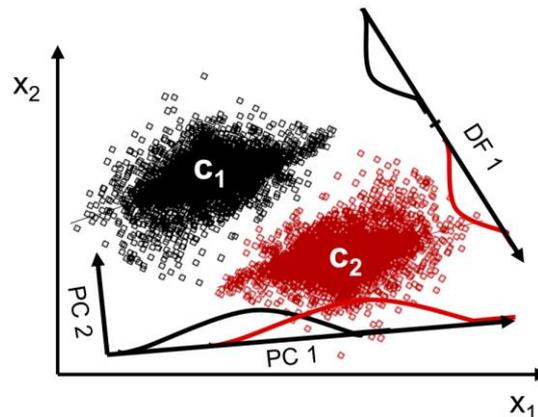


Abbildung 2-5. Projektionsrichtungen PCA und LDA bei zwei Merkmalen (x_1, x_2) und Klassen (c_1, c_2).

2.3.5 Abstands- und Wahrscheinlichkeitsmaße

Die Klassifikation der originalen oder dimensionsreduzierten Daten erfolgt i.d.R. über Wahrscheinlichkeits- oder Abstandsmaße. Die gängigsten werden im Folgenden erläutert.

2.3.5.1 Abstandsmaße

Das einfachste Abstandsmaß zur Klassifizierung stellt die quadrierte euklidische Distanz zwischen Datenpunkt und den Gruppenmittelpunkten dar, bei der ein Merkmalsvektor derjenigen Gruppe zugeordnet wird, zu deren Zentroid er die geringste Distanz aufweist [46].

$$D_{ng,euk}^2 = (x_n - \bar{x}_g)^2 = \sum_{k=1}^K (x_{kn} - \bar{x}_{kg})^2 \quad (g = 1, \dots, G) \quad (2.44)$$

mit x_{kn} = Merkmalswert von Element n bezüglich Dimension k

\bar{x}_{kg} = Zentroid von Gruppe g bezüglich Dimension k

Der k-nächste-Nachbarn (k-NN) Klassifikator basiert typischerweise ebenfalls auf der euklidischen Distanz und zählt zu den nicht-parametrischen Verfahren. Daneben sind in der Literatur auch weitere Distanzmaße (Minkowski, Hamming, Jaccard) zu finden [56], [57]. Bei dem Verfahren wird die Gruppenzugehörigkeit der k

Datenpunkte mit geringstem Abstand um den zu klassifizierenden Datenpunkt anhand einer Mehrheitsentscheidung bestimmt. Zur Erhöhung der Robustheit können die Abstände zusätzlich mit einer Gewichtung versehen werden [58]. Die Wahl von k hat einen wesentlichen Einfluss auf dessen Verhalten. Bei kleinen Werten von k , etwa 1-NN, neigt der Klassifikator zum Overfitting, da einzelne Ausreißer mit derselben Gewichtung behandelt werden wie Areale mit hoher Punktdichte einer Gruppe. Aus diesem Grund wird typischerweise $k=3$ oder $k=5$ gewählt [14].

Grundsätzlich setzt das euklidische Abstandsmaß Orthogonalität und standardisierte Merkmale voraus, da ansonsten die Skalierung über die Dominanz einzelner Merkmale entscheiden würde [46].

Ein verallgemeinertes Distanzmaß, welches letzteres nicht voraussetzt, ist die Mahalanobis-Distanz (hier in quadrierter Form) [25]:

$$D_{ng, Mahal}^2 = (\mathbf{x} - \bar{\mathbf{x}}_g)^T \mathbf{S}^{-1} (\mathbf{x} - \bar{\mathbf{x}}_g) \quad (2.45)$$

mit \mathbf{x} = Test-Merkmalvektor

$\bar{\mathbf{x}}_g$ = Zentroid der Gruppe g

\mathbf{S} = Innergruppen-Kovarianzmatrix der Merkmalsvariablen

Anschaulich dargestellt skaliert die Mahalanobis-Distanz den Abstand zwischen dem Test-Datenpunkt und der Gruppe mit der Standardabweichung innerhalb der Gruppe in der entsprechenden Richtung [14]. Befindet sich hierbei der zu klassifizierende Punkt innerhalb der Distanz der einfachen Standardabweichung zum Gruppenmittelpunkt, so gehört er mit hoher Wahrscheinlichkeit zu dieser Gruppe. Sind die Standardabweichungen der k Dimensionen gleich skaliert und die Merkmale in der Gruppe unkorreliert, geht die Mahalanobis-Distanz in die euklidische Distanz über [59].

2.3.5.2 Wahrscheinlichkeitsmaße

Eine Verallgemeinerung des Distanzkonzeptes ist die Verwendung von Wahrscheinlichkeitsmaßen, welche in der Praxis häufig angewendet werden [60], [61]. Mit diesen können A-priori-Wahrscheinlichkeiten einzelner Klassen berücksichtigt werden [46]. Klassifiziert wird ein Element n zu der Gruppe g , wenn die Klassifizierungswahrscheinlichkeit $P(g|x_n)$ größer als die der übrigen Gruppen ist. Für die Berechnung bedingter Wahrscheinlichkeiten wird das Bayes-Theorem verwendet:

$$P(g|x_n) = \frac{P(x_n|g)P_n(g)}{\sum_{g=1}^G P(x_n|g)P_n(g)} \quad (g = 1, \dots, G) \quad (2.46)$$

mit $P(g|x_n)$ = A-posteriori-, bzw. Klassifizierungs-Wahrscheinlichkeit

$P(x_n|g)$ = Bedingte Wahrscheinlichkeit

$P_n(g)$ = A-priori-Wahrscheinlichkeit

Die Klassifizierungswahrscheinlichkeiten ergeben sich aus den Distanzmaßen und dem Bayes-Theorem wie folgt

$$P(g|x_n) = \frac{\exp\left(\frac{-D_{ng}^2}{2}\right) \cdot P_n(g)}{\sum_{g=1}^G \exp\left(\frac{-D_{ng}^2}{2}\right) \cdot P_n(g)} \quad (g = 1, \dots, G) \quad (2.47)$$

mit D_{ng} = Distanz zwischen Element n und dem Gruppenzentrum von g

$P_n(g)$ = A-priori-Wahrscheinlichkeit, dass das Element n zur Gruppe g gehört

Bei obiger Formel wird eine identische Gruppenstreuung angenommen, die vorab mit Box's M verifiziert werden sollte [46].

2.3.6 Künstliche neuronale Netze

Weit verbreitet sind zudem künstliche neuronale Netze (engl. artificial neural network, ANN), die in Anlehnung an die Funktionsweise des natürlichen Vorbilds, des Gehirns, verschiedene Problemstellungen des maschinellen Lernens, etwa Klassifikation, Clustering, Regression oder die Voraussage von Zeitreihen [62] lösen. Die folgenden Ausführungen basieren auf [63], [64]. Der Grundaufbau eines neuronalen Netzes (Abbildung 2-6) besteht aus einer Eingabeschicht, die aus der Information des Merkmalsvektors gespeist wird, einem oder mehreren verdeckten Zwischenschichten (Hidden Layer) und einer Ausgabeschicht von Neuronen, deren Ausgang die Zielgröße repräsentiert. Die verschiedenen Eingaben x_i eines Neurons werden mit w_{ij} gewichtet und deren Summe, auch Netzeingabe genannt, um den Schwellenwert θ_j verschoben⁶. Auf Basis dieser Summe wird die Aktivierungsfunktion, typischerweise eine Sigmoidfunktion der Form

$$f(x) = \frac{1}{1 + \exp(-ax)} \quad (2.48)$$

berechnet, die den Ausgangswert o_j des Neurons bestimmt. Bei feed-forward Netzen sind hierbei alle Verknüpfungen in Richtung der Ausgabeschicht gerichtet, während bei rekurrenten Netzen Rückkopplungen von Neuronen derselben oder nachfolgender Schichten vorliegen können, was insbesondere für die Klassifizierung sequentieller und zeitlich codierter Information (z.B. Spracherkennung) verwendet wird [65].

⁶ In Anlehnung an das Schwellenpotential von biologischen Nervenzellen

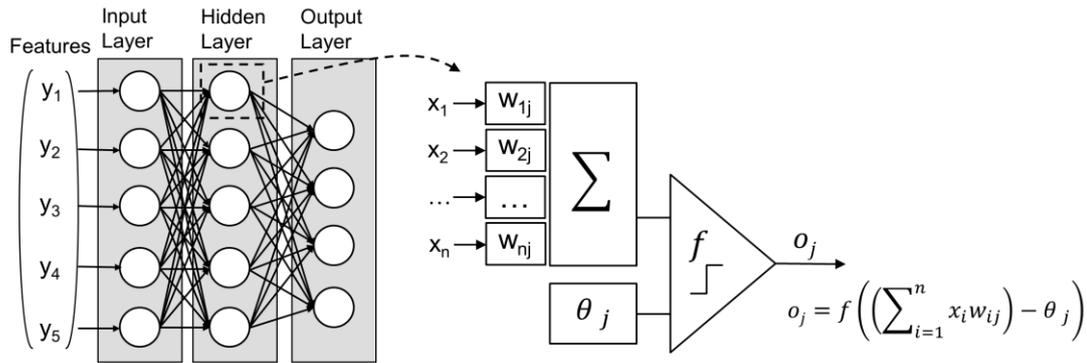


Abbildung 2-6. Beispiel für ein einfaches künstliches neuronales feed-forward Netz mit einer verdeckten Schicht und Aufbau des künstlichen Neurons nach [66].

Die Modellbildung, beim ANN im Gegensatz zur LDA oder PCA ein iterativer Prozess, erfolgt im überwachten Fall für ein mehrschichtiges Feed-Forward-Netz (Multilayer Perceptron, MLP) meist über den sogenannten Backpropagation-Algorithmus. Hierbei werden die Gewichtungen der Neuronen ausgehend von der Ausgangsschicht adaptiert, bis der Abbildungsfehler (lokal) minimiert wird. Dieser ist definiert als

$$e = \frac{1}{2} \sum_{i=1}^n (t_i - o_i)^2 \quad (2.49)$$

mit e = Abbildungsfehler

n = Anzahl der Beobachtungen

t_i = vorgegebener Zielwert

o_i = Voraussagewert am Ausgang

Durch partielle Ableitung der Fehlerfunktion nach den Neuronen-Gewichtungen ergibt sich die Adaption der Gewichte Δw_{ij} von Neuron i zu Neuron j [67]:

$$\Delta w_{ij} = -\eta \frac{\partial e}{\partial w_{ij}} = -\eta \delta_j o_i \quad (2.50)$$

mit $\delta_j = \begin{cases} f'(net_j) \cdot (o_j - t_j), & \text{falls } j \text{ ein Ausgabeneuron} \\ f'(net_j) \cdot \sum_k \delta_k w_{jk}, & \text{falls } j \text{ ein verdecktes Neuron} \end{cases}$

η = Lernrate, skaliert die Stärke der Gewichtsänderung

δ_j = Fehlersignal des Neurons j

f = sigmoide Aktivierungsfunktion

net_j = Netzeingabe von j

t_j = Sollausgabe Ausgabeneuron j

o_i, o_j = Aktuelle Ausgaben der Neuronen i, j

k = Index des nachfolgenden Neuron von j

Bildlich gesprochen wird versucht, in der mehrdimensionalen Fehlerfläche über einen Gradientenabstieg das Minimum zu finden. Die Wahl von η (i.d.R. zwischen 0

und 1) ist nicht trivial, bei einem kleinen Wert werden viele Lern-Iterationen benötigt und es besteht die Gefahr, in der typischerweise stark zerklüfteten Fehlerfläche nur ein lokales Minimum zu finden. Bei großen Werten hingegen steigt die Wahrscheinlichkeit, dass das Verfahren aus dem Bereich des globalen Minimums herausspringt oder dass Oszillationseffekte an den Rändern des Optimums entstehen. Verschiedene Konzepte, etwa die Einführung einer variablen Lernrate oder eines Trägheitsmoments, können diese Effekte abmildern, dennoch ist selbst bei geeigneter Wahl der Parameter kein Lernerfolg garantiert, da die Anfangsinitialisierung der Neuronengewichte, die typischerweise randomisiert erfolgt, einen erheblichen Einfluss auf das Ergebnis hat.

Nichtsdestotrotz wurde die Leistungsfähigkeit von MLP in vielen Anwendungen demonstriert [68], [69], [70]. Sie erlauben auch die Lösung nichtlinearer Klassifikationsprobleme; zudem kann der Trainingsalgorithmus effizient parallelisiert bzw. mittels GPU berechnet werden [71]. Als großer Nachteil der ANN ist die geringe Transparenz und ihr Blackbox-Charakter zu bewerten, weswegen sie beispielweise für sicherheitskritische Anwendungen [12] ungeeignet sind. Wie andere Klassifikationsmethoden ist auch das MLP von Overfitting betroffen, insbesondere bei einer hohen Zahl von Neuronen und verdeckten Layern, auch als Deep Learning bezeichnet, was eine ausreichende Validierung unerlässlich macht.

2.3.7 Support Vector Machines

Support Vector Machines (SVM) sind ein nicht-parametrisches Verfahren zur Klassifikation. Ziel ist es, diejenige Hyperebene zu finden, die die Trennschleife (Margin) zwischen zwei Klassen und somit die Generalisierbarkeit der Klassentrennung maximiert. Die Ebene kann nur mit Hilfe der äußersten, benachbarten Punkten der unterschiedlichen Klassen (Support Vektoren) bestimmt werden. Wird keine Fehlklassifikation erlaubt (also bei einem vollständig linear trennbaren Datensatz), spricht man von Hard-Margin-SVM. Für nicht vollständig trennbare Daten wird mit den sog. Soft-Margin-SVM eine Schlupfvariable ξ eingeführt, die Fehlklassifikationen, also Datenpunkte einer Klasse innerhalb oder jenseits des Margins erlaubt, diese jedoch negativ bewertet (Abbildung 2-7a).

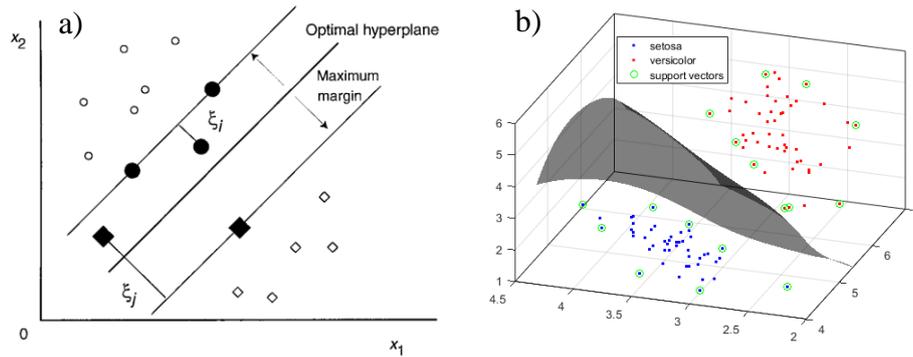


Abbildung 2-7. a) Soft-Margin-SVM in zwei Dimensionen [72], b) Hyperebene der SVM mit RBF-Kernel am Beispiel des Datensatzes Iris flower [73].

Man erhält das Optimierungsproblem [72]

$$Q(\mathbf{w}, b, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^M \xi_i \rightarrow \min \quad (2.51)$$

mit der Nebenbedingung $y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i$, $\xi_i \leq 0$ für $i = 1, \dots, M$ (2.52)

mit \mathbf{w} = Normalenvektor der Hyperebene

b = Bias-Term mit dem Abstand der Ebene zum Ursprung $\frac{-b}{|\mathbf{w}|}$

ξ_i = Schlupfvariable

C = Gewichtungparameter der Margin-Verletzung

y_i = Klassenlabel 1 oder -1

M = Anzahl der Trainingsdaten

Mithilfe der Karush-Kuhn-Tucker Bedingung kann eine optimale Lösung des Minimierungsproblems gefunden werden [72]. In der Standard-Formulierung (linearer Kernel) wird der über den Eingangsvektor aufgespannte Raum zur Identifikation der trennenden Hyperebene verwendet, sodass nur eine lineare Trennung möglich ist. Zur Abbildung komplexer nichtlinearer Probleme wird eine Kernel-Funktion eingeführt, die den Eingangsvektor in einen höherdimensionalen Raum projiziert, in dem eine optimal trennende Hyperebene gefunden werden kann. Mittels des sogenannten Kernel-Tricks können die Skalarprodukte des Merkmalsraums der linearen Formulierung mit der Kernel-Funktion ersetzt werden, sodass besagte Transformation nur implizit und somit rechnerisch effizient realisiert werden kann. Häufig verwendet wird der RBF-Kernel (Radial Basis Function, vgl. Abbildung 2-7b)

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x}-\mathbf{x}'\|^2}{2\sigma^2}\right) \quad (2.53)$$

mit σ = Radiusparameter des RBF-Kernels

Daneben existiert eine Vielzahl weiterer Kernel (polynomial, hyperbolisch tangential, etc.), deren Wahl je nach Anwendung einen wesentlichen Einfluss auf die Leistungsfähigkeit der SVM hat [74].

Da SVM nur für binäre Klassifikationsprobleme formuliert sind, müssen Multiklassenprobleme in mehrere Zweiklassenprobleme überführt werden. Gängige Verfahren sind die Gegenüberstellung jeweils zweier einzelner Klassen (one-vs-one, OVO) oder einer Klasse gegenüber allen anderen (one-vs-all, OVA) [75]. Multiklassen-SVM sind bereits nativ in der Matlab-Toolbox „Statistics and Machine Learning“ implementiert [76].

SVM haben, wie von Abe [72] beschrieben, verschiedene Vor- und Nachteile gegenüber ANN. So finden diese das globale Optimum des Optimierungsproblems, minimieren nicht wie bei ANN den Abbildungsfehler anhand der Trainingsdaten, sondern maximieren die Generalisierbarkeit, was sie weniger empfindlich gegenüber Overfitting macht. Zudem können sie durch die Wahl der Kernelfunktion für verschiedenste Anwendungen eingesetzt werden und sind, bei geeigneter Wahl des Margin-Parameters C , unanfällig gegenüber Ausreißern. Gleichzeitig stellt die geeignete Wahl der Parameter C und σ , mit denen sich der Grad der Anpassung an die Trainingsdaten einstellen lässt (analog zur Anzahl der verdeckten Layer beim ANN), jedoch ein Problem dar. An einem Datensatz aus der Gassensorik [77] konnte Schneider [78] beispielsweise Overfitting-Effekte bei einer Wahl von $C > 10^4$ und $\sigma < 2$ feststellen, jedoch ist dies stark vom Datensatz abhängig und sollte demzufolge individuell empirisch untersucht werden. Ähnlich wie die ANN sind auch nichtlineare SVM Blackbox-Verfahren, die aufgrund der komplexen Trennebenen gegenüber der LDA mit Distanzklassifikator nur schwer interpretierbar und nachvollziehbar sind [79].

2.3.8 Validierung

Die nachfolgend beschriebenen Validierungsmethoden umfassen zum einen Tests auf Normalverteilung, mit denen etwa die Beschaffenheit von Merkmalen und deren Eignung für Verfahren, die eine Normalverteilung voraussetzen (z.B. LDA und ANOVA), überprüft werden kann, zum anderen Prüfverfahren, die eine Abschätzung der Leistungsfähigkeit der erstellten statistischen Modelle erlauben.

2.3.8.1 Tests auf Normalverteilung

Statistische Tests zum Nachweis von Normalverteilung stellen üblicherweise die Nullhypothese H_0 (die Stichprobe liegt mit einer Normalverteilung vor) der alternativen Hypothese H_1 (die Stichprobe liegt nicht normalverteilt vor) gegenüber. Im Folgenden werden die bekanntesten Vertreter erläutert.

Der *Pearson's Chi-Square-Test* verwendet als Prüfgröße χ^2 das Maß, inwieweit die tatsächlichen Häufigkeiten O_g zur Gruppe g von den hypothetisch zu erwartenden Häufigkeiten E_g bei Normalverteilung abweichen [80]:

$$\chi^2 = \sum_g \frac{(O_g - E_g)^2}{E_g} \quad (2.54)$$

Liegt der Wert χ^2 oberhalb des vom Signifikanzniveaus α (typ. 0,05) und der Anzahl von Freiheitsgraden m bestimmten Quantils $\chi^2_{(1-\alpha, m-1)}$, so wird die Nullhypothese zurückgewiesen, d.h. es liegt wahrscheinlich keine Normalverteilung vor.

Der *Shapiro-Wilk-Test* beschreibt mit der Prüfgröße W den Quotient zwischen der Varianz bei Normalverteilung und der tatsächlichen Varianz der Stichprobe [81]:

$$W = \frac{b^2}{(n-1)\sigma^2} = \frac{(\sum_{i=1}^n a_i x_{(i)})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.55)$$

$$\text{mit } a^T = (a_1, \dots, a_n) = \frac{m^T V^{-1}}{(m^T V^{-1} V^{-1} m)^{\frac{1}{2}}} \quad (2.56)$$

b ist die Schätzung der Steigung einer linearen Regression der geordneten Beobachtungen $x_{(i)}$ auf Basis der zu erwarteten Werte m_i der Ordnungsstatistik bei Normalverteilung. Die Koeffizienten a_i werden hierbei mittels der bei H_0 zu erwartenden Werte m und der Kovarianzmatrix V bestimmt. Im Gegensatz zu den übrigen Tests wird die Nullhypothese beim Unterschreiten der Schranke (abhängig von α) zurückgewiesen.

Der *Jarque-Bera-Test* basiert auf den statistischen Größen Schiefe S und Kurtosis K der Stichprobe [82]:

$$T = \frac{n}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (2.57)$$

Weichen die Parameter S und K von der Normalverteilung ($S = 0, K = 3$) ab, steigt der Wert von T an. Anhand des Signifikanzniveaus α ergibt sich die Schranke für T , oberhalb derer die Nullhypothese verworfen wird (z.B. Schrankenwert 6 bei $\alpha = 0,05$).

Der *Kolmogorov-Smirnov-Test* stellt die kumulative Stichprobenverteilung $S_N(x)$ der idealen kumulativen Normalverteilung $F(x)$ unter Berücksichtigung der als bekannt vorausgesetzten Parameter Mittelwert und Varianz gegenüber [83]:

$$D_{KS} = \max |F(x) - S_N(x)| \quad (2.58)$$

Überschreitet die maximale Distanz D_{KS} beider Verteilungen die kritische Schranke $D_{crit}(\alpha, N)$, wird die Nullhypothese zurückgewiesen. Im Gegensatz hierzu erlaubt der darauf aufbauende *Lilliefors-Test* [84] eine Schätzung von Stichproben-Varianz und -Mittelwert und ist somit allgemeiner anwendbar.

2.3.8.2 Klassifikation

Der abschließende Schritt jeder statistischen Modellbildung sollte eine hinreichende Validierung sein, um deren Aussagekraft beurteilen zu können.

Speziell die Dimensionsreduktionsverfahren PCA und LDA bieten vielfältige Möglichkeiten zur visuellen Validierung, da sie hochdimensionale Merkmalsvektoren in eine typischerweise zweidimensionale Darstellung überführen und somit eine bessere Nachvollziehbarkeit und Transparenz der Entscheidungsfindung im Vergleich zu ANN oder SVM ermöglichen. Ein wichtiges Indiz ist hierbei die Beschaffenheit der LDA Trainingsdaten-Projektion. Neben den offensichtlichen Parametern wie Klassenstreuung und -überlapp ist bei quantitativer Variation der Zielgröße die korrekte Reihenfolge der Klassenabbildung entlang der Diskriminanzfunktionen ein wichtiger Anhaltspunkt für ein valides Modell (Abbildung 2-8). Eine vollständige Klassentrennung rein auf Basis von Trainingsdaten ist hingegen kein ausreichendes Kriterium, da sie durch Overfitting, etwa durch eine zu große Anzahl von Merkmalen in Relation zu den verfügbaren Beobachtungen, selbst bei Merkmalen mit nur normalverteiltem Rauschen erreicht werden kann [14], indem jeder Trainingsdatenpunkt von einem eigenen Merkmal beschrieben wird.

Voneinander abgesetzte Cluster der gleichen Klasse deuten darauf hin, dass relevante Einfluss- und Störgrößen nicht im Zielvektor annotiert sind, oder lassen vermuten, dass Annahmen wie die gruppenbezogene Normalverteilung der Merkmale in erheblichem Maße verletzt werden. Daneben können bei quantitativ vorliegender Zielgröße Klassen aus dem Training zurückgehalten werden, die nachfolgend in das statistische Modell auf Basis der übrigen Klassen projiziert werden. Erfolgt die Abbildung in die entsprechenden Zwischenpositionen, ist diese Interpolationsfähigkeit als starkes Validierungskriterium zu bewerten, da die physikalischen Zusammenhänge offensichtlich korrekt erfasst und auf unbekanntes Daten angewendet werden können (Abbildung 2-8).

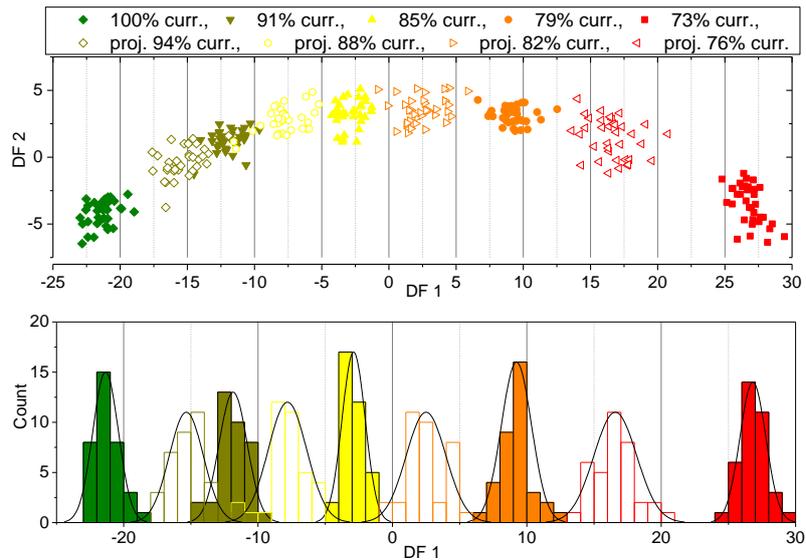


Abbildung 2-8. Beispiel für ein valides statistisches Modell: Projektion der Trainings- und Testdaten mit quantitativer Abbildung der Zielgröße entlang DF 1 [85].

Ein weit verbreitetes, für alle Arten von Klassifikatoren verwendetes Verfahren ist die Kreuzvalidierung (CV). Bei diesem wird der verfügbare Datensatz in Trainings- und Testdaten partitioniert, anhand derer das statistische Modell erzeugt bzw. getestet wird, sodass neben der allgemeinen Performanz Effekte wie Overfitting (vgl. Abbildung 2-3) aufgedeckt werden können. Die Kreuzvalidierungs-Klassifikationsrate beschreibt hierbei die Anzahl korrekter Klassifikationen relativ zur Anzahl aller getesteten Klassifikationen und wird vielfach als Benchmark verwendet [31], [86], [87].

Das einfachste CV-Verfahren ist die Holdout-Methode, welche den Datensatz in zwei Bereiche, typischerweise $\frac{2}{3}$ der Datenpunkte zum Training und $\frac{1}{3}$ zum Testen, unterteilt. Das Ergebnis kann stark variieren, je nachdem, wie die Datenpunkte partitioniert werden; gleichzeitig werden die verfügbaren Daten nur ineffizient genutzt.

Ein weiteres Verfahren ist das sog. Random Subsampling, bei dem eine randomisierte Unterteilung des Datensatzes in Trainings- und Testdaten mit k -facher Wiederholung erfolgt, dessen Klassifikationsrate über die k Experimente gemittelt wird.

Die k -fold Kreuzvalidierung (Abbildung 2-9) stellt einen systematischen Ansatz der Holdout-Methode dar und ist im Bereich des maschinellen Lernens am weitesten verbreitet. Bei dieser wird der Datensatz in k Bereiche gleicher Größe unterteilt, mit $k-1$ Bereichen trainiert und dem verbleibenden Bereich evaluiert. Dies wird k -fach wiederholt, sodass alle Datenpunkte einmal in der Testgruppe enthalten sind; die Klassifikationsrate wird über die einzelnen Ergebnisse gemittelt. Grundsätzlich wird

empfohlen, die Segmentierung stratifiziert vorzunehmen [88], d.h. die Häufigkeiten der Klassenzugehörigkeiten bei der Einteilung zu berücksichtigen, sodass die einzelnen Felder repräsentative Stichproben der Gesamtheit darstellen.

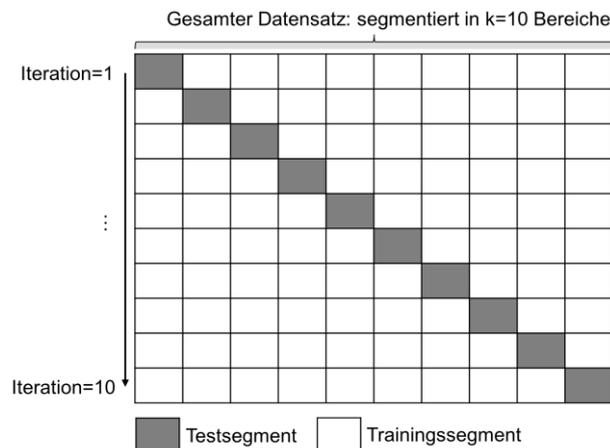


Abbildung 2-9. Vorgehen der k-fold Kreuzvalidierung mit k=10 nach [13].

Je weniger Datenpunkte zum Training gewählt werden (kleine Werte von k), desto pessimistischer ist die Abschätzung, da ein relevanter Teil der Information nicht in das statistische Modell einfließt. Bei hohen Werten von k (bis hin zu $k = n$ bei der Leave-one-out Kreuzvalidierung, LOOCV) gibt es große Überschneidungen bei den Trainingsdaten, die zu hochgradig korrelierten Modellen führen. Somit lässt das Verfahren nur in geringem Maße eine Aussage über die Generalisierbarkeit bzw. Übertragbarkeit der Trainingsdaten zu, da ein fast identisches Modell (ein Trainingselement wird jeweils variiert) n-fach evaluiert wird. Dieses grundsätzliche Problem der Kreuzvalidierung wird in der Literatur als Trade-Off zwischen Bias und Varianz bezeichnet. Kohavi [88] empfiehlt aus diesem Grund die 10-fold Kreuzvalidierung, die einen guten Kompromiss aus beiden Größen darstellt und somit ein geeigneteres Kriterium für die Beurteilung des Klassifikators darstellt als LOOCV, welche zudem mit einem erheblich höheren Berechnungsaufwand verbunden ist. Arlot [87] hingegen spricht keine pauschale Empfehlung aus, da die optimale Wahl von k stark von der Beschaffenheit des Datensatzes, etwa der Anzahl von Datenpunkten und Klassen abhängt.

3 Methodik zur teilautomatisierten multivariaten Sensordatenanalyse

3.1 Datengenerierung

Zur Erzeugung von aussagekräftigen statistischen Modellen müssen die zugrundeliegenden Daten verschiedene Anforderungen erfüllen. Hierfür ist auf Basis einer typischen generischen Anwendung ein Konzept für eine Labor-Prüfumgebung abzuleiten, mit der realistische Schadens- und Verschleißeffekte systematisch abgebildet werden sollen (Abbildung 3-1). Typischerweise sind die Maschinen bzw. Prüflinge, im Folgenden anhand der Beispiele hydraulisches und elektromechanisches Antriebssystem betrachtet, schon in der Anwendung standardmäßig mit Sensorik ausgestattet um eine spezifische Funktion zu erfüllen, etwa eine Positions- oder Lastregelung.

Bei der Datengenerierung sind insbesondere folgende Konzepte relevant:

- a) **Arbeitszyklus:** Industrielle Maschinen sind, etwa in der Produktion, häufig in Bearbeitungsprozesse eingebunden, deren Ablauf sich in kleinste, sich wiederholende Arbeitszyklen unterteilen lässt. Das Konzept der Arbeitszyklen wird für die Laborerprobung übernommen und als unterste Vergleichseinheit der statistischen Datenanalyse verwendet. Im Vergleich zur Gassensorik, wo ein Temperaturzyklus in Hinblick auf Sensitivität und Selektivität optimiert werden kann, ist in der industriellen Anwendung der Zyklusverlauf üblicherweise durch den übergeordneten Prozess vorgegeben und wird deswegen im Folgenden als nichtvariable Größe betrachtet.
- b) **Zielgrößenvariation:** Zum Trainieren des statistischen Modells müssen Sensordaten aufgezeichnet werden, die das Verhalten der Maschine unter dem Einfluss der Zielgröße, d.h. des Schadens-/Verschleißgrads, widerspiegeln. Im Versuch ist der Schweregrad für die automatisierte Auswertung sinnvollerweise so zu wählen, dass ein Spektrum von ersten Anzeichen bis hin zu deutlicher Degradation abgedeckt wird, jedoch ohne einen unspezifischen Funktionsausfall zu bewirken. Gleichzeitig können

Wiederholungen und eine Randomisierung der Zielgrößenvariation die Robustheit der Modellbildung deutlich erhöhen.

- c) **Störgrößen:** Neben den Zielgrößen wird das Verhalten auch durch Störgrößen (z.B. variierende Umgebungstemperatur, Luftfeuchtigkeit, Vibrationen, etc.) beeinflusst. Diese können gezielt mit in den Prüfablauf aufgenommen werden, sodass spezifisch Merkmale selektiert werden, die einer möglichst geringen Beeinflussung durch Störgrößen unterliegen und somit eine selektive Bewertung des Maschinenzustands erlauben.

Auf Basis der voran genannten experimentellen Größen sowie von Domänenwissen, etwa der Symptomatik von Schadensmechanismen und deren Zeitkonstanten, bekannten Störgrößen sowie der Prüfablaufgenerierung können die Anforderungen an die Instrumentierung und Datenerfassung abgeleitet werden. Konkret ist im ersten Schritt eine „Überinstrumentierung“, d.h. Ausstattung des Systems mit einer vergleichsweise hohen Anzahl von Sensoren das Ziel, welche in der realen Applikation aufgrund von Aufwand und Kosten nicht sinnvoll umsetzbar wäre. Zudem bedeutet jeder zusätzliche Sensor eine potentielle Störungsquelle, welcher die Zuverlässigkeit in konventionellen CMS reduziert.

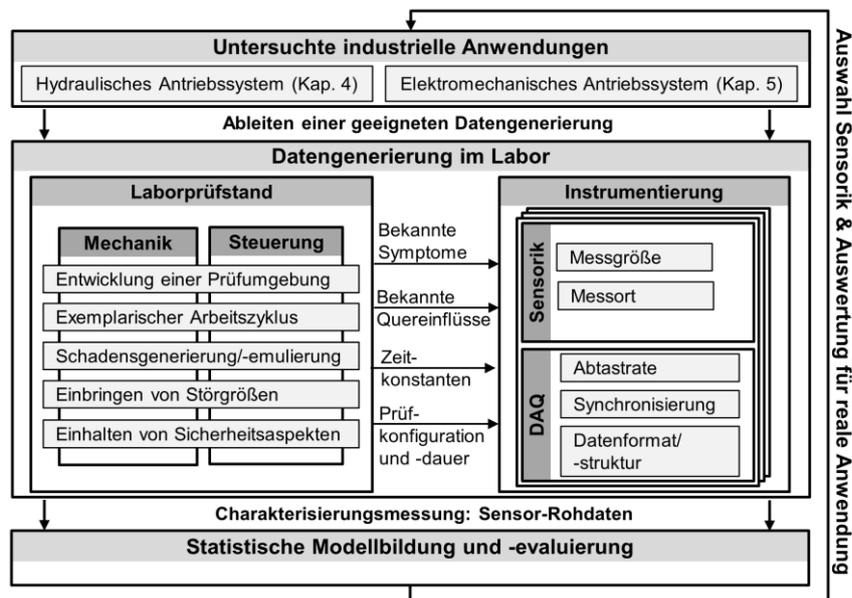


Abbildung 3-1. Vorgehen zur Datengenerierung.

Bei der Auswahl der zusätzlich installierten Sensorik wird über die Wahl von Messgröße/-ort sowie der Parameter der Datenerfassung (engl. data acquisition, DAQ), etwa der Abtastrate, implizit Wissen über die Anwendung und Schadenseffekte eingebracht, welches als ein wichtiger Aspekt die Qualität der Sensordatenbasis und somit maßgeblich die Performanz der statistischen Modellbildung beeinflusst. Die Ergebnisse von letzterer fließen wiederum in eine

Empfehlung ein, wie die Anzahl der Sensoren für die reale Anwendung sinnvoll reduziert und mit geeigneten Algorithmen der Merkmalsextraktion kombiniert werden kann, um eine Online-Zustandsbewertung durchführen zu können.

3.2 Datenanalyse

Die Schritte der multivariaten Sensordatenanalyse sind in Abbildung 3-2 dargestellt. Die **Signalvorverarbeitung** (Kap. 2.3.1) als erster und gleichzeitig optionaler Schritt dient der Signalkonditionierung der Rohdaten, mit der beispielsweise dominant überlagerte Störeinflüsse durch Standardisierung bzw. Signalskalierung unterdrückt werden. Gleichzeitig besteht die Gefahr, dass hierdurch relevante Information verloren geht, sodass der Nutzen für die individuelle Anwendung kritisch geprüft werden sollte.

Die Dimensionsreduktion beginnt mit der **Merkmalsextraktion** (Kap. 2.3.2). Hierzu werden die Sensordaten innerhalb eines jeden Arbeitszyklus im Zeitbereich segmentiert, sodass charakteristische Signalausschnitte einen zusammenhängenden dynamischen Vorgang (z.B. Ventilschalten, Beschleunigung) oder eine konstante Phase (konstante Last, Verfahren mit konstanter Geschwindigkeit) beschreiben. Wird die Information nicht im Zeitbereich vermutet, etwa bei primär periodischen Sensorsignalen (Körper-/Luftschall, Motorstrom) erfolgt nach der zeitlichen Segmentierung mittels DFT eine Transformation in den Frequenzbereich mit nachgelagerter Segmentierung der Frequenzbereiche des Amplitudenspektrums.

Die Anzahl und Bereiche der Segmentierungen im Zeit- und Frequenzbereich werden vom Benutzer vorgegeben und benötigen somit die Kenntnis über den Ablauf des Arbeitszyklus sowie eine grobe Abschätzung der zu erwartenden Frequenzbereiche. Aus den Signalausschnitten des Zyklus werden über die gesamte Charakterisierungsmessung statistische Parameter (Median, Varianz, Schiefe und Kurtosis) sowie formbeschreibende Merkmale (linearer Fit sowie Extremwerte und deren Position) bestimmt und in einem annotierten Merkmalspool abgelegt. Optional können aus den Merkmalsverläufen, gefenstert über eine vorgegebene Anzahl von Zyklen, weitere Sekundärmerkmale extrahiert werden, mit denen beispielsweise eine Mittelung über mehrere Zyklen oder eine Analyse der Varianz von Primärmerkmalen durchgeführt werden kann. Gegebenenfalls kann über das Einbeziehen größerer Zeitbereiche eine zuverlässigere Klassifizierung der Zielgröße erreicht werden, zumal eine Verschleiß- und Schadensprogression typischerweise im Bereich von Tagen, Wochen oder gar Monaten stattfindet. Eine zyklensweise Entscheidung ist

demzufolge nicht zwingend notwendig, sodass eine Zyklus-Analyse auch in festen Zeitintervallen denkbar wäre.

Der Faktor der Dimensionsreduzierung wird von einer Vielzahl von Parametern (z.B. Abtastraten, Zyklenunterteilung, etc.) beeinflusst und liegt typischerweise im Bereich 10^2 bis 10^4 . Das Vorgehen zielt primär auf eine gute Nachvollziehbarkeit und Verständlichkeit der Merkmale in Bezug zu den ablaufenden physikalischen Prozessen ab und weniger auf eine möglichst akkurate Approximation der Rohdaten.

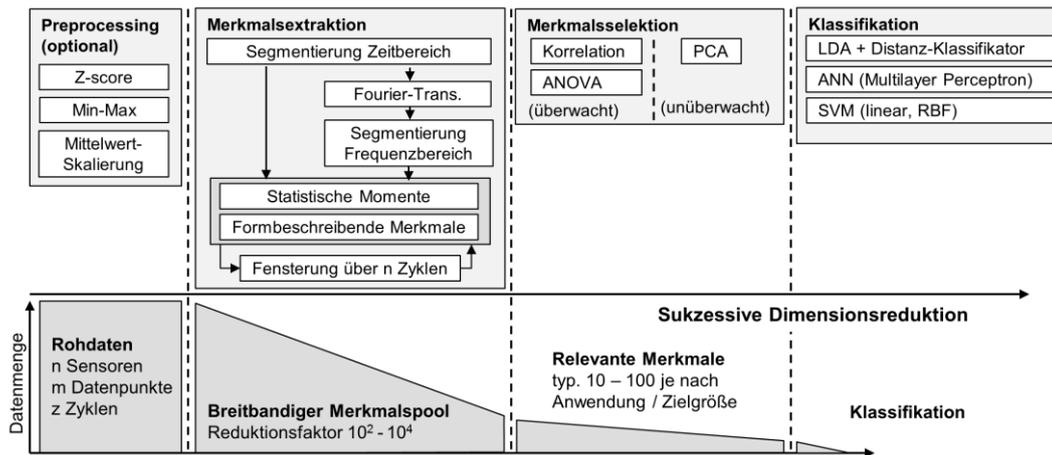


Abbildung 3-2. Vorgehen zur Sensordatenanalyse.

Aus den zuvor breitbandig extrahierten Merkmalen werden bei der **Merkmalsselektion** (Kap. 2.3.3) diejenigen ausgewählt, die im Bezug zur Zielgröße die höchste statistische Signifikanz aufweisen. Letztere wird durch den Vergleich der zeitlichen Verläufe der Merkmalswerte und der Zielgröße mithilfe von univariaten Kriteriumsfunktionen, also der linearen Pearson-Korrelation, der Spearman Ranglistenkorrelation oder anhand der Varianzanalyse (ANOVA) bestimmt. Abschließend erfolgt eine Sortierung nach deren Betragswerten und die Auswahl der n Merkmale mit dem höchsten Ranking. Die Wahl von n bestimmt, wieviel Spielraum dem nachfolgenden Klassifikator bei der Gewichtung der verfügbaren Merkmale überlassen werden soll. Insbesondere die LDA ist hierbei anfällig für Overfitting bei einer zu hohen Anzahl von Merkmalen. Daneben wird auch eine unüberwachte Merkmalsreduktion auf Basis der PCA untersucht.

Die abschließende **Klassifikation** erfolgt mittels LDA und Mahalanobis-Distanz Klassifikator. Um den Einfluss des Klassifikators zu bestimmen, werden zudem zwei alternative Referenzverfahren auf Basis von künstlichen neuronalen Netzen (Feed-Forward Multilayer Perceptron) sowie Support Vector Machines (mit linearem und RBF-Kernel) gegenübergestellt. Deren Vor- und Nachteile sind in Tabelle 3-1 aufgeführt.

Tabelle 3-1. Gegenüberstellung der verwendeten Klassifikatoren (+ gut, o neutral, - schlecht)

	LDA mit Distanzkl.	ANN (MLP mit Backpropagation)	SVM (linear / RBF Kernel)
Lösbare Klassifizierungsprobleme	linear	nichtlinear	linear/nichtlinear
Nachvollziehbarkeit / Visualisierung	+	-	o/-
Aufwand Training	+	-	- /-
Aufwand Anwendung	+	+	+/o
Anfälligkeit Overfitting	-	-	+/o
Globales Optimum garantiert	+	-	+
Statistische Anforderungen Merkmale	-	+	+

3.3 Realisierung

Das im vorangegangenen Kapitel aufgezeigte Konzept ist in Form eines Skriptes in Matlab R2016b implementiert. Der zweistufige Ablauf der Auswertung ist in Abbildung 3-3 illustriert. Im ersten Schritt wird zunächst aus den Rohdaten ein sogenanntes Source-File generiert, welches mit dem PCA/LDA-Tool [14] und dessen Nachfolger DAV³E (Data Analysis and Verification/Visualization/Validation Environment [89]) zur händischen Auswertung geladen werden kann. Beides sind am Lehrstuhl für Messtechnik entwickelte Software-Tools mit graphischer Benutzeroberfläche, welche u.a. vielfältige Möglichkeiten zur Selektion von Merkmals- und Zyklensubsets, zum Trainieren und Testen von PCA/LDA-Projektionen sowie zur Kreuzvalidierung bieten. Die Funktionen zur Merkmalsextraktion und -selektion sind hierbei modular erweiterbar und können mit geringem Aufwand mit weiteren Algorithmen ergänzt werden. Parameter-Studien können zudem mit einem Batch-Skript durchgeführt werden, mit dem die Klassifikationsrate bzw. Klassentrennung in Abhängigkeit der Zielgröße und Merkmalsanzahl sowie des verwendeten Klassifikators breitbandig analysiert werden kann.

Standardmäßig wird die Merkmalsselektion auf den gesamten Datensatz angewendet, sodass in der späteren Partitionierung zur Kreuzvalidierung die Information der Testdaten implizit durch die Merkmalselektion bereits einfließt; insofern sind die Ergebnisse tendenziell mit einem optimistischen Bias versehen. Eine saubere Auftrennung kann durch die Partitionierung in Trainings- und Testdaten bereits nach der Merkmalsextraktion erfolgen. In der Praxis ist der Unterschied jedoch, wie nachfolgend in Kapitel 4.9.3 gezeigt, mit den verwendeten Methoden vernachlässigbar.

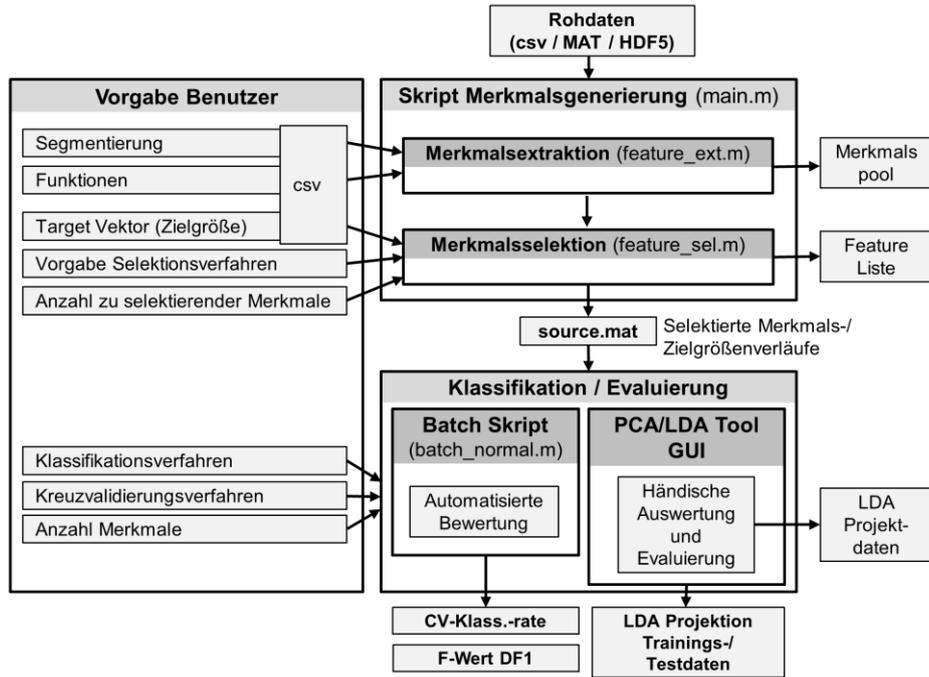


Abbildung 3-3. Ablauf der Sensordatenanalyse und Evaluierung in Matlab.

Eine Übersicht der für die Auswertung verwendeten Funktionen ist in Tabelle 3-2 dargestellt. Diese sind größtenteils aus Matlab und dessen Toolboxen entnommen.

Tabelle 3-2. Verwendete Matlab Funktionen.

		Beschreibung	Matlab Funktion	Toolbox
Merkmalsextraktion	statistisch	Median	med = median(A);	M A T L A B n a t i v
		Varianz (2. Moment)	va = var(A);	
		Schiefe (3. Moment)	skew = skewness(X);	
		Kurtosis (4. Moment)	kur = kurtosis(X);	
	Form	Linearer Fit	p = polyfit(x,y,1);	
		Extremwerte	maximum = max(A); minimum = min(A);	
Merkmalsredukt.	überwacht	Position lokaler Maxima	pks = findpeaks(data);	
		Lineare Korrelation	rp = corr(X,Y,'type','Pearson');	
		Ranglistenkorrelation	rs = corr(X,Y,'type','Spearman');	
	unüberw.	F-Wert einfaktorielle ANOVA	p = anova1(y,group);	Statistics / Machine Learning [90]
Klassifikation		Hauptkomponentenanalyse	[pcdata, p] = pca(data, energy_limit, pcaMethod)	LDA/PCA Tool [14] basierend auf Statistics / Machine Learning Toolbox
		LDA mit Mahalanobis-Distanz Klassifikator	[coeff, r] = lda2(data, classes, num_coeffcol, flag_stepwise); [result] = Mahal_Classifier(ldadata, tclass);	Neural Network [62]
		ANN Multilayer Perceptron	net = patternnet(hiddenLayerSize); [net,tr] = train(net,inputs,targets);	Statistics / Machine Learning [90]
		SVM (linear, RBF Kernel)	t = templateSVM(Name,Value); Mdl = fitcecoc(inputs,targets);	

4 Anwendungsszenario Hydraulisches System

4.1 Einführung

Die Hydraulik befasst sich mit der Kraft- und Leistungsübertragung auf Basis des statischen Drucks von Fluiden [91] – in industriellen Anwendungen meist Hydrauliköl. Hydraulische Systeme zeichnen sich insbesondere durch eine hohe Leistungsdichte aus, was sie für Mobilanwendungen, etwa im Bereich Bau-, Forst- und Bergbaumaschinen interessant macht. Aber auch bei stationären Hochkraft-Anwendungen, etwa Pressen und Vorschub- bzw. Spanneinheiten von Werkzeugmaschinen finden diese vielfach Verwendung. Weitere Vorteile sind die Möglichkeit zur Energiespeicherung und die effiziente Wandlung von rotatorischer und linearer Bewegung. Demgegenüber stehen als Nachteile auftretende Leitungsverluste sowie die Beeinflussung des Systems durch Viskositätsänderungen des Fluids. Obwohl hydraulische Systeme aufgrund ihrer kontinuierlichen Schmierung durch das Betriebsmedium eine geringe Verschleißneigung und hohe Lebensdauer aufweisen [91], treten doch einige typische Schadensszenarien gehäuft auf, sodass eine systematische Zustandsüberwachung sinnvoll ist, um die Anlagenverfügbarkeit zu steigern.

4.2 Problemstellung

Das Betriebsverhalten von hydraulischen Systemen ist neben dem Zustand der Hydraulikkomponenten von verschiedenen Einflussgrößen, etwa Umgebungs-, Prozess- und Fluidparametern abhängig (Abbildung 4-1). Zur gezielten Charakterisierung und Generierung von Trainingsdaten ist deswegen die Entwicklung einer generischen hydraulischen Prüfumgebung, mit der experimentell unter Laborbedingungen typische Schadensszenarien nachgestellt werden, notwendig.

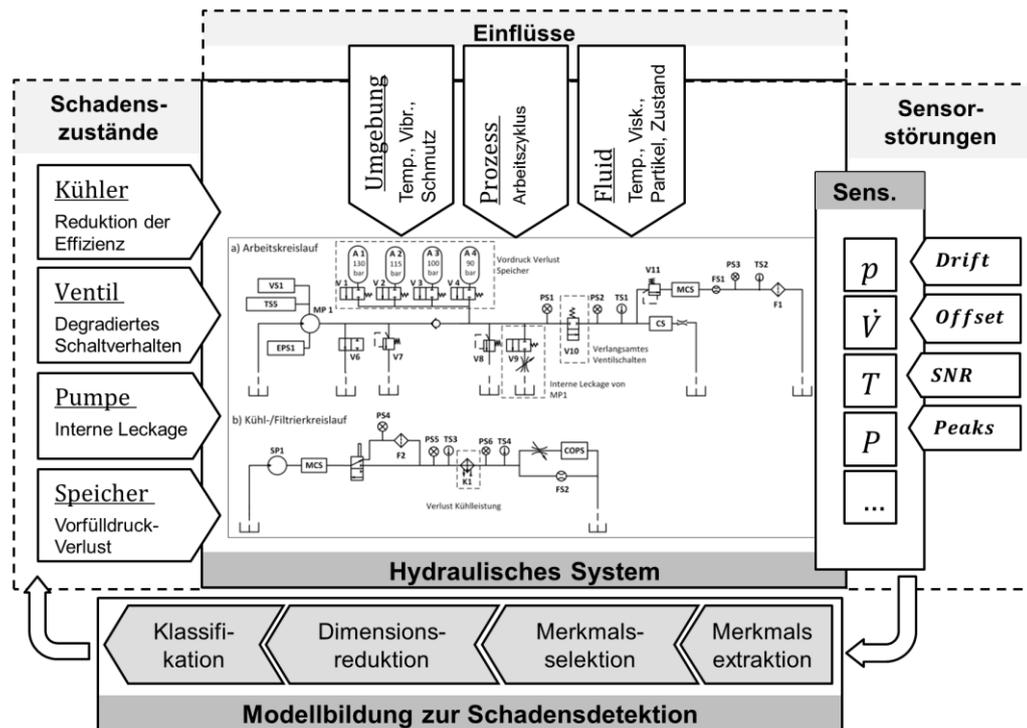


Abbildung 4-1. Hydraulisches System und dessen Einflussgrößen.

Der Fokus der Sensorik liegt hierbei auf Prozesssensoren, die typischerweise bereits zur Prozesssteuerung und -regelung verwendet werden, etwa Druck, Volumenstrom, Temperatur und Motorleistung, sodass keine zusätzliche Sensorik zum Condition Monitoring benötigt wird. Die in Kapitel 3 vorgeschlagene Methodik soll hierbei mit folgenden Aspekten untersucht werden:

- Erkennen und Quantifizieren von typischen Komponentenschäden durch die Verknüpfung von Prozesssensordaten mit multivariaten Verfahren
- Übertragbarkeit der statistischen Modelle bei ähnlich aufgebauten Systemen
- Langzeitstabilität sowie die Querempfindlichkeit gegenüber Störgrößen
- Anfälligkeit für Sensorstörungen, Detektion und Kompensation von Sensorfehlfunktionen und -ausfällen

Verglichen mit dem derzeitigen Stand der Technik in Sachen kommerzieller Fluid Condition Monitoring Systeme, die sich im Wesentlichen auf Sensorik, Datenerfassung und Visualisierung beschränken [92], [93], [94], soll somit ein deutlich höherer Grad an Information sowie eine höhere Robustheit erzielt werden.

4.3 Stand der Technik und Forschung

In der Literatur finden sich Arbeiten zur Zustandsüberwachung von hydraulischen Systemen primär im Kontext von physikalischer Modellierung, Simulation sowie

Parameterabschätzung, etwa mit physikalisch-statistischen Verfahren wie Kalman Filtern. Gleichwohl lässt sich in den letzten Jahren eine zunehmende Zahl von Veröffentlichungen im Bereich der datengetriebenen Zustandsüberwachung und Diagnose auf Basis multivariater Verfahren erkennen.

Die untersuchten Szenarien und Systeme sind heterogen und reichen von stationären Anlagen mit konstantem Arbeitszyklus [95] bis hin zu mobilen Anwendungen. He et al. [96] untersuchten etwa typische Be- und Entladevorgänge einer Baumaschine zur Erkennung von Schäden im hydraulischen System. Daneben sind Windenergieanlagen [15], [97] insbesondere im Off-Shore Bereich aufgrund ihrer kostenintensiven Wartung vielfach untersuchte Anwendungen. Neben dem Condition Monitoring komplexer Systeme werden hydraulische Teilsysteme und Komponenten, etwa Pumpen, Ventile und Speicher, betrachtet.

Ebenso heterogen ist die Instrumentierung der untersuchten Systeme, die von einzelnen Drucksensoren [97] bis hin zu komplexer Prozesssensorik (Drücke, Volumenströme, Temperaturen) [98] und Spezialsensorik zur Fluid- [15] und Schwingungsüberwachung [99], [100], [101] reicht. In den meisten Fällen erfolgt die Merkmalsextraktion auf Basis physikalischer Modelle [102], [103], [104], aber auch rein datengetriebene Verfahren zur Beschreibung der Signalform, etwa der Zeitkonstante von Drucktransienten beim Ladevorgang eines Hydrospeichers [99] oder des Zeit-Frequenz-Verhaltens (Wavelets) [97] werden vorgeschlagen.

Bei der multivariaten Auswertung (vgl. Kap. 2.3) werden in vielen Fällen künstliche neuronale Netze verwendet [96], [105], [106], [107] und in jüngerer Vergangenheit zunehmend Support Vector Machines [100], [108], [104]. Weitere Klassifikations- und Dimensionsreduktionsverfahren wie Random Forests, Decision Trees, k-NN, Logistic Regression, LDA und QDA [98] finden dagegen nur vereinzelt Verwendung.

Die Generierung von Trainingsdaten erfolgt mittels Simulation oder experimentell verursachter Schäden. Untersucht wurden etwa Kolben- und Dichtungsverschleiß beim Hydraulikzylinder [96], Spulenverschleiß und Verklemmen bei einem Proportionalventil [96], Schmutz- und Partikelkontamination bei einem elektrohydraulischen Servoventil [103], interne Leckage durch Verschleiß von Dichtungen und Dichtflächen bei einer Kolben- [100] und Zahnradpumpe [98], [109], unruhiges Pumpen-Laufverhalten sowie der Filterzustand [99].

Der Einfluss von Prozess-Störgrößen wird nur in wenigen Fällen systematisch untersucht. Liniger et al. [97] bezogen bei der Überwachung des Speicher-Vordrucks im Hydrauliksystem einer WEA Schwankungen der Umgebungstemperatur im Bereich von 22 bis 60 °C sowie den Einfluss von externer Leckage mit ein und

konnte damit die Selektivität der Analyse nachweisen, zeigte aber gleichzeitig, dass mit der Variation der Umgebungstemperatur die Zuverlässigkeit signifikant abnahm.

Ein Vergleich verschiedener Klassifikationsverfahren zum Condition Monitoring wurde von Adams [98] vorgestellt, bei dem Random Forests und Decision Trees bei der Leckage-Erkennung die besten Klassifikationsergebnisse lieferten, jedoch auf Basis einer rudimentären Merkmalsextraktion (einfache Mittelwertbildung der Sensordaten).

Insgesamt lässt sich zusammenfassen, dass bisherige Untersuchungen von hydraulischen Systemen sich auf Teilaspekte des maschinellen Lernens beschränken, aber nicht systematisch die gesamte Signalverarbeitungs- und Dimensionsreduktionskette von der Datengenerierung, Merkmalsextraktion und -selektion bis hin zur Klassifikation abbilden. Somit soll diese Arbeit einen Beitrag dazu leisten, diese Lücke konzeptionell zu schließen.

4.4 Komponenten des hydraulisches Systems und deren Schadensmechanismen

Die Vorgabe der zu untersuchenden Schadensszenarien sowie die Zusammenstellung des hydraulischen Systems erfolgte im Projekt durch die Fa. Hydac [110] und zielt primär auf eine Zustandsüberwachung der Komponenten Pumpe, Wegeventil, Hydrospeicher und Kühler. Deren Funktionsweise sowie typische Schadens- und Verschleißmechanismen werden nachfolgend erläutert. Daneben erfolgt eine Einführung der wichtigsten Eigenschaften des Betriebsmediums Hydrauliköl.

4.4.1 Pumpe

Hydraulische Pumpen, nachfolgend auf Basis von [91], [111] beschrieben, arbeiten nach dem Verdrängerprinzip und erzeugen einen theoretischen Volumenstrom Q_{th} , der sich aus der Antriebsdrehzahl n und dem Verdrängervolumen V berechnet.

$$Q_{th} = V \cdot n \quad (4.1)$$

Der tatsächlich verfügbare Volumenstrom Q_{real} fällt jedoch aufgrund druckabhängiger volumetrischer Verluste geringer aus; zu diesen zählen innere und äußere Leckageströme Q_L , Gas- oder Dampfeinschlüsse im Fluid Q_S sowie, bei Druckanstieg, ein Verluststrom Q_K aufgrund von Fluidkompressibilität. Somit gilt:

$$Q_{real} = Q_{th} - Q_L - Q_K - Q_S \quad (4.2)$$

Des Weiteren treten drehwinkelabhängige Pulsationen des Förderstroms aufgrund von Pumpengeometrie und Fluidkompressionseffekten auf. Dieser Effekt kann jedoch durch den Einsatz eines Hydrospeichers (hydraulische Kapazität) oder konstruktive Maßnahmen (gezielte Dämpfung durch $\lambda/4$ -Schlauchlänge der Pulsationsfrequenz) reduziert werden. Für Details sei an der Stelle auf weiterführende Literatur verwiesen [91],[111]. Eine spektrale Analyse der Signalform dieser Druckpulsation kann, ähnlich zur Vibrationsanalyse, gezielt zur Zustandsüberwachung genutzt werden [103].

Gleichzeitig erfolgt eine Wandlung von mechanischer in hydraulische Leistung, mit dem Drehmoment M_{th} des antreibenden Motors bei Kreisfrequenz ω , dem Volumenstrom Q_{th} und dem aufgebauten Differenzdruck Δp :

$$P_{th} = M_{th} \cdot \omega = Q_{th} \cdot \Delta p \quad (4.3)$$

Aufgrund von Verlustmomenten durch Newtonsche Reibung $M_{R\omega}$, Coulombscher Reibung M_{RC} sowie Stoß- und Massenkräften M_{Rp} ist das tatsächlich benötigte Antriebsmoment der Pumpe M_{real} :

$$M_{real} = M_{th} + M_{R\omega} + M_{Rp} + M_{RC} \quad (4.4)$$

Der Wirkungsgrad der Pumpe η_p setzt sich somit aus einer volumetrischen (η_{vP}) und einer mechanischem (η_{mech}) Komponente zusammen:

$$\eta_p = \frac{P_{in}}{P_{out}} = \eta_{vP} \cdot \eta_{mech} = \frac{P_{v,real}}{P_{v,th}} \cdot \frac{P_{mech,th}}{P_{mech,real}} = \left(1 - \frac{Q_L + Q_K + Q_S}{Q_{th}}\right) \cdot \frac{M_{th}}{M_{th} + M_{R\omega} + M_{Rp} + M_{RC}} \quad (4.5)$$

Der Volumenstrom Q_L einer Leckage kann mithilfe der Querschnittsfläche A_D bei bekannter Druckdifferenz Δp vor und hinter der Leckagestelle mit der Blendengleichung berechnet werden zu [112]:

$$Q_L = \alpha \cdot A_D \cdot \sqrt{\frac{2 \cdot \Delta p}{\rho}} \quad (4.6)$$

Die geometrieabhängige Durchflusszahl α beschreibt den Einfluss von Reibungs- und Geschwindigkeitseffekten sowie Turbulenzen [112].

Der schematische Aufbau einer Zahnradpumpe mit Innenverzahnung, auf der in den nachfolgenden Experimenten der Fokus liegt, ist in Abbildung 4-2a dargestellt. Das innere Zahnrad wird über die Ritzelwelle mechanisch angetrieben und versetzt das Hohlrad mit Innenverzahnung in Rotation. Hierbei entstehen sich öffnende Zahnkammern, die Unterdruck bilden und somit das Fluid aus dem Tank ansaugen können. Die Volumenänderung erfolgt typischerweise über einen weiten Drehwinkelbereich von 120° , was eine vergleichsweise hohe Laufruhe dieses Pumpentyps bewirkt. Das Fluid wird entlang eines eingelegten Dichtkeils zur

Druckseite der Pumpe befördert. Auf der Druckseite bewirkt die ineinandergreifende Verzahnung eine Volumenverringering und somit den Druckaufbau.

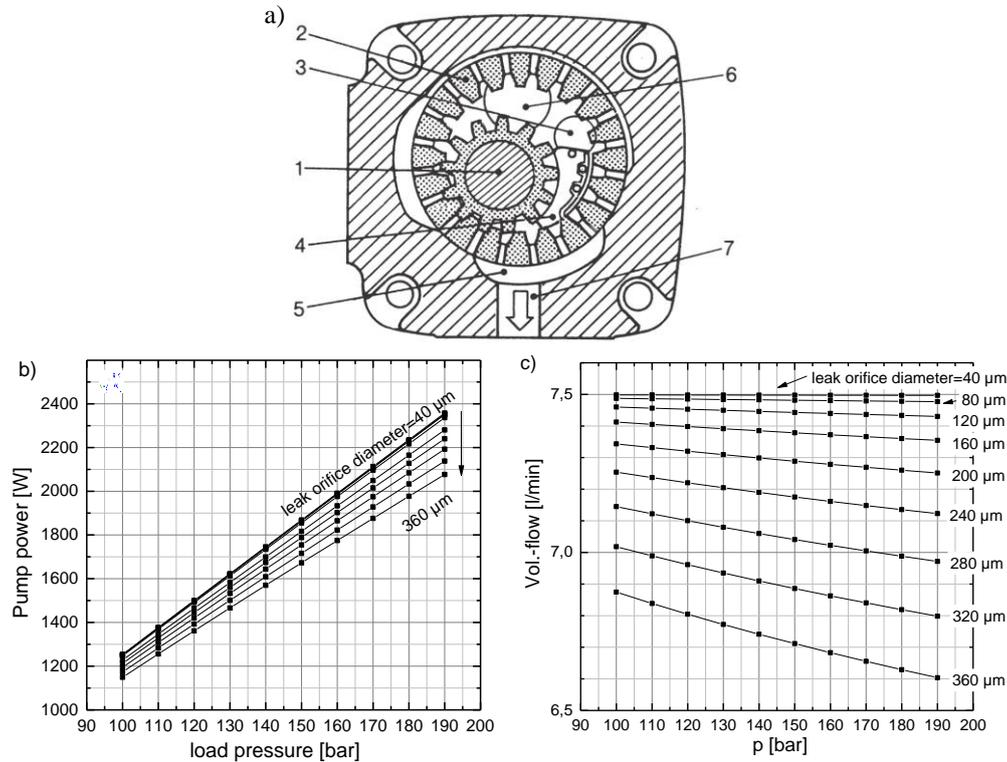


Abbildung 4-2. (a) Zahnradpumpe mit Innenverzahnung [113]: 1 Ritzelwelle, 2 Hohlräder, 3 Stift, 4 Füllstück/Dichtkeil, 5 Hydrostatisches Lager, 6 Sauganschluss, 7 Druckanschluss, (b) AMESim-Simulation interner Pumpenleckage: Pumpenvolumenstrom und -leistung in Abhängigkeit des Gegendrucks und der Verschleiß-Geometrie, simuliert als Bypass-Blende (Ölmodell FP04 bei 40°C, $\eta=51\text{cP}$).

Das wesentliche Kriterium für den Zustand einer Pumpe ist die dichte Abtrennung zwischen Ansaug- und Druckseite. Abbildung 4-2 (b,c) zeigt den Zusammenhang zwischen dem Ausmaß interner Undichtigkeit und der verfügbaren hydraulischen Pumpenleistung bzw. des Förderstroms.

Pietkiewicz [114] untersuchte die Ursachen von Ausfällen bei Außenzahnradpumpen und stellte fest, dass der größte Teil durch Verschleiß der Gleitplatten hervorgerufen wurde, die axial das Verdrängervolumen abdichten und somit in direktem Kontakt zu den sich bewegenden Zahnradern stehen. Die häufigsten Verschleißformen waren hierbei Kratzer $> 16 \mu\text{m}$ in 74,0 % der Fälle, Unebenheiten $> 100 \mu\text{m}$ (67,7 %), Korrosion (45,2 %) und Abrieb der Kupfer-Beschichtung (32,3 %) [114]. Dagegen weist die Untersuchung von Hlawitschka [115] an 150 Zahnradpumpen, die in der Landtechnik eingesetzt wurden, darauf hin, dass primär das Radialspiel zwischen Zahnrad und Gehäuse aufgrund von Verschleiß der häufigste Ausfallgrund ist. Auf Basis eines physikalischen Modells entwickelten Lamoureux et al. [116] einen Zustandsindikator für Zahnradpumpen, mit dem das Ausmaß unerwünschter interner und externer Leckagen abgeschätzt werden kann.

Als wesentliche Ursachen für erhöhten Verschleiß gelten:

- Unzulässige Betriebsparameter des Öls (Partikelkontamination, Viskosität, freie Luft in Öl)
- Unzulässige Betriebsparameter der Pumpe (Überlast, Lastsprünge, Drehzahl)
- Kavitationserosion und Mikro-Diesel-Effekt durch Luftblasenimplosion im Fluid [117]

4.4.2 Wegeventil

Wegeventile sind unverzichtbare Komponenten zur Steuerung von Fluidströmen in Hydrauliksystemen. Der Aufbau eines einfachen direktgesteuerten 2/2-Wege-Sitzventils ist in Abbildung 4-3a dargestellt. Hierbei sperrt und öffnet der von einem Hubmagnet bewegte Steuerkolben den Flusspfad zwischen den Hydraulikanschlüssen 1 und 2. Im unbestromten Zustand wird der Steuerkolben des Ventils von einer Feder im geöffneten (normally open, NO) oder geschlossenen Zustand gehalten (normally closed, NC), wobei im Folgenden der Fall NC betrachtet wird.

Mathematisch kann die Bewegung des Kolbens analog zu einem schwach gedämpften Feder-Masse-System beschrieben werden. Zur Bewegung des Kolbens müssen folgende Kraftkomponenten überwunden werden [118], [119]:

$$F_{Aktor} > F_{Tr} + F_{Feder} + F_{RN} + F_{RC} + F_{Str} \quad (4.7)$$

$$\text{mit Trägheitskraft } F_{Tr} = m_{Kolben} \cdot \ddot{x} \quad (4.8)$$

$$\text{Federkraft } F_{Feder} = (x_{vor} + x) \cdot c_F \quad (4.9)$$

$$\text{Viskose Reibung } F_{RN} = d_{RN} \cdot \dot{x} \quad (4.10)$$

$$\text{Coulombsche Reibung } F_{RC} = \text{sign}(\dot{x}) \cdot \mu \cdot F_N \quad (4.11)$$

$$\text{Strömungskraft } F_{Str} = k_{Str}(Re) \cdot \Delta p \cdot x \cdot \cos(\varepsilon) \quad (4.12)$$

c_F ist die Federkonstante der Rückstellfeder, d_{RN} der Koeffizient der viskosen Reibung bei laminarer Strömung, $k_{Str}(Re)$ der Strömungskoeffizient und ε der Einströmwinkel; die Trägheitskraft des Kolbens und die Coulombsche Reibung können aufgrund der geringen Stellbeschleunigung und -geschwindigkeit bei magnetbetätigten Ventilen vernachlässigt werden [120]. Für eine detaillierte mathematische Beschreibung des Ventilverhaltens sei auf [119] und [120] verwiesen.

Im betrachteten Fall eines direktgesteuerten Ventils wird die Kraft mit einem elektromagnetischen Hubmagneten erzeugt. Die Magnet- oder auch Reluktanzkraft,

die in Richtung des Induktivitätsmaximums wirkt, d.h. den Tauchkern in die Spule hineinzieht, ist definiert als

$$F_{mag} = \frac{\partial}{\partial x} \int \psi(i, x) di \quad (4.13)$$

Da nach Backé [120] bei Hubmagneten ohne Kennlinienbeeinflussung im Tauchkern meistens keine Sättigung vorliegt, kann für diesen Fall ein linearer Zusammenhang zwischen dem verketteten magnetischen Fluss ψ und dem Erregerstrom angenommen werden, sodass die erzeugte Kraft quadratisch vom Ansteuerstrom i der Spule sowie linear von der Induktivitätsänderung in Hubrichtung abhängt.

$$F_{mag} = \frac{1}{2} i^2 \frac{dL(x)}{dx} \quad (4.14)$$

Dies wird insbesondere bei Proportionalventilen zur vereinfachten Steuerung angestrebt, üblicherweise liegt bei Wegeventilen jedoch eine magnetische Sättigung vor. Die auslenkungsabhängigen Kräfte am Ventil überlagern sich qualitativ wie in Abbildung 4-3b dargestellt. Das typische Schaltverhalten eines Magnetventils ist in (c) dargestellt: Wird die Spule bestromt, baut sich zunächst abhängig von der Induktivität ein Magnetfeld auf, bis dieses groß genug ist (I_1) den Ventilkolben in Bewegung zu setzen. Diese Bewegung induziert einen entgegengesetzten Strom, sodass der Gesamtspulenstrom auf I_2 absinkt. Gleichzeitig öffnet sich das Ventil, sodass das Fluid durch das Ventil strömen kann und sich der Differenzdruck abbaut. Ist der Kolben in der Endposition angelangt, steigt der Spulenstrom auf den stationären, vom Widerstand der Spule bestimmten Endwert I_3 an.

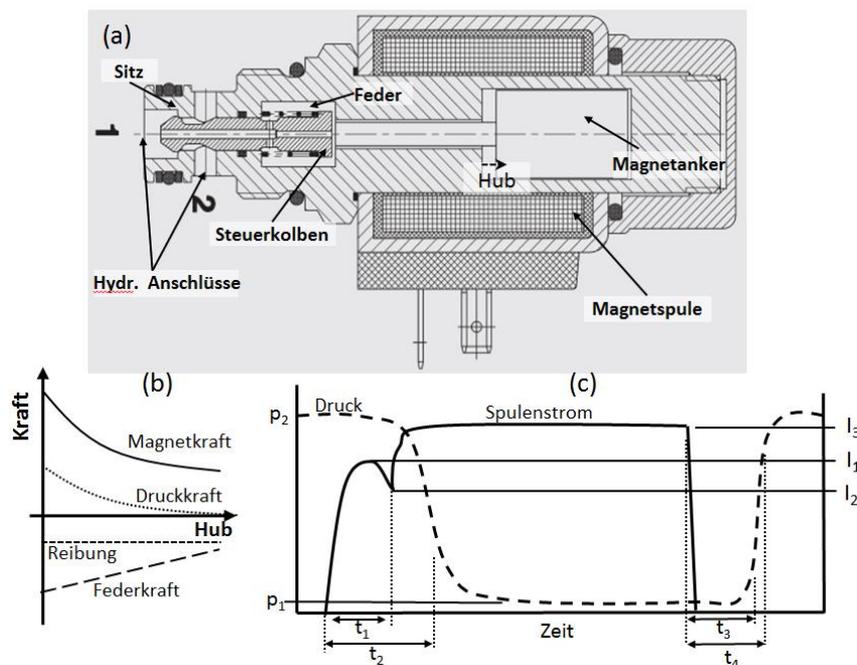


Abbildung 4-3. a) Aufbau Sitzventil nach [121], b) überlagerte Kräfte beim Schalten über den Hubweg nach [122], c) zeitlicher Verlauf des Spulenstroms und Fluiddrucks beim Be- und Entstromen der Spule nach [122].

Der Vorgang des Ventilschaltens ist von einer Vielzahl von Parametern beeinflusst. Pültz [123] untersuchte das Schaltverhalten eines direktgesteuerten magnetbetätigten 2/2-Wegesitzventils in Abhängigkeit verschiedener Parameter und stellte eine relativ geringe Temperaturabhängigkeit (10 ms Verzögerung bei 20 K Temperaturerhöhung), eine deutliche Abhängigkeit vom Gegendruck (bis zu 100 ms Verzögerung bei 180 bar) sowie eine gravierende Auswirkung der Standzeit bei hohem Betriebsdruck im geschlossenen Zustand (bis zu 300 ms Verzögerung bei 180 bar bei über 10 min) fest. Somit ist der Vergleich des Absolutwerts der Ventilschaltzeit unterschiedlicher Anwendungen als Zustandsindikator nicht sinnvoll; gleichwohl deuten relative Änderungen bei konstanten Prozess- und Umgebungsparametern durchaus auf eine Verschiebung einzelner Kraftanteile und somit auf mögliche Ventilschäden hin. Branco et al. [118] nennen in dem Kontext als häufigste Schadensszenarien:

- Spule: Bei Stromstärken oberhalb der magnetischen Sättigung erfolgt eine Erhitzung (im Extremfall bis hin zur permanenten Schädigung) der Spule und somit eine Erhöhung der Impedanz, was bei vorgegebener Spannung zu einem geringeren Spulenstrom und somit einer reduzierten Stellkraft führt. Des Weiteren sind Ventile in mobilen Anwendungen einem breiten Temperaturspektrum ausgesetzt (typ. Spezifikation $-40 \dots 120 \text{ }^\circ\text{C}$), was im Betrieb zu starken Variationen des Spulenwiderstands im Bereich $-23,4 \text{ } \% \dots +39 \text{ } \%$ von R_{20} [124] und somit auch der Magnetkraft bei spannungsgesteuerter Umschaltung führt.
- Feder: Bei einem Bruch ist die Rückstellung des Ventils nicht gewährleistet, daraus resultiert eine undefinierte Schaltstellung bei unbestromter Spule.
- Fluid: Häufigster Ausfallgrund des Ventils ist eine unzulässig hohe Partikelkontamination des Öls (vgl. Kap. 4.4.5). Mögliche Folgen sind eine veränderte p-Q-Kennlinie aufgrund des versperrten Flusspfades, eine gehemmte Schließbewegung aufgrund von Reib- und Verkeileffekten mit großen Partikeln ($> 5 \mu\text{m}$) sowie der beschleunigte Verschleiß der Steuerkante. Daneben können freie Phasen von Luft oder Wasser im Öl zu Fehlfunktionen, etwa durch erhöhte Schwingungsneigung [125], führen.

4.4.3 Hydrospeicher

Hydrospeicher zählen zu den Gasdruckflüssigkeitsspeichern und sind in der Lage, ein bestimmtes Nutzvolumen Hydrauliköl aufzunehmen und im Bedarfsfall wieder an den Kreislauf abzugeben. Sie werden in Hydrauliksystemen zur

Energiespeicherung, Notbetätigung, Lecköl- und Volumenkompensation sowie zur Schockabsorption und Pulsationsdämpfung eingesetzt.

Die damit verbundene Energiespeicherung erfolgt üblicherweise über die Kompression einer Gasfeder (Füllgas meist N_2), die je nach Bauart über bewegliche Dichtflächen (Kolbenspeicher), oder mittels Elastomerelementen (Membran- und Blasenspeicher) von der Fluidphase separiert wird (Abbildung 4-4). Die Zustandsbeschreibung des Gases erfolgt über die Polytropengleichung idealer Gase [91].

Hierbei gilt:

$$p \cdot V^n = p_1 \cdot V_1^n = \text{const.} \quad (4.15)$$

Je nach Zykluszeit der Zustandsänderung kann von isothermen ($n = 1$), adiabaten ($n = \text{Isentropenexponent } \kappa = 1,4$ für zweiatomigen Stickstoff) oder polytropen ($1 < n < \kappa = 1,4$) Randbedingungen ausgegangen werden. Im Falle der Anwendung als Energiespeicher (Zykluszeit < 1 min.) erfolgt die Zustandsänderung näherungsweise adiabatisch.

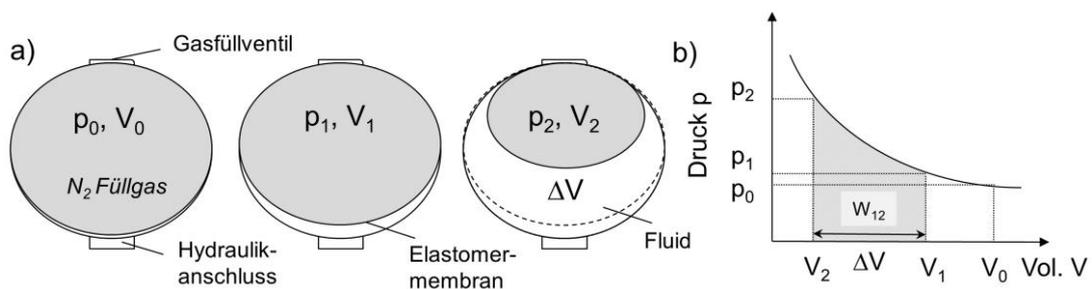


Abbildung 4-4. (a) Aufbau und Betriebszustände Membranspeicher, (b) qualitatives p-V-Diagramm nach [111].

Ein typisches Problem stellt der Verlust des Gasfülldrucks dar, von dem insbesondere der Kolbenspeicher betroffen ist. Aber auch bei den hermetisch dichten Bauarten wie dem Membranspeicher treten aufgrund von Permeation über längere Zeiträume signifikante Leckageverluste auf. Will [111] nennt hierbei die Größenordnung von 1 - 10 % Verlust Gasvolumen pro Jahr. Die Fa. Parker empfiehlt eine Prüfung des Gasfülldrucks in Intervallen von mindestens drei Monaten [126]. Eine Überwachung ist insbesondere bei Anwendungen mit wechselnden Umgebungstemperaturen (Mobilhydraulik, WEA) und somit auch stark variierenden Permeationsraten von Interesse.

Die Folge eines geringeren Gasfülldrucks p_0 ist ein reduziertes Nutzvolumen ΔV , also das Fluidvolumen, welches beim Wechsel von p_1 auf p_2 vom Hydrospeicher aufgenommen bzw. nachfolgend wieder abgegeben werden kann. Für den adiabaten Fall gilt:

$$\Delta V = V_0 \cdot p_0 \frac{1 - \left(\frac{p_1}{p_2}\right)^{\frac{1}{n}}}{p_1} \quad (4.16)$$

Somit ist bei unzureichender Wartung mit einer verschlechterten Leistung des Hydrospeichers und, bei einem Abfall von p_0 unter das maximal zulässige Verhältnis $\frac{p_2}{p_0}$ (vgl. Tabelle 4-1), mit einem frühzeitigen Ausfall des Hydrospeichers, etwa durch unzulässige Walkbelastung des Elastomers, zu rechnen.

Tabelle 4-1. Einsatzbedingungen und Parameter hydropneumatischer Speicher nach [91], [111].

Bedingung	Blasenspeicher	Membranspeicher	Kolbenspeicher
Gasfülldruck p_0	$\leq 0,9 p_1$ = 0,6 bis 0,9 p_m (Schockabsorbtion) = 0,6 p_m (Pulsationsdämpfung)	$\leq 0,9 p_1$	$\leq p_1 - 5 \text{ bar}$ $\geq 2 - 10 \text{ bar}$
Max zul. $\frac{p_2}{p_0}$	$\leq 4:1$	$\leq 6:1$ bis $8:1$	Keine Einschränkung
Max. Vol.-strom	$\leq 15 \text{ l/s}$	$\leq 6 \text{ l/s}$	Kolbengeschw. $\leq 3,5 \text{ m/s}$
Überwachungsmöglichkeit	bedingt	nein	ja
Schadensanfälligkeit	relativ hoch	gering bis mittel	gering

Abbildung 4-5 zeigt exemplarisch die Zusammenhänge der Prozessgrößen beim Lade- und Entladevorgang eines Hydrospeichers bei Gasvorfülldrücken im Bereich von 130 bis 90 bar, reduziert in 10 bar Schritten. Alle Parameter der Simulation (LMS AMESim) sowie die Druckstufen p_1 und p_2 wurden in Anlehnung an den für die nachfolgenden Experimente genutzten Hydraulikprüfstand (Kap. 4.5) gewählt.

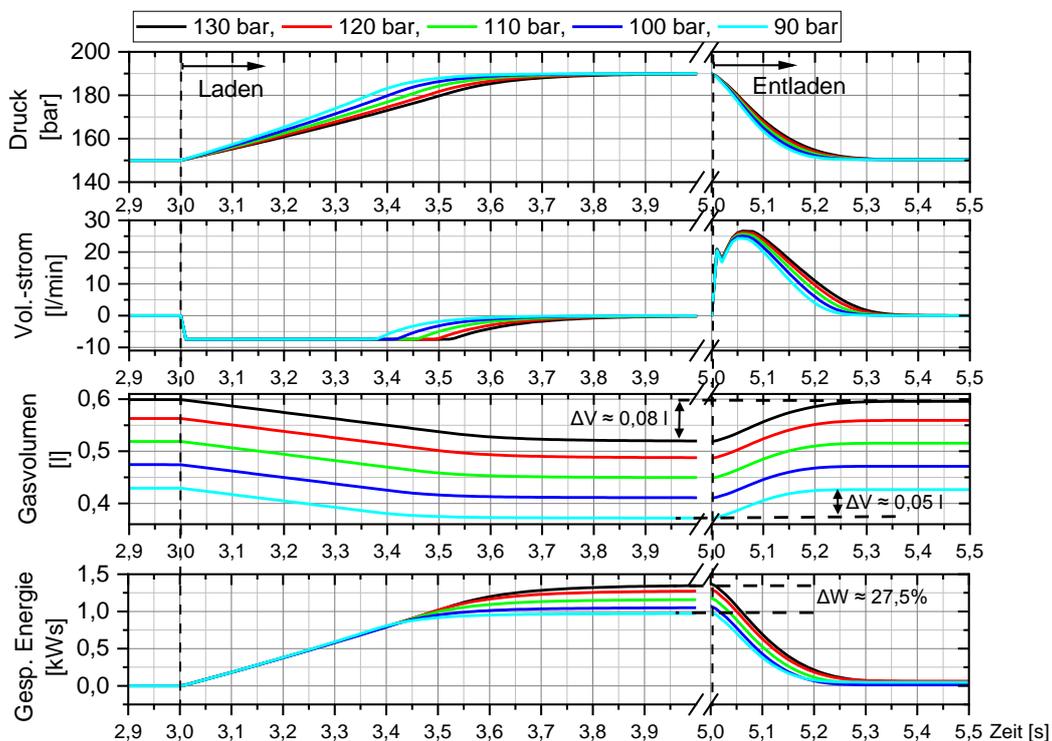


Abbildung 4-5. Simulierte Prozessgrößen beim Hydrospeicher beim Lade- und Entladevorgang in Abhängigkeit des Gasvorfülldrucks p_0 mit den Druckstufen 90, 100, 110, 120 und 130 bar mit dem Öldruck, dem Volumenstrom aus dem Speicher, dem Gasvolumen sowie der gespeicherten Energie. Zustandsbeschreibung als reales Gas nach dem Modell von Peng-Robinson in AMESim.

Zu erkennen ist die deutliche Verringerung des Nutzvolumens ($\approx 37,5\%$) sowie der vom Hydrospeicher gespeicherten Energie ($\approx 27,5\%$) bei einem Absinken des Vordrucks von 130 auf 90 bar. Bei reduziertem p_0 ist das Gasvolumen V_1 bei der vorgegebenen Druckstufe p_1 schon signifikant vorkomprimiert, sodass sich der nutzbare Hubbereich der Gasfeder reduziert und der Speicher nicht mehr im optimalen Arbeitsbereich (vgl. Tabelle 4-1) betrieben wird. Des Weiteren zeigt Abbildung 4-5, dass Änderungen von p_0 anhand des Druck- und Volumenstromverlaufs mit geeigneter Merkmalsextraktion, etwa anhand der Steigung der Druckrampe während des Ladevorgangs, identifiziert werden können. Die Ladedauer und Druck-Rampensteigung hängen hierbei nicht linear mit dem Gasvordruck zusammen, wie man anhand der idealen Gasgleichung vermuten könnte, sondern nähern sich in der Praxis (reales Gas) mit zunehmendem Vordruck an.

Von besonderer Relevanz sind sicherheitskritische Anwendungen, etwa die Notabschaltung von Windenergieanlagen [97], die im Falle eines Stromausfalls die Rotorblätter mithilfe der in einem Hydrospeicher gespeicherten Energie auf einen Anstellwinkel von 90° verfährt, sprich „aus dem Wind“ dreht. Diese Funktion kann bei reduziertem Gasfülldruck nicht oder nicht vollständig durchgeführt werden, was bei stürmischer Wetterlage zu kostspieligen Schäden führen kann.

4.4.4 Öl-Luft-Kühler

In der Praxis werden meist Fluidtemperaturen zwischen 50°C und 60°C bei stationären Anlagen und bis zu 85°C bei mobilhydraulischen Anwendungen angestrebt [111]. Je nach Anwendung kann es somit notwendig sein, Flüssigkeitskühler oder -vorwärmer einzusetzen. Insbesondere wenn die systembedingte Wärmeabfuhr nicht ausreicht, um stationär den Richttemperaturbereich zu gewährleisten, muss eine zusätzliche Kühlung eingesetzt werden. Diese wird meist in Kombination mit einer Filtrierung in Form von Wasser-/Luftkühlung oder eines Kühlaggregates im Nebenstrom realisiert.

Die vom Kühler abgeführte Wärme wird im Wesentlichen von der Advektion bestimmt [127]:

$$P_{\text{kühl}} = \dot{m}_{\text{öl}} \cdot c_p \cdot \Delta T_{\text{öl}} \quad (4.17)$$

\dot{m} beschreibt hierbei den Massenstrom des Öls durch den Kühler, c_p die spezifische Wärmekapazität ($\approx 1,764 \text{ kJ/kgK}$ [112]) und ΔT die Temperaturdifferenz des Öls vor und nach dem Kühler.

Für die Effizienz des Kühlers spielt die Wärmeabfuhr an die Umgebung eine entscheidende Rolle. Hierbei gilt allgemein für den stationären Wärmestrom bei der Durchgangsfläche A , der Temperaturdifferenz ΔT zwischen Öl und Umgebungsluft und dem Wärmedurchgangskoeffizienten k [128]:

$$\dot{Q} = k \cdot A \cdot \Delta T \quad (4.18)$$

Da in der Praxis mit Beeinträchtigungen des Wärmetauschers durch Ablagerungen und Schmutz zu rechnen ist, kann das Gesamtsystem als mehrschichtiger Wärmedurchgang betrachtet werden. Bei einer Platte mit N Schichten gilt [129]:

$$k = \frac{1}{\frac{1}{\alpha_i} + \sum_{j=1}^N \frac{s_j}{\lambda_j} + \frac{1}{\alpha_a}} \quad (4.19)$$

mit $\alpha_i, \alpha_a =$ Wärmeübergangskoeffizient der Innen- und Außenseite

$\lambda_j =$ Wärmeleitkoeffizient der j -ten Schicht

$s_j =$ Schichtdicke der j -ten Schicht

Im Falle eines mehrschichtigen Rohres mit N Hüllschichten gilt analog:

$$k = \frac{1}{\frac{1}{r_i \alpha_i} + \sum_{j=1}^N \frac{1}{\lambda_j} \ln\left(\frac{r_{a,j}}{r_{i,j}}\right) + \frac{1}{r_a \alpha_a}} \cdot \frac{1}{r} \quad (4.20)$$

Abbildung 4-6 zeigt eine Abschätzung des Störeinflusses von unerwünschten Ablagerungen am Wärmetauscher auf die Wärmeabgabe an die Umgebung, etwa Staub bei Öl-Luft-Kühlern oder Ablagerungen wie sogenanntes Kristallisations-, Partikel- oder Korrosionsfouling [130] bei Öl-Wasser-Kühlern. Es lässt sich abschätzen, dass selbst Ablagerungen geringer Schichtdicke mit niedriger Wärmeleitfähigkeit die Kühlleistung erheblich reduzieren. Aus diesem Grund ist es bei der Auslegung des Kühlsystems üblich, eine Sicherheit von mindestens 10 % der benötigten Kühlleistung zu berücksichtigen [127].

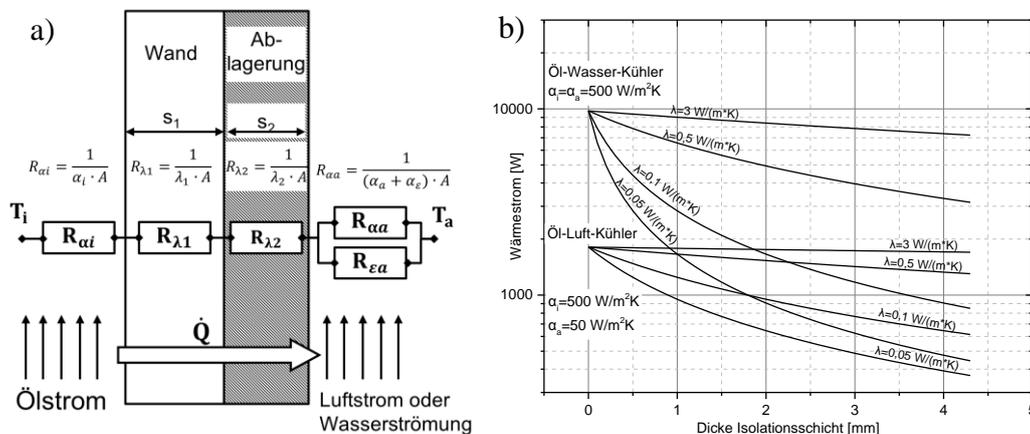


Abbildung 4-6. Kühler: (a) verwendetes Wärmewiderstandsnetzwerk, (b) Wärmestrom vs. Schichtdicke s_2 der Verschmutzung sowie Wärmeleitfähigkeit der Ablagerung. Angenommen wird

eine Rohrwandstärke von 2 mm (Edelstahl, $\lambda_{Rohr} \approx 20 \frac{W}{m \cdot K}$), eine Isolationsschicht variabler Dicke ($\lambda_{is} = 0,05 \frac{W}{m \cdot K}$ bei Staub, $3 \frac{W}{m \cdot K}$ bei Kalk), bei einer Austauschfläche $A = 1 \text{ m}^2$ und $\Delta T = 40 \text{ K}$. Der Wärmeübergangskoeffizient wurde mit $\alpha = 500 \frac{W}{m^2 \cdot K}$ (Fluid mit erzwungener Konvektion) bzw. $\alpha = 50 \frac{W}{m^2 \cdot K}$ (Luft bei erzwungener Konvektion) angenommen [129].

4.4.5 Hydrauliköl

In einem hydraulischen System dient das Fluid der Leistungsübertragung, Schmierung, Wärmeabfuhr und dem Korrosionsschutz. Bei üblichen Anforderungen werden paraffinbasierte Öle auf Mineralölbasis eingesetzt. Falls jedoch spezifische Eigenschaften, etwa biologische Abbaubarkeit und erhöhte Alterungsbeständigkeit gefordert werden, sind auch synthetische Öle (Polyalphaolefine, Carbonsäureester) im Einsatz. Neben den Eigenschaften des Grundöls werden die Fluideigenschaften durch die Zugabe von Additiven beeinflusst. Sie dienen beispielsweise dem Oxidations-, Korrosions- oder Verschleißschutz, verändern das Viskositätsverhalten und das Abscheidevermögen von Fremdstoffen [111]. Die wesentlichen Eigenschaften von Hydrauliköl werden nachfolgend erläutert.

4.4.5.1 Dichte

Die Dichte eines Hydrauliköls ist näherungsweise linear von der Temperatur abhängig [112]

$$\rho_T = \rho_{T=15^\circ C} [1 - \alpha \cdot (T - 15)] \quad (4.21)$$

mit ρ_T = Dichte bei Temperatur T in °C

α = Dichteänderungskoeffizient (ölabhängig, typischer Wert $7 \cdot 10^{-4} \frac{1}{K}$)

$\rho_{15^\circ C}$ = Dichte des Fluids bei 15 °C und Atmosphärendruck, typ.
 $0,8 \dots 0,92 \frac{kg}{dm^3}$

Ebenso weist die Dichte des Öls ein lineares Verhalten gegenüber dem Druck auf (Kompressibilität $7 \cdot 10^{-5} \frac{1}{bar}$) und ist insbesondere bei hohen Drücken > 150 bar zu berücksichtigen.

4.4.5.2 Viskosität

Einer der wichtigsten Kennwerte ist die Viskosität, die die innere Reibung des Öls beschreibt und ein Maß für die Zähflüssigkeit darstellt. Sie beeinflusst in hohem Maße das Strömungs- und somit auch das gesamte Systemverhalten.

Die dynamische Viskosität η beschreibt das Maß der Abhängigkeit der Parallelgeschwindigkeit zweier Platten bei gegebener Scherspannung in einem Fluid von deren Abstand (vgl. Abbildung 4-7). Es gilt:

$$\tau = -\eta \cdot \frac{dv_x}{dy} \quad (4.22)$$

mit τ = Schubspannung

dv_x = Geschwindigkeitsdifferenz der Platten in Parallelrichtung pro Einheit Filmdicke dy des Fluids, bei Hydraulikölen konstant (Newton'sches Fluid)

Wird die dynamische Viskosität η auf die Dichte ρ bezogen, erhält man die kinematische Viskosität ν :

$$\nu = \frac{\eta}{\rho} \quad (4.23)$$

Die kinematische Viskosität kann beispielsweise direkt mittels eines Ubbelohde-Kapillarviskosimeters über die Flusszeit (Gesetz von Hagen-Poiseuille) bestimmt werden.

Beide Viskositätsmaße weisen eine hohe Temperaturabhängigkeit auf, die dynamische Viskosität von Mineralölen kann in Abhängigkeit der fluidspezifischen Konstanten k , b und c nach Vogel näherungsweise wie folgt beschrieben werden [111]:

$$\eta(T) = k \cdot e^{\frac{b}{c+T}} \quad (4.24)$$

Die kinematische Viskosität weist nach Ubbelohde und Walter folgenden Zusammenhang mit der Temperatur auf [131]:

$$\log \log (\nu + 0,8) = \log \log (\nu_1 + 0,8) - m \log \frac{T}{T_1} \quad (4.25)$$

mit ν = kinematische Viskosität bei der Temperatur T

ν_1 = Referenzwert der kinematischen Viskosität bei der Temperatur T_1

m = Richtungskonstante

In Abbildung 4-7b ist der Viskosität verschiedener Hydrauliköle bei Variation der Temperatur dargestellt.

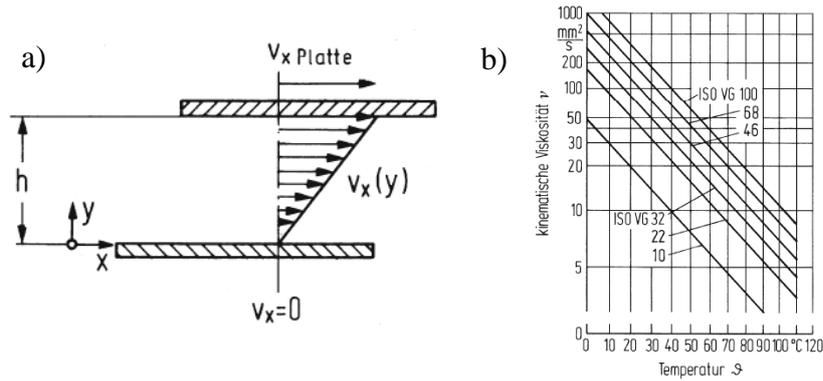


Abbildung 4-7. a) Versuchsaufbau zur Bestimmung der dynamischen Viskosität [131], b) Ubbelohde-Diagramm für Hydrauliköle ISO VG 10 bis 100, VI 100, $p_0 = 1$ bar [131].

Daneben erhöht sich die Viskosität auch in Abhängigkeit des Druckes, als Faustformel kann von einer Viskositäts-Verdopplung bei einer Druckerhöhung von 1 auf 400 bar ausgegangen werden. Nach Barus wird der Zusammenhang wie folgt beschrieben [131]:

$$\eta(p) = \eta_0 \cdot e^{\alpha(p-p_0)} \quad (4.26)$$

mit $\eta(p)$ = Dynamische Viskosität bei Druck p

η_0 = Referenz der dynamischen Viskosität bei Druck p_0

α = Temperaturabhängiger Viskositäts-Druck-Koeffizient

4.4.5.3 Partikelkontamination

Der häufigste Ausfallsgrund hydraulischer Systeme liegt in der Kontamination des Betriebsmediums und wird in 75 % aller ungeplanten Anlagenstillstände diagnostiziert [132]. Hierbei spielen insbesondere Feststoffpartikel eine Rolle, die in der Größenordnung der Spaltmaße der Hydraulikaktoren liegen (Abbildung 4-8b). Das Ausmaß der Schädigung hängt von verschiedenen Parametern ab, etwa von Material, Größe, Form und Anzahl der Partikel und dem im System vorliegenden Betriebsdruck. Abbildung 4-8 zeigt die Arten der Fluidkontamination und qualitativ deren Schädigungspotential.

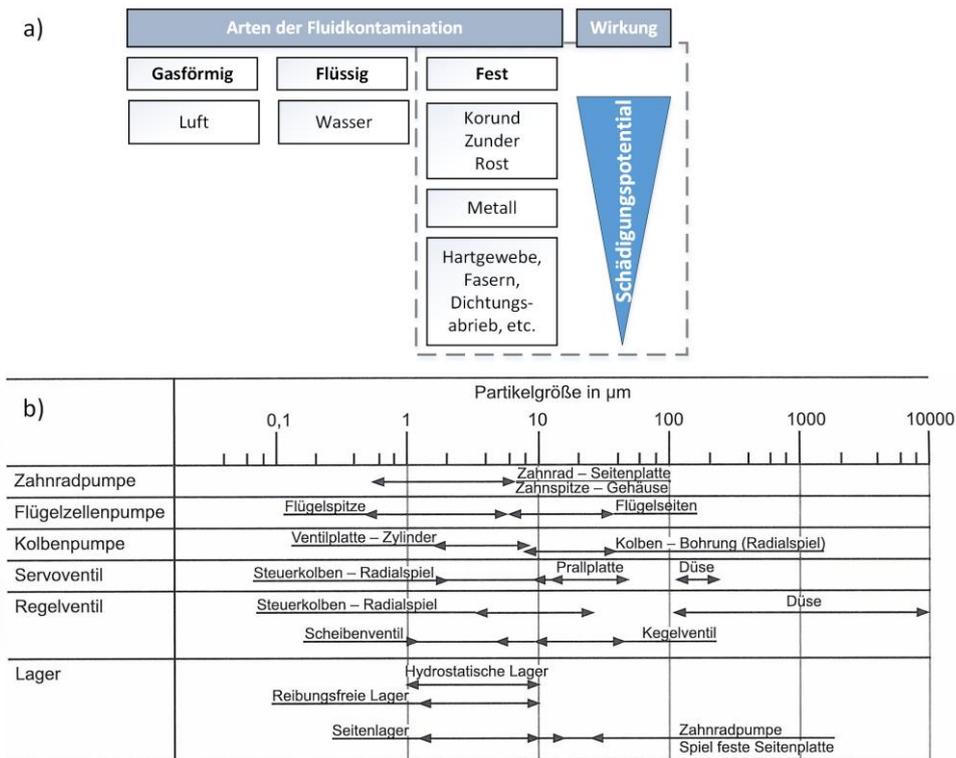


Abbildung 4-8. a) Einteilung der Fluidkontaminationsarten, b) kritische Partikelgrößen unterschiedlicher Komponenten nach [132].

Verbreitete Methoden zur Klassifizierung der Feststoffverschmutzung sind ISO 4406 und SAE AS4059 [133]. Bei beiden Normen erfolgt eine Partikelzählung, unterteilt in drei Bereiche der Partikelgröße. Die Zählung erfolgt kumulativ in den Bereichen > 4 µm, > 6 µm und > 14 µm und wird jeweils mit einer Kennzahl, der Reinheitsklasse bewertet, sodass sich ein dreistelliger ISO-Code ergibt. Die höchste Reinheitsklasse 0 nach ISO 4406 erlaubt demnach maximal einen Partikel pro 100 ml Ölvolumen, die Grenzwerte verdoppeln sich sukzessive in den nachfolgenden Klassen (Tabelle 4-2).

Tabelle 4-2. ISO 4406: Auszug der Reinheitsklassen nach Anzahl der Partikel pro 100 ml.

>	<	Reinheitsklasse ISO 4406
500.000	1.000.000	20
250.000	500.000	19
130.000	250.000	18
64.000	130.000	17
32.000	64.000	16
16.000	32.000	15
8.000	16.000	14
4.000	8.000	13
2.000	4.000	12
1.000	2.000	11
500	1.000	10
250	500	9

Eine Auswertung des Öl-Verunreinigungsgrades erfolgt durch Probenentnahme und anschließende Laboranalyse oder, in zunehmendem Maße, direkt „inline“ mittels Fluidsensoren, die typischerweise in einem Nebenkreislauf induktiv metallische

Partikel (ferromagnetisch und nicht-ferromagnetisch) oder optisch Partikelgrößen und -verteilungen mittels Lichtabschattung im Öl messen [134].

4.4.5.4 Wechselwirkung mit Luft

Nach [112] kann das Luftlösungsvermögen des Hydrauliköls bis ca. 300 bar mit dem Henry-Dalton-Löslichkeitsgesetz beschrieben werden und ist somit proportional zum Druck:

$$V_{Lu} = V_{Fl} \cdot \alpha_L \cdot \frac{p}{p_0} \quad (4.27)$$

mit V_{Lu} = gelöstes Luftvolumen bei Druck p

V_{Fl} = Fluidvolumen bei p_0

α_L = Löslichkeitskoeffizient z.B. 0,08-0,09 für Mineralöle bei 25 °C

Der Sättigungszustand des Öls bei atmosphärischem Druck liegt bei ca. 9 Vol-% Luft. Bei Überschreitung der Sättigungsgrenze entsteht eine Dispersion aus ungelöster freier Luft und Öl mit einem resultierenden Anstieg der Kompressibilität. Die Temperaturabhängigkeit des Luftlösungsvermögens unterhalb von 100 °C ist gering und kann in guter Näherung vernachlässigt werden [135]. Unter Annahme eines idealen Gasverhaltens ergibt sich für die Volumenänderung des Gemischs bei dem Kompressionsmodul K des Öls [112]:

$$\Delta V(p) = \Delta V_{\text{Öl}}(p) + \Delta V_{Lu}(p) = V_{\text{Öl}} \left(\frac{1}{K} + \frac{V_{Lu0}}{V_{\text{Öl}} p} \cdot \left[1 - \left(\frac{p_0}{p} \right)^{\frac{1}{K}} \right] \right) \cdot p \quad (4.28)$$

In freier Form kann Luft neben dem Auftreten mechanischer Schwingungen im hydraulischen System aufgrund der Fluidkompressibilität weitere unerwünschte Effekte verursachen, etwa eine erhöhte Kavitations- und somit Verschleißneigung an Pumpen und Querschnittsverengungen. Daneben erfolgt lokal durch die Kompression der Gasblasen eine starke Erhitzung des Öls, teilweise bis zur Zündung, sog. Mikro-Diesel-Effekt [117], mit einhergehender beschleunigter Ölalterung.

4.4.5.5 Chemische Alterung

Die chemische Alterung des Öls erfolgt durch verschiedene, teilweise parallel ablaufende Prozesse. Ein wesentlicher ist Oxidation, welcher alle Bestandteile des Hydrauliköls, also Basisöl, Additive sowie Viskositätsmodifizierer betrifft [134]. Die entstehenden polaren Verbindungen wirken korrosiv und können zudem Ablagerungen und Ölschlamm bilden, welche die Hydraulik beeinträchtigen können. Begünstigt wird der Oxidationsvorgang durch katalytische Metallionen sowie hohe Öltemperaturen. Als Faustformel wird eine Verdopplung der

Alterungsgeschwindigkeit pro 10 K Temperaturerhöhung in der Literatur genannt [112]. Die wichtigsten Kenngrößen zur Bestimmung des chemischen Zustands sind die Säurekonzentration (Acid number), die Konzentration alkalischer Komponenten (Base number) und die Viskosität des Öls. Neben der herkömmlichen Probennahme und Laboranalyse (z.B. Titration) wurden in jüngerer Vergangenheit Online-Sensoren auf Basis von Infrarotspektroskopie entwickelt [134], [136], die eine selektive Messung von Alterungseffekten anhand der IR-Transmission bei charakteristischen spektralen Banden erlauben.

4.5 Experimenteller Aufbau

Die Datenerhebung erfolgt auf Basis einer im Rahmen dieser Arbeit entwickelten hydraulischen Prüfumgebung, deren mechanischer Aufbau, Steuerung und Instrumentierung im Folgenden vorgestellt wird.

4.5.1 Hydraulikaggregat

Das Hydrauliksystem setzt sich aus zwei Kreisläufen zusammen (Abbildung 4-9), einem primären Arbeitskreislauf (a) sowie einem sekundären Kühl- und Filtrierkreislauf (b), die beide über einen Tank (Volumen 40 l) verbunden sind. Das verwendete Hydrauliköl ist HLP 32 [137].

Der Primärkreislauf wird von einer Innenzahnpumpe MP1 versorgt, welche einen konstanten Volumenstrom von 7,5 l/min bereitstellt. Als Last fungiert das Proportionaldruckbegrenzungsventil V11, welches einen Gegendruck proportional zum Eingangssignal aufbaut. Bei einem Überschreiten des eingestellten Druckwertes wird das überschüssige Öl weiter zum Tank geführt. Somit erfolgt durch das Lastventil im Wesentlichen eine Umwandlung hydraulischer Leistung in Wärme, die an das Öl abgegeben wird. Das Wegeventil V10 sperrt bzw. öffnet die Verbindung zur hydraulischen Last. Des Weiteren sind zur kurzzeitigen Energiespeicherung zuschaltbare (V1-V4) Hydrospeicher (A1-A4) mit einem Volumen $V_0 = 0,6$ l installiert. Zur Vermeidung von sicherheitskritischem Überdruck begrenzen zwei Druckbegrenzungsventile V7 und V8 den maximalen Systemdruck auf 190 bar.

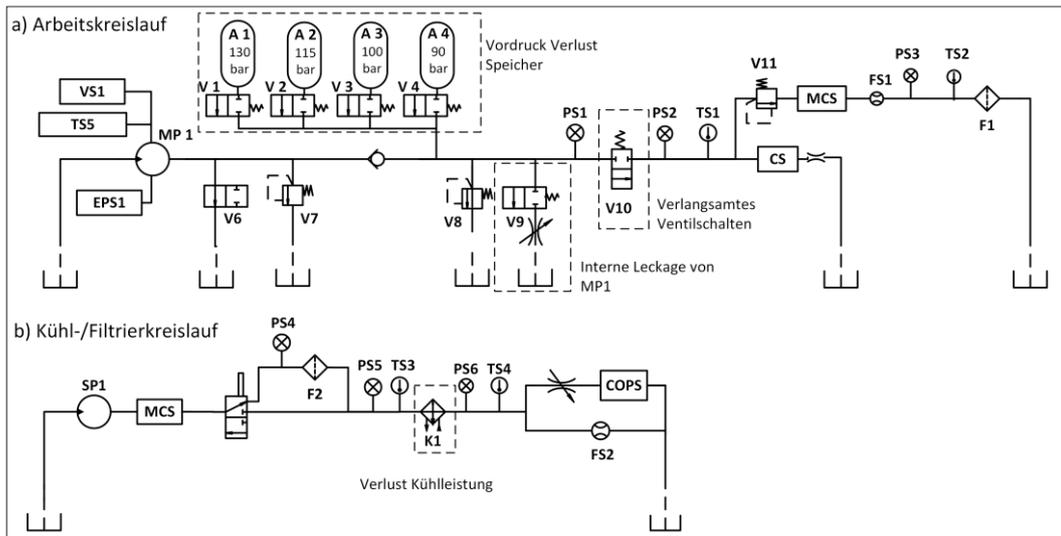


Abbildung 4-9. Hydraulikschaltplan Prüfstand nach [138], [139].

Der Sekundärkreislauf in (b) wird von einer Außenzahnpumpe SP1 mit einem konstanten Volumenstrom von 15 l/min versorgt, wälzt somit das gesamte Ölvolumen etwa alle drei Minuten um und führt es durch den Nebenstromfilter F2 sowie den Öl-Luft-Kühler K1. Abbildung 4-10 zeigt den mechanischen Aufbau der beiden Prüfstände zur Schadens-Charakterisierung (Prüfstand 1) sowie zur Dauerlauf-Erprobung (Prüfstand 2). Letzterer besteht aus einem identischen hydraulischen Grundsystem, verfügt aber nicht über die Modifikationen zur Generierung von künstlichen Schäden.

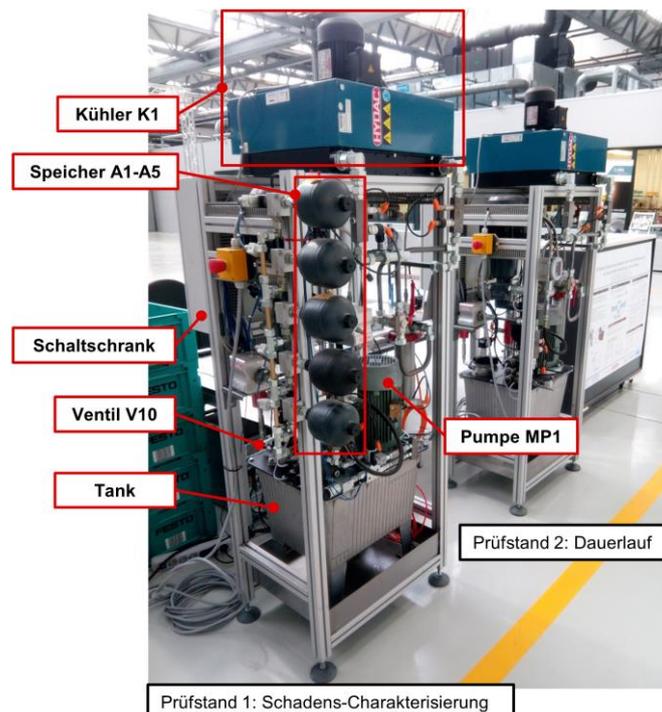


Abbildung 4-10. Prüfstände zur Schadens- und Dauerlauf-Charakterisierung. Prüfstand 1 verfügt insgesamt über fünf Speicher, von denen vier mit unterschiedlichen Gasvordrücken p_0 befüllt sind und zur Auswertung verwendet werden.

4.5.2 Schadenszustände

Das Aggregat 1 wurde dahingehend modifiziert, dass vier Komponentenzustände gezielt über die Ansteuerung verändert werden können (vgl. Tabelle 4-3).

Tabelle 4-3. Generierbare Schadenszustände an Prüfstand 1.

Komponente	Zielzustand	Steuerparameter	Möglicher Bereich
Kühler K1	Reduzierte Kühlleistung	Gepulste Ansteuerung des Lüfters	0...100 % (0.6...2.2 kW)
Wegeventil V10	Verzögertes Schaltverhalten	Ansteuerstromstärke V10	0...100 %
Pumpe MP1	Interne Leckage	Zuschaltbare Leckageströme (V9)	Keine, 3 x 0.2 mm, 3 x 0.25 mm
Hydrospeicher (A1-A4)	Verlust Gasfülldruck	Umschalten der Speicher A1-A4	90, 100, 115, 130 bar

Um die **Kühlwirkung des Öl-Luft-Kühlers** (Hydac OK-EL4L [127]) zu reduzieren, welche maßgeblich vom Wärmeübergangskoeffizienten zwischen Wärmetauscher und Umgebungsluft abhängt (vgl. Kap. 4.4.4), wird der Lüfter des Kühlers von der SPS gepulst angesteuert, was den Wärmeabtransport einschränkt. Hierbei kann der Tastgrad (Verhältnis der Zeitdauer Lüftermotor bestromt zur Periodendauer bestromt/unbestromt) basierend auf einer Zeitskala von 10 Sekunden variabel vorgegeben werden, was aufgrund der thermischen Zeitkonstante des Systems mit entsprechender Tiefpasswirkung näherungsweise einer konstant reduzierten

Wärmeabfuhr entspricht, wie sie etwa durch Verschmutzungen und Ablagerungen am Wärmetauscher verursacht wird. Abbildung 4-11 zeigt die Auswirkung des Lüfter-Tastgrads auf die Kühleffizienz (vgl. Kap. 4.5.4.1). Zu erkennen ist in (a) ein näherungsweise linearer Zusammenhang zur Kühlleistung und Öltemperatur (TS3) im Bereich 20 – 100 %. Darunter bricht die Kühlleistung zunehmend ein. Unterhalb von 5 % wird kein Gleichgewichtszustand innerhalb des betrachteten Zeitfensters von 1h erreicht, bei komplett deaktiviertem Lüfter würde die Fluidtemperatur auf kritische Werte oberhalb von 100 °C ansteigen. Die höchsten Öltemperaturen werden hierbei hinter dem Lastventil V11 gemessen.

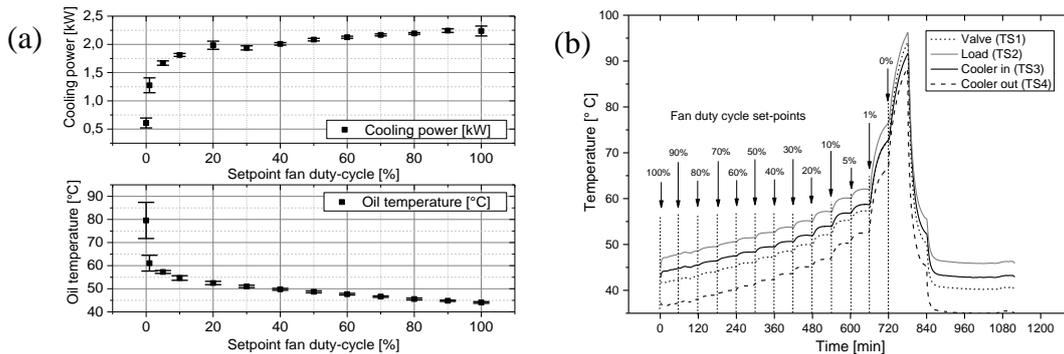


Abbildung 4-11. a) Boxplot Tastgrad Lüfter vs. Kühlleistung und Öltemperatur, b) Zeitliches Temperaturverhalten an den Messstellen im Hydrauliksystem.

Als zweites Schadensszenario wird eine **interne Leckage der Innenzahnradpumpe MP1**, Typ PGI100 [140], über zuschaltbare (V9) Bypass-Blenden emuliert. Ziel ist die Detektion des Blendendurchmessers, welcher verschiedene Verschleißgrade und geometrische Abweichungen durch Abrasion der Dichtflächen innerhalb der Innenzahnradpumpe nachbilden soll. Ein Teil des Volumenstroms, abhängig vom Betriebsdruck, fließt über die Blende zurück in den Tank, ohne dass er bei der Last hydraulische Arbeit verrichten kann. Realisiert wird dies über zwei Schaltstufen mit jeweils drei kaskadierten Blenden mit einem Durchmesser von 0,2 mm und 0,25 mm. Der sich einstellende Leckstrom ist von verschiedenen Einflussgrößen abhängig, etwa dem anliegenden Druck, der Öldichte und der dynamischen Viskosität (vgl. Kap. 4.4.1). Abbildung 4-12 zeigt den gemessenen Volumenstromverlust bei Variation der Öltemperatur und Blendenöffnung. Schon durch den Öltemperatureinfluss ergibt sich ohne Blende systembedingt ein von FS1 gemessener relativer Leckageverlust von bis zu 1,3 %; bei der ersten Stufe liegen die Verluste im Bereich 3,2 - 4,9 % und bei der zweiten Stufe im Bereich 4,5 - 6,4 % mit einem entsprechenden Überlappungsbereich.

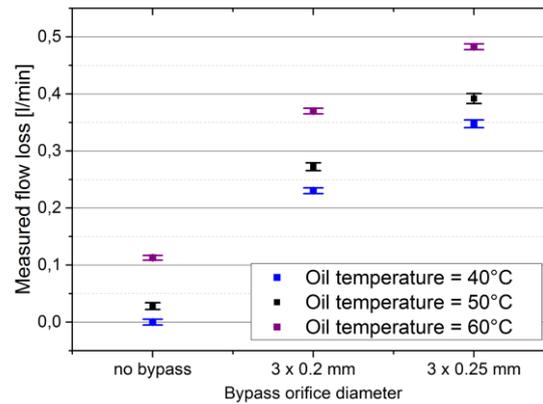


Abbildung 4-12. Leckage-Boxplot in Abhängigkeit von Öltemperatur und Blendendurchmesser, gemessen von FS1 und referenziert auf den Volumenstrom bei 40 °C Öltemperatur.

Eine weitere Zielgröße ist das **Schaltverhalten des Wegeventils V10** vom Typ WSM06020W [121] der Fa. Hydac, einem direktgesteuerten, magnetbetätigten 2/2-Wegesitzventil (NC), welches gezielt über die Begrenzung der Erregerstromstärke beeinträchtigt wird. Dies hat beim Öffnungsvorgang den Effekt, dass die nominelle Schaltzeit von 35 ms nicht mehr erreicht wird und es zu einer wesentlichen zeitlichen Verzögerung kommt, bis eine ausreichend hohe Reluktanzkraft aufgebaut wird, um bei entgegengerichteter Reibungs- und Federkraft den Ventilkolben in Bewegung zu setzen sowie kurz darauf das Strömungskraftmaximum zu überwinden (vgl. Kapitel 4.4.2). Ziel ist es, eine erhöhte interne Reibung des Ventils zu simulieren, wie sie beispielsweise durch Korrosion der zueinander bewegten Kolben- und Gehäuseflächen, Verklemmen durch Feststoffpartikel in Spaltmaßgröße oder den Abriss des Ölfilms durch einen Eintrag freier Luft verursacht werden können [117]. Abbildung 4-14c zeigt den Einfluss der Strombegrenzung relativ zur nominellen Ansteuerstromstärke von 0,8 A bei 24 V im Bereich 100 % bis 71 % auf das von PS1 gemessene Drucksignal; bei einer weiteren Reduktion des Erregerstroms ist ein zuverlässiger Schaltvorgang nicht mehr gewährleistet. Die resultierende Zeitverzögerung relativ zum Schaltvorgang bei 100 % auf Basis des gemessenen Druckverlaufs ist in Abbildung 4-13 dargestellt.

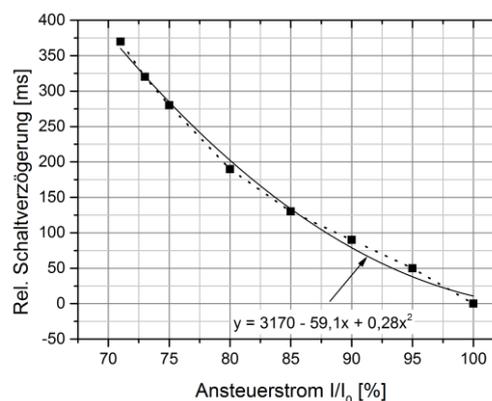


Abbildung 4-13. Gemessene Ventil-Schaltverzögerung in Abhängigkeit des Erregerstroms (Öltemperatur ca. 32 °C).

Als vierte Schadensgröße wird die **Gasleckage des Hydro-Membranspeichers** vom Typ SBO330 [141] der Fa. Hydac mit einem Nennvolumen von 0,6 l betrachtet. Hierbei dient als Zielgröße der Gasfülldruck p_0 , der sich aufgrund von Permeation über längere Zeiträume verringert, was effektiv zu einer Reduktion des Nutzvolumens sowie der speicherbaren Energiemenge führt (vgl. Kapitel 4.4.3). Im Prüfstand wird die Variation des Gasfülldrucks über verschiedene Hydrospeicher gleichen Typs realisiert, die mit unterschiedlichen Gasdrücken im Bereich 90 bis 130 bar befüllt wurden. Über die Ventile V1-V4 kann somit ein Hydrospeicher mit dem System verbunden und die übrigen entkoppelt werden. In Übereinstimmung mit der Simulation zeigt sich der Einfluss von p_0 beim Laden und Entladen des Speichers. Die gemessenen Druckverläufe (Abbildung 4-14b) bei niedrigem Vordruck (90 bar) setzen sich hierbei deutlich nichtlinear ab, bzw. nähern sich bei hohen Vordruckstufen (115 und 130 bar) in Übereinstimmung mit der Simulation (Abbildung 4-5) einander an.

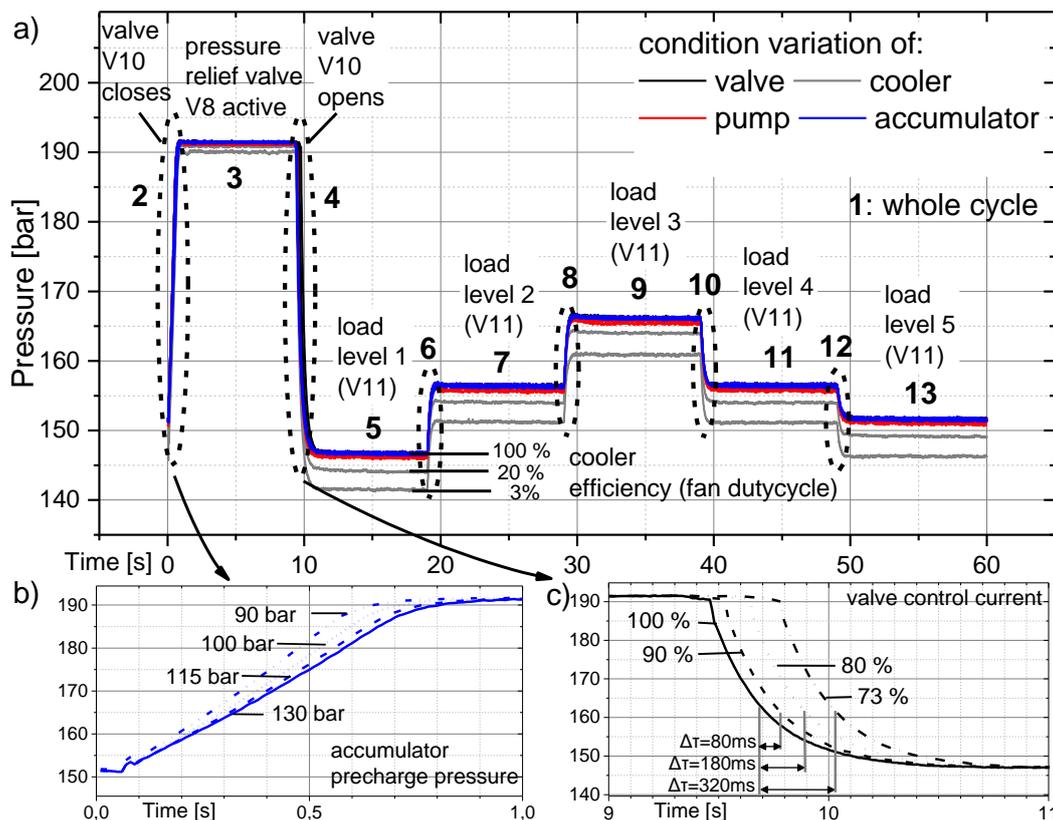


Abbildung 4-14. Gemittelter Druckverlauf (PS1) bei konstantem Arbeitszyklus (a) unter Einwirkung isolierter Schäden, (b) Ladephase Speicher (vgl. Abbildung 4-5), (c) Ventilschaltvorgang.

4.5.3 Variation der Ölparameter

An das Hydraulikaggregat können optional durch ankoppelbare Zugabe-Systeme (Abbildung 4-15) die Störmedien Luft und Teststaub-Partikel in das Öl eingetragen

werden. Der Lufteintrag (a) erfolgt direkt in den Ansaugbereich von MP1 über ein Proportionalventil (Typ ASCO Numerics 202 Posiflow [142]), welches von einem Druckluft-Kompressor (1 bar) versorgt wird. Der Luft-Volumenstrom ist proportional zur Ventilansteuerstromstärke, welche von dem SPS-Ausgangsmodul (Beckhoff EL2535 [143]) geregelt wird. Die Ventilkennlinie wurde vorab mit einem Schwebekörper-Durchflussmesser bei Umgebungsdruck an der Ausgangsseite bis zu einem Volumenstrom von 1 l/min abgeglichen. Der Luft-Volumenstrom wird im Prozess nicht überwacht, sodass Schwankungen während der Messung, etwa durch Erwärmung des Spulenkörpers, nicht ausgeschlossen werden können.

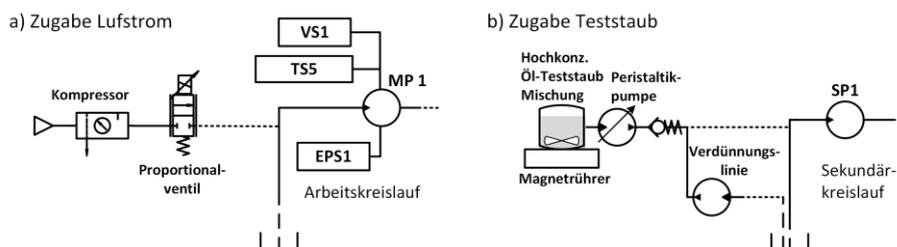


Abbildung 4-15. (a) Lufteintrag in den Arbeitskreislauf, (b) Teststaubzugabe in den Kühl-Filterier-Kreislauf.

Die Zudosierung von Partikeln (b) in den Kühl-Filterierkreislauf in Form einer hochkonzentrierten Teststaub-Öl-Dispersion (ISO MTD A3 [144]), die mittels eines Magnetrührers konstant durchmischt wird, erfolgt mit einer Peristaltik-Dosierpumpe mit geregelter Schrittmotor (Typ Saier Concept 420sm [145]). Diese fördert in Abhängigkeit der Schlauchgeometrie und Drehzahl einen einstellbaren Volumenstrombereich von 0,02...2,1 ml/min bis zu 1,0...200 ml/min der Dispersion in den Konstantstrom (300 ml/min) der Bypasslinie, die wiederum dem Ansaugbereich von SP1 zugeführt und dort weiter verdünnt wird, sodass insgesamt ein volumetrischer Verdünnungsfaktor von mindestens 1:75 bis 1:7140 erreicht wird.

4.5.4 Steuerung, Datenerfassung und Arbeitszyklus

Die Steuerung und Datenerfassung der Prüfstände erfolgt auf zwei Ebenen (Abbildung 4-16): Eine SPS (Beckhoff CX5020) auf Basis eines Embedded PCs (Intel Atom CPU mit 1,1 GHz, 1 GB RAM, Windows Embedded 7) sorgt mit der Software TwinCAT 2 [146] für eine Echtzeit-Steuerung und -Datenerfassung des Hydrauliksystems.

Über die Programmierumgebung Codesys [147] sind auf dem Controller verschiedene Arten von Arbeitszyklen hinterlegt, die nach dem Start zyklisch bis zum Abschluss der Messung wiederholt werden. Unterschieden werden hierbei konstante und randomisierte Zyklen. Beide besitzen einen vorgegebenen Ablauf

(Abbildung 4-14) bei dem zunächst das Wegeventil V10 schließt (Int. 2), sodass anschließend das Druckbegrenzungsventil V8 aktiv wird (Int. 3). Nach dem Öffnen des Wegeventils (Int. 4) werden in den Bereichen 5, 7, 9, 11, 13 Laststufen über das Proportional-Druckbegrenzungsventil V11 vorgeben. Im Fall des konstanten Zyklus bleiben die Laststufen über die gesamte Messung unverändert, bei der Vorgabe des randomisierten Zyklus erfolgt die Generierung jeder Laststufe pseudorandomisiert von der SPS im Bereich 120 - 200 bar (OSCAT Codesys-Bibliothek [148]).

Der konstante Arbeitszyklus repräsentiert exemplarisch den Ablauf eines industriellen Prozesses mit sich wiederholenden Betriebs- und Lastzuständen, etwa dem zyklischen Umformvorgang einer hydraulischen Presse oder dem Arbeitszyklus einer hydraulisch angetriebenen Spritzgießmaschine. Demgegenüber steht der randomisierte Arbeitszyklus, mit dem Anwendungsfälle nachgebildet werden sollen, bei denen sich Prozessbedingungen und -abläufe typischerweise in nicht vorhersagbarer Weise ändern. Als Beispiel seien hier Abläufe der Mobilhydraulik, etwa von Baumaschinen genannt, die sich in repetitive Muster unterteilen lassen, welche jedoch abhängig von der durchgeführten Tätigkeit stark wechselnde Lastparameter aufweisen können.

Die Messdatenaufnahme erfolgt über die Analog-Eingangsmodule (4-20 mA Schnittstelle, 12 bit, vgl. Tabelle 4-4) der Steuerung; die Sensordaten werden im Controller über zwei Buffer-Arrays zwischengespeichert, welche im Wechsel als Schreib- und Sendepuffer verwendet werden. Somit wird die Datenkonsistenz und Synchronität der via EtherCAT an den PC gestreamten Datenpakete sichergestellt. Am PC erfolgt mit einer LabVIEW-Software die Entgegennahme, zyklische Strukturierung und Speicherung der Daten im lesbaren Text-Format. Daneben werden über die LabVIEW-Software auch die Abläufe der Schadensgrößen konfiguriert, zur SPS übertragen und als Textdatei für die nachfolgende Auswertung abgelegt.

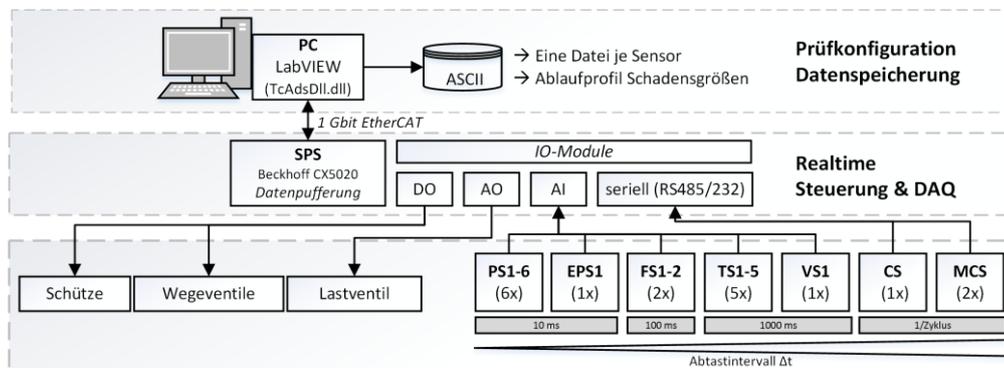


Abbildung 4-16. Konzept Steuerung und Datenerfassung.

Abbildung 4-17 zeigt die Realisierung des Systems mit den wichtigsten Komponenten im Schaltschrank.

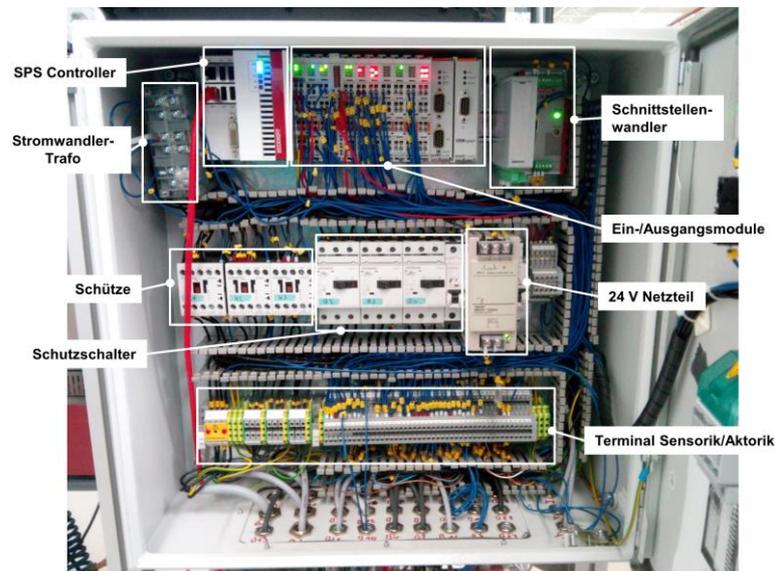


Abbildung 4-17. Umsetzung Schaltschrank.

4.5.4.1 Physische und virtuelle Prozesssensoren

Tabelle 4-4 zeigt die verwendeten Prozesssensoren. Diese setzen sich aus den physischen, also tatsächlich im System installierten Sensoren (vgl. Abbildung 4-9) und aus den physischen Sensoren abgeleiteten, nachfolgend als „virtuell“ bezeichneten, Messgrößen zusammen.

Die Abstraten sind so gewählt, dass sie die Symptome der Zustände zeitlich auflösen können, wobei insbesondere vom Hydrospeicher (Ladedauervariation von ca. 100 ms laut Simulation, vgl. Kap. 4.4.3) und Ventil (Schaltverzögerungen bis zu 300 ms [123]) erhöhte Anforderungen ausgehen, sodass 10 ms als ausreichende zeitliche Auflösung für Druck und elektrische Leistung betrachtet werden. Die Volumenströme werden aufgrund der Trägheit des (Turbinen-) Messprinzips mit niedrigerer zeitlicher Auflösung (100 ms) erfasst. Bei den Messgrößen Temperatur und Schwingungsgeschwindigkeits-Effektivwert sind relevante Signaländerungen mit Zeitkonstanten < 1 s nicht zu erwarten. Die Erfassung der Ölkontamination mit Festkörperpartikeln (CS, MCS) erfolgt einmalig in jedem Zyklus, wobei die Information nicht in die statistische Auswertung einfließt.

Tabelle 4-4. Physische und virtuelle Sensoren im ICM-Hydraulik System.

Sensor	Messgröße	Einheit	ADC/Interface	Abtastrate	Aufl.
PS1- PS6	Druck	bar	Beckhoff EL3058 (4...20 mA)	100 Hz	12 bit
EPS1	El. Motorleistung MP1	W	Beckhoff EL3403 (3 Phasen RMS)	100 Hz	10 mW
FS1 FS2	Volumenstrom	l/min	Beckhoff EL3058 (4...20 mA)	10 Hz	12 bit
TS1- TS5	Temperatur	°C	Beckhoff EL3058 (4...20 mA) / EL3204 (RTD)	1 Hz	12 bit
VS1	Vibration (Effektivwert)	mm/s	Beckhoff EL3058 (4...20 mA)	1 Hz	12 bit
CE	Virtuell: Kühleffizienz	%	-	1 Hz	12 bit
CP	Virtuell: Kühlleistung	kW	-	1 Hz	12 bit
SE	Virtuell: System-Wirkungsgrad	%	-	1 Hz	12 bit
CS	Kontamination nach ISO 4406	-	Beckhoff EL6021 (RS485)	1/Zyklus	-
MCS	Kumulierte Zahl von Metallpartikeln	-	Beckhoff EL6021 (RS485)	1/Zyklus	-

Die virtuellen Messgrößen werden folgendermaßen berechnet:

$$\text{Kühleffizienz } CE = \frac{\Delta T_{\text{Kühler}}}{\Delta T_{\text{max}}} = \frac{T_{TS3} - T_{TS4}}{T_{TS3} - T_{\text{Umgebung}}} \quad (4.29)$$

$$\text{Kühlleistung } CP = \frac{dQ}{dt} = Q_{FS2} \rho c_p (T_{TS3} - T_{TS4}) \quad (4.30)$$

$$\text{System-Wirkungsgrad } SE = \frac{P_{\text{hyd}}}{P_{\text{el}}} = \frac{p_{PS2} \cdot Q_{FS1}}{P_{EPS1}} \quad (4.31)$$

Die Kühleffizienz CE beschreibt hierbei die Abkühlung des Öls $T_{TS3} - T_{TS4}$ beim Durchfließen des Kühlers in Relation zur maximal möglichen Abkühlung $T_{TS3} - T_{\text{Umgebung}}$, die durch die Umgebungstemperatur bestimmt wird.

Bei der Berechnung der Kühlleistung CP (vgl. Kap. 4.4.4) werden die Öl-Parameter $c_p = 1,764 \frac{\text{kJ}}{\text{kg}\cdot\text{K}}$ und $\rho = 0,87 \frac{\text{g}}{\text{cm}^3}$ [137] im betrachteten Temperaturbereich zur Vereinfachung als konstant angenommen.

Der Wirkungsgrad SE bildet das Verhältnis zwischen der über der Last anliegenden hydraulischen Leistung und der am Antrieb eingebrachten elektrischen Leistung ab.

Die virtuellen Messgrößen werden bereits im SPS-Controller mit einer Rate von 1 Hz berechnet, sodass sie nachfolgend wie reguläre Sensordaten behandelt werden.

4.5.4.2 Schwingungssensoren

An den Pumpen MP1 und SP1 wurde zusätzlich zur Analyse des Schwingungsverhaltens je ein dreiachsiger low-cost MEMS Schwingungsaufnehmer (STMicroelectronics LIS352 [149]) verwendet, der mit einer umhausten Adapterplatine starr mit dem Pumpengehäuse verschraubt ist (Abbildung 4-18). Der Sensor besitzt eine Bandbreite von maximal 2 kHz bei einem Messbereich von $\pm 2 \text{ g}$.

Die Datenerfassung der insgesamt 6 Beschleunigungssignale erfolgt Zyklus-synchronisiert mit der SPS über ein Triggersignal mit einem NI USB-6343 Datenerfassungssystem (Abtastrate 8,192 kHz, Auflösung 16 bit).



Abbildung 4-18. Positionierung der 3-Achsen Beschleunigungsaufnehmer an MP1 (links) und SP1 (rechts) mit eingezeichneter Motor-Drehrichtung [150].

4.5.4.3 Benutzerinterface und Versuchsdurchführung

Das LabVIEW-Benutzerinterface zur Konfiguration und Ablaufsteuerung der Schadensgrößen sowie zur Datenerfassung ist in Abbildung 4-19 dargestellt. Es beinhaltet in (1) die Auswahl des Arbeitszyklen-Typs (konstant oder randomisiert), der Speicheroptionen (Speichern de-/aktivieren, abspeichern jedes x-ten Zyklus bei Langzeitmessungen) sowie das Starten und Stoppen der Messung, in (2) den Reiter zum Wechseln zwischen Visualisierungs- und Ablaufkonfigurationsfenster, in (3) den Graph der aktuellen Sensordaten mit (4) der Auswahl der anzuzeigenden Sensoren sowie (5) dem Fortschrittsbalken der Charakterisierungsmessung.

Vor dem Start der Messung erfolgt die Konfiguration des Ablaufs (Abbildung 4-20), welcher aus verschachtelten Basiselementen zusammengesetzt wird. Ein solches Basiselement besteht aus:

- *Element description*: Optionale Beschreibung des Zustands
- *Cycles*: Anzahl der abzuwartenden Zyklen bis zur Transition zum nächsten Element
- *Ignore-Flag*: Flag, ob die zum Element zugehörigen Zyklen bei der Auswertung verworfen werden sollen, bspw. Übergangszustände bei Zielgrößen mit hoher Zeitkonstante über mehrere Zyklen
- *Condition variables*: Array aus Struct-Kombinationen von SPS-Variablenamen und zugehörigen Werten zum Konfigurieren des Zustands, z.B. ‚MAIN.set_valve_curr‘ mit dem Wert 90 setzt die Strombegrenzung des Wegeventils V10 auf 90 % des nominellen Ansteuerstroms. Pro Element können mehrere Variablen-Wert-Paare gesetzt werden.

Die Basiselemente werden horizontal und vertikal wie in Abbildung 4-20 (1) und (2) gezeigt hierarchisch strukturiert. Das Ablaufschema wird in Abbildung 4-21a illustriert: Bei einer Charakterisierungsmessung werden die Elemente zunächst vertikal von oben nach unten durchlaufen bis zur untersten Zeile. Ist diese erreicht, werden deren Elemente horizontal durchlaufen. Anschließend wird das nächste Element der nächsthöheren Ebene angesteuert und anschließend wieder die unterste Ebene horizontal durchlaufen. Die Iterationen erfolgen sukzessive nach diesem Schema bis zum Durchlaufen aller Einträge der obersten Stufe. Damit ergeben sich komplex verschachtelte und gleichzeitig einfach zu konfigurierende Schadens-Profile (Abbildung 4-21b), die alle Wechselwirkungen der Zielgrößen abbilden.

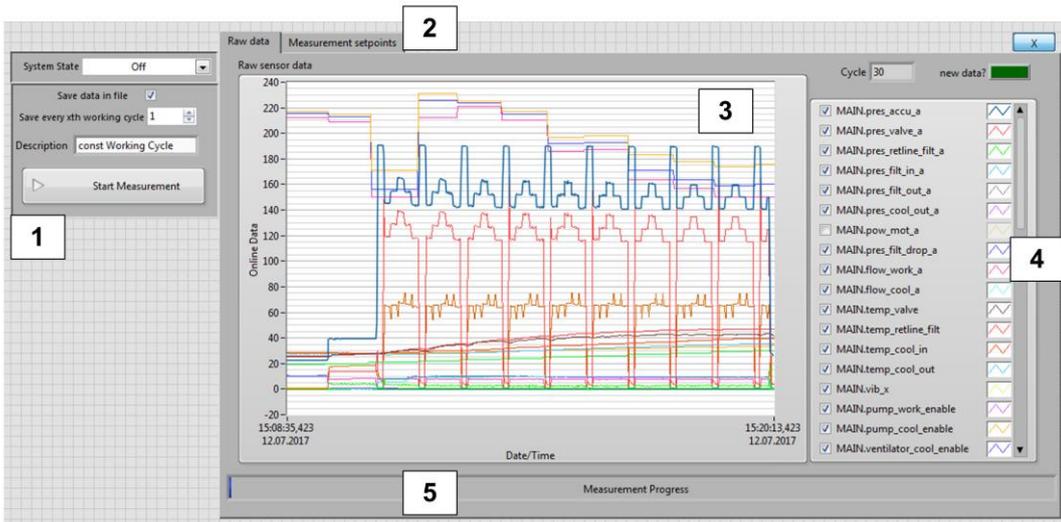


Abbildung 4-19. LabVIEW Benutzeroberfläche während laufender Messung (konstanter Arbeitszyklus) mit (1) Versuchssteuerung (2) Reiter Visualisierung/Ablaufkonfiguration (3/4) Graph Sensordaten und (5) Fortschrittsanzeige.

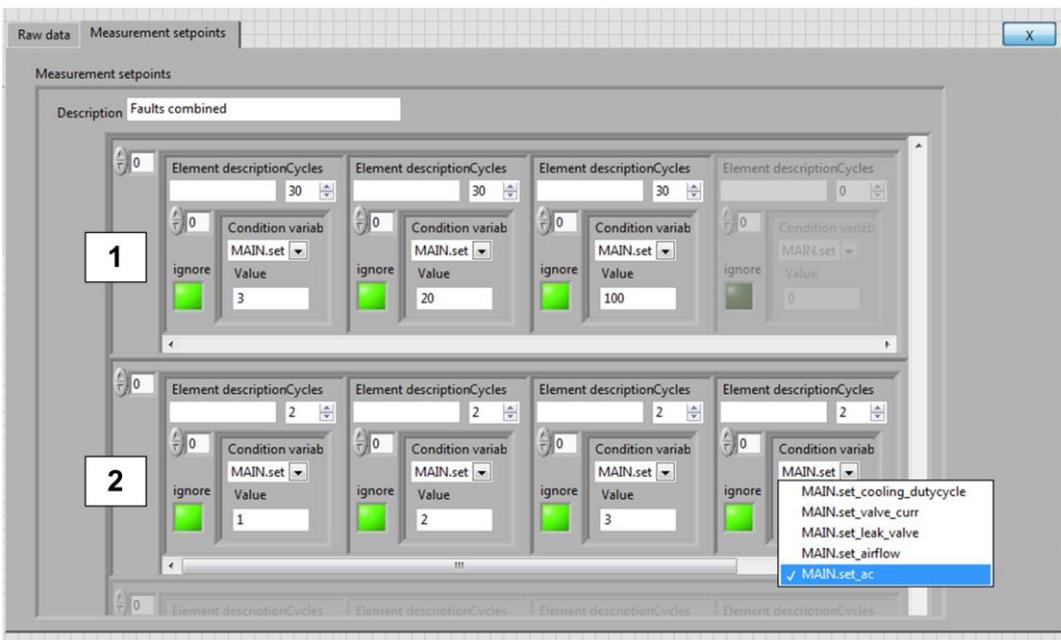


Abbildung 4-20. Konfiguration des Messablaufs in LabVIEW mit den Ablaufstufen (1) und (2).

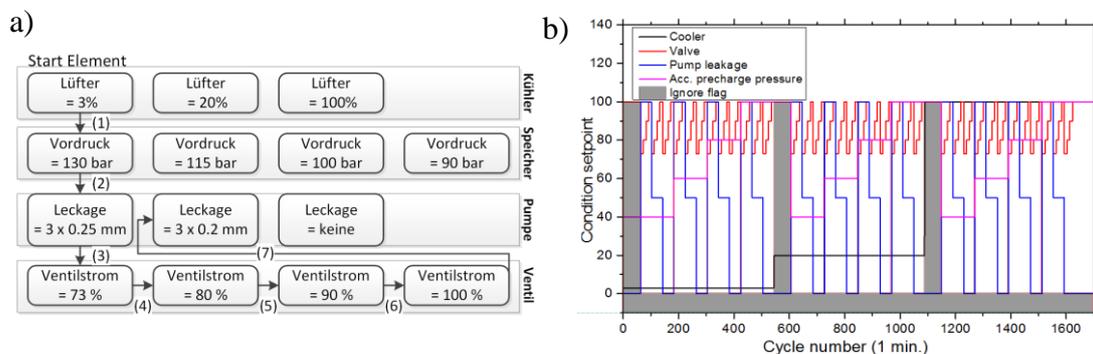


Abbildung 4-21. a) Konfiguration der Schadenszustände, b) resultierende Charakterisierungsmessung.

4.6 Detektion von Maschinenfehlern und -verschleiß

4.6.1 Erkennung und Quantifizierung isolierter Schadenstypen

Auf Basis des in Kapitel 3 erläuterten Konzepts erfolgt die Quantifizierung der einzelnen, isoliert vorliegenden Schadensfälle der vier Komponenten. Zur Verifikation der Validität wird hierbei der aufgenommene Datensatz mit konstantem Arbeitszyklus in Trainings- und Evaluierungsklassen unterteilt. Die Öltemperatur ist bei der Untersuchung näherungsweise konstant.

Abbildung 4-22a zeigt die LDA-Projektion der ersten beiden Diskriminanzfunktionen bei sukzessiver Verschlechterung der Kühleffizienz (in 10 % Schritten sowie 5, 1, 0 % Lüfter-Tastgrad). Zu erkennen ist, dass DF 1 zur Quantifizierung des Schweregrades genutzt werden kann und dass die nachträglich projizierten Klassen an die bei kontinuierlichem Verlauf zu erwartenden Positionen im LDA-Raum abgebildet werden. Ähnlich zu Abbildung 4-11 ist auch hier der nichtlineare Zusammenhang bei geringen Lüfter-Tastgraden ($< 10\%$) sichtbar. Die gruppenbezogenen DF 1 Projektionen ($> 10\%$) entsprechen der Nullhypothese der Normalverteilung (vgl. Tabelle 4-5), somit kann die Unschärfe der Detektion unter Einbeziehung der Ergebnisse von Abbildung 4-11 mit $\sigma \approx 10\text{ W}$ Kühlleistung abgeschätzt werden.

Die Abschätzung des Ventilschaltverhaltens (b) erfolgt ebenfalls mit Trainings- (100, 90, 80, 73, 69 %) und Evaluierungsgruppen (95, 85, 75, 71 %), wobei auch hier DF 1 als Zustandsindikator genutzt werden kann. Eine Normalverteilung liegt nur etwa bei der Hälfte der Klassen vor (Tabelle 4-5), mit $\sigma \approx 0,4\% I/I_{nom}$, was etwa einer Verzögerung des Schaltverhaltens von 10 ms (vgl. Abbildung 4-13) und somit der zeitlichen Auflösung der Datenerfassung entspricht.

Die LDA-Projektion zur Pumpenleckage ist in (c) dargestellt. Neben dem normalen Betriebszustand und der Auswirkung der beiden Leckageblenden wurde ein Totalausfall über das geöffnete Ventil V6 simuliert. Letzterer hebt sich wie zu erwarten deutlich von den übrigen Klassen ab und wird entsprechend der Reihenfolge im stark negativen Bereich von DF1 abgebildet. Die Detektionsgrenze der relativen Leckage kann mit ca. 0,5 % des Pumpenförderstroms abgeschätzt werden.

Zuletzt kann auch gezeigt werden, dass die Gasfülldruck-Überwachung des Hydrospeichers im Prozess möglich ist (d). Die Anordnung der Klassen deutet hierbei auf einen nichtlinearen Zusammenhang zwischen den Merkmalen und Zielgrößen hin (vgl. Abbildung 4-14). Die Unsicherheit von DF 1 beträgt $\sigma \approx 5,0 \text{ bar}$.

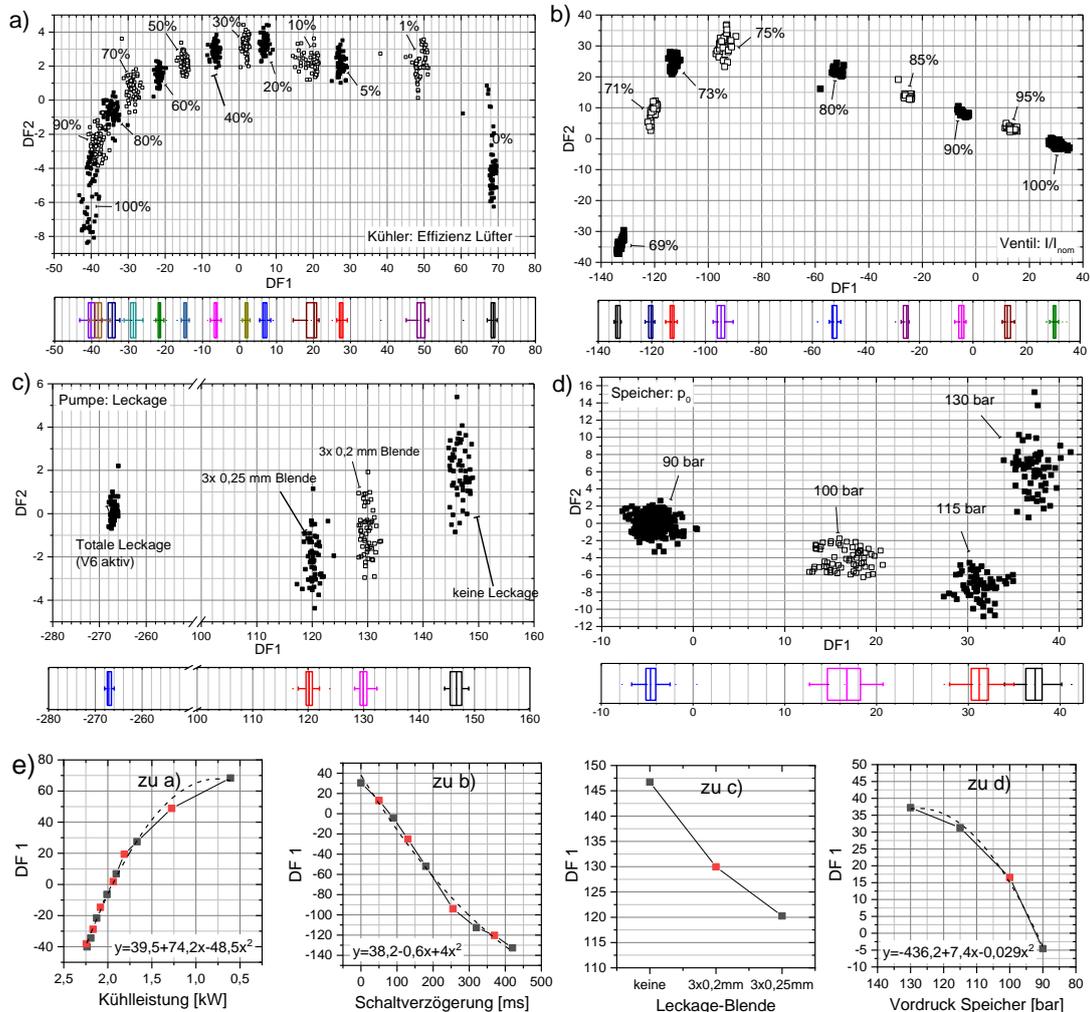


Abbildung 4-22. LDA-Plot und Boxplot DF 1 der Schadensstufen (a) Öl-Luft Kühler (10 Merkmale, n=780), (b) Ventilzustand (10 Merkmale, n=697), (c) Pumpenleckage (10 Merkmale, n=1.136), (d) Fülldruck Hydrospeicher (10 Merkmale, n=1.163), (e) DF 1 Kennlinien auf Basis der Gruppenzentroiden (schwarz: Training, rot: Evaluierung).

Stellt man die Projektion der höchstkorrelierten Merkmale mittels PCA (Abbildung 4-23) und LDA (Abbildung 4-22) gegenüber, lässt sich erkennen, dass selbst bei Betrachtung eines isolierten Zielzustands die Zielgröße nicht notwendigerweise mit der maximalen Streurichtung (PC 1) übereinstimmt, sondern z.T. über Linearkombinationen von PC 1 und PC 2 beschrieben wird (Kühler, Ventil). Dadurch resultiert eine signifikant höhere Unschärfe der Projektion zur Zustandsidentifikation von PC 1 gegenüber DF 1. Zusammenfassend kann für alle untersuchten Schadensszenarien DF 1 zur Abschätzung des Schadensausmaßes

genutzt werden, da sie eine ideale Trennbarkeit der Projektion entsprechend der physikalischen Plausibilität aufweist. Die klassenbezogenen Verteilungen von DF 1, sowohl Trainings- als auch Evaluierungsprojektionen, sind überwiegend normalverteilt (Speicher, Pumpe, Kühler). Die auf Basis der höchstkorrelierten Merkmale erzeugten statistischen Modelle sind jeweils in der Lage, unbekannte Zwischenklassen korrekt abzubilden und somit Zwischenzustände zu interpolieren.

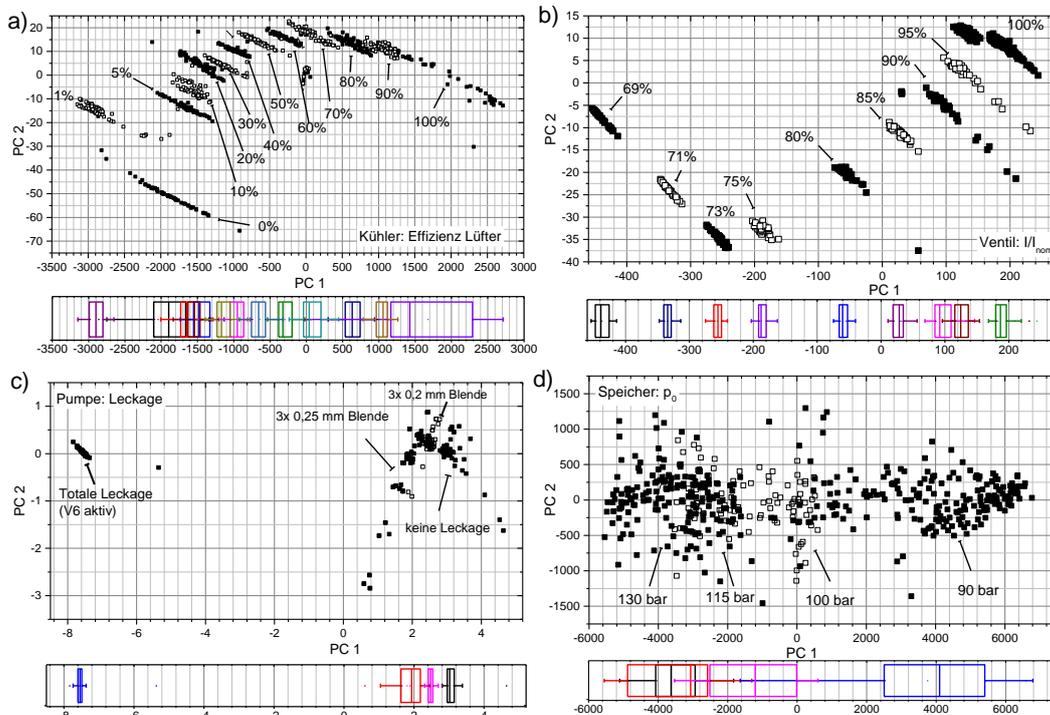


Abbildung 4-23. PCA-Plot und Boxplot PC 1 (Preprocessing: Z-Score Standardisierung) der Schadensstufen (a) Öl-Luft Kühler (10 Merkmale, n=780), (b) Ventilzustand (10 Merkmale, n=697), (c) Pumpenleckage (10 Merkmale, n=1.136), (d) Fülldruck Hydropspeicher (10 Merkmale, n=1.163).

Tabelle 4-5. Test auf Normalverteilung DF 1 nach Klassen aufgeschlüsselt (grau hinterlegt: Projektion) nach Shapiro-Wilk (SW), Lilliefors (Lill), Kolmogorov-Smirnov (KS). Markierung (x), wenn Normalverteilung nicht zurückgewiesen werden kann (Signifikanzniveau 0,05).

Kühler							Ventil																
Kl.	0	5	20	40	60	80	100	1	10	30	50	70	90	69	73	80	90	100	71	75	85	95	
SW	x	x	x	x	x	x	x			x		x	x	x		x		x		x		x	
Lill	x	x	x	x	x	x	x			x	x	x	x		x		x		x		x		x
KS	x	x	x	x	x	x	x			x	x	x	x	x	x	x	x	x	x	x	x	x	x

Pumpe				Speicher				
Kl.	keine	3x0,25mm	total	3x0,2mm	130	115	90	100
SW	x		x		x		x	
Lill	x		x		x		x	
KS	x		x		x		x	

4.6.2 Unterscheidung gleichzeitig auftretender Schäden

Zur Untersuchung überlagerter Schadenszustände wurden vier Messungen durchgeführt (vgl. Tabelle 4-6). Wie in Abbildung 4-21 dargestellt, werden die Schadenstypen und -stufen verschachtelt überlagert, sodass sich insgesamt 108 bis 144 individuelle Kombinationen ergeben. Das Ziel im Folgenden ist die Quantifizierung einzelner Komponenten-Zustände, sodass die übrigen Zustände, wie in Abbildung 4-24 dargestellt, als Störgrößen fungieren [138]. Abbildung 4-24 stellt die zu erwartenden Quereinflüsse dar, wobei insbesondere eine dominante Beeinflussung durch den Kühler auf die Detektion der übrigen Komponentenzustände sowie die stärkste Beeinträchtigung beim Hydrospeicher zu erwarten ist.

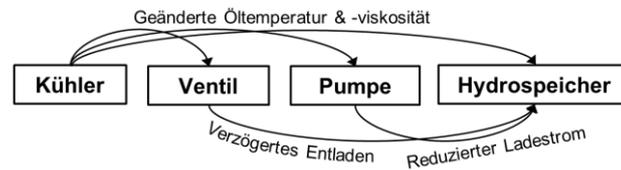


Abbildung 4-24. Interaktion der Komponentenzustände.

Des Weiteren wird untersucht, inwieweit eine unbekannte, randomisierte Lastverteilung (Datensätze Rnd. 1/2) der Intervalle 5 bis 13 des Arbeitszyklus (vgl. Abbildung 4-14) die Klassifikation beeinflusst.

Tabelle 4-6. Untersuchte Datensätze mit jeweiligen Prozess-/Schadensparametern. Zyklen mit Übergangszuständen bzw. Ausreißern wurden vorab aus den Datensätzen entfernt.

	Datensatz			
	Const. 1 (20140731)	Const. 2 (20140822)	Rnd. 1 (20140801)	Rnd. 2 (20140820)
Zyklus	konstant	konstant	randomisiert	randomisiert
Kühler	3,20,100	3,20,100	3,20,100	3,20,100
Ventil	73,85,100	73,80,90,100	73,80,90,100	73,80,90,100
Pumpe	0,1,2	0,1,2	0,1,2	0,1,2
Speicher	130,115,100,90	130,115,100,90	130,115,100,90	130,115,100,90
Komb.	108	144	144	144
n =	1.108	2.206	2.092	2.693

Abbildung 4-25 zeigt die Klassifikationsraten (10-fold Kreuzvalidierung) bei konstantem Arbeitszyklus auf Basis der überwachten Dimensionsreduktion mittels LDA und Mahalanobis-Distanz-Klassifikation. Variiert wurden hierbei die Merkmalsselektionsmethode sowie die Anzahl der Merkmale im Bereich von 1 bis 100.

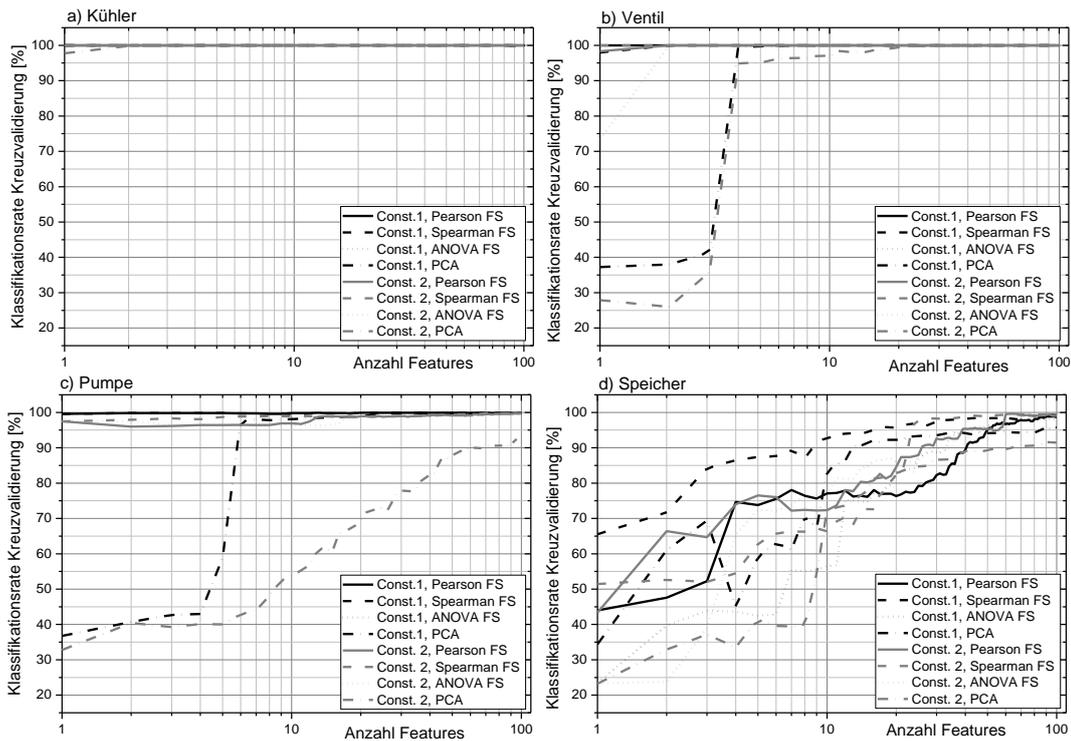


Abbildung 4-25. Klassifikationsraten bei konstantem Arbeitszyklus in Abhängigkeit der Merkmalsselektion und -anzahl (LDA mit Mahalanobis-Distanz-Klassifikator, 10-fold Kreuzvalidierung).

Ersichtlich ist, dass die Erkennung der Kühleffizienz (a) auch in diesem Falle ein einfach lösbares Klassifikationsproblem darstellt, das im Grunde keine multivariate Auswertung benötigt, da schon ein einziges Merkmal eine perfekte Klassifikation ermöglicht. Auch das degradierte Ventilschalten (b) wird bereits von wenigen Merkmalen zuverlässig detektiert. Das vergleichsweise schlechte Ergebnis bei der Merkmalsselektion mit PCA (b, c, d) lässt sich dadurch erklären, dass erst höhere Hauptkomponenten Informationen über den stark zeitlich lokalisierten Ventilschaltvorgang beinhalten, die allerdings nur einen geringen Anteil an der Gesamtstreuung der Merkmale beisteuern. Ähnliches ist auch bei Detektion der Pumpenleckage zu erkennen, bei der sich die PCA-basierte Merkmalsreduktion erst ab der 6. PC sprunghaft (Const. 1), bzw. langsam ansteigend (Const. 2), verbessert. Die überwachten Selektionsverfahren erreichen hingegen ab einem Merkmal Klassifikationsraten von über 95 % bzw. eine annähernd optimale Detektion (1 Fehlklassifikation) ab 13 Merkmalen. Das komplexeste Klassifikationsproblem ist die Speicherüberwachung mit der im Vergleich schlechtesten Performanz. Hier zeichnen sich die größten Unterschiede bei der Merkmalsselektion ab, mit einem überdurchschnittlichen Abschneiden der Spearman-Rangkorrelation (Const. 1). Allgemein muss eine große Zahl (> 24) von Merkmalen für eine akzeptable Performanz (> 95 %) des Modells ausgewählt werden. Tabelle 4-7 zeigt die signifikanten Merkmale, die zur Klassifikation ausgewählt wurden.

Tabelle 4-7. Höchstkorrelierte Merkmale (Spearman) nach Zielgröße für den Datensatz Const.1 mit zugehörigem Ranking-Wert $|\rho|$. Die Merkmals-Funktionen sind Median (Med), Varianz (Var), Schiefe (Sch), Kurtosis (Ku), Steigung (St) sowie Position des Maximums (Pos). Sensorbezeichnungen (Sns) nach Abbildung 4-9, Intervallbezeichnungen (Int) nach Abbildung 4-14.

Kühler				Ventil			
Sns	Int	Fk	$ \rho $	Sns	Int	Fk	$ \rho $
'PS1'	'3'	'Med'	'0.93546'	'PS2'	'4'	'Med'	'0.94754'
'FS2'	'11'	'Med'	'0.93544'	'ESP1'	'4'	'Var'	'0.94197'
'FS2'	'10'	'Med'	'0.93544'	'ESP1'	'5'	'Var'	'0.94197'
'FS2'	'5'	'Med'	'0.93544'	'PS1'	'4'	'St'	'0.94197'
'FS2'	'1'	'Med'	'0.93544'	'ESP1'	'4'	'St'	'0.94197'
'FS2'	'9'	'Med'	'0.93544'	'PS2'	'1'	'Ku'	'0.94197'
'FS2'	'7'	'Med'	'0.93543'	'PS2'	'1'	'Sch'	'0.94197'
'FS2'	'3'	'Med'	'0.93543'	'PS1'	'4'	'Sch'	'0.94197'
'FS2'	'13'	'Med'	'0.93543'	'PS2'	'4'	'Sch'	'0.94197'
'TS1'	'11'	'Med'	'0.93542'	'FS1'	'4'	'Sch'	'0.94139'
'FS2'	'4'	'Med'	'0.93542'	'PS1'	'4'	'Var'	'0.94113'
'FS2'	'8'	'Med'	'0.93542'	'SE'	'4'	'Med'	'0.9403'
'FS2'	'6'	'Med'	'0.93542'	'SE'	'4'	'Var'	'0.9403'
'FS2'	'12'	'Med'	'0.93541'	'SE'	'4'	'St'	'0.9403'
'TS4'	'5'	'Med'	'0.93541'	'SE'	'5'	'Var'	'0.93452'
'TS4'	'13'	'Med'	'0.93541'	'PS3'	'4'	'St'	'0.92349'
'TS4'	'3'	'Med'	'0.93541'	'PS1'	'4'	'Ku'	'0.90188'
'TS4'	'9'	'Med'	'0.93541'	'PS3'	'4'	'Sch'	'0.89581'
'TS1'	'13'	'Med'	'0.93541'	'PS1'	'5'	'Var'	'0.88297'
'TS4'	'7'	'Med'	'0.93541'	'PS2'	'5'	'Var'	'0.88074'

Pumpe				Speicher			
Sns	Int	Fk	$ \rho $	Sns	Int	Fk	$ \rho $
'SE'	'9'	'Med'	'0.9379'	'PS1'	'2'	'Var'	'0.92047'
'SE'	'11'	'Med'	'0.93573'	'PS2'	'3'	'Med'	'0.68884'
'SE'	'1'	'Med'	'0.93564'	'PS1'	'2'	'Ku'	'0.68461'
'SE'	'7'	'Med'	'0.93426'	'PS3'	'3'	'Med'	'0.66886'
'SE'	'13'	'Med'	'0.93366'	'PS3'	'3'	'Var'	'0.6465'
'SE'	'5'	'Med'	'0.92986'	'FS1'	'12'	'Pos'	'0.60334'
'SE'	'1'	'Var'	'0.89388'	'ESP1'	'6'	'St'	'0.59962'
'SE'	'2'	'Med'	'0.88837'	'PS1'	'6'	'Var'	'0.58802'
'SE'	'3'	'Var'	'0.88837'	'FS1'	'2'	'Var'	'0.58544'
'FS1'	'9'	'Med'	'0.84637'	'FS1'	'8'	'Sch'	'0.57905'
'FS1'	'1'	'Med'	'0.83073'	'PS2'	'3'	'Sch'	'0.57196'
'FS1'	'11'	'Med'	'0.82009'	'ESP1'	'12'	'St'	'0.55645'
'FS1'	'7'	'Med'	'0.81487'	'PS2'	'4'	'Pos'	'0.55219'
'FS1'	'13'	'Med'	'0.81348'	'FS1'	'1'	'Ku'	'0.55191'
'FS1'	'5'	'Med'	'0.77875'	'PS3'	'4'	'Var'	'0.54403'
'FS1'	'1'	'Var'	'0.76978'	'FS1'	'1'	'Sch'	'0.53148'
'SE'	'8'	'Med'	'0.72938'	'PS2'	'10'	'Sch'	'0.53107'
'SE'	'10'	'Med'	'0.71037'	'PS3'	'1'	'Sch'	'0.52316'
'SE'	'12'	'Med'	'0.69219'	'PS1'	'3'	'Ku'	'0.51137'
'FS1'	'12'	'Med'	'0.65963'	'FS1'	'8'	'Ku'	'0.51059'

Auffällig ist hierbei, dass die Zielzustände vom Kühler und Ventil viele starke, austauschbare Merkmale aufweisen, während die Klassifikation von Pumpe und Hydrospeicher sich auf relativ wenige relevante Merkmale beschränkt, nach denen

das Korrelationsniveau deutlich abfällt. Die Kühleffizienz-Detektion basiert im Wesentlichen auf den Mittelwerten von Volumenstrom und Temperatur, während die Ventilüberwachung primär Merkmale aus dem Zeitintervall des Ventilschaltvorgangs (Int. 4) der Sensoren Druck, Leistung, Vol.-strom und Wirkungsgrad selektiert. Die Pumpenüberwachung fokussiert sich primär auf die Mittelwerte von Wirkungsgrad und Vol.-strom aus dem gesamten Zyklus, wohingegen die Vordruck-Klassifikation ihre Information aus den transienten Lastbereichen (gerade Intervallnummern) der Druck- und Vol.-stromsignale bezieht, an denen das Lade- und Entladeverhalten des Speichers zu erkennen ist. Im letzten Fall sticht insbesondere das Merkmal Varianz des Drucks am Hydrospeicher während der Druckrampe zur Druckbegrenzung (Int. 2) mit weit überdurchschnittlicher Korrelation hervor.

Bei den Datensätzen mit randomisierten Arbeitszyklen (Abbildung 4-26) wirken die unbekanntes Lastgrößen wie eine zusätzliche Störgröße, sodass eine verschlechterte Detektion zu erwarten ist.

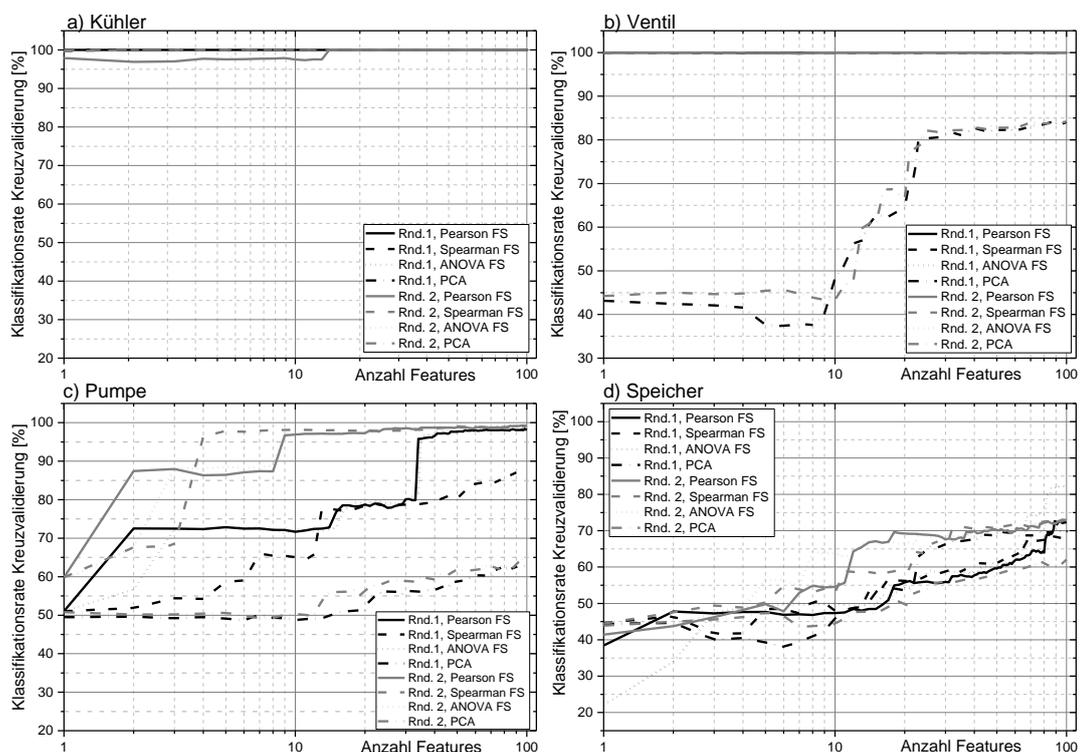


Abbildung 4-26. Klassifikationsraten bei randomisiertem Arbeitszyklus in Abhängigkeit der Merkmalsselektion und -anzahl (LDA mit Mahalanobis-Distanz Klassifikator, 10-fold Kreuzvalidierung).

Dies ist insbesondere bei der Pumpen- (c) und Speicherüberwachung (d) der Fall, während die Kühler- und Ventildetektion (a,b) weitgehend unbeeinflusst sind. Dies ist auch naheliegend, da der Kühler im separaten Kreislauf nicht unmittelbar von dem Lastverlauf des Arbeitszyklus betroffen ist. Der Ventilschaltvorgang ist hingegen vom anliegenden Druck während des Öffnens (Druckbegrenzung, Int. 3)

abhängig, der auch bei randomisierten Zyklus konstant vorgegeben ist. Die nachfolgende zufällig generierte Laststufe (Int. 5) führt nicht zu einer erkennbaren Störung der Klassifikation.

Die Pumpenleckage-Stufen (c) werden erst ab 34 Merkmalen bei beiden Datensätzen relativ zuverlässig ($> 95\%$) detektiert, während beim Hydrospeicher (d) selbst mit sehr großen Merkmalsets unabhängig von der Selektionsmethode keine ausreichend zuverlässige Aussage getroffen werden kann ($< 75\%$).

Um zu untersuchen, ob die nachgelagerte Klassifikation einen wesentlichen Einfluss hat, wurden alternative Verfahren, ein neuronales Netz (Multilayer-Perzeptron, MLP) sowie Support Vector Machines mit linearem (SVM-lin) und Gauß'schem Kernel (SVM-rbf), in Abbildung 4-27 gegenübergestellt. Das MLP in (a) zeigt zwar eine im Schnitt bessere Klassifikationsrate, aber auch eine starke Streuung der Ergebnisse. Letztere lässt sich damit begründen, dass mit dem Gradientenabstiegs-Lernverfahren (vgl. Kap. 2.3.6) nicht notwendigerweise das globale Optimum des Klassifikationsproblems identifiziert wird und somit bei der randomisierten Initialisierung der Neuronen-Gewichtungen jeweils lokale Minima mit schwankender Qualität gefunden werden. Dennoch erzielt es in Kombination mit ANOVA FS ein vergleichsweise gutes Ergebnis ($> 85\%$ bei > 70 Merkmalen).

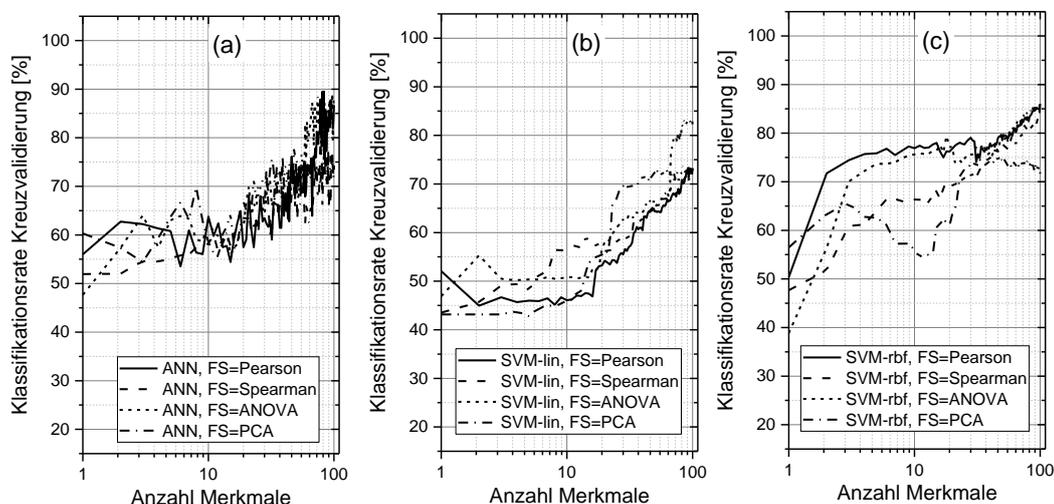


Abbildung 4-27. Hydrospeicherklassifikation bei randomisiertem Zyklus (20140801) mit alternativen Klassifikatoren: a) Neuronales Netz (Multilayer Perzeptron mit 5 Neuronen, eine verdeckte Schicht), Multiclass-SVM mit b) linearem und c) RBF Kernel (,KernelScale'='auto', $\sigma=3,7\dots5,2$) mit jeweils one-vs-one Klassifikation, $C = 1$ und ,Standardize' = 1 und jeweils 10-fold CV.

Die lineare SVM (b) weist im Wesentlichen einen ähnlichen Performanz-Verlauf wie die LDA auf. Dagegen erzielt die SVM mit RBF-Kernel eine überdurchschnittliche Klassifikation bei wenigen Merkmalen (< 30) und liegt bei Verwendung vieler Merkmale (> 70) auf einem ähnlichen Niveau wie das neuronale Netz. Bei Vorgabe einer komplexeren Struktur (Abbildung 4-28a) des ANN mit mehreren verdeckten

Schichten (> 3) ist deutlich ein Overfitting-Effekt zu sehen, ebenso bei der Wahl eines zu geringen Radius des Gauß-Kernels der SVM in (b). In diesem Fall spielt der Regulierungsparameter C , mit dem der Anpassungsgrad an die Trainingsdaten vorgegeben wird, eine untergeordnete Rolle. Bei der Hard-Margin SVM wird hierbei keine Fehlklassifikation der Trainingsdaten zugelassen, während bei der Soft-Margin SVM (kleiner Wert von C) der Fokus auf der Generalisierbarkeit, d.h. Maximierung der Margin, liegt.

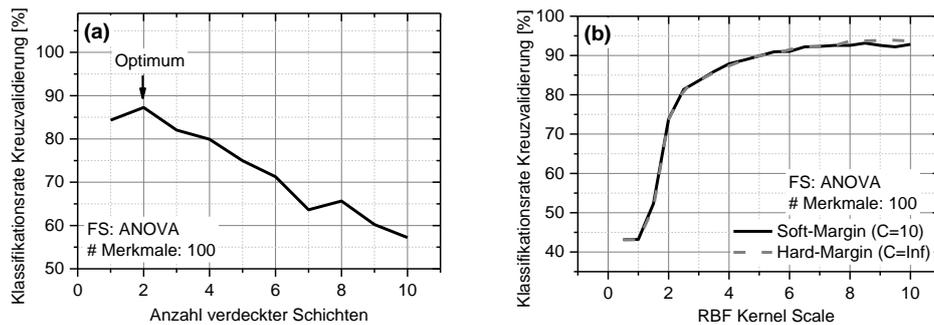


Abbildung 4-28. Parametervariation von (a) der Anzahl der verdeckten Schichten des MLP (jeweils 5 Neuronen) und (b) des RBF-Radius der SVM, 10-fold CV.

4.6.3 Auswertung über mehrere Zyklen

Im vorangegangenen Kapitel konnten, unabhängig von den untersuchten Merkmalsselektionsverfahren und Klassifikationsmethoden, für die Zustandsüberwachung des Hydrospeichers keine zufriedenstellenden Ergebnisse bei randomisierten Lastverläufen erzielt werden. Deswegen wird im Folgenden die Merkmalsextraktion von einem Zyklus auf mehrere Zyklen erweitert (vgl. Kap. 3), indem der zyklusbasierten Merkmalsextraktion eine zweite Merkmalsextraktion auf Basis der primären Merkmale über x Zyklen angeschlossen wird. Abbildung 4-29a zeigt den Einfluss der Zyklen- und Merkmalsanzahl auf die Klassifikationsrate. Es ist festzustellen, dass tendenziell große Merkmalssets (> 40) in Kombination mit einer Merkmalsextraktion über mehr als 40 Zyklen zu einer signifikanten Verbesserung der Detektion führen. Abbildung 4-30 zeigt die LDA-Projektionen, die mit zunehmender Zahl einbezogener Zyklen eine verbesserte Klassentrennung der Vordruck-Stufen entlang DF 1 aufweisen.

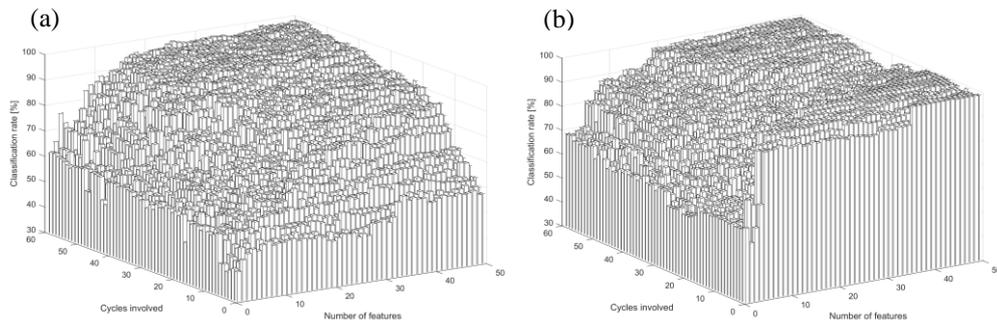


Abbildung 4-29. a) Speicher- und b) Pumpen-Klassifikationsrate in Abhängigkeit der Anzahl involvierter Zyklen und Merkmale (randomisierter Zyklus, 10-fold CV).

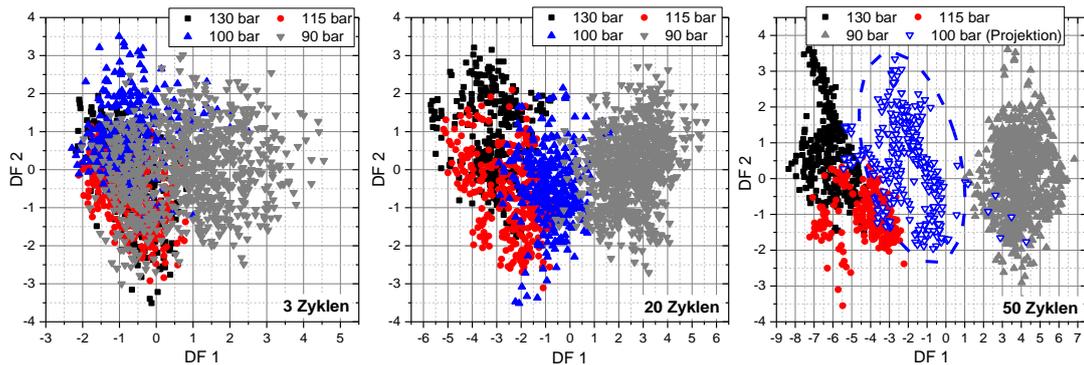


Abbildung 4-30. Verbesserte Klassentrennung der LDA Projektionen (Speicher-Vordruck) bei zunehmender Zyklenzahl, jeweils 20 Merkmale.

Dieser Zusammenhang ist jedoch nur begrenzt übertragbar: Bei der Pumpendetektion (Abbildung 4-29b) ist eine deutlich schlechtere Performanz bei einer zyklusübergreifenden Auswertung (> 5 Zyklen bei < 20 Merkmalen) erkennbar, sodass für diese Anwendung eher die Betrachtung einzelner Zyklen bei einer hohen Merkmalsanzahl einen Vorteil bringt.

Zusammenfassend lässt sich feststellen, dass die zyklusübergreifende Auswertung ein vielversprechender Ansatz ist, um die Stabilität und Robustheit zu erhöhen. Bei Betrachtung ausreichend großer Zeitbereiche (> 40 Zyklen) und somit statistisch aussagekräftigen Stichproben können bei randomisierten Lastvorgaben die Erkennungsraten des Speicher-Vordrucks signifikant (um bis zu 40 %) gesteigert werden. Die Gewichtung des einzelnen Zyklus sinkt und somit auch der Einfluss von Störeinflüssen (z.B. Ausreißer). Gleichzeitig erlaubt der Ansatz auch, Trendinformation von Primärmerkmalen in Sekundärmerkmale abzubilden und somit den Informationsgehalt wesentlich zu erweitern. Nichtsdestotrotz konnte gezeigt werden, dass der Ansatz nicht notwendigerweise Vorteile bietet und individuell evaluiert werden muss, ob sich der Mehraufwand für die zweistufige Merkmalsextraktion lohnt.

4.6.4 Langzeitstabilität und Übertragbarkeit

Zur Erprobung der Übertragbarkeit und Stabilität des statistischen Modells wurden mit einem zweiten, weitgehend baugleichen Hydraulikaggregat (Abbildung 4-10) Messdaten bei identischem konstanten Arbeitszyklus über die Zeitdauer eines Monats aufgezeichnet. Das statistische Modell wurde mit dem Datensatz Const. 1 erzeugt, der mit der ersten Woche der Langzeitmessung von Prüfstand 2 ergänzt wurde. Die ergänzten Daten wurden als jeweils schadensfrei deklariert. Die Idee hierbei ist, die Schadensmechanismen anhand von Prüfstand 1 anzulernen und durch das Einbeziehen des Normalzustands von Prüfstand 2 zu verallgemeinern und übertragbar zu machen. Abbildung 4-31 zeigt die LDA-Projektion der Trainings- sowie die Projektion der Testdaten.

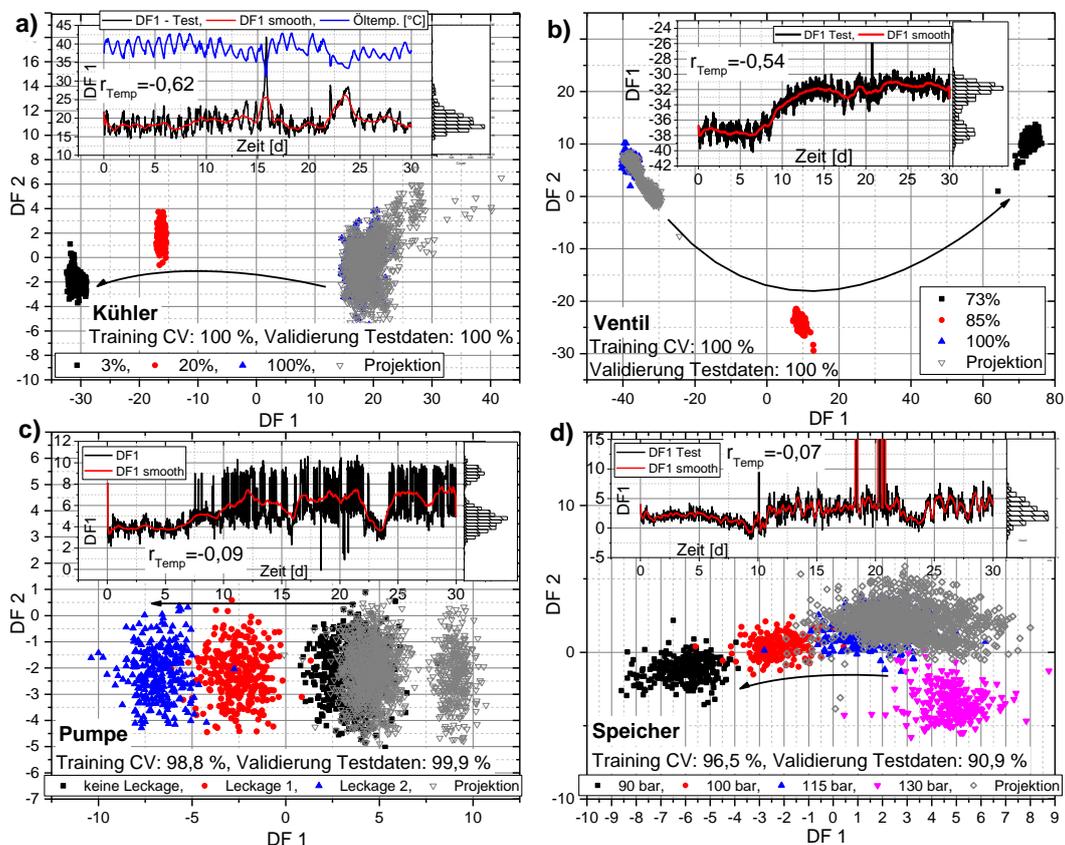


Abbildung 4-31. Anlernen der Komponentenschäden mit Prüfstand 1, Projektion der Langzeitdaten über einen Monat von Prüfstand 2. Verwendet wurden 20 (a,b,c) und 50 (d) Merkmale.

Zu erkennen ist, dass sich die Daten beider Prüfstände kombinieren lassen, ohne dass sich der Kreuzvalidierungsfehler des Trainingsmodells verschlechtert. Erfolgt nun die Projektion der Testdaten über den gesamten Zeitraum, ist eine deutliche Zunahme der Streuung zu beobachten. Im Fall der Kühlerüberwachung (a) weisen sowohl DF 1 als auch DF 2 eine deutliche Korrelation zur Öltemperatur auf, in der sich sinusförmig der Tag-Nacht-Verlauf der Umgebungstemperatur widerspiegelt,

welche wiederum einen direkten Einfluss auf die Kühleffizienz hat. Bei der Ventilüberwachung (b) weist DF 1 nach der ersten Woche eine Driftbewegung in Richtung der ersten Schadensklasse auf, sodass sich hier erste Degradationseffekte des Ventils vermuten lassen, die sich ab Tag 14 aber stabilisieren. In den Fällen c) und d) lässt sich erkennen, dass DF 1 an Stabilität verliert, sobald die Testphase (ab Tag 8) beginnt. In beiden Fällen treten Ausreißer primär entgegen der vermuteten Schadensrichtung auf und bilden teilweise ein versetztes Nebencluster (c) aus. Bei der Vordruck-Detektion (d) wurde der Zustand des zweiten Systems (120 bar) mit der benachbarten Klasse (115 bar) des ersten Systems zusammengefasst, wobei die Projektion wie zu erwarten in Richtung 130 bar tendiert. An den Tagen 18 und 20 treten insgesamt vier Ausreißer ($DF\ 1 > 200$) auf, die Basislinie bleibt jedoch stabil.

Daraus resultieren in allen untersuchten Schadensfällen Klassifikationsraten von 100 % (a, b) bzw. nahe 100 % (c, d) unter der Annahme, dass im betrachteten Zeitraum keine signifikanten Degradationsprozesse abgelaufen sind. Dies zeigt, dass eine Übertragbarkeit der Sensorsignalmuster zwischen ähnlichen Systemen möglich ist, sofern unvermeidbare systemimmanente Unterschiede (Verrohrung, Toleranzen, etc.) mit in den Trainingsdaten abgebildet und somit gezielt bei der statistischen Modellbildung unterdrückt werden. Alternativ könnte durch Angleichen des Lageparameters $w_{i,0}$ der LDA-Projektionsvorschrift (vgl. Kap. 2.3.4.2) eine DF-Offsetkorrektur durchgeführt werden, welche die Normalzustände auf eine identische Position abbildet.

4.6.5 Einfluss der Abtastrate

Neben der Instrumentierung des zu überwachenden Hydrauliksystems spielt die Datenerfassung, insbesondere die Samplingrate, eine wichtige Rolle. Hierbei ist eine Abwägung zwischen benötigter zeitlicher Auflösung und anfallender Datenrate zu treffen. Im vorliegenden Fall erfolgte die Datenaufnahme wie in Tabelle 4-4 in den Abstufungen 100, 10 und 1 Hz je nach Messgröße. In der folgenden Untersuchung erfolgt eine künstliche Reduzierung der Datenrate zum einen mittels direkter Reduktion, d.h. Herausgreifen jeden x-ten Datenpunktes, zum anderen mittels Downsampling, d.h. mit vorangegangener FIR Antialiasing Tiefpass-Filterung des Signals mithilfe der Matlab Funktion `resample` [151].

Abbildung 4-32 zeigt den Einfluss der maximalen Samplingfrequenz im Bereich von 100 Hz bis 2 Hz auf die Schadenserkenung. Wie zu erwarten, weist die Klassifikationsrate in den Fällen mit primär statischen Symptomen (Kühler, Pumpe) keine oder nur sehr geringe Änderungen (bis zu 2 %) auf. Demgegenüber ist bei den Schadensfällen mit transienten Symptomen eine verringerte Performanz der

Hydrospeicher- (konstanter Zyklus) bzw. Ventil-Klassifikation (randomisierter Zyklus) zu erkennen. Dies ist insbesondere bei der direkten Datenreduktion ohne Antialiasing deutlich zu erkennen, während eine vorangegangene Tiefpassfilterung der Sensorsignale diesen Effekt verringert und eine Verletzung des Nyquist-Shannon-Abtasttheorems verhindert.

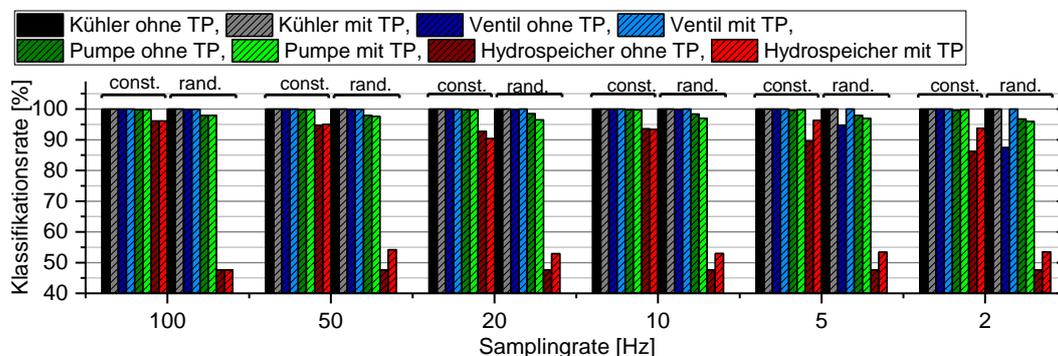


Abbildung 4-32. Einfluss der Samplingrate auf die Klassifikationsrate mit und ohne Tiefpass (TP) unterteilt nach Schadenstyp und Arbeitszyklus (konstant, randomisiert). 20 Merkmale, Spearman FS, 10-fold CV.

Abbildung 4-33 greift obengenannte Fälle auf und stellt zusätzlich den Einfluss der Anzahl von verwendeten Merkmalen dar. Hierbei zeigt sich, dass sich insbesondere bei Verwendung von wenigen Merkmalen eine Reduzierung der Samplingrate negativ auswirkt, während bei vielen Merkmalen (> 30) der Einfluss weitgehend kompensiert wird.

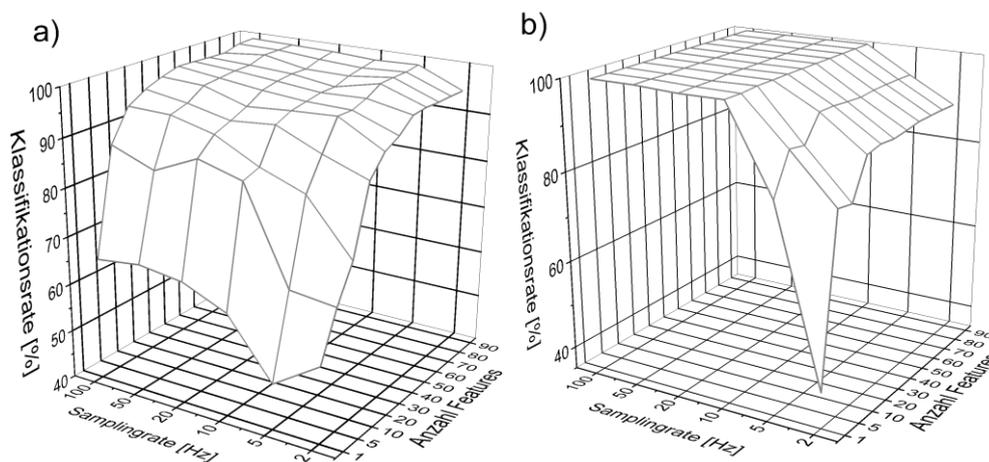


Abbildung 4-33. Klassifikationsrate gegenüber Samplingrate und Anzahl der Merkmale ohne Antialiasing bei a) Hydrospeicher bei konstantem Arbeitszyklus und b) Ventil bei randomisiertem Arbeitszyklus.

Grundsätzlich lässt sich erkennen, dass bei den meisten untersuchten Szenarien die Samplingfrequenz der Datenerfassung und somit die anfallende Datenrate ohne nennenswerte Einbußen der Klassifikationsrate signifikant verringert werden könnte. Dadurch reduzieren sich die Hardware-Anforderungen der nachfolgenden

Signalverarbeitung insbesondere bei der Merkmalsextraktion, sodass sich hier perspektivisch die Implementierung der Zustandsdetektion auf weniger leistungsfähigen, kostengünstigen Systemen, etwa direkt in der SPS, anbietet.

4.6.6 Diskussion

Die isoliert vorliegenden Schadensfälle können bei konstantem Arbeitszyklus zuverlässig quantifiziert werden mit einer Detektionsgrenze von ca.

- 10 W Leistungsreduktion des Öl-Luft Kühlers
- 10 ms Schaltverzögerung des Wegeventils (begrenzt durch zeitliche Auflösung der Datenerfassung)
- 0,5 % relativer Pumpenleckage
- 5 bar Vordruck-Verlust des Hydrospeichers

Somit ist eine hochaufgelöste Zustandsüberwachung der untersuchten Komponenten möglich. Die durchgeführten systematischen Charakterisierungsmessungen erlauben mit dem vorgestellten teilautomatisierten Vorgehen eine effektive Erzeugung von statistischen Modellen. Die hierfür aus den Sensorsignalen extrahierten und selektierten Merkmale sind für die untersuchten Zielgrößen physikalisch plausibel. Als übergreifend relevante Messgrößen sind insbesondere Drücke, Volumenströme, Antriebsleistung sowie Wirkungsgrad zu nennen. Der Einfluss der Abtastrate der Sensorsignale im untersuchten Bereich 2 bis 100 Hz ist als eher gering zu bewerten, sodass für die industrielle Anwendung eine Abtastung mit 10 Hz ausreichend und praktikabel wäre. Bei Überlagerung der Schadenszustände, die untereinander als Störgröße fungieren, kann eine optimale (Kühler, Ventil) bzw. nahezu optimale (Pumpe, Speicher) Detektion der betrachteten Schadensstufen mittels LDA erreicht werden. Im Gegensatz zur PCA erlaubt dieses Dimensionsreduktionsverfahren auf Basis der selektierten Merkmale eine direkte Quantifizierung mittels der ersten Projektionskomponente. Bei der Merkmalsreduktion erreichen die überwachten Merkmalsselektionsverfahren im Vergleich zur unüberwachten PCA deutlich bessere Ergebnisse, sodass diese zu bevorzugen sind.

Erfolgt die Vorgabe der Arbeitszyklen mit randomisierten Laststufen, reduziert sich die Zuverlässigkeit des Modells insbesondere bei der Pumpen- und Speicherüberwachung auf Basis eines einzelnen Zyklus bei wenigen Merkmalen drastisch. Eine Erhöhung der Merkmalszahl verbessert zwar die Detektion, bleibt aber selbst bei 100 Merkmalen bei der Vordrucküberwachung des Speichers auf niedrigem Niveau (< 85 %). Alternative nichtlineare Klassifikationsverfahren (ANN, SVM RBF) ermöglichen bei gleicher Merkmalsanzahl leicht bessere, aber insgesamt

ebenfalls nicht zufriedenstellende Ergebnisse. Bei ungünstiger Wahl ihrer Eingangsparameter konnte zudem Overfitting nachgewiesen werden.

Eine deutliche Verbesserung kann je nach Zielgröße durch eine sekundäre Merkmalsextraktion über mehrere Zyklen erreicht werden, mit der bei geeigneter Wahl der Merkmals- und Zyklenanzahl eine nahezu optimale Erkennungsrate (Hydrospeicher) erreicht werden kann.

Die Übertragbarkeit des Modells zwischen zwei größtenteils baugleichen Hydraulik-Systemen ist mit den Prozesssensordaten indirekt, d.h. nach Offset-Abgleich bzw. einer Kombination der Trainingsdaten, möglich und über einen betrachteten Zeitraum von 30 Tagen stabil, wenngleich deutliche Streuungen, etwa durch wechselnde Umgebungstemperaturen, bei den LDA-Projektionen erkennbar sind.

4.7 Einfluss von Ölparametern

4.7.1 Öltemperatur und freie Luft

In der Praxis liegen nicht notwendigerweise konstante Rahmenbedingungen bei Betrieb des hydraulischen Systems vor. Typische Störgrößen, die das Verhalten der Anlage beeinflussen, sind Umgebungstemperaturschwankungen sowie der Eintrag freier Luft in den Fluidkreislauf.

Abbildung 4-34 schlüsselt die DF 1 Projektion der Trainingsdaten in Abhängigkeit des Öltemperaturbereichs auf. Hierbei ist in (d) deutlich zu erkennen, dass eine Aufweitung des Temperaturintervalls die Unsicherheit der Detektion insbesondere in den Fällen (b, c) deutlich erhöht.

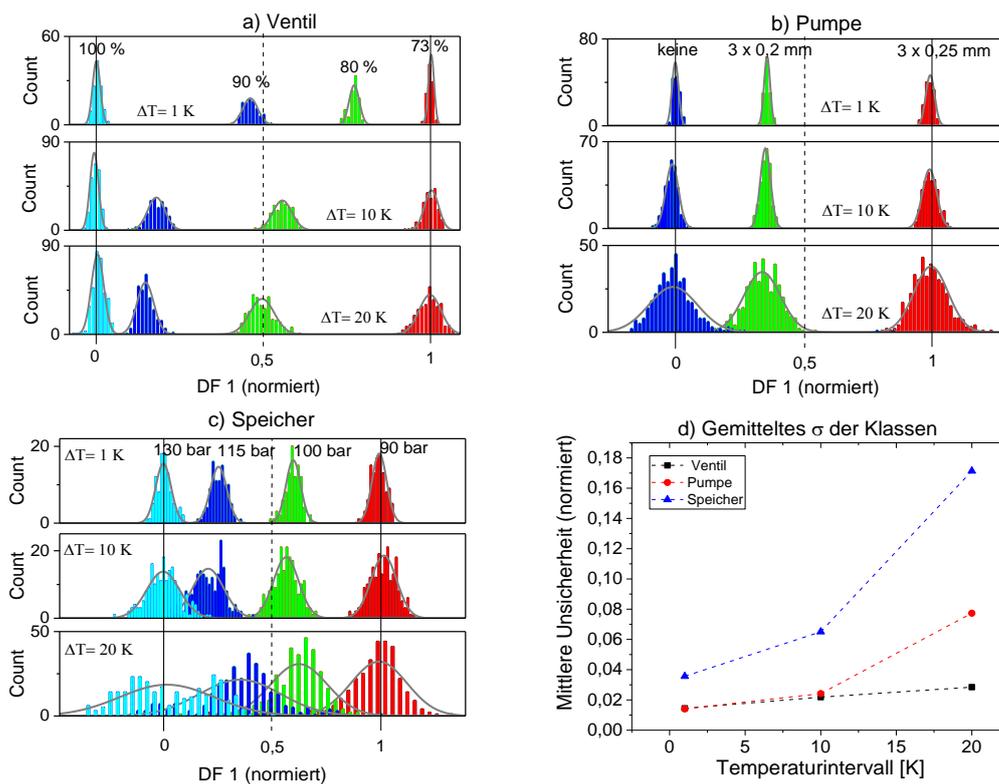


Abbildung 4-34. Erhöhung der Detektions-Unsicherheit bei Erweiterung des Öltemperaturbereichs, Datensatz Const. 2 mit $n = 405$ bei $1\text{ K} / 800$ bei $10\text{ K} / 1.195$ bei 20 K , 20 Merkmale. Zur Vergleichbarkeit erfolgt die Skalierung von DF 1 anhand der äußeren Zentroide im Bereich 0 bis 1.

Neben der Variation der Öltemperatur wird nachfolgend auch der Eintrag freier Luft ins Öl experimentell nachgestellt und deren Einfluss auf die statistische Modellbildung untersucht. In einer Charakterisierungsmessung wurden hierbei 0, 1,3 und 4,0 Vol.-% Luft in Relation zum Fluid-Volumenstrom von MP1 mithilfe des Proportionalregelventils (vgl. Kap. 4.5.3) mit drei Wiederholungen bei unterschiedlichen Kühlleistungen (100, 50, 20 % Tastgrad des Lüfters) eingebracht, wobei Öltemperaturen von ca. 46, 53 und 63 °C hinter dem Lastventil V11 gemessen wurden. In den inneren Verschachtelungsschleifen wurde der Pumpenzustand sowie der Ventilzustand mit jeweils 3 Stufen variiert, vgl. Abbildung 4-35.

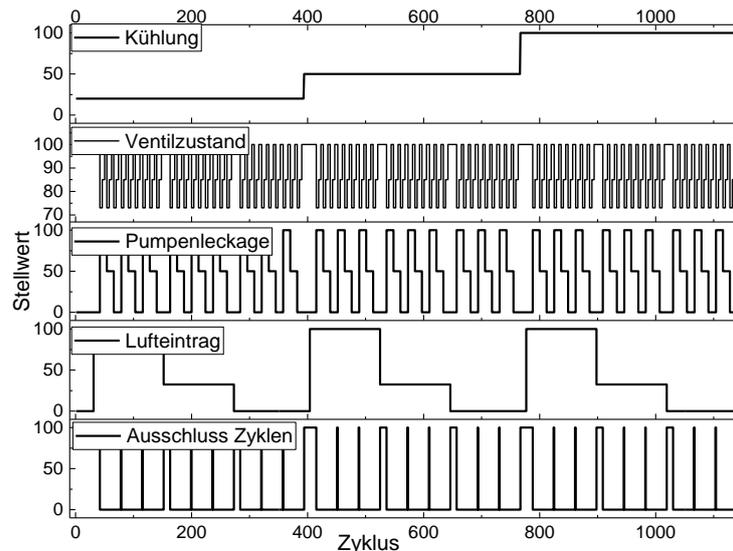


Abbildung 4-35. Charakterisierungsmessung der Störparameter Lufteintrag und Öltemperatur.

Anschließend erfolgt eine Partitionierung des Datensatzes in die 9 individuellen Gruppenkombinationen von je drei Luft- und Öltemperaturzuständen, um deren Einfluss auf die Zielgrößen Ventil- und Pumpenzustand zu untersuchen. Hierbei werden die 20 höchstkorrelierten Merkmale nach Spearman verwendet, sodass das minimale Verhältnis der Merkmals- zu Beobachtungsanzahl bei 1:10 liegt. Abbildung 4-36 zeigt in (a) als Maß der Klassentrennung das Verhältnis von Streuung innerhalb der Klassen zur Streuung zwischen den Klassen von DF 1 auf Basis der Trainingsdaten bei Ausweitung der Störgrößenbereiche und in (b) die korrespondierende LDA-Projektion. Zu erkennen ist hierbei, dass eine isolierte Störgröße einen verhältnismäßig geringen Einfluss hat (jeweils 100 % Klassifizierung), während insbesondere die Kombination von erhöhten Öltemperaturen und hohem Lufteintrag die Klassentrennung erschwert.

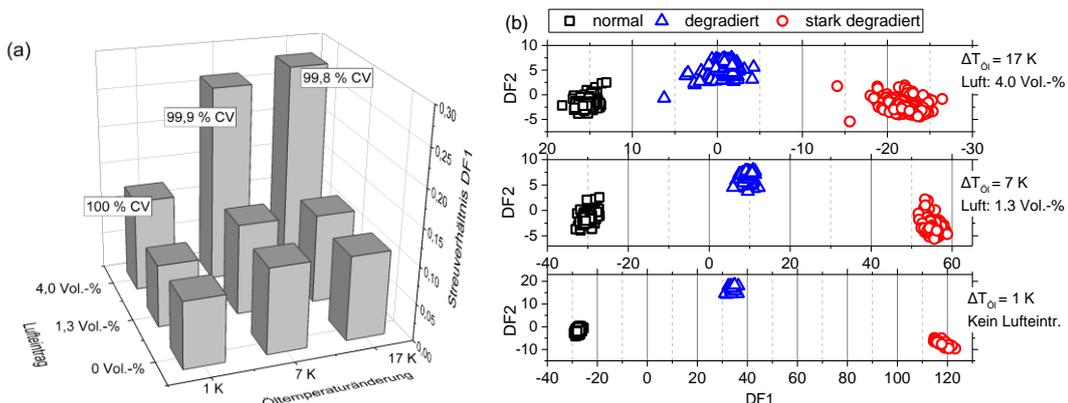


Abbildung 4-36. Detektion Ventilzustand bei freier Luft und Ausweitung des Öltemperaturbereichs mit (a) dem Streuverhalten von DF1 und (b) der zugehörigen LDA-Projektion nach [152], 20 Merkmale.

Bei der Pumpendetektion ist der Störeinfluss nochmals deutlicher zu erkennen (Abbildung 4-37): Im ersten Fall (Ventil) verschlechtert sich die Klassentrennung

maximal um den Faktor 3, bei der Pumpenüberwachung jedoch um den Faktor 12. Wie in der Projektion in (b) zu erkennen, entsteht bei Berücksichtigung aller Störgrößen ein deutlicher Überlapp der Klassen, der zu einer Klassifikationsrate $< 88\%$ führt.

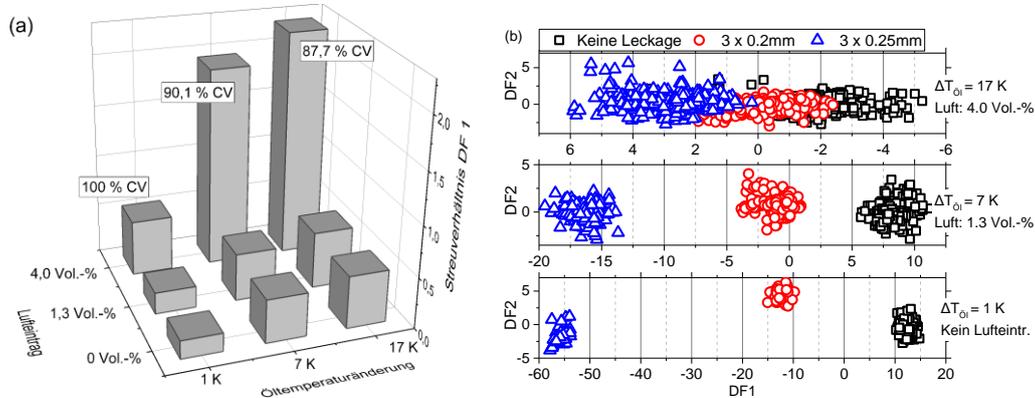


Abbildung 4-37. Detektion Pumpenleckage vs. freie Luft und Ausweitung des Öltemperaturbereichs mit (a) Streuverhalten von DF_1 , (b) zugehörige LDA-Projektion nach [152], 20 Merkmale.

Am stärksten gewichtet sind hierbei die Wirkungsgrad-Merkmale, die bei hoher Lufteintragsrate und erhöhten Öltemperaturen um bis zu 10 % einbrechen (Abbildung 4-38). Dies resultiert aus den überlagerten volumetrischen Verlusten aufgrund niedriger Ölviskosität, eingebrachter Luftblasen sowie erhöhter Fluidkompressibilität, sodass die mithilfe der Blenden simulierten Verschleißstufen der Pumpe mit kleinen relativen Änderungen des Wirkungsgrads im Bereich von ca. 3 % überdeckt werden.

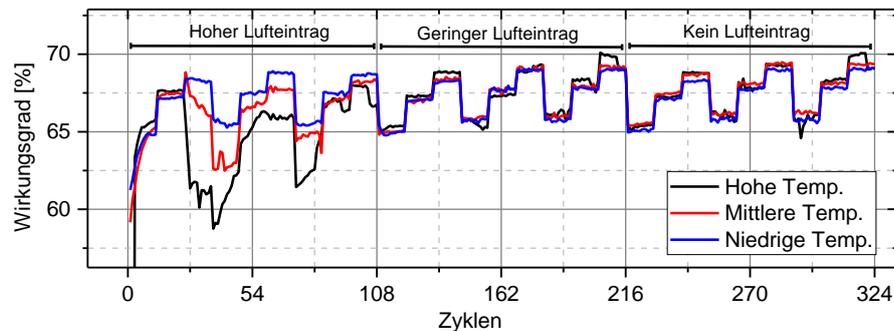


Abbildung 4-38. Wirkungsgradverlauf bei Störgrößeneinfluss.

Die gezeigte Auswertung setzt den Fall voraus, dass die Störparameter bereits „bekannt“, d.h. in den Trainingsdaten enthalten sind, sodass gezielt Merkmale selektiert werden können, die möglichst unempfindlich gegenüber der Störung sind. Tritt eine dominante Störgröße erst nach dem Training auf, bedeutet dies eine Extrapolation der Projektion durch das statistische Modell, bei der die Validität des Modells i.d.R. nicht mehr gewährleistet ist. Dieses Phänomen ist in Abbildung 4-39a dargestellt, bei der die Pumpenleckage-Detektion bei normaler Öltemperatur trainiert und die höheren Temperaturstufen projiziert werden. Dies führt zu deutlichen

Drifteffekten in Diagonalrichtung mit DF 1 und DF 2 Anteilen und instabiler Projektion, d.h. einem überlagerten Offset betragsmäßig eine Größenordnung höher als die eigentliche Leckageerkennung in negativer Richtung DF 1 und somit letztendlich zu fehlerhafter Klassifikation.

Die Erkennung eines übergeordneten abweichenden Systemverhaltens ist eine typische Anwendung der Anomaliedetektion [51] bzw. kann als Ein-Klassen Problem [153] formuliert werden, soll jedoch im Rahmen dieser Arbeit nicht betrachtet werden.

Bekannte Störgrößen können beim Training gezielt mit im Zielgrößenvektor annotiert werden, um der Bildung von Sub-Clustern innerhalb einer Klasse entgegenzuwirken und eine klassenbezogene Normalverteilung der Merkmale zu erreichen. Abbildung 4-39b zeigt, dass es ausreichend sein kann, die Extremwerte der Störgröße (normale und hohe Öltemperatur) beim Training einzubeziehen und auf deren Basis die Zwischenstufen zu interpolieren.

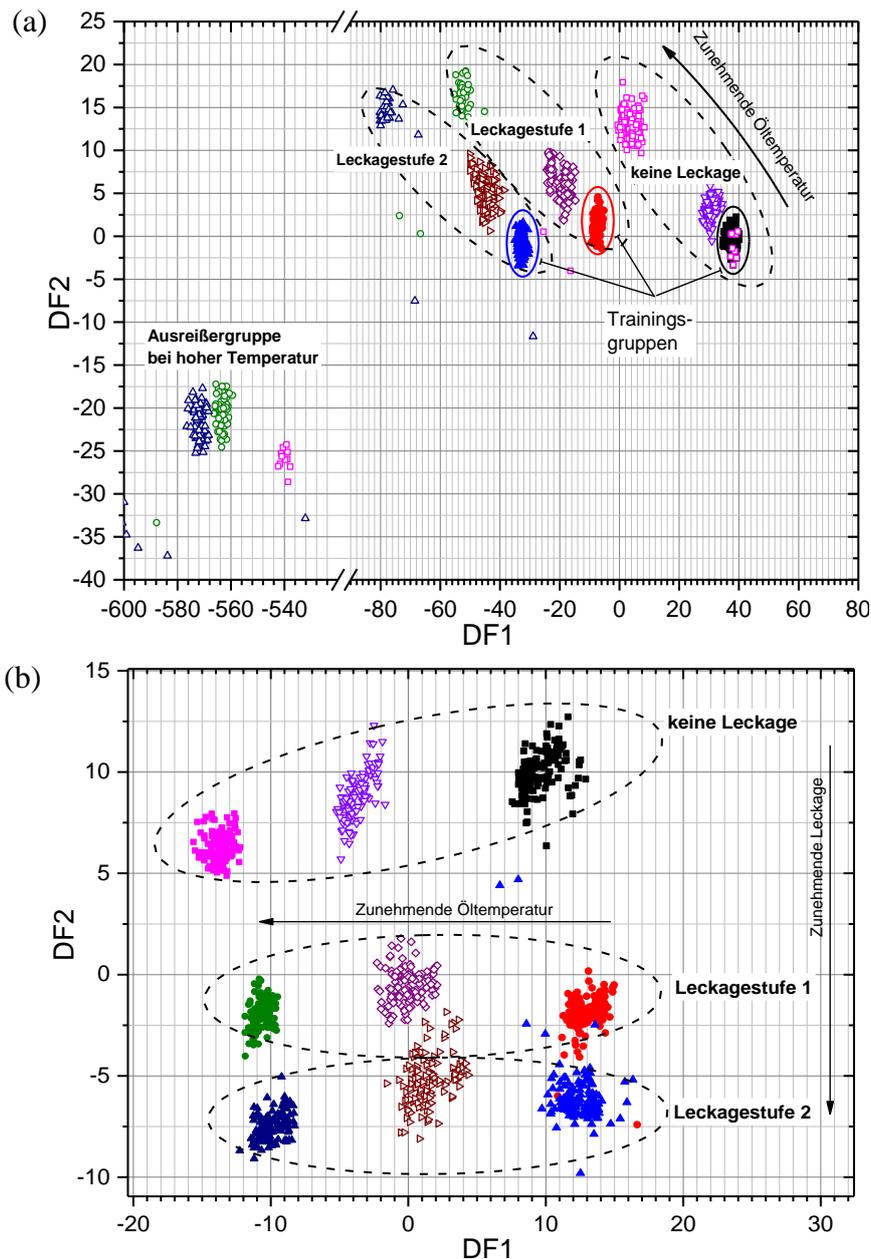


Abbildung 4-39. (a) Pumpenleckage trainiert bei normaler Öltemperatur, Projektion der übrigen Klassen, (b) Training bei normaler und hoher Temperatur, Projektion der Zwischenklasse, jeweils 20 Merkmale.

Im Folgenden wird nun der Einfluss der Öltemperatur auf die Merkmalselektion betrachtet, bei der sich teilweise deutliche Verschiebungen erkennen lassen. Abbildung 4-40 stellt die Gewichtung der Sensoren, Intervalle und Merkmalsfunktionen als relativen Anteil des summierten Korrelationsbetrags zur jeweiligen Zielgröße dar. Während die selektierten Merkmale bei der Ventilüberwachung (a) weitgehend unverändert bleiben, ist im Falle des Pumpenzustands (b) eine Verschiebung der Sensor-Anteile von den Drucksensoren zu Wirkungsgrad und Volumenstrom zu erkennen sowie eine stärkere Gewichtung des Gesamtzyklus bei reduziertem Einfluss der konstanten Druckplateaus (Int. 5, 7,

11, 13). Besonders auffällig sind die Änderungen jedoch bei der Speicherüberwachung (c). Bei der Sensorselektion ohne Störgröße wird die Öltemperatur TS1 als statistisch relevant beurteilt, was mit dem physikalischen Modell des Hydrospeichers nicht in Einklang gebracht werden kann. Dieser Effekt lässt sich auf eine zufällig überlagerte Korrelation des Schadensverlaufs mit der Öltemperatur zurückführen. Durch das Einbeziehen der Wiederholungen bei unterschiedlichen Öltemperaturen wird die Temperaturinformation vollständig verworfen und die Gewichtung verschiebt sich zu den physikalisch sinnvollen Messgrößen Druck und Volumenstrom.

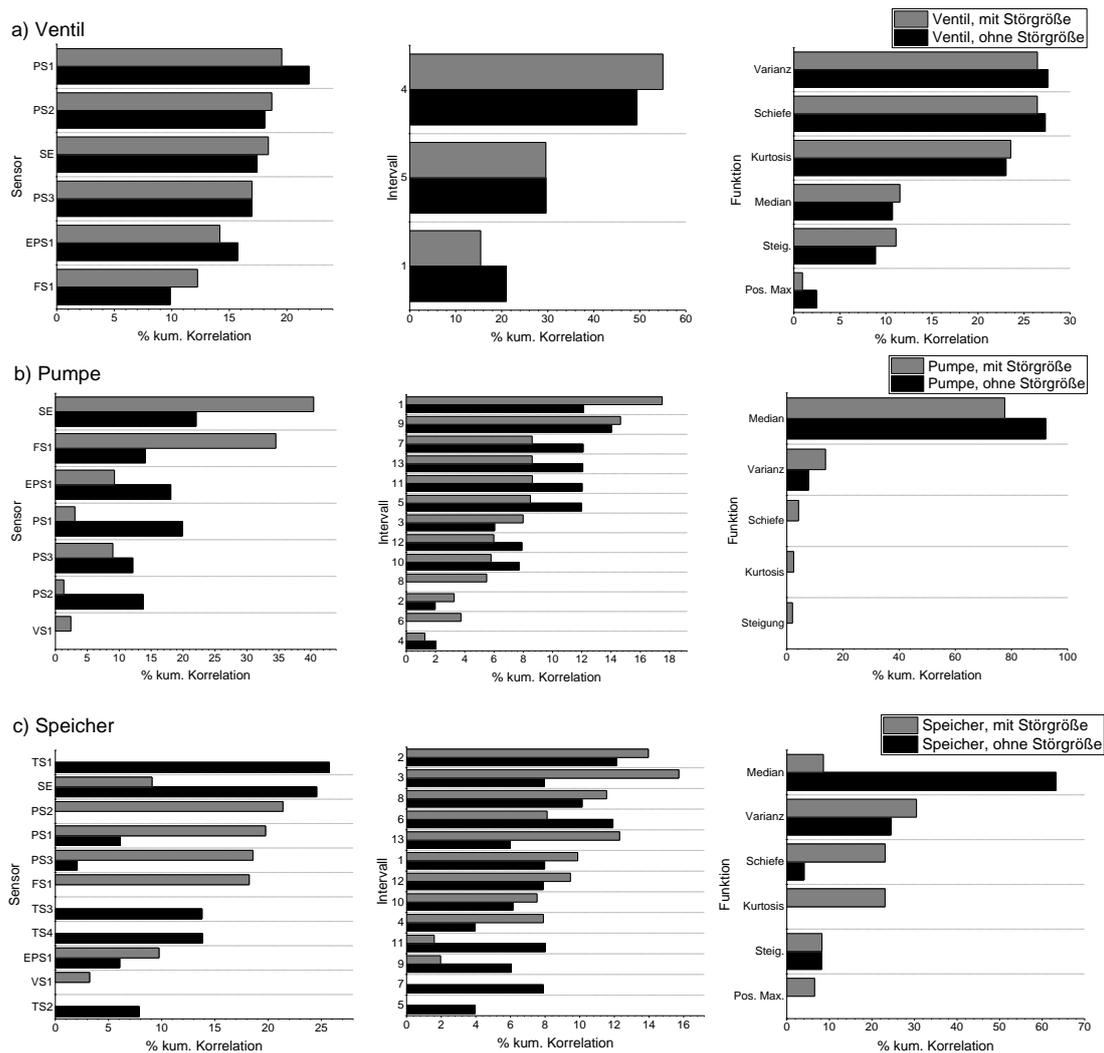


Abbildung 4-40. Vergleich der Selektion auf Basis des Datensatzes Const. 1 bei konstanter (ohne Störgröße) und variierter (mit Störgröße) Öltemperatur aufgeschlüsselt nach Sensoren, Intervallen und Funktionen der 50 relevantesten Merkmale (Spearman).

4.7.2 Partikelkontamination und Filterbeladung

Im Folgenden wurde an den sekundären Kühl-Filterkreislauf des Hydrauliksystems in der Ansaugleitung der Pumpe MP2 der Aufbau zur Injektion von definierten Partikelkonzentrationen angeschlossen (Abbildung 4-15). In Anlehnung an die Testkonfiguration des Multipass-Tests nach ISO 16889 [154] wird in einem zweiten Tank eine Suspension von Hydrauliköl und ISO-Teststaub (ISO MTD A3, ISO 12103-1) mit einer Konzentration von 30 g/l über zwei Verdünnungsstufen dem Hauptstrom zudosiert.

In einer Messung über ca. 40 Stunden wird die Fördermenge der Peristaltikpumpe in drei Schritten (16, 11, 22 *mg/min* Partikelzugabe bei angenommener homogener Durchmischung), alternierend mit Phasen ohne Beimischung, variiert (Abbildung 4-41). Die Kontamination wird der intrinsischen Hintergrundbelastung des Hydrauliksystems, welche vorab mit ISO-Klasse 14/9/7 bestimmt wurde, überlagert. Die Messung der Konzentration erfolgt mit dem optischen Partikelsensor Hydac CS 1000 [133], der hinter dem Filter F2 positioniert ist (c), wobei von letzterem die Partikel $> 14 \mu\text{m}$ weitestgehend zurückgehalten werden, sodass die Konzentration unterhalb der Detektionsgrenze des Sensors liegt. Der Differenzdruck (b), Indikator für die akkumulierte, vom Filter zurückgehaltene Staubmenge steigt während des Versuchs mit einer wie von Vetter et al. [154] beschriebenen Kurvenform kontinuierlich an. Während der Messung wurde die Öltemperatur randomisiert variiert ($\Delta T \approx 10 \text{ }^\circ\text{C}$), um gezielt eine Störgröße mit abzubilden. Diese überlagerte Störung ist erkennbar in Form eines Signalripples beim CS 1000 und Differenzdruck (a,b). Die Messung wurde nach der Zugabe von ca. 20,5 g Teststaub beim Überschreiten des Filter-Differenzdrucks von 5 bar beendet. In der nachfolgenden Auswertung wurden die Übergangszustände (60 Minuten) nach jeder Sollwert-Änderung verworfen.

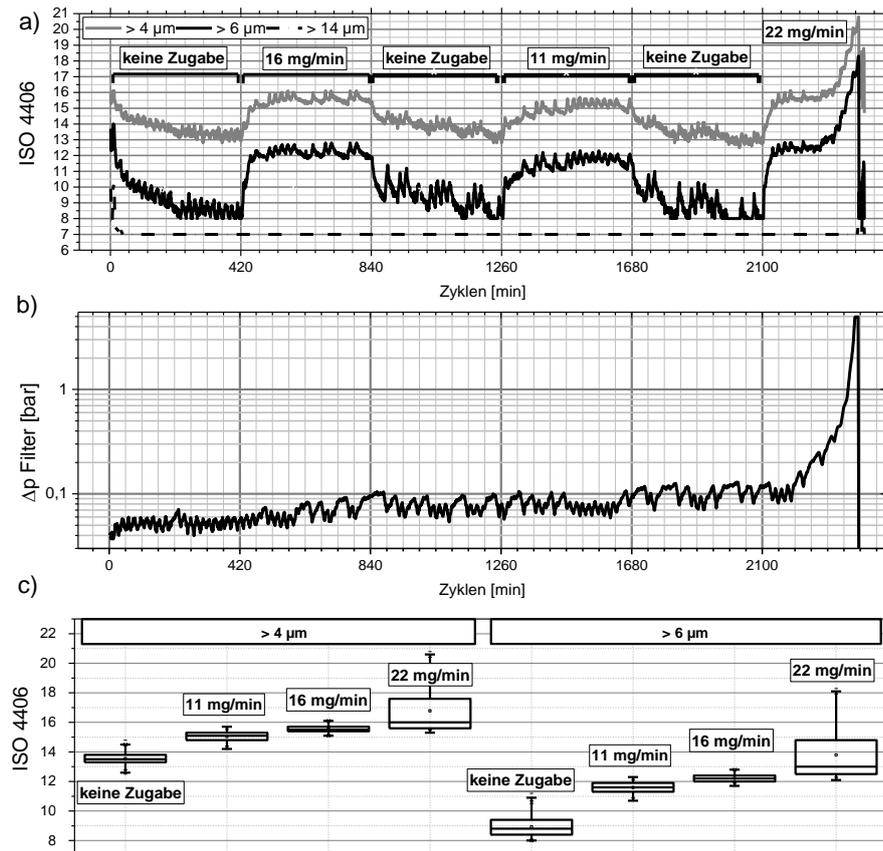


Abbildung 4-41. Charakterisierungsmessung mit (a) Partikelkontamination gemessen mit Hydac CS1000 mit Partikel $> 14 \mu\text{m}$ unterhalb des Detektionslimits, (b) Differenzdruck über Filterelement F2, (c) Boxplot der Reinheitsklassen nach ISO 4406 hinter dem Filter, extrahiert aus (a), nach [152].

Nachfolgend dient die Konzentration der Staubzudosierung als Zielgröße der Klassifikation auf Basis der Prozesssensoren (Abbildung 4-42). Die selektierten Sekundärmerkmale, extrahiert über 60 Zyklen, spiegeln hierbei primär die Langzeit-Druckverläufe und -anstiege wider. Bei der LDA-Projektion lässt sich eine quantitative Aufschlüsselung der Klassen entlang von DF 1 mit deutlichem Überlapp bei den niedrigeren Konzentrationsstufen erkennen (b). Die höchste Fluidverunreinigungsstufe (22 mg/min) setzt sich deutlich von den übrigen Klassen ab, was vermutlich wesentlich durch den zu diesem Zeitpunkt angestiegenen Differenzdruck über dem Filter verursacht wird. Insofern ist die Aussagekraft der Projektion begrenzt; zudem sind die zudosierten Staubkonzentrationen wesentlich höher als die in der Praxis zu erwartenden Einträge, sodass das statistische Modell ohne Verwendung von spezialisierter Partikelsensorik keine ausreichende Genauigkeit für eine praktikable Kontaminationsabschätzung aufweist.

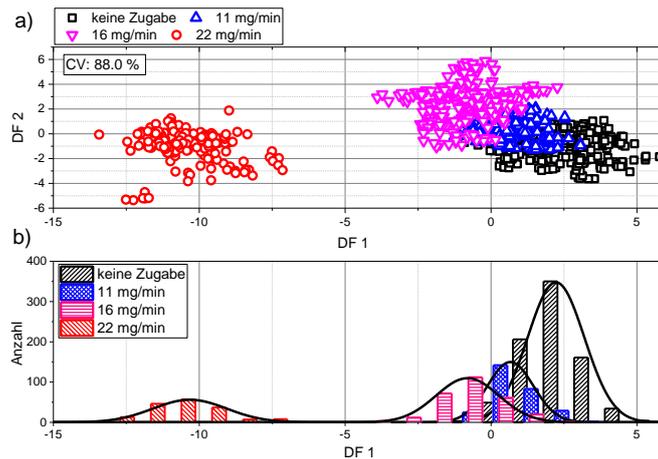


Abbildung 4-42. Abschätzung der Partikelbelastung [152] aus Basis von 50 Langzeit-Merkmalen über 60 Zyklen; (a) LDA-Projektion der vier Kontaminationsklassen und (b) gruppenbezogenes Histogramm von DF 1.

Im zweiten Schritt erfolgt die Klassifikation des stationären Filterbeladungszustandes, also der kumulierten Teststaubmenge in den Bereichen ohne Zugabe (0 g/6,7 g/11,3 g). Die Beladungsbestimmung nach dem Stand der Technik erfolgt über den Filter-Differenzdruck, mit dem jedoch eine eindeutige Unterscheidung der drei Klassen aufgrund der Öltemperaturvariation nicht möglich ist (Abbildung 4-43a). Mithilfe des multivariaten statistischen Modells (b) reduziert sich die Standardabweichung von DF 1 innerhalb der Gruppen deutlich, sodass eine vollständige Klassentrennung erreicht werden kann. Der Störeinfluss der Öltemperatur wird somit gezielt im Modell mit abgebildet und kompensiert. Zur Verifikation erfolgt in (c) die Projektion der zuvor nicht berücksichtigten Übergangszustände, die korrekt als transiente Punktwolken zwischen den Trainingsklassen interpoliert, bzw. kurz vor Ausfall in beiden Diskriminanzfunktionen ansteigend extrapoliert dargestellt werden.

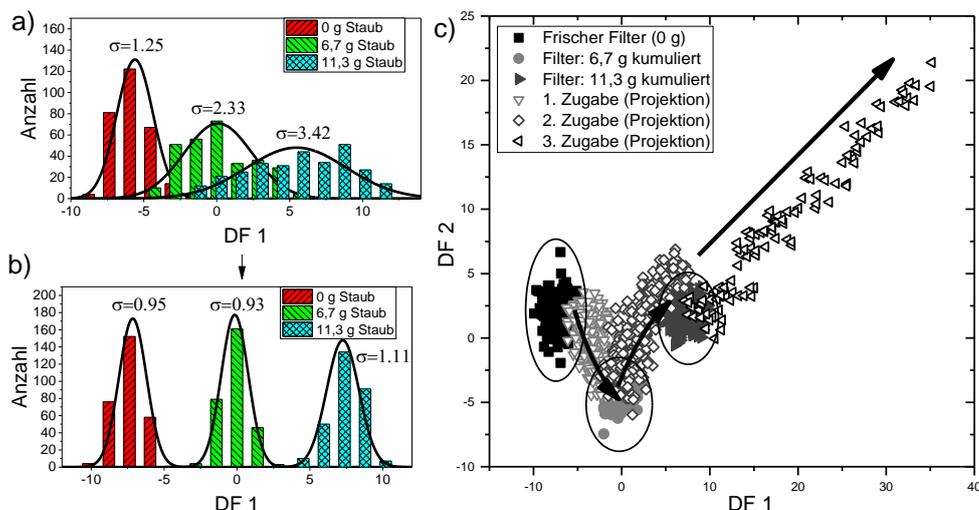


Abbildung 4-43. Überwachung Filterbeladung [152] mit (a) Histogramm des Mittelwerts von Δp , (b) Histogramm DF 1 auf Basis der 50 höchstkorrelierten Merkmale, jeweils mit angeglicherer Skalierung, (c) LDA-Projektion zu (b).

4.7.3 Diskussion

Die Eigenschaften des Hydraulikfluids haben einen deutlichen Einfluss auf die Modellbildung. Hierbei konnte gezeigt werden, dass Variationen der einzelnen Öl-Parameter Temperatur und Lufteintrag das Training nur leicht, aber bei kombiniertem Auftreten deutlich verschlechtern, da sich der Wirkungsgrad der Anlage signifikant reduziert, welcher gleichzeitig ein wichtiger Zustandsindikator, etwa des simulierten Pumpenverschleißes, ist.

Zudem wurde gezeigt, dass im Training nicht berücksichtigte Störgrößen zur Instabilität des Modells führen können, gleichzeitig aber eine Einbeziehung der bekannten Grenzwerte ausreicht, um Zwischenzustände von Ziel- und Störgröße interpolieren zu können.

Auch die Merkmalsselektion ist stark von den Ölparametern beeinflusst. Aus diesem Grund ist es ratsam, diese in den Trainingsdaten zu variieren, um gezielt diejenigen Merkmale im statistischen Modell zu selektieren, die eine möglichst geringe Querempfindlichkeit besitzen. Gleichwohl zeigt das Beispiel der Merkmalsselektion beim Hydrospeicher (Abbildung 4-40), dass das Merkmalsranking bei ungünstiger Wahl des Zielgrößenverlaufs (kontinuierlich ansteigend, ohne Wiederholung) an seine Grenzen stößt und tendenziell ungeeignete Merkmale auswählt.

Eine zuverlässige Erkennung erhöhter Partikelkontamination des Öls (bis zu 22 mg/min ISO MTD A3) auf Basis der Prozesssensoren konnte nicht nachgewiesen werden. Für die Filterbeladungsüberwachung konnte jedoch ein Modell erstellt werden, das im Vergleich zur üblichen Differenzdruck-Analyse eine wesentlich geringere Querempfindlichkeit gegenüber der Fluidtemperatur aufweist mit einer Reduktion der Unsicherheit σ um bis zu Faktor 3.

4.8 Schwingungsüberwachung

4.8.1 Auswertung auf Basis von Schwingungsmerkmalen

Neben den Prozesssensordaten wurde auch eine Detektion der Zustände des Ventils, der Pumpe und des Speichers auf Basis eines MEMS-Beschleunigungssensors (Kap. 4.5.4.2) erprobt. Hierbei wurden aus den aufgezeichneten Beschleunigungs-Rohdaten (Abbildung 4-44a) der drei Achsen 1s-Bereiche der Intervalle gemäß Abbildung 4-14 extrahiert, und deren Amplitudenspektrum mittels diskreter Fourier-Transformation, DFT (Frequenzauflösung 1 Hz), berechnet. Wie in Abbildung 4-44b dargestellt, lassen sich die Laststufen innerhalb des Zyklus deutlich im Amplitudenspektrum

erkennen. Die Amplitudenspektren wurden wiederum in 16 Segmente mit einer Breite von 256 Hz unterteilt und auf deren Basis die Merkmalsextraktion durchgeführt, sodass ein Merkmalspool von insgesamt 9.984 Merkmalen erzeugt wird.

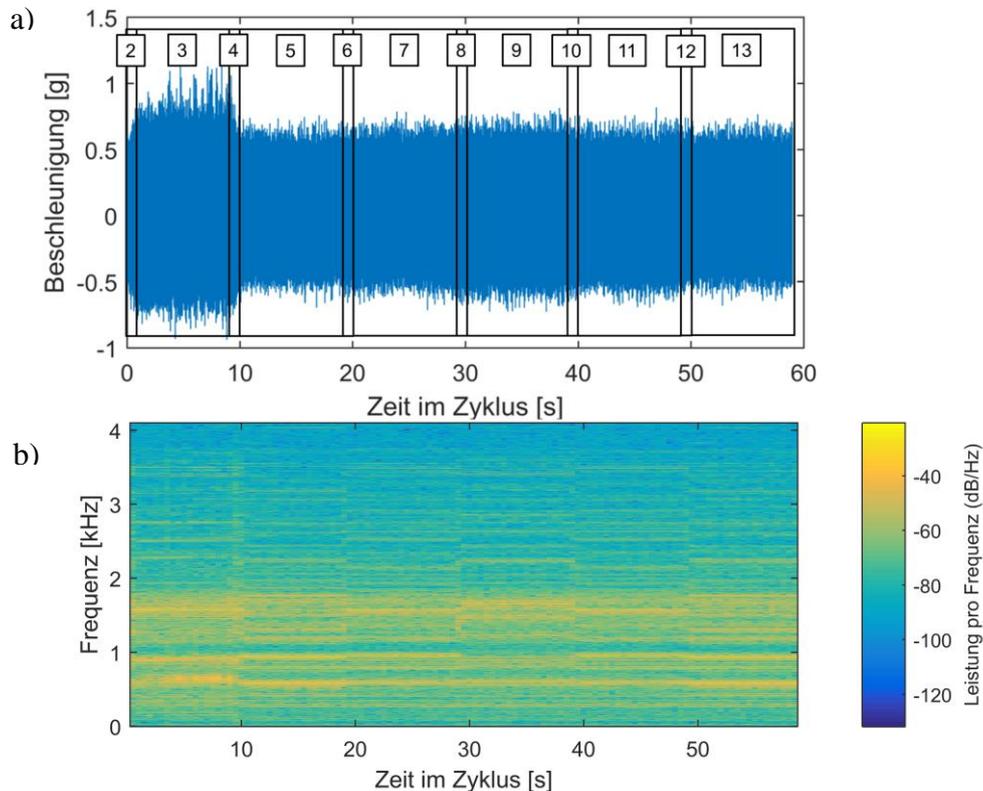


Abbildung 4-44. Arbeitszyklus analog zu Abbildung 4-14: (a) Rohsignal Beschleunigung in x-Richtung von MP1, (b) Spektrogrammдарstellung von (a) mit den erkennbaren Laststufen des Zyklus.

Tabelle 4-8 zeigt die ausgewählten Schwingungsmerkmale nach Schadenstyp. Die relevanten Ventil-Merkmale werden während des Ventilschaltens (Int. 4) in radialer und tangentialer Beschleunigungsrichtung zur Motor-Drehachse aus einem Frequenzbereich oberhalb von 768 Hz selektiert, während die Unterscheidung des Pumpenzustands auf Basis der radialen Beschleunigung im Frequenzbereich 1536 bis 1792 Hz verteilt über den gesamten Zyklus erfolgt. Bei der Speicher-Detektion ist die Lade-Phase des Speichers zu Beginn des Zyklus bei hohen Schwingungsfrequenzen oberhalb von 3328 Hz dominant vertreten.

Abbildung 4-45 zeigt die Ergebnisse als LDA-Projektionen der Trainingsdaten, generiert mit Aggregat 1, und der Testdaten von Aggregat 2 über 13 Tage. Das beste Trainingsergebnis wird für die Ventilüberwachung (a) erzielt (100 % CV), gefolgt von der Speicherüberwachung (97,4 %) in (c), wohingegen die Pumpenüberwachung (b) deutlich abfällt (77,5 %), was insbesondere daran liegt, dass eine quantitative Bestimmung des Leckagegrads auf Basis der Pumpenschwingung nicht möglich ist. Die Anordnung der Klassen lässt zudem vermuten, dass die Detektion durch den

experimentellen Aufbau (geändertes Resonanzverhalten des Systems aufgrund des zugeschalteten Leckagekanals) und nicht durch die Leckage selbst verursacht wird.

Tabelle 4-8. Ausgewählte Schwingungsmerkmale von MP1 nach Schadenstyp (beste 5 aus 20, Spearman-Korrelation).

Ventil ($\rho=0,93$)				Pumpe ($\rho=0,83..0,82$)				Speicher ($\rho=0,75..0,70$)			
Sns	Int	Freq [Hz]	Fkt	Sns	Int	Freq [Hz]	Fkt	Sns	Int	Freq [Hz]	Fkt
y	4	1536-1792	Sk	y	12	1536-1792	Va	y	2	3328-3584	Ku
y	4	3328-3584	Sk	y	6	1536-1792	Va	z	2	3328-3584	Ku
y	4	768-1024	Max	y	10	1536-1792	Va	y	2	3328-3584	Sk
z	4	768-1024	Max	y	13	1536-1792	Va	z	2	3328-3584	Sk
z	4	3328-3584	Sk	y	9	1536-1792	Va	x	2	1280-1536	Max

Im Gegensatz zu den Prozesssensoren ist eine direkte Übertragung der Schwingungsmuster, d.h. ohne Offset- oder Trainingsabgleich, möglich (a, b, c). Diese Langzeit-Projektionen werden optimal (a,b) bzw. überwiegend korrekt (c) klassifiziert. (d) zeigt das Konfidenzintervall $\pm 2\sigma$ von DF 1 auf Basis des Trainings, welches von der gemittelten Basislinie nur bei einer deutlichen Änderung der Umgebungstemperatur (Tag 35 - 37) überschritten wird.

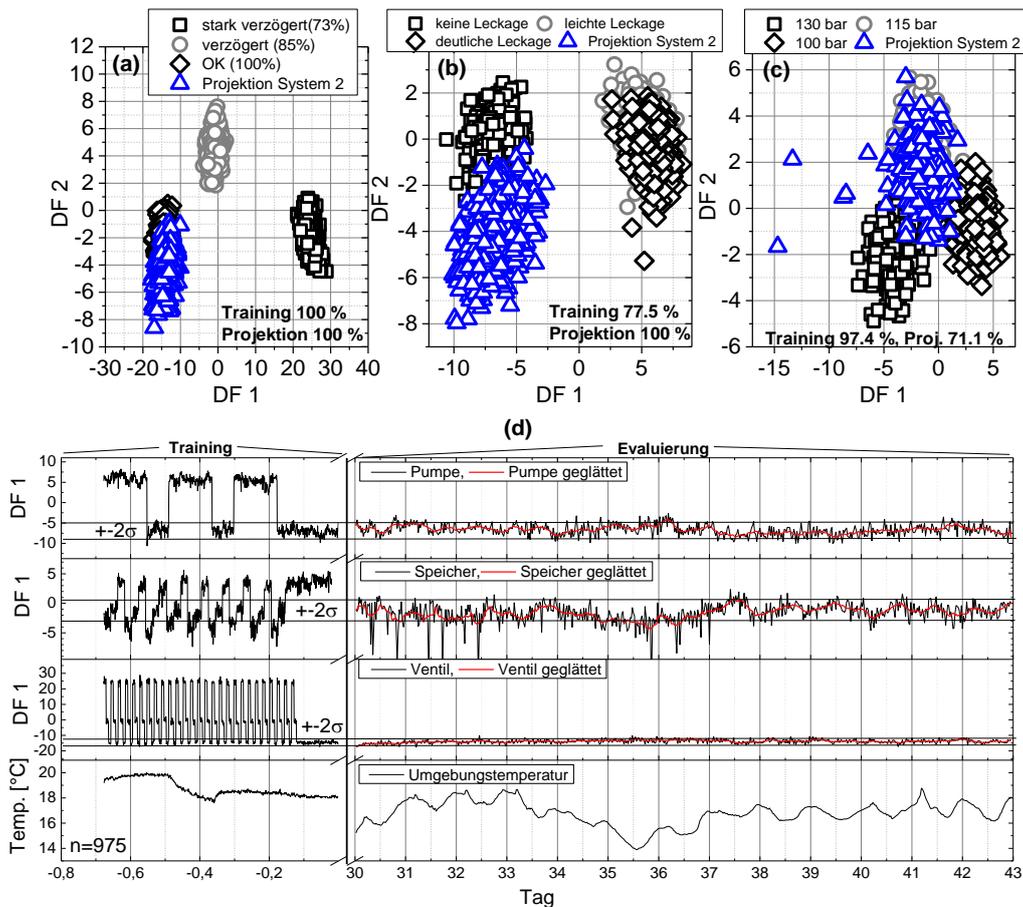


Abbildung 4-45. Training auf Basis der Schwingungsdaten von Hydraulikaggregat 1, Projektion Langzeitdaten Aggregat 2 von (a) Ventil, (b) Pumpe, (c) Speicher, (d) zeitlicher Verlauf DF 1 nach [85]. Zum Zeitpunkt $t = 0$ Start der Projektionsphase (dargestellt ist der Zeitraum Tag 30 bis 43 nach dem Training), zuvor ($t < 0$) Generieren der Trainingsdaten.

4.8.2 Pumpenkavitation

Eine ungünstige Auslegung der Pumpen-Ansaugleitung (niedriger Querschnitt, unzulässige Förderhöhe) führt zu einer Erhöhung des Unterdrucks und ist damit häufige Ursache für Pumpenkavitation. Mit diesem Szenario soll nachfolgend ein Vergleich der Detektion auf Basis von Prozess- und Schwingungssensorik durchgeführt werden.

Hierfür wird der Querschnitt der Ansaugleitung von SP1 mittels eines Proportional-Drosselventils händisch sukzessive verengt und somit der nachfolgend gemessene Unterdruck im Ansaugbereich auf bis zu -0,9 bar erhöht (vgl. Abbildung 4-46a). Zum Ausschließen zeitlich korrelierter Störgrößen wurde die Drossel an drei unterschiedlichen Zeitpunkten der Messung komplett geöffnet (Stufe 0, Normalzustand).

Sowohl auf Basis der Prozesssensoren als auch mithilfe der spektral ausgewerteten Schwingungsdaten können die Zustände erkannt und interpoliert werden (Abbildung 4-46b,c). Gleichwohl erlauben die Prozesssensoren insbesondere bei geringeren Verengungen (Stufe 1) eine zuverlässigere Detektion, da sich die Effizienzparameter (Volumenstrom, Druck) der Pumpe bereits deutlich ändern, bevor sich merkliche Symptome im Schwingungsspektrum entwickeln. In letzterem weisen die Stufen 0-3 eine hohe Ähnlichkeit auf, erst die Pumpenvibration der höchsten Drosselstufe unterscheidet sich signifikant von den übrigen, was sich mit dem subjektiven Höreindruck des Laufgeräuschs der Pumpe deckt.

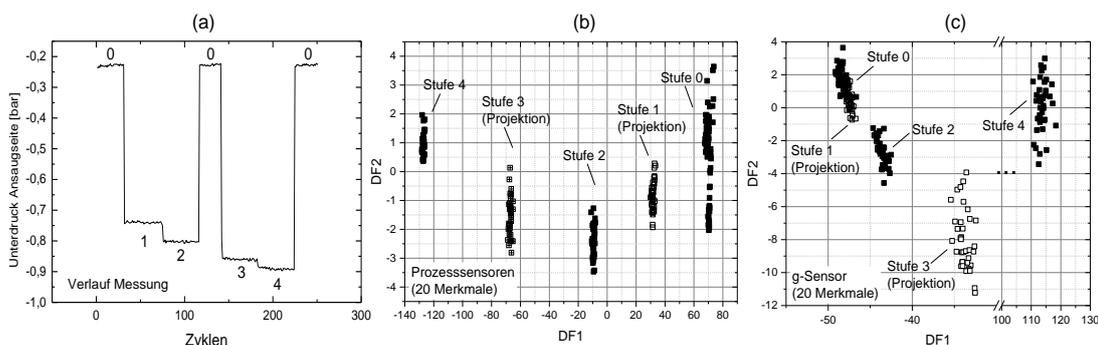


Abbildung 4-46. (a) Verlauf der Charakterisierungsmessung, (b) LDA-Projektion auf Basis der Prozesssensoren, (c) LDA-Projektion der Zustände auf Basis des 3-Achsen MEMS g-Sensors an SP1 mit 20 Merkmalen.

Tabelle 4-9 zeigt die Klassifikationsrate der fünf Klassen in Abhängigkeit der Merkmalsselektion. Im Fall der spektralen Schwingungsmerkmale ist insbesondere die PCA-Merkmalsreduktion vorteilhaft.

Tabelle 4-9. LDA-Kreuzvalidierungsrate (10-fold, 20 Merkmale) der Pumpenzustände in Abhängigkeit der Merkmalsselektion und des Klassifikators (3-nächste-Nachbarn, 3-NN, und Mahalanobis-Distanz).

FS	MEMS g-Sensor		Prozesssensoren	
	Mahalanobis	3-NN	Mahalanobis	3-NN
Pearson	99,1	99,1	100	100
Spearman	99,1	99,1	100	100
ANOVA F	95,9	95,4	100	100
PCA	100	99,5	100	100

Die spektrale Merkmalsextraktion wird wesentlich durch die Breite der untersuchten Frequenzintervalle bestimmt (Abbildung 4-47). Hierbei ist die Untersuchung kleiner Intervalle < 20 Hz unvorteilhaft, da die PCA mit sehr vielen und potentiell störungsanfälligen Merkmalen berechnet wird, was sich negativ auf die Kreuzvalidierungsrate auswirkt. Je größer das Frequenzintervall gewählt wird, desto stabiler werden die einzelnen Beschreibungsmerkmale des Spektrums, gleichzeitig besteht jedoch die Gefahr, dass potentiell relevante Information nicht ausreichend in den Merkmalen repräsentiert wird. Dies lässt sich beispielsweise an dem abnehmenden F-Wert von DF1 für $\Delta f > 1300$ Hz erkennen. Hierbei ist aber zu beachten, dass der F-Wert von der Separierung einzelner Klassen, speziell der abgesetzten höchsten Stufe, dominiert werden kann.

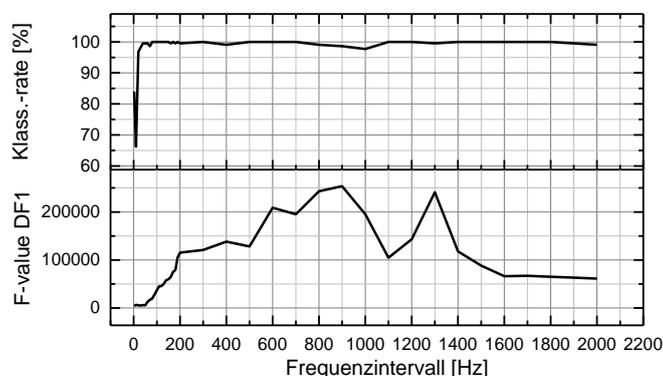


Abbildung 4-47. Einfluss der Frequenzbreite bei der Merkmalsextraktion auf die Klassifikation (oben: 10-fold Mahalanobis-Distanz Kreuzvalidierung, unten: ANOVA F von DF 1; FS = PCA).

4.8.3 Diskussion

Eine Zustandsüberwachung auf Basis des installierten dreiachsigen MEMS-Beschleunigungsaufnehmers ist insbesondere für die Komponenten möglich, die ihre Symptome in transienten Lastbereichen aufweisen (Ventil, Speicher). Eine mögliche Erklärung ist, dass eine Degradation in beiden Fällen den Zeitraum beeinflusst, bis der nachfolgende stationäre Lastzustand erreicht wird. Da die Laststufen deutlich variierende Schwingungsspektren aufweisen (Abbildung 4-44b), sind die DFT-

Amplitudenmerkmale in dem fixen transienten Zeitbereich ein Indikator für die Zeitkonstante des Umschaltvorgangs, da sie beschreiben, in welchem Maß Schwingungsanteile der nachfolgenden Stufe bereits enthalten sind. Hier müsste zusätzlich noch untersucht werden, ob eine Merkmalsextraktion im Zeitbereich diese Information besser abbilden könnte. Die quantitative Überwachung der Pumpenleckage konnte, vermutlich aufgrund des experimentellen Aufbaus, mit der Schwingungsanalyse nicht erreicht werden.

Die selektierten Schwingungsmerkmale sind direkt auf das zweite Aggregat übertragbar und über einen Zeitraum von 14 Tagen stabil, wenngleich sie einen Temperatur-Quereinfluss aufweisen.

Eine übermäßige Erhöhung des Unterdrucks in der Ansaugleitung der Pumpe SP1 kann aufgrund der verringerten Effizienz frühzeitig von den Prozesssensoren detektiert werden. Die Schwingungsmerkmale weisen dagegen erst bei der höchsten Stufe, bei der die Effizienz der Pumpe bereits um 50 % reduziert ist, eine signifikante Änderung auf, die auf einsetzende Kavitation hindeutet. Zusammenfassend bietet die untersuchte Schwingungsüberwachung der Pumpen somit bei den betrachtete Fällen keinen Mehrwert gegenüber der auf den Prozesssensoren basierenden Analyse; gleichwohl könnte der redundante Einsatz beider Methoden die Robustheit der Detektion weiter erhöhen [155], allerdings auf Kosten einer deutlich höheren Komplexität.

4.9 Untersuchung der Modellbildung

4.9.1 Signalvorverarbeitung

In vorangegangenen Arbeiten, speziell im Bereich Gassensorik, konnte gezeigt werden, dass unerwünschte Stör- und Drifteinflüsse mittels Signalvorverarbeitung reduziert oder gänzlich eliminiert werden können [12], [156].

In Tabelle 4-10 werden vier Standardisierungsverfahren (vgl. Kap. 2.3.1) gegenüber gestellt, die auf die Rohdaten einer Messung mit konstantem und randomisierten Arbeitszyklus vor der Merkmalsextraktion angewendet werden.

Tabelle 4-10. Einfluss der Signalvorverarbeitung auf die Kreuzvalidierungsrate [%] (10-fold CV, Mahalanobis-Distanz Klassifikator, 20 Merkmale, Spearman FS)

Preprocessing	Kühler		Ventil		Pumpe		Speicher	
	Konst.	Rand.	Konst.	Rand.	Konst.	Rand.	Konst.	Rand.
Kein	100	100	100,0	99,9	99,8	97,8	95,7	59,5
z-Score	99,4	89,8	100,0	99,9	82,1	54,6	93,7	48,6
Min-Max	95,8	90,8	100,0	99,9	82,7	56,5	95,2	47,9
Div. Mean	99,9	99,1	100,0	99,9	77,0	56,3	94,8	51,5
Sub. Mean	100,0	98,8	100,0	99,9	99,6	69,8	96,7	54,7

Die normierten Daten zeigen demnach keinen Vorteil gegenüber den originalen Daten, im Gegenteil ist tendenziell eine deutlich verschlechterte Klassifikation festzustellen. Speziell bei der Überwachung von Kühler und Pumpe, bei der die Absolutwerte die wesentliche Information enthalten, ist die Normierung nicht empfehlenswert; bei der Überwachung dynamischer Vorgänge (Ventil, Speicher) ergeben sich keine nennenswerten Veränderungen (konstanter Zyklus) bzw. tendenziell eine Verschlechterung (randomisierter Zyklus). Somit ist eine Signalvorverarbeitung in Form einer Standardisierung bei diesem Anwendungsfall kein sinnvoller Ansatz zur Optimierung der Merkmalsextraktion.

4.9.2 Beschaffenheit der Merkmale

Die Beschaffenheit der Merkmale ist ein wesentlicher Einflussfaktor auf die nachfolgende Auswertung. So erzielt etwa die LDA die besten Ergebnisse bei unkorrelierten Merkmalen mit normalverteilten Datenpunkten der Klassen bei ähnlichen Standardabweichungen. Mit dem automatisierten Vorgehen zur Merkmalsextraktion und -selektion ist die Erfüllung dieser Voraussetzungen jedoch nicht gewährleistet: Exemplarisch sind in Abbildung 4-48 Merkmalsverteilungen der Anwendung dargestellt, die aufgrund der Zielgröße eine gruppenbezogen stark unterschiedliche Streuung aufweisen (a) oder nicht der Normalverteilung entsprechen (b). Das Szenario in (a) kann dazu führen, dass die Minimierung der übermäßigen inneren Streuung einer Klasse das Optimierungsproblem bestimmt und das eigentliche Ziel der maximalen Klassentrennung vernachlässigt wird. Auch die Abweichung von der Normalverteilung ist ein typisches Problem, etwa wenn sich die Verteilung einer Klasse wie in (b) aus jeweils zwei leicht versetzten Normalverteilungen zusammensetzt, die durch den Einfluss von Störgrößen, hier die Öltemperatur, entstehen. Die Anforderung an die Normalverteilung spielt insbesondere bei probabilistischen Klassifikatoren eine Rolle, die jedoch in dieser Arbeit nicht untersucht werden. Des Weiteren ist es naheliegend, dass durch die univariate Merkmalsselektion diejenigen Merkmale selektiert werden, die auch

untereinander korreliert sind. Wie exemplarisch in Tabelle 4-11 dargestellt, können die gegenseitigen Korrelationen der selektierten Merkmale eine starke Abhängigkeit im Bereich $0,8 < |r| < 0,99$ aufweisen. Die niedriger zur Zielgröße korrelierten Merkmale besitzen hingegen auch untereinander typischerweise eine geringe Korrelation. Auffällig ist hierbei, dass insbesondere Zielgrößen mit untereinander stark korrelierten Merkmalen (Kühler, Ventil) eine besonders zuverlässige Detektion ermöglichen, sodass dies bei der LDA nur eine untergeordnete Rolle zu spielen scheint. Dies deckt sich mit der Feststellung von Klecka [54], dass die LDA relativ robust gegenüber Verletzungen der oben genannten Annahmen ist.

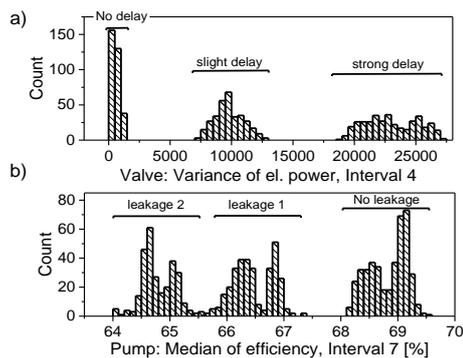


Abbildung 4-48. Beispiel für (a) Heteroskedastizität und (b) nicht normalverteilte Merkmale.

Tabelle 4-11. Pearson Korrelationsmatrix der 5 höchstkorrelierten Merkmale zur Ventilüberwachung.

	F1	F2	F3	F4	F5
F1	1,00	0,97	-0,81	-0,87	-0,95
F2	0,97	1,00	-0,88	-0,94	-0,99
F3	-0,81	-0,88	1,00	0,98	0,93
F4	-0,87	-0,94	0,98	1,00	0,97
F5	-0,95	-0,99	0,93	0,97	1,00

4.9.3 Validierung der Merkmalsselektion

Bisher wurde der gesamte Datensatz zur Merkmalsselektion genutzt und erst nachfolgend zur Kreuzvalidierung die Partitionierung in Trainings- und Testdaten vollzogen. Da die Merkmalsselektion Teil der überwachten Dimensionsreduktion ist, und in der Praxis somit bei diesem Schritt keine Information über die Testdaten vorliegen sollte, wird nachfolgend untersucht, ob dadurch eine relevante Verfälschung der Klassifikationsrate entsteht. Exemplarisch untersucht werden in Abbildung 4-49 die Datensätze Const. 2 und Rnd. 2 bei 10-fold Partitionierung nach der Merkmalsselektion (FS nicht validiert) und nach der Merkmalsextraktion (FS validiert). Dargestellt sind hierbei die Klassifikationsraten als Boxplot der 10 Partitionierungen.

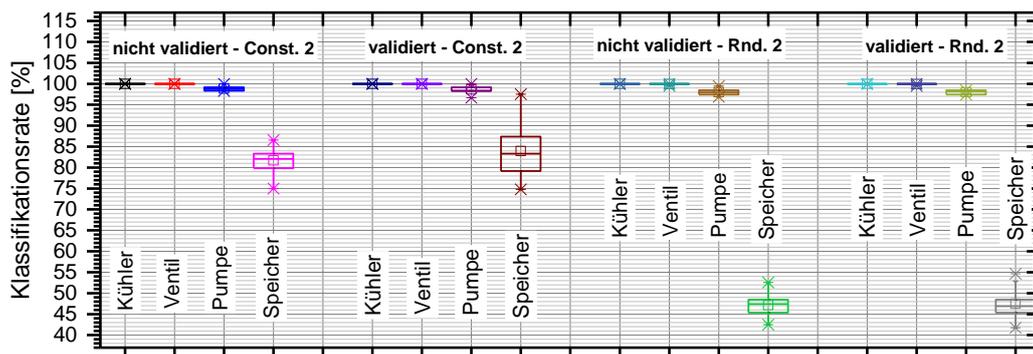


Abbildung 4-49. Vergleich der 10-fold Kreuzvalidierung mit und ohne Einbeziehung der Merkmalsselektion (Spearman FS, 20 Merkmale, Mahalanobis-Distanz Klassifikator).

Im Mittel ist im Vergleich keine eindeutige Verschlechterung (ca. $\pm 1\%$) des Ergebnisses zu erkennen. Jedoch ist eine Zunahme der Streuung im Falle der kreuzvalidierten Merkmalsselektion bei den 10 Unterklassifikationen zu beobachten, insbesondere bei den Fehlerfällen Pumpe (Anstieg σ von 0,6 auf 1,0 %) und Speicher (3,1 auf 7,3 %) bei konstantem Zyklus. Es liegt nahe, dass die Detektionsraten größeren Schwankungen unterliegen, wenn die Testdaten nicht bei der Merkmalsselektion einbezogen werden. Der im Mittel vernachlässigbare Effekt zeigt, dass die Merkmalsselektion mit univariaten Filtern aufgrund ihrer fehlenden Interaktion mit dem Klassifikationsverfahren im Gegensatz zu Wrapper-/Embedded-Verfahren nicht notwendigerweise kreuzvalidiert werden muss.

4.9.4 Berechnungsaufwand

Der Berechnungsaufwand bei der Generierung des Modells auf Basis der Prozesssensoren ist, wie in Abbildung 4-50a dargestellt, dominiert von der Merkmalsextraktion, die über 99 % der verwendeten Zeit benötigt (ca. 500 s Berechnungsdauer für 1.323 Merkmale bei 2.200 Zyklen). Davon wiederum wird der wesentliche Teil für das Merkmal ‚Position des Maximums‘ (b) aufgewendet, welchem bei der Merkmalsselektion jedoch kaum statistische Signifikanz zugemessen wird. Ein Verwerfen dieses Merkmals würde somit die Berechnung erheblich beschleunigen ohne das Modell merklich zu verschlechtern. Bei schneller abgetasteten Sensor-Signalen (Luft-/Körperschall) mit vorangestellter DFT und mehrstufiger Segmentierung verschiebt sich der Aufwand nochmals weiter in Richtung Merkmalsextraktion. Bei der Selektion (c) liegen die univariaten Verfahren, Korrelationen und ANOVA, dicht beieinander (0,7 - 3,0 s), während der Berechnungsaufwand der multivariaten PCA aufgrund der hochdimensionalen Eingangsdaten zwei Größenordnungen darüber liegt (358 s). Das schnellste Training

(d) erzielt die LDA mit Mahalanobis-Distanz-Klassifikator (0,4 s), gefolgt von SVM linear (1,2 s), ANN (1,9 s), und SVM mit RBF-Kernel (2,8 s).

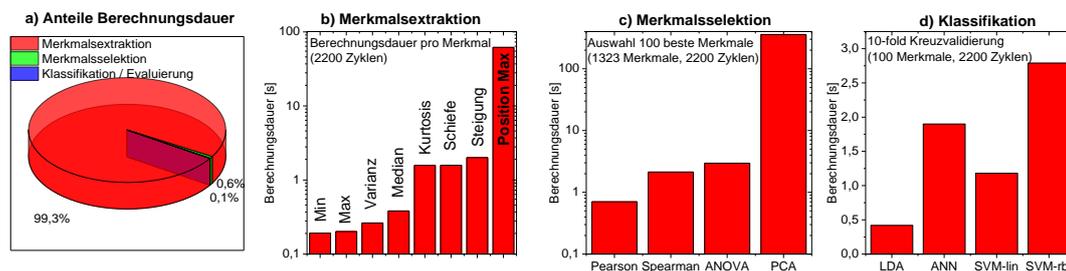


Abbildung 4-50. Berechnungsdauer (a) im Gesamtkontext, (b) nach Merkmal, (c) nach Selektionsverfahren, (d) nach Klassifikationsverfahren. Die Berechnungen wurden sequentiell auf einem HP EliteBook 8540w Laptop (Core i5 M560 @ 2,67 GHz, 8 GB RAM, MATLAB R2016b, Windows 7 Professional SP1) durchgeführt.

4.9.5 Diskussion

Die Signalvorverarbeitung in Form einer Standardisierung der Sensorsignale vor der Merkmalsextraktion ist für die betrachtete Zustandsüberwachung des hydraulischen Systems nicht sinnvoll und führt zu deutlich schlechteren Klassifikationsraten. Bei Betrachtung der Eigenschaften der selektierten Merkmale fällt auf, dass diese in einigen Fällen nicht den Voraussetzungen der LDA entsprechen (Normalverteilung, Streuverhalten, gegenseitige Korrelation); dies hat jedoch keine signifikanten Auswirkungen auf die Modellbildung. Bei einem Vergleich der Kreuzvalidierungsschleife mit und ohne Berücksichtigung der Merkmalsselektion konnte gezeigt werden, dass der Einfluss bei den univariaten Ranking-Methoden im Mittel vernachlässigbar ist und das bisherige Vorgehen zu keiner relevanten Verfälschung der Ergebnisse führt. Der Aufwand bei der Modellgenerierung ist von der breitbandigen Merkmalsextraktion bestimmt, sodass hier durch eine sinnvolle Reduktion der Merkmalsanzahl und eine Optimierung der Extraktionsmethoden der Gesamtprozess wesentlich beschleunigt werden könnte.

4.10 Detektion und Kompensation von Sensorfehlern

In den vorangegangenen Auswertungen wurde vorausgesetzt, dass die Sensordaten valide sind und nicht von fehlerbehafteten Sensoren stammen. Im Folgenden werden die Auswirkungen von Sensorfehlern, insbesondere Offset, Drift, SNR-Degradation und zufällig überlagerte Signal-Ausreißer für den Anwendungsfall betrachtet. Hierzu

werden in MATLAB iterativ die Sensordaten des Datensatzes Const. 1 manipuliert (Abbildung 4-51).

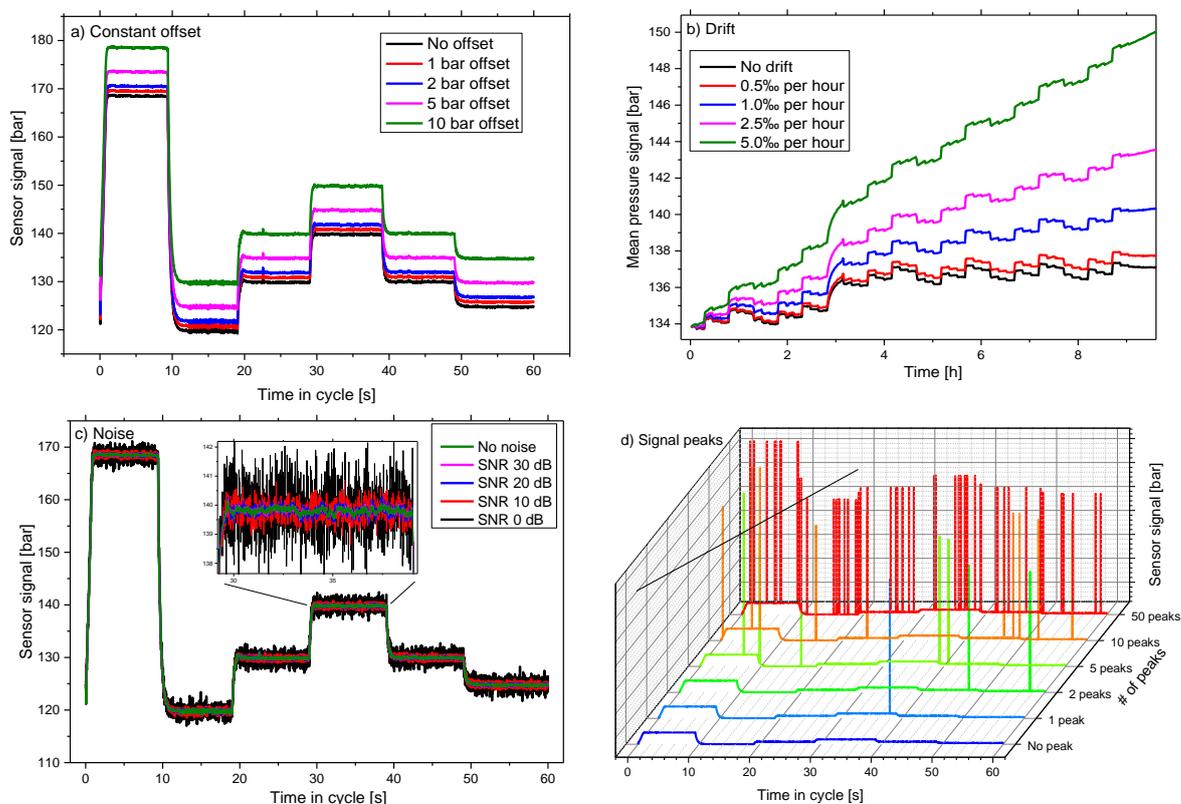


Abbildung 4-51. In MATLAB simulierte Sensorfehler bei PS1 nach [157].

Der von Offset und Drift überlagerte Datenpunkt $\tilde{x}_{i,j}$ wird wie folgt berechnet:

$$\tilde{x}_{i,j} = x_{i,j} + offset + t(i) \cdot driftrate \cdot \sum_{k=1}^N \frac{1}{n} x_{i,k} \quad (4.32)$$

Mit j dem Zeitpunkt innerhalb des Zyklus i , $x_{i,j}$ dem originalen Sensordatenpunkt, $t(i)$ der relativen Zeit seit Start der Messung und N der Anzahl von Datenpunkten innerhalb eines Zyklus.

Die Rauschüberlagerung des Sensorsignals erfolgt mit der Matlab-Funktion ‚awgn‘ [158] aus der Communication System Toolbox. Diese überlagert weißes, d.h. über den Frequenzbereich mit konstanter Leistungsdichte versehenes Rauschen mit normalverteilter Amplitude, wobei der Signal-Rausch-Abstand in dB vorgegeben werden kann. Die Signal-Ausreißer werden zyklweise mittels je n zufällig erzeugter Indizes zugewiesen, wobei die Anzahl der Ausreißer n pro Zyklus vorgegeben werden kann.

4.10.1 Einfluss auf die Klassifikationsrate

Zur Evaluierung des Einflusses von Sensorfehlern werden die als besonders kritisch bewerteten Fälle Drift und Rauschen mit verschiedenen Stufen auf alle Sensoren gleichzeitig verschachtelt überlagert. Hierzu werden die Rohdaten mit fünf Drift- (0...1 %/h) und sieben Rauschstufen (SNR Inf...0 dB) versehen und auf Basis aller 35 Kombinationen identische Merkmalssets extrahiert. Das statistische Modell wird nachfolgend mit dem originalen Datensatz (SNR Inf, Drift 0 %/h) trainiert und die Merkmale der degradierten Rohdaten projiziert. Abbildung 4-52 stellt die resultierenden Klassifikationsraten für die besonders anfälligen Zielgrößen dar, die Überwachung von Kühler und Ventil bleibt bei den betrachteten Sensorstörungen hingegen unbeeinflusst.

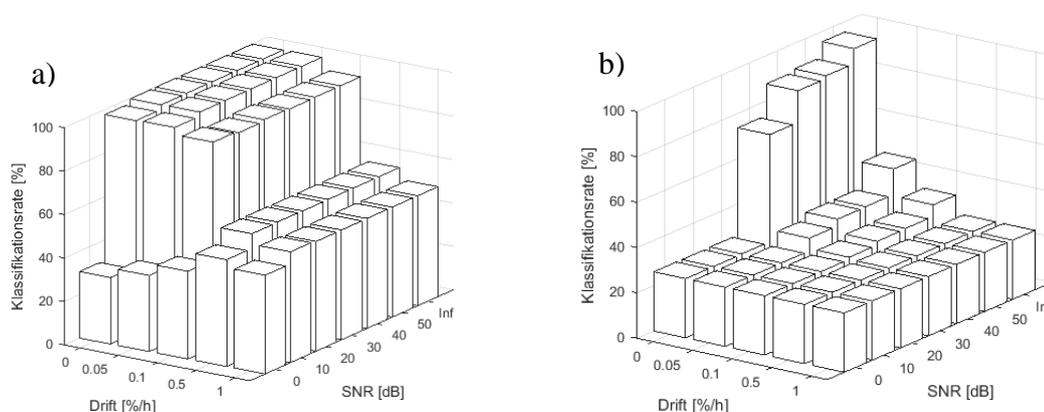


Abbildung 4-52. Einfluss von überlagertem Rauschen und Drift (alle Sensoren) auf die Klassifikation: a) Pumpe, b) Speicher (20 Merkmale).

Insbesondere in (b) ist ersichtlich, dass selbst kleinste Rauschamplituden im Bereich 30 dB SNR und sehr langsame Drifteffekte (0,05%/h) bereits zu deutlichen Einbrüchen der Zuverlässigkeit führen. Jedoch ist zu beachten, dass es sich hierbei um eine Worst-Case Abschätzung für den unrealistischen Fall handelt, dass alle Sensoren gleichzeitig von einer Störung betroffen sind. Dennoch ist deutlich zu erkennen, wie stark abhängig das Verfahren von validen Sensordaten ist. Eine parallele Zustandsüberwachung der Sensoren ist somit sinnvoll, um Fehlklassifikationen zu vermeiden und die Robustheit zu verbessern.

4.10.2 Detektion von Sensorfehlern

Wird nun Art sowie Ausmaß der künstlichen Sensorfehler als Zielvektor definiert, können die Sensorzustände selbst detektiert werden. Im Folgenden wird das Sensorsignal des Drucksensors PS1 degradiert, die übrigen Sensordaten bleiben unverändert.

Zur Detektion von Schadenstyp und -schweregrad von PS1 wird die Merkmalsextraktion um Merkmale erweitert, welche die Relationen zwischen den Sensorsignalen eines Zyklus beschreiben, etwa deren Pearson-Korrelation und Mittelwertverhältnisse. Die im Folgenden gezeigte Auswertung basiert jeweils auf der Sekundärmerkmalsextraktion über 60 Zyklen. Als Primärmerkmale wurden die zyklusweisen Korrelationen der Sensoren zueinander verwendet, mit denen überlagerte Rauschamplituden ab 40 dB erkannt werden können (Abbildung 4-53a). Die Drift- und Offset-Erkennung (b, c) basiert auf den Mittelwertverhältnissen der Sensoren als Primärmerkmal, die bereits die Erkennung sehr langsamer Driftvorgänge (0,05 %/h) und minimaler Offsets (1 bar \sim 0,4 % des Messbereichs) ermöglichen. Bei der Detektion zufälliger Signalausreißer hat sich die reguläre statistische Primärmerkmalsextraktion einzelner Sensoren als am zuverlässigsten erwiesen: Mit dieser können bereits einzeln auftretende Ereignisse zuverlässig detektiert werden.

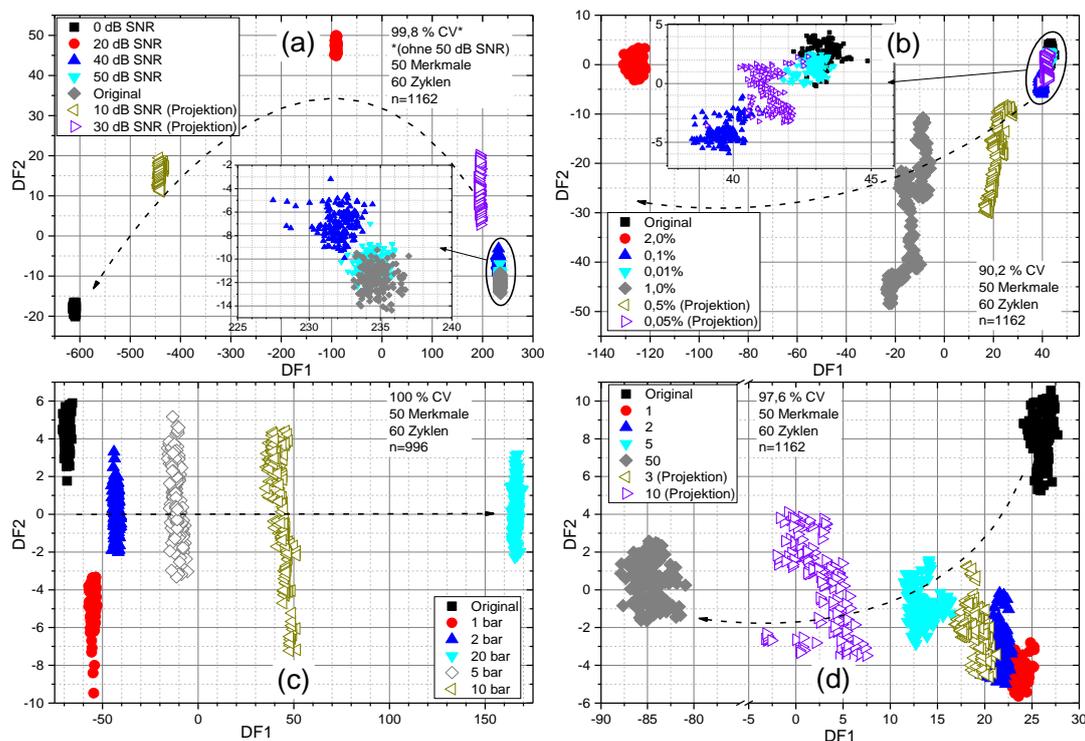


Abbildung 4-53. LDA-Projektion zum Erkennen von Sensorfehlern am Beispiel von PS1: a) SNR Degradation, b) Signaldrift, c) Signaloffset, d) Anzahl zufälliger Ausreißer pro Zyklus.

Grundsätzlich zeigt sich, dass die multivariate automatisierte Analyse bei geeigneter Wahl der Primärmerkmalsextraktion ebenfalls geeignet ist, überlagerte Sensorfehler zu erkennen, wobei in den untersuchten Fällen (a-d) die erste Diskriminanzfunktion das Ausmaß hinreichend quantifiziert; im Fall (d) kann die zweite Diskriminanzfunktion zudem zum qualitativen Fehlernachweis in Abgrenzung zum Normalzustand verwendet werden. Zudem erfolgt auch in dieser Anwendung die

Projektion von Zwischenklassen in die korrekte Position des Schadensraums, sodass damit die Validität des statistischen Modells angenommen werden kann. Die jeweiligen Erkennungslimits erlauben hierbei eine Detektion der Sensorfehler, bevor diese zu einer signifikanten Verschlechterung der Klassifikation führen (vgl. Abbildung 4-52); somit wäre ein zweistufiger Prozess denkbar, bei dem zunächst die Sensordaten auf Validität überprüft werden und erst im zweiten Schritt die eigentliche Zustandsbewertung der Maschine durchgeführt wird.

4.10.3 Kompensation ausgefallener Sensoren

Im Sinne der Resilienz ist es grundsätzlich erstrebenswert, wenn das Gesamtsystem bei Ausfall eines oder mehrerer Sensoren weiterhin voll oder zumindest eingeschränkt funktionstüchtig bleibt. Hierzu ist das Vorgehen festzulegen, wie fehlerbehaftete Sensordaten gehandhabt werden. Eine naheliegende Möglichkeit, die nachfolgend untersucht wird, ist die Exklusion der Daten des betroffenen Sensors aus den Trainingsdaten. Dies kann beispielsweise über die Filterung des Merkmalsrankings nach Sensoren erfolgen, sodass die verbleibenden n besten Merkmale der übrigen Sensoren ausgewählt und die LDA-Projektionsvektoren neu bestimmt werden. Abbildung 4-54 demonstriert die Leistungsfähigkeit des Vorgehens: Iterativ wird der jeweils relevanteste Sensor aus den Trainingsdaten ausgeschlossen, die Zustandsüberwachung neu angelernt und evaluiert. Hierbei ist zu erkennen, dass durch die gezielte Ausnutzung inhärenter Korrelationen der Sensoren der Ausfall von bis zu fünf Sensoren in allen Fällen kompensiert werden kann. Während das Klassifikationsverfahren in den ersten beiden Fällen keinen relevanten Einfluss hat, wird bei der Pumpen- und Speicherklassifikation bei mehreren ausgeschlossenen Sensoren ein Vorteil der nichtlinearen Methoden, insbesondere der SVM mit RBF-Kernel, deutlich, was sich etwa im Falle der Pumpenüberwachung anhand der Kompensationsfähigkeit zweier zusätzlicher Sensoren zeigt. Auffällig ist zudem bei der Speicherklassifikation im Bereich von einem bis vier Sensorexklusionen entgegen der vermuteten konstanten Verschlechterung tatsächlich ein leichtes Ansteigen der Kreuzvalidierungsrate. Eine mögliche Erklärung ist die Verwendung einer suboptimalen Merkmalsselektion, welche die Interaktion der Merkmale untereinander und mit dem Klassifikator nicht berücksichtigt (Spearman-Korrelation) und gleichzeitig durch die Filterung auf 10 Merkmale den Spielraum des Klassifikators hinsichtlich des Klassifikationsproblems stark eingrenzt, sodass erst bei Ausschluss eines zwar höher korrelierten, aber tatsächlich zur Klassifikation weniger geeigneten Sensors eine verbesserte Detektion möglich ist. Dieser Effekt ließe sich vermutlich durch die Selektion eines größeren Merkmalssets und der damit

einhergehenden Verschiebung des Einflusses von der Merkmalsselektion hin zur Dimensionsreduktion und Klassifikation vermindern.

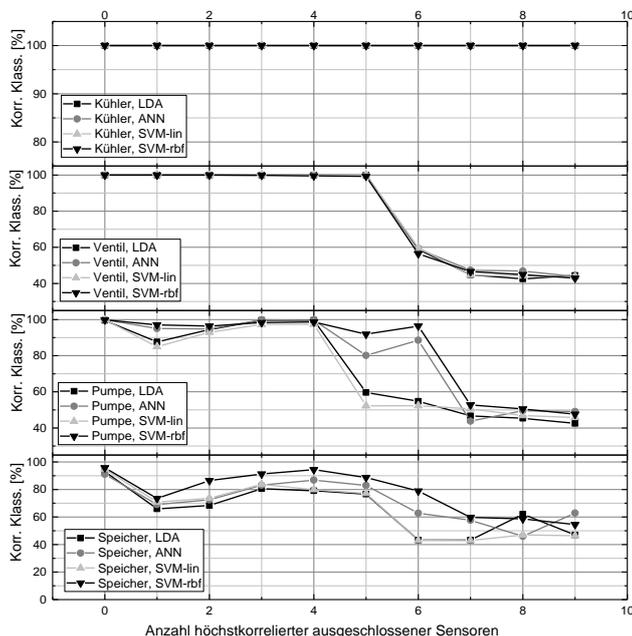


Abbildung 4-54. Resilienzverhalten: Klassifikationsrate in Abhängigkeit der Anzahl ausgeschlossener relevanter Sensoren (10 Merkmale, Spearman FS, 10-fold CV, Mahalanobis-Distanz Klassifikator bei LDA).

4.10.4 Diskussion

Fehlfunktionen von Prozesssensoren, etwa Offset, Drift, Rauschen und überlagerte Signalpeaks, können die Leistungsfähigkeit der Zustandsüberwachung signifikant beeinträchtigen. Hierbei zeigten sich deutliche Unterschiede, die von einer vernachlässigbaren Beeinflussung (Kühler, Ventil) bis hin zu stark instabilem Verhalten (Speicher) bei sehr geringen überlagerten Driftgeschwindigkeiten (0,05 %/h) und Rauschleistungen (30 dB SNR) reichen. Letzteres motiviert zu einer Detektion einzelner Sensorfehler: Auf Basis von Merkmalen zur Beschreibung der Signalrelationen (Korrelation, Mittelwertverhältnisse) konnten exemplarisch für einen Drucksensor statistische Modelle zur Detektion von

- Signalrauschen (Detektionslimit 40 dB SNR),
- Drift (0,05 %/h),
- Offset (0,4 % des Messbereichs) und
- randomisiert überlagerten Peaks (einzelnes Event)

erstellt und erfolgreich evaluiert werden. Im Falle von detektierten Sensorausfällen kann die Funktion des Gesamtsystems weitgehend aufrecht gehalten werden, indem die Daten der fehlerbehafteten Sensoren aus den Trainingsdaten entfernt und das System mit dem reduzierten Datensatz automatisiert neu angelern wird. Da an dieser

Stelle bereits auf die von der Merkmalsselektion bewerteten Merkmale zurückgegriffen werden kann, reduziert sich der Aufwand auf eine erneute Filterung des Merkmalpools und das Training der Dimensionsreduktion bzw. Klassifikation. In der untersuchten Anwendung kann je nach Zielgröße mindestens der Ausfall von 5 der insgesamt 17 Prozesssensoren ohne signifikanten Qualitätsverlust kompensiert werden.

Für die praktische Anwendung, etwa im Offshore-Bereich, könnte somit auch beim Ausfall einiger Sensoren die Überwachung der Anlage aufrecht erhalten und der Sensortausch erst bei einem regulären Wartungstermin durchgeführt werden. Gleichwohl ist zu prüfen, ob dieses Vorgehen praktikabel ist, da die Relationen der Sensorsignale auf Basis der Trainingsdaten angeleitet werden und wiederum von verschiedensten Einflussgrößen abhängig sind, sodass deren Langzeitstabilität nicht gewährleistet ist. Zudem müsste für jeden Sensor, Fehlertyp und jeden Datensatz ein eigenes Modell generiert werden, was bei einem komplexen System einen erheblichen Aufwand darstellt. Zusammenfassend bietet das Vorgehen zur Detektion und Kompensation von Sensorfehlern dennoch großes Potential, die Robustheit und das Resilienzverhalten wesentlich zu erhöhen.

4.11 Zusammenfassung des Anwendungsszenarios

Das Potential der vorgeschlagenen systematischen Prozesssensordaten-Analyse auf Basis der mehrstufigen Dimensionsreduktion konnte mit der Zustandsüberwachung eines Hydrauliksystems demonstriert werden. Durch die Nachbildung typischer Schadensmechanismen hydraulischer Komponenten in Laborversuchen und deren systematische Messdatenerfassung ist die Anwendung prädestiniert für überwachte Lernverfahren. Alle untersuchten Schadensszenarien können sowohl bei konstantem als auch randomisiertem Prozessablauf zuverlässig detektiert werden. Gleichzeitig stößt die Auswertung bei einer Ausweitung von Einfluss-, Prozess- und Störparametern an ihre Grenzen. In zukünftigen Arbeiten sollten die vorgestellten Ergebnisse auf Basis der simulierten Komponentenschäden mit realen, in der praktischen Anwendung verursachten Schadensbildern abgeglichen und verifiziert werden.

Ein wichtiger Einflussfaktor bei der Modellbildung ist die Versuchsdurchführung und Datengenerierung. Sie sollte grundsätzlich als erster Schritt des maschinellen Lernens betrachtet werden. So zeigt sich beispielsweise, dass bei ungünstiger Vorgabe der Zielgröße mit dem automatisierten Ranking bei der Selektion

physikalisch nicht sinnvolle Merkmale ausgewählt werden, die zufällig mit einer parallel variierenden Störgröße korrelieren. Dies zeigt zum einen, dass Zielgrößenabläufe wiederholt und randomisiert durchgeführt werden sollten, zum anderen, dass ein kritisches Hinterfragen der Merkmalsauswahl auf Basis von Prozess- und Expertenwissen unerlässlich ist. Mit letzterem Punkt ist auch die Wahl der Merkmalsanzahl verbunden. Während in der Terminologie des maschinellen Lernens typischerweise eine Merkmalsanzahl im Bereich zwischen Under- und Overfitting angestrebt wird, würde dies für die vorliegende Applikation die Verwendung von einer kaum nachvollziehbaren Menge an Merkmalen bedeuten. Um eine Nachvollziehbarkeit der Entscheidungsfindung zu gewährleisten, die die Voraussetzung für die Akzeptanz in industriellen Anwendungen darstellt, sollten so wenige Merkmale wie möglich und so viele wie nötig verwendet werden. Konkrete Anhaltspunkte hierzu liefern Parameterstudien, wie in Kap. 4.6.2 gezeigt.

Eine andere Möglichkeit zur Reduktion der Merkmalsanzahl besteht darin, die Qualität einzelner Merkmale zu optimieren, etwa durch das Ableiten von Sekundärmerkmalen über längere Zeiträume und mehrere Zyklen, was insbesondere vor dem Hintergrund, dass die betrachteten Schadensmechanismen sich über Zeiträume von Wochen und Monaten entwickeln, für den praktischen Einsatz ein sinnvoller Ansatz ist.

Bei der Klassifikation zeigen sich nur in wenigen Fällen relevante Vorteile der nichtlinearen Verfahren ANN und SVM, etwa bei dem unrealistischen Fall eines gleichzeitigen Ausfalls vieler Sensoren. Demgegenüber stehen als Nachteile eine geringe Transparenz und die erhöhte Berechnungskomplexität, die allerdings im Kontext des von der Merkmalsextraktion dominierten Gesamtprozesses vernachlässigbar ist. Die Dimensionsreduktionsverfahren PCA und LDA bieten im Vergleich eine zusätzliche Möglichkeit zur graphischen Repräsentation multidimensionaler Merkmalsvektoren und somit zur intuitiven visuellen Evaluierung des statistischen Modells, was ebenfalls ein nicht zu unterschätzender Faktor bei der Akzeptanz des Verfahrens ist.

5 Anwendungsszenario

Elektromechanischer Zylinder

5.1 Einführung

Elektromechanische Zylinder auf Basis eines Kugelgewindetriebs sind leistungsfähige Linearantriebe und besitzen aufgrund der geringen Rollreibung gegenüber Gleitgewindetrieben einen hohen Wirkungsgrad ($\eta > 0,9$) [159]. Ein weiterer Vorteil besteht in der Kombination von hoher Wiederhol-Positioniergenauigkeit (typischerweise $\pm 10 \mu\text{m}$ [160]) bei gleichzeitig hoher Axialkraft bis in den mehrstelligen kN-Bereich. Dies macht sie zu universell eingesetzten Antriebseinheiten von Handling- und Positionierungssysteme bis hin zu Vorschubantrieben von Werkzeugmaschinen. Diesen Vorteilen steht jedoch gegenüber, dass aufgrund der hohen Flächenpressungen die an der Kinematik beteiligten Bauteile stark belastet werden. Bei ungünstigen Lastkollektiven, etwa einer Kombination von hoher Beschleunigung und hohen Kräften, erreicht der Kugelgewindtrieb in der Regel nicht die erwartete Lebensdauer [161]. So haben Untersuchungen ergeben, dass Vorschubantriebe für den größten Teil der Ausfälle und ungeplanten Maschinenstillstandszeiten bei Werkzeugmaschinen verantwortlich sind, verursacht wiederum im Wesentlichen durch Verschleiß [143].

5.2 Problemstellung

Ziel dieses Anwendungsszenarios ist die Lebensdauerprognose von elektromechanischen Zylindern (EMZ) mit dem Fokus auf der Komponente Kugelgewindtrieb (KGT) zur zustandsbasierten Wartung von Handling- und Positionierungssystemen. Das Betriebsverhalten von EMZ als Bestandteil komplexerer Systeme ist bei der Wandlung von elektrischer Leistung in mechanische Nutzleistung von einer Vielzahl von Einflussgrößen bestimmt, die in Abbildung 5-1 dargestellt sind.

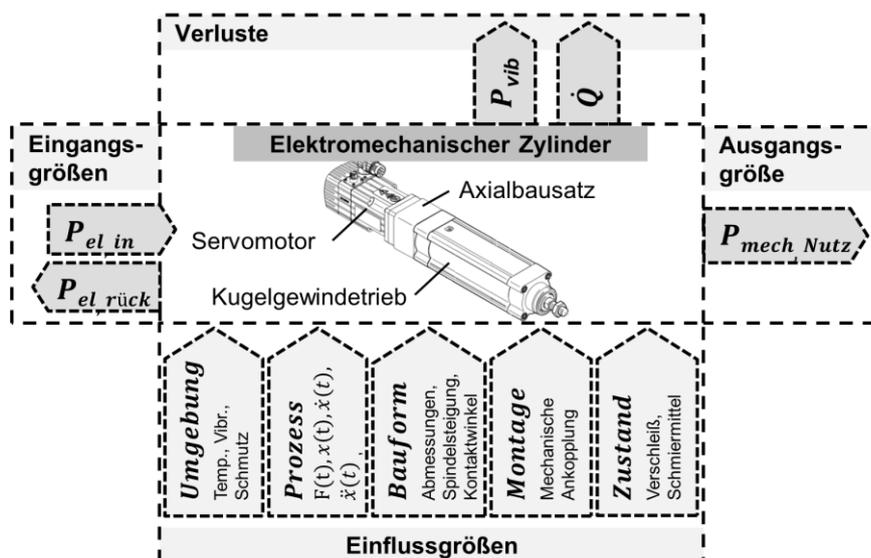


Abbildung 5-1. Betriebsverhalten elektromechanischer Zylinder.

In dieser Arbeit werden die Verschleißindikatoren mithilfe der multivariaten statistischen Auswertung (Kap. 3) anhand von Laborversuchen bestimmt. Dazu wird der EMZ zyklisch im Hochkraftbetrieb belastet - vom Neuzustand bis zum Ausfall. Dies erforderte die Entwicklung eines Prüfstands mit geeigneter Mechanik, Steuerung und Sensorik (Kap. 5.6).

Ein weiteres Ziel ist das Ableiten relevanter Sensorik und Auswerteverfahren, welche die Zustandsüberwachung in der industriellen Anwendung ermöglichen. Hierbei sind mehrere Kriterien relevant:

- Zuverlässige, eindeutige Quantifizierung des Zustands möglichst als kumulative Kenngröße
- Geringe Querempfindlichkeit gegenüber Störgrößen (Temperatur, etc.)
- Universelle Anwendbarkeit, d.h. Unempfindlichkeit gegenüber individuellen Streuungen

Der letzte Punkt bezieht sich darauf, dass typgleiche EMZ individuell ein durchaus heterogenes Betriebsverhalten aufweisen können, welches sich etwa durch stark abweichende Laufgeräusche bemerkbar macht [162], was im Kontext der Zustandsüberwachung ebenfalls als Störgröße zu bewerten ist.

Da der Bereich Antriebstechnik wirtschaftlich von erheblichem Kostendruck geprägt ist, ist der Einsatz zusätzlicher aufwändiger Sensorik als unrealistisch einzustufen [162]. Gleichwohl soll eine Überinstrumentierung mit Referenzsensorik in den Laborversuchen die Potentiale von Messgrößen aufzeigen, sodass in einem zweiten Schritt daraus potentiell mechanisch in die EMZ zu integrierende Sensormodule abgeleitet werden können [30], die durch den Einsatz kostengünstiger MEMS-Technologie den betriebswirtschaftlichen Anforderungen genügen. Gleichwohl ist

aus Sicht der Hersteller die optimale Ausnutzung vorhandener Sensorsignale, insbesondere des Motorcontrollers, etwa Position, Geschwindigkeit und Motorstrom, zu bevorzugen.

Neben der Verschleißidentifikation während des Betriebs ist auch die Eignung der statistischen Modellbildung bei der Qualitätskontrolle im End-of-Line (EoL) Test als letzter Schritt der Fertigung von Interesse. Das Ziel aus Sicht des Herstellers ist es hierbei, ein möglichst homogenes Betriebsverhalten der ausgelieferten EMZ innerhalb der Spezifikation zu erreichen und somit die Anzahl von Reklamationen und Rückläufern zu minimieren. Ein wichtiger Einflussfaktor ist hierbei der teilweise manuelle Montageprozess, bei dem typische Fehlerbilder wie eine Verspannung der Wälzlager, eine variierende Wälzkörperanzahl im Kugelgewindtrieb oder eine variierende Menge des aufgetragenen Schmiermittels [163], welche die Lebensdauer negativ beeinflussen können und somit während des Prüfzyklus erkannt werden müssen, auftreten können.

Problematisch an dem Anwendungsszenario der Verschleißidentifikation ist zu bewerten, dass im Gegensatz zur vorangegangenen Applikation (Kap. 1) bei den Versuchen keine definiert vorgegebenen Zustände vorliegen. So ist der Verschleiß im KGT während des Prozesses nicht direkt messbar. Es liegt also keine Zielgröße vor, die einem überwachten maschinellen Lernverfahren vorgegeben werden kann. Diese Problematik wird zusätzlich dadurch erschwert, dass die Form der Verschleißprogression nicht notwendigerweise als gleichmäßig, kontinuierlich oder gar linear ansteigend vorausgesetzt werden kann.

5.3 Stand der Technik und Forschung

Die Zustandsüberwachung und -prognose von Kugelgewindtrieben wurde in jüngerer Vergangenheit vielfach untersucht (Tabelle 5-1), primär im Kontext von Vorschubantrieben bei Werkzeugmaschinen. Ziel der meisten Arbeiten ist es hierbei, ohne zusätzliche Sensorik aus den verfügbaren Signalen des Motorcontrollers einen Indikator abzuleiten, der eine eindeutige und möglichst frühzeitige Bestimmung des Zustands und eine Extrapolation zur Prognose der verbleibenden Lebenszeit ermöglicht. Daneben findet sich auch die Strategie, breitbandig verschiedenste Sensorsignale, etwa Körper- und Luftschall, Temperaturen und IR-Strahlung zu untersuchen. Auch spezifisch für den KGT entwickelte Sensorlösungen, die etwa mittels einer DMS-Vollbrücke die direkte Messung der Mutter-Vorspannung ermöglichen, werden vorgeschlagen [164]. Die Methodik der Signalauswertung reicht hierbei von modellgestützten Verfahren, etwa der Bestimmung tribologischer

Kennwerte wie coulombscher und viskoser Reibmomente [165] bis hin zu rein datengetriebener Analyse. Bei letzterer wird üblicherweise sowohl eine Betrachtung im Zeit- als auch im Frequenzbereich (DFT oder Hilbert-Huang Transformation, HHT [166]) durchgeführt. Auf Basis experimenteller Untersuchungen werden verschiedene Zustandsindikatoren vorgeschlagen, etwa gemittelte Temperaturen und Drehmomente [161], [165], Schwingungsenergie mittels Geschwindigkeit [167] und Körperschall [168] sowie die Verschiebung der Resonanzfrequenz und die Lagedifferenz zwischen linearer und rotatorischer Wegmessung [166]. Abgesehen von Siegwart [163], der mittels PCA typische Montage-Fehlerbilder von Spindelachsen bei der Endprüfung untersuchte, wurden in den betrachteten Arbeiten multivariate statistische Verfahren, die mehrere Merkmale zu einer Kenngröße zusammenführen, bislang nicht systematisch verwendet, sodass insbesondere dieser Aspekt in der vorliegenden Arbeit untersucht werden soll.

Tabelle 5-1. Relevante Arbeiten im Bereich Zustandsüberwachung von KGT mit den verwendeten Messgrößen Temperatur (T), Drehmoment (M), Vibration (Vib.), Position (s), Geschwindigkeit (v), Motorstrom (I), Drehzahl (n) und Kraft (F).

Autor	Ziel	Anwendung	Methoden	Exp.	Sens.
Forstmann [161]	Lebensdauerprognose	Schwerlast-KGT Kunststoffspritzgießmaschinen	Modellbasiert, FEM Analyse, DFT, Kurtosis	Dauerlauf	T, M, Vib.
Maier [166]	Lebensdauerprognose	KGT Vorschubantrieb	Verschiebung Resonanzfrequenz, Lagedifferenz lineare u. rot. Bewegung, DFT, HHT, statistische Analyse	Gezielte Schädigung, Dauerlauf	M, s
Walther [167]	Lebensdauerprognose	KGT + Wälzlager Werkzeugmaschine	DFT, Schwingungsenergie	Schmutzeintrag, Schadstelle Spindel, Mangel-schmierung	T, I, s, v
Hirschmann [165]	Zustandsbewertung	Antriebseinheit: Motor, Getriebe, belastete Wälzlager	Modell tribologischer Parameter mit statistischer Trendanalyse, Spielbestimmung, Reibmoment	Ausfalltest	T, I, s, n
Huf [169]	Lebensdauerprognose	KGT Werkzeugmaschine	Belastungsintegral	Rekonstruktion externer Belastung	I, s, v
Theobald [168]	Schädigungsbewertung	KGT für Positioniersysteme	DFT, Kurtosis, Schwingungsenergie, Kreuzkorrelation	Dauerlauf	Vib., s, I, T, F
Siegwart [163]	Optimierung End-of-Line	KGT für Positioniersysteme	Statistische Merkmalsextraktion, multivariate Auswertung (PCA)	Gezielt eingebrachte Fehler	Vib., s, I, M

5.4 Kugelgewindetrieb

5.4.1 Allgemeiner Aufbau

Herzstück des elektromechanischen Zylinders ist der Kugelgewindetrieb (KGT), welcher aus den Komponenten Spindel, Spindelmutter und den zirkulierenden Wälzkörpern besteht (Abbildung 5-2). Eine Adapterhülse führt die Spindelmutter im Gehäuse mittels Gleitringen und verfügt über ein Innengewinde, in welches die Kolbenstange verschraubt wird. Über zwei gegeneinander verspannte Schrägkugellager ist die Spindel motorseitig fest gelagert. Auf der gegenüberliegenden Seite wird die Kolbenstange durch ein Gleitlager geführt. Als passives mechanisches Bauelement wandelt der KGT rotatorische Bewegung, die über einen Servomotor am Antriebszapfen eingebracht wird, in eine translatorische Bewegung der Kolbenstange, bzw. im Stillstand erfolgt eine Umwandlung von Drehmoment in Kraft. Hierfür muss sichergestellt werden, dass die Spindelmutter nicht mit der Spindel rotieren kann, was über eine Kunststoff-Verdrehsicherung, die in einer Nut des Aluminiumgehäuses geführt wird, gewährleistet wird. Kugelgewindetriebe weisen im Vergleich zu alternativen Linear-Aktoren wie etwa Gleitgewindetriebe einen wesentlich höheren Wirkungsgrad auf, da durch den Einsatz von Wälzkörpern die Kontaktreibung bewegter Körper näherungsweise über Punktkontakte beschrieben werden kann. Im Gegenzug resultiert dies aber in höheren lokalen Flächenpressungen und potentiell beschleunigter Werkstoffermüdung [161], wie in Abschnitt 5.5 näher erläutert.

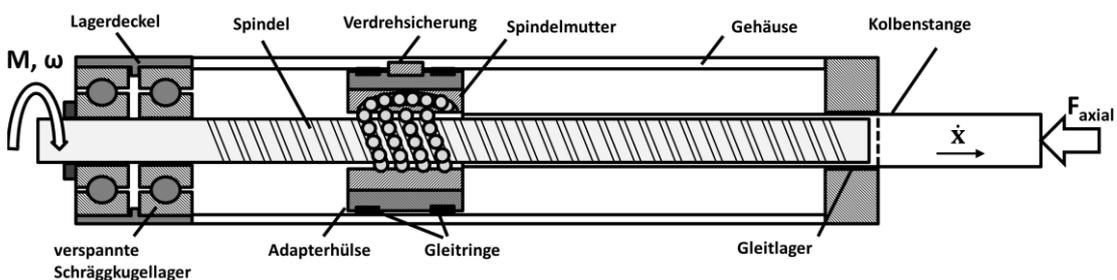


Abbildung 5-2. Aufbau elektromechanischer Zylinder (vereinfachte Darstellung).

Abbildung 5-3 zeigt die antriebsseitige Kaskadenregelung des Servomotors. Daraus ergeben sich die nativen Messgrößen Position, Drehzahl und Motorstrom, die für eine Zustandsüberwachung ohne zusätzliche Sensorik zur Verfügung stehen.

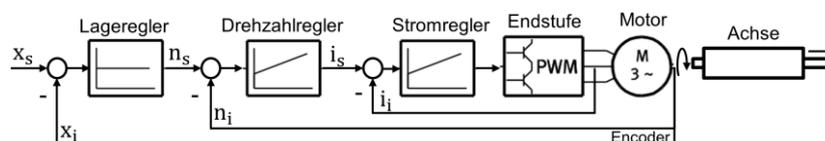


Abbildung 5-3. Kaskadenregelung nach [167], [170].

5.4.2 Vorspannung

Da eine spielfreie Fertigung der Baugruppe Spindel, Mutter und Wälzkörper mit hohen Kosten verbunden wäre, wird in der Praxis der KGT gezielt vorgespannt. Dies geschieht bei einem Zweipunktkugellkontakt entweder über zwei Muttern, die in axialer Richtung gegeneinander verspannt sind, oder über einen leichten Versatz der inneren Gewindegänge einer Mutter. Alternativ sind auch, vor allem im Low-Cost Segment, Vorspannungen mit Vierpunktkugellkontakt aufzufinden, die gezielt durch Auswahl von Wälzkörpern mit Übergroße in Kombination mit einer sog. Spitzbogenform der Gewinderillen realisiert werden.

Das Betriebsverhalten des KGT wird wesentlich durch die Vorspannkraft beeinflusst. Sie führt zu Spielfreiheit, der Reduzierung der Umkehrspanne und einer hohen Steifigkeit und somit letztlich zu einer hohen Positioniergenauigkeit. Gleichzeitig erhöht die Vorspannung die Reibungsverluste, insbesondere bei hohen Drehzahlen, die sich längerfristig in erhöhtem Verschleiß und einer Verkürzung der Lebensdauer niederschlagen. Typischerweise wird die Vorspannung in der Produktion auf Basis des Leerlaufdrehmoments bestimmt und eingestellt [166].

5.4.3 Umlenkssystem

Da die Kugeln beim Verfahren der Spindelmutter ebenfalls einen Bewegungsanteil in axialer Richtung zurücklegen, muss die Kugeldicke in einem kontinuierlichen Kreislauf bewegt werden. Konstruktiv wird dies mit einer internen oder externen Rückführung umgesetzt (Abbildung 5-4). Die externe Rückführung ist meist über ein Umlenkröhr realisiert, welche die Kugeln über mehrere bzw. alle Gewindegänge der Mutter zurückführt. Die interne Rückführung hingegen erfolgt über in die Mutter eingebrachte Einzelumlenkstücke bzw. Umlenkleisten, welche die Kugeln in den vorangegangenen Gewindegang zurückführen. Nach Maier [166] weisen KGT mit externer Rückführung eine höhere Steifigkeit auf, da sie im Verhältnis eine höhere Anzahl tragender Kugeln besitzen, wobei die Anzahl von 120 zurückgeführten Kugeln pro geschlossenem Umlauf nicht überstiegen werden sollte [161]. Letztere Konstruktion wird auch im betrachteten KGT der Fa. Eichenberger verwendet.

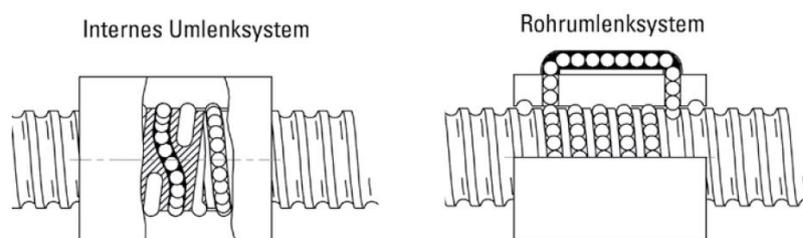


Abbildung 5-4. Interne (links) und externe (rechts) Kugelrückführung [171].

Das Durchlaufen des Umlenkensystems stellt eine Störung der Kugelkinematik und eine Belastung der Wälzkörper dar. Beim Eintreten in das Rückführsystem wird die Rotationsbewegung einer Kugel durch die Reibungskräfte mit der Rohrwand stark verzögert, sodass eine undefinierte Kombination aus Wälz- und Gleitbewegung vorliegt. Von den nachfolgenden Kugeln durch die Rückführung gedrückt, erfolgt beim Wiedereintritt in den Gewindegang wiederum eine rotatorische Beschleunigung.

Das Umlenkensystem hat somit einen erheblichen Einfluss auf den Kugelverschleiß und kann, etwa bei unzulässig hohen Kugelgeschwindigkeiten, einen plötzlichen Ausfall des KGT durch Verklemmen verursachen [161]. Daneben trägt es wesentlich zur Geräuschbildung beim Betrieb des KGT bei [168] und ist somit ein vielversprechender Ansatzpunkt für die Körper-/Luftschallanalyse.

5.4.4 Relevante geometrische Größen

Die Kinematik und Tribologie des KGT wird im Wesentlichen durch die Geometrie des Gewindeprofils bestimmt. Relevante Einflussgrößen des Wirkungsgrades sind hierbei Reibbeiwert, Steigungs- und Kontaktwinkel (vgl. Abbildung 5-5), die im Folgenden auf Basis von [161], [165], [166], [172] erläutert werden.

Der Steigungswinkel φ bestimmt das Übersetzungsverhältnis von Rotationswinkel und Hub bzw. Drehmoment und Kraft. Er bestimmt die maximal zulässigen Parameter des KGT wie externe Axialkraft, Antriebsmoment sowie Beschleunigung und Geschwindigkeit.

Der Kontaktwinkel α beeinflusst wesentlich die Normalkraft zwischen Kugel und Laufbahn bei vorgegebener Axialkraft. Ein großer Kontaktwinkel reduziert die Belastung der Kontaktzonen, führt aber gleichzeitig zur Erhöhung von Bohrreibung, sodass zwischen beiden Effekten abgewogen werden muss. In der Praxis ist zudem relevant, dass die Fertigung von tiefen Gewindegängen, die für große α benötigt werden, mit einem fertigungstechnischen Mehraufwand verbunden ist, sodass in der Praxis Winkel im Bereich von 40 bis 55 Grad üblich sind [161].

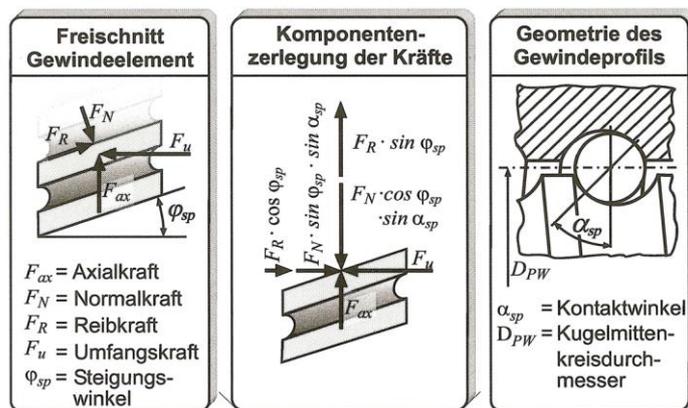


Abbildung 5-5. Kräftebilanz am Gewindetrieb [173] (entnommen aus [161]).

Der Steigungswinkel der Kugelbahn φ kann durch die Steigung P (vgl. Abbildung 5-7c) und den Nenndurchmesser der Spindel bestimmt werden:

$$\tan(\varphi) = \frac{P}{\pi \cdot D_{pw}} \quad (5.1)$$

Die Normalkraft berechnet sich zu [166]:

$$F_N = \frac{F_{ax}}{\cos(\varphi) \sin(\alpha) - \mu \cdot \sin(\varphi)} \quad (5.2)$$

Der Reibbeiwert μ des KGT liegt typischerweise im Bereich $\mu=0,003 \dots 0,01$ [161].

Die Umfangskraft nach [166] ist:

$$F_U = \frac{F_{ax}(\mu \cdot \cos(\varphi) \cdot \sin(\varphi) - \mu \cdot \sin(\varphi))}{\mu \cdot \cos(\varphi) + \sin(\varphi) \sin(\alpha)} \quad (5.3)$$

Das Moment M_S , das bei Anlegen einer axialen Kraft F_{ax} bei Reibungsfreiheit entsteht, berechnet sich zu [172]

$$M_S = \frac{1}{2} D_{pw} \cdot F_{ax} \cdot \tan(\varphi) = \frac{F_{ax} \cdot P}{2\pi} \quad (5.4)$$

Tatsächlich müssen aber zusätzliche Reibmomente M_r überwunden werden, sodass sich das Gesamtmoment M_{ges} ergibt zu [172]

$$M_{ges} = M_S \pm M_r \text{ mit } M_r = F \cdot \frac{1}{2} D_{pw} \cdot \mu \quad (5.5)$$

wobei $F = F_{ax} + F_V$, sich aus der externen Kraftkomponente F_{ax} und der internen Vorspannungskraft F_V zusammensetzt.

Der Wirkungsgrad des KGT für den betrachteten Fall der Umsetzung eines Drehmoments in eine Axialkraft ist nach [166] definiert als:

$$\eta = \frac{\sin(\varphi) \cdot (\cos(\varphi) \cdot \sin(\alpha) - \mu \cdot \sin(\varphi))}{\cos(\varphi) \cdot (\mu \cdot \cos(\varphi) + \sin(\varphi) \sin(\alpha))} \quad (5.6)$$

Typische Wirkungsgrad-Kennlinien für KGT und Trapezspindeln sind in Abbildung 5-6 dargestellt.

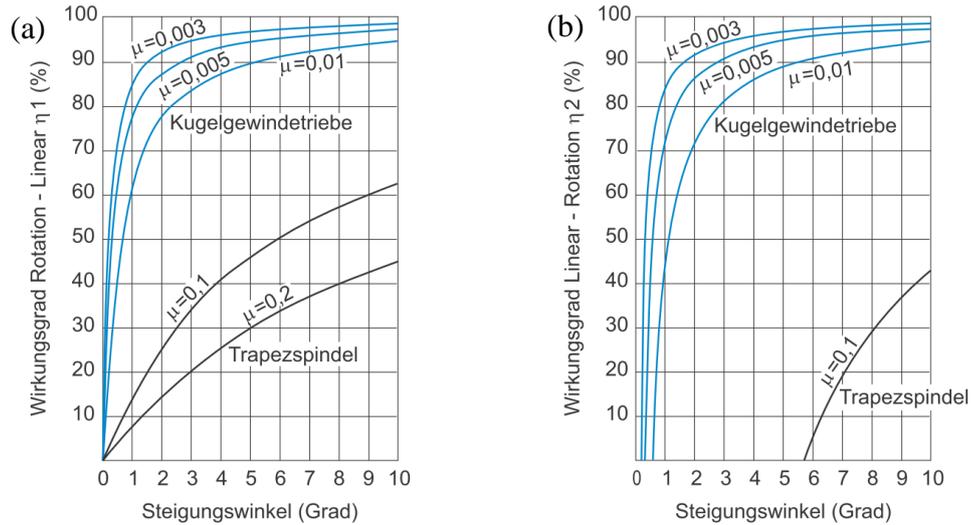


Abbildung 5-6. Wirkungsgrad in Abhängigkeit des Reibungskoeffizienten μ und des Steigungswinkels φ bei (a) der Umwandlung einer Rotationsbewegung in eine Linearbewegung, (b) vice versa [174].

5.4.5 Kinematik und charakteristische mechanische Frequenzen

Auf Basis der Geometrie des Kugelgewindetriebs und des Kugellagers können auftretende mechanische Frequenzen bestimmt werden, anhand derer schadhafte Komponenten identifiziert werden können. Bei den nachfolgenden Betrachtungen muss berücksichtigt werden, dass die Kugeln beim Wälzlager eine reine Kreisbewegung, beim KGT hingegen eine Schraubenbahn durchlaufen. Abbildung 5-7 zeigt die relevanten Geometriegrößen mit dem Kugelmittelkreisdurchmesser D_{pw} , dem Kugel-Neendurchmesser D_w , dem Kontaktwinkel α zwischen Kugel und Laufbahn sowie im Falle des KGT (c) der Spindelsteigung P . Angenommen wird zur Vereinfachung eine ideale Rollbewegung sowie Schlupf- und Reibungsfreiheit.

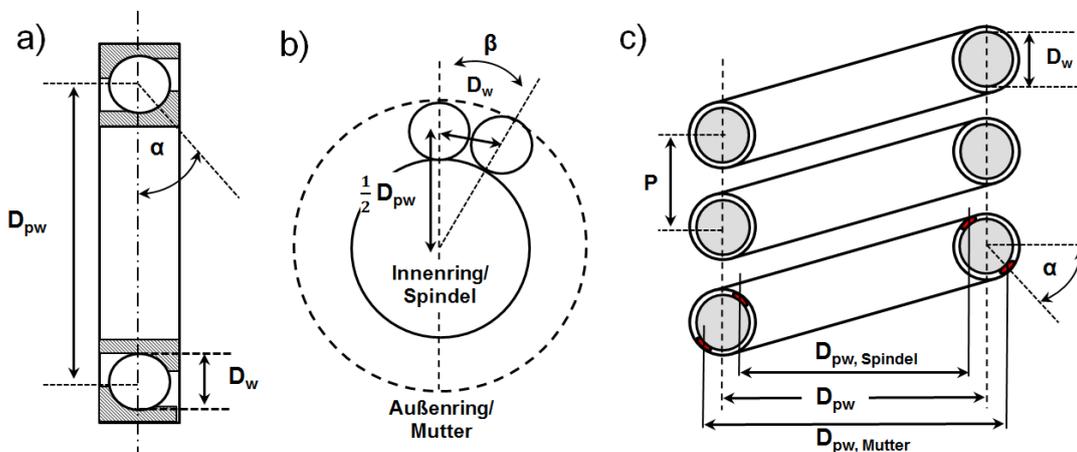


Abbildung 5-7. Relevante Maße beim Kugellager (a,b), und beim Kugelgewindetrieb (b,c) nach DIN 69051 [167].

Beim KGT erhöht sich durch die Spindelsteigung der Laufbahnweg U_{Helix} pro Umdrehung im Vergleich zum Wälzlager, sodass sich der effektive Kugelmittelkreisdurchmesser $D_{pw,KGT}$ ergibt:

$$D_{pw,KGT} = \frac{U_{Helix}}{\pi} = \frac{\sqrt{(\pi D_{pw})^2 + P^2}}{\pi} \quad (5.7)$$

Die Kugeln liegen jeweils auf der Innen- und Außenseite auf den Laufbahnen auf. Die inneren (r_i) und äußeren (r_a) Kontaktradien sind hierbei

$$r_i = \frac{1}{2}(D_{pw} - D_w \cos(\alpha)) \quad (5.8)$$

$$r_a = \frac{1}{2}(D_{pw} + D_w \cos(\alpha)) \quad (5.9)$$

Der Winkel β zwischen den Mittelpunkten zweier aneinander liegender Kugeln ergibt sich beim Wälzlager:

$$\beta_{Lager} = \arcsin\left(\frac{2 \cdot D_w}{D_{pw}}\right) \quad (5.10)$$

Im Falle des KGT sollte zusätzlich der Steigungswinkel φ der Spindel berücksichtigt werden:

$$\beta_{KGT} = \arcsin\left(\frac{2 \cdot D_w \cos \varphi}{D_{pw}}\right) \quad (5.11)$$

Die Anzahl der Wälzkörper z pro Umlauf ist:

$$z = \frac{2\pi}{\beta} \quad (5.12)$$

Die folgende Herleitung der Überrollfrequenzen bezieht sich auf [166], [167], [175], [176].

Nimmt man einen konstanten Kontaktwinkel α an, so kann die Geschwindigkeit der Wälzkörpermittelpunkte, welche die Translation auf der Laufbahn beschreibt, aus dem arithmetischen Mittel der Umfangsgeschwindigkeiten v_i und v_a bestimmt werden. Je nachdem, ob der Außen- oder Innenring rotiert, befindet sich der Momentanpol der Kugel jeweils auf der anderen Kontaktseite.

$$v_K = \frac{1}{2}(v_i + v_a) \quad (5.13)$$

Nimmt man an, dass der Innenring bzw. die Spindel mit der Kreisfrequenz ω_S angetrieben wird und der Außenring / die Mutter fixiert bleiben, ergibt sich daraus gemäß Formel 5.8 die Kreisfrequenz des Kugelmittelpunkts:

$$\omega_K = \frac{1}{2} \cdot \omega_S \cdot \frac{D_{pw} - D_w \cos(\alpha)}{D_{pw}} \quad (5.14)$$

Die Differenz zwischen ω_K und ω_S bestimmt die Periodendauer T_i , die benötigt wird, bis die nachfolgende Kugel an derselben Stelle der Spindel aufliegt unter der Voraussetzung, dass diese dicht aneinander anliegen.

$$\beta = (\omega_S - \omega_K) \cdot T_i \quad (5.15)$$

Somit ergibt sich für die Überrollfrequenz der Innenseite aus den vorangegangenen Formeln bei gegebener Spindeltriebsfrequenz f_n :

$$f_i = \frac{1}{2} \cdot f_n \cdot z \cdot \left(1 + \frac{D_w \cos(\alpha)}{D_{pw}} \right) \quad (5.16)$$

Da die Mutter bzw. der Außenring fixiert ist, gilt die Überrollbedingung:

$$\beta = \omega_K \cdot T_a \quad (5.17)$$

Daraus folgt wiederum unmittelbar für die Überrollfrequenz:

$$f_a = \frac{1}{2} \cdot f_n \cdot z \cdot \left(1 - \frac{D_w \cos(\alpha)}{D_{pw}} \right) \quad (5.18)$$

Letztere ist gleichzeitig auch die Passierfrequenz, mit der die Kugeln das Rücklaufsystem durchlaufen [175].

Nachfolgend soll die Wälzkörperrotationsfrequenz bestimmt werden. Unter der Voraussetzung, dass die Drehachse der Kugeln parallel zur Laufbahntangente verläuft, berechnet sich die Umfangsgeschwindigkeit des Wälzkörpers als Differenz der Umfangsgeschwindigkeit des Innenrings im Berührungspunkt von Kugel und Innenring und der reinen Kugeltranslations-Kreisfrequenz im selben Punkt. Betrachtet wird der Fall angetriebener Innenring:

$$v_w = v_i - \omega_K r_i \quad (5.19)$$

Nach einigen Umformungen resultiert die Drehgeschwindigkeit v_w des Wälzkörpers, mit der dieser über seinen Umfang $\pi \cdot D_w$ abrollt und daraus wiederum die in Tabelle 5-3 dargestellte Rotationsfrequenz.

$$v_w = \frac{1}{2} \cdot \pi \cdot f_n \cdot D_w \left(\frac{D_{pw}}{D_w} - \frac{D_w \cos^2(\alpha)}{D_{pw}} \right) \quad (5.20)$$

Somit ergeben sich die charakteristischen mechanischen Frequenzen in Tabelle 5-3 sowie die exemplarisch berechneten Werte bei $f_n = 40 \text{ Hz}$ auf Basis der in [160], [168] genannten Geometriedaten der im untersuchten EMZ verwendeten Komponenten (Tabelle 5-2).

Nach [168], [177] sind im Schwingungsspektrum zudem Anteile verursacht durch elektrische Effekte des E-Motors, etwa statische und dynamische Exzentrizität oder Spiel zwischen Stator und Rotor zu erwarten, die sich bei charakteristischen Frequenzen zeigen, die wiederum abhängig von der Drehfrequenz sowie der

Konfiguration des E-Motors (z.B. Polpaarzahl N_{pp}) sind. Für eine detaillierte Beschreibung sei auf [177] verwiesen.

Tatsächlich sollte bei der Identifikation der Frequenzen eine Toleranz von $\pm 5\%$ berücksichtigt werden, da es je nach Fertigungstoleranz, Temperatur, Verspannung, Belastungskollektiv oder Verschleißgrad zu Abweichungen der Geometriedaten oder Verletzungen der Annahmen (ideale Rollkinematik, vernachlässigte Reibung) kommen kann.

Abbildung 5-8 zeigt eine Verifizierungsmessung, bei der die Magnetfeldänderungen der vorbeilaufenden ferromagnetischen Kugeln am Rücklaufsystem mit einem GMR-Brückensensor (Sensitec GLM713) gemessen und mittels DFT ausgewertet wurden. Die im Amplitudenspektrum dominante Frequenz von 392 Hz stimmt hierbei mit der berechneten Überrollfrequenz der Mutter, welche gleichzeitig die Passierfrequenz der Wälzkörper ist, in guter Näherung überein (Abweichung 4 Hz bzw. 1 %).

Tabelle 5-2. Geometriedaten der verwendeten Komponenten nach [168]. Die Anzahl z der Kugeln pro Umdrehung im KGT muss hierbei nicht ganzzahlig vorliegen.

Parameter	Schräggugellager Typ 7304-B-2RS-TVP	Kugelgewindetrieb Typ ESBF-63-400-5P
D_{pw}	36,4 mm	22,5 mm
D_w	10 mm	3,5 mm
α	40°	71,8°
z	10	20,4
P	-	5 mm

Tabelle 5-3. Charakteristische mechanische Frequenzen des elektromechanischen Zylinders, berechnete Werte bei $f_n = 40$ Hz. Nach [175], [176].

Teilkomponente		KGT	Wälzlager
Innenring / Spindel	$f_i = \frac{1}{2} \cdot f_n \cdot z \cdot \left(1 + \frac{D_w \cdot \cos(\alpha)}{D_{pw}}\right)$	427 ± 21 Hz	242 ± 12 Hz
Außenring / Mutter	$f_a = \frac{1}{2} \cdot f_n \cdot z \cdot \left(1 - \frac{D_w \cdot \cos(\alpha)}{D_{pw}}\right)$	388 ± 19 Hz	158 ± 8 Hz
Käfig / Kugelkette	$f_k = \frac{1}{2} \cdot f_n \cdot \left(1 - \frac{D_w \cos(\alpha)}{D_{pw}}\right)$	19 ± 1 Hz	16 ± 1 Hz
Wälzkörper Rotation	$f_w = \frac{1}{2} \cdot f_n \cdot \left(\frac{D_{pw}}{D_w} - \frac{D_w \cos^2(\alpha)}{D_{pw}}\right)$	129 ± 6 Hz	70 ± 4 Hz
Wälzkörper Kontakt	$f_{wk} = 2 \cdot f_w$	257 ± 13 Hz	139 ± 7 Hz
Motor Typ EMMS-AS			
Drehfeld	$f_{el1} = f_n \cdot N_{pp}$	240 Hz	
2 x Drehfeld	$f_{el2} = 2 \cdot f_{el1}$	480 Hz	
Drehfeld · Polpaarzahl	$f_{el3} = f_n \cdot N_{pp}^2$	1440 Hz	

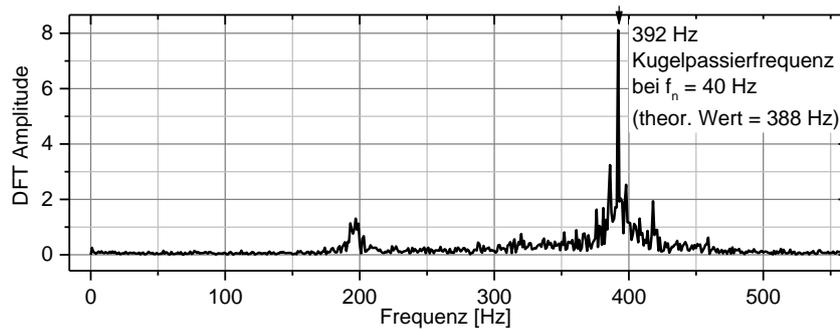


Abbildung 5-8. Gemessene Kugelpassierfrequenz am Rückführsystem bei einem neuen KGT.

Betrachtet man die real vorliegenden Schwingungsspektren in Abhängigkeit der Spindelfrequenz im Bereich der theoretischen Überrollfrequenzen, beispielhaft in Abbildung 5-9 bei einem verschlissenen KGT gezeigt, sind bei den drehzahlabhängigen Anteilen im Wesentlichen die mechanische Grundfrequenz und deren Harmonische sowie Resonanzanteile im Bereich 160 und 390 Hz sichtbar. Die zuvor berechneten Überrollfrequenzen sind, wie schon zuvor in [168], kaum erkennbar. Mögliche Ursachen sind:

- signifikante Abweichungen der vorangegangenen Annahmen (Reibungsfreiheit, keine Gleitanteile, unterbrechungsfreie Kugeldrehbewegung) bei fortgeschrittenem Verschleiß und teilweise chaotische Kugelkinematik durch reduzierten Kugeldurchmesser
- vergleichsweise geringe Abmaße der Wälzkörper und somit eine geringe mechanische Anregung der Überrollfrequenzen
- nicht optimale Sensorplatzierung (Kolbenstange) zur Überwachung des KGT

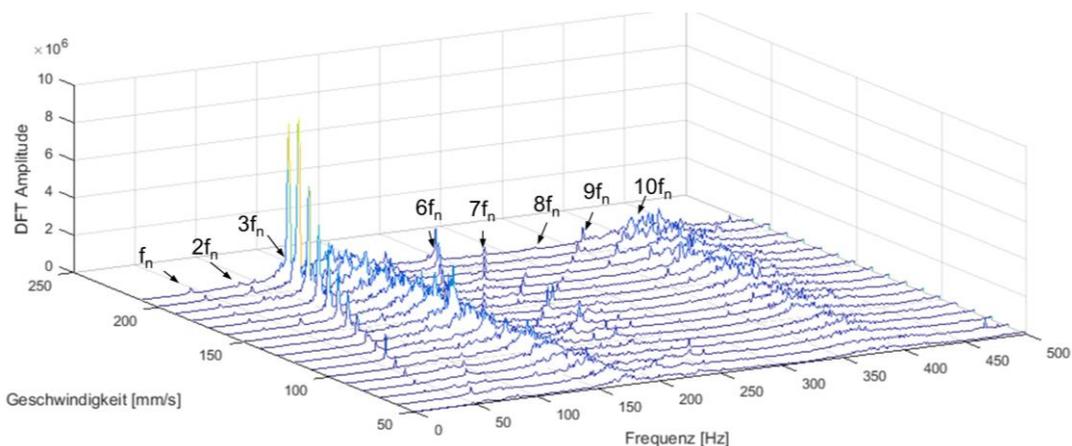


Abbildung 5-9. Gemittelte Schwingungsanteile < 500 Hz an der Kolbenstange in Abhängigkeit der Verfahrensgeschwindigkeit bei verschlissenen KGT ohne axiale Last.

Des Weiteren wird das Schwingungsverhalten wesentlich durch die axial anliegende Kraft beeinflusst; Abbildung 5-10 stellt die Abhängigkeit vom Betrag der Belastung dar. Zu erkennen ist, dass die hochfrequenten Amplituden > 12 kHz proportional zur Last ansteigen, während die Drehfrequenz und deren Harmonische eher gedämpft

werden. Eine Frequenzverlagerung aufgrund der Erhöhung der Steifigkeit durch die externe Axialkraft, wie von Theobald [168] beschrieben, konnte nicht beobachtet werden.

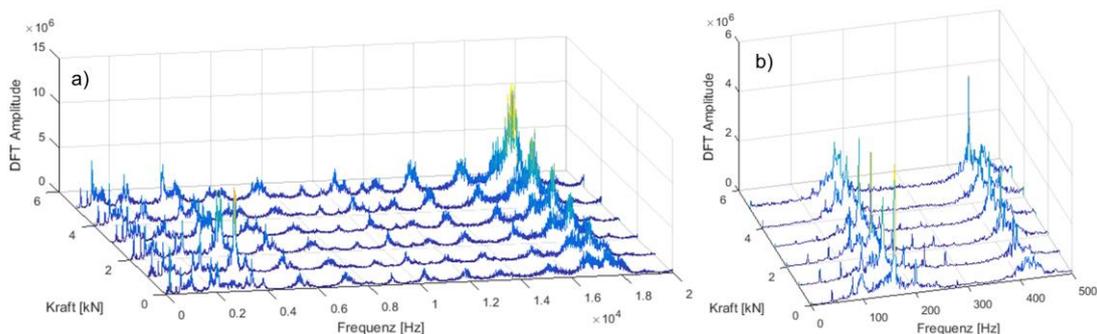


Abbildung 5-10. Lastabhängigkeit des Schwingungsspektrums bei verschlissenenem KGT (200 mm/s), (a) bis 20 kHz und (b) Ausschnitt bis 500 Hz.

5.5 Tribologie und Verschleißeffekte

Verschleiß ist definiert als der fortlaufende Materialverlust von Festkörpern, der durch tribologische Beanspruchungen und Kontaktvorgänge verursacht wird. Die relevanten Schädigungsformen und mechanischen Verschleißursachen beim KGT werden nachfolgend knapp erläutert.

5.5.1 Schädigungsformen

Oberflächenzerrüttung ist insbesondere bei Roll- und Wälzkontakten vorzufinden, bei denen eine hohe Schwellbelastung entsteht, die wiederum zu Mikroverformungen, Versetzungsaufbau an Korngrenzen und Gefügeeinschlüssen führen kann [161]. Bei wiederholter Einwirkung begünstigt dies die Bildung von Rissen, insbesondere im Material unter dem Kontaktpunkt, und deren Wachstum. Erreichen die Risse die Oberfläche, können Teile des Materials herausbrechen und es entstehen charakteristische Grübchen, auch Pittings genannt, sowie sog. Graufleckigkeit [178]. Neben den Materialeigenschaften, der Oberflächenbeschaffenheit und der Geometrie der Kontaktkörper spielen auch die Eigenschaften des Schmiermittels und -films eine wichtige Rolle.

Abrasion tritt bei einer Relativbewegung der Berührungspunkte zweier Reibpartner, insbesondere bei Gleitbewegung auf und führt vor allem bei im Schmiermittel eingebrachten Fremdpartikeln mit hoher Härte zu Mikrozerspannung, -pflügen und -brechen [161]. Langfristig entsteht hierdurch makroskopischer Verschleiß durch die Bildung von Ritzen und Furchen.

Adhäsion beruht auf atomaren Wechselwirkungskräften und chemischen Bindungen bei berührenden Grenzflächen. Unterschieden werden hierbei starke Hauptvalenzverbindungen (Ionen-, Atom- und metallische Bindung) mit einer typischen Bindungsenergie von 2 bis 8 eV/Atom und schwachen Nebervalenzbindungen (van-der-Waals-Bindungen) mit ca. 0,1 eV/Atom [179]. Übersteigt bei einer Relativbewegung der Kontaktpartner die Festigkeit der adhäsiven Bindung die des weicheren Körpers, bricht aus diesem Material heraus, das entweder am härteren Körper haften bleibt oder abgetrennt wird [161]. Aufgrund der starken plastischen Verformung sowie teilweise der Einbindung von Metalloxiden weisen die Ausbrüche typischerweise eine höhere Härte als der Grundkörper auf und können somit wiederum Quelle von Abrasionsvorgängen werden. Tatsächlich ist bei Betrachtung der Adhäsionskräfte die lokale Oberflächenbeschaffenheit (Oberflächenrauigkeit, Metalloxidschicht) zu beachten, die dazu führt, dass die reale Kontaktfläche nur einem Bruchteil der idealen Kontaktfläche entspricht.

Des Weiteren ist die **Tribochemie** als Einflussfaktor des Verschleißvorgangs zu nennen. Diese beschreibt die chemischen und korrosiven Einflüsse des Umgebungsmediums auf die Reibpartner. Die von der tribologischen Beanspruchung eingebrachte mechanische und thermische Energie kann chemische Reaktionen aktivieren und längerfristig zu einer Ausbildung von lokalen Deckschichten, typischerweise Oxiden, führen. Diese weisen i.d.R. eine hohe Härte und Sprödigkeit auf, sodass sie bei mechanischer Belastung bevorzugt von der Oberfläche abgetrennt werden und, transportiert über das Schmiermittel, wiederum als Abrasivpartikel in Erscheinung treten.

5.5.2 Mechanische Verschleißursachen

Zunächst soll der Wälzvorgang betrachtet werden: Theoretisch liegt zwischen den Kugeln und Laufflächen und den Kugeln untereinander ein punktförmiger Kontakt vor. Tatsächlich entsteht aufgrund von Elastizität beim Überrollen eine elliptische Berührfläche, sodass sich die maximale Spannung (Hertz'sche Pressung) bei gegebener Normalkraft nach [161], [180] ergibt zu:

$$p_{max} = \frac{1}{\pi} \sqrt[3]{\frac{3 \cdot F_N \cdot E^2}{2 \cdot r^2 \cdot (1 - \nu^2)^2}} \quad (5.21)$$

mit $r = \frac{1}{4} D_w$ für Kugel-Kugel Kontakt und $r = \frac{1}{2} D_w$ bei Kugel-Laufbahn

ν = Poissonzahl

E = E-Modul

Obige Formel stellt allerdings nur eine Näherung dar, da die Interaktion mit dem Schmierfilm nicht berücksichtigt wird. In der Realität liegt elasto-hydrodynamische Schmierung oder Mischreibung vor [181].

Bei der Betrachtung der Gleitvorgänge sind Schlupf und Bohrbewegungen relevant. Mikroschlupf ist hierbei ein unvermeidlicher Effekt, der aus der elastischen Verformung von Kugel und Laufbahn während des Wälzvorgangs entsteht. Die lokale Stauchung im Kontaktpunkt verursacht eine Geschwindigkeitsdifferenz der Umfangsgeschwindigkeiten, die durch eine Gleitbewegung des Rands der Kontaktzone ausgeglichen werden muss; diese wird als Mikroschlupf bezeichnet. Makroskopischer Kugelschlupf hingegen entsteht, wenn die Trägheitskraft der Kugel betragsmäßig die Haftreibungskraft übersteigt, etwa bei hohen Beschleunigungen der Verfahrbewegung. Hierbei wird angenommen, dass die Kugeln vollständig an der Laufbahn der Spindel durchrutschen und an der Laufbahn der Mutter haften [161].

Ein weiterer unvermeidbarer Effekt im KGT ist die Bohrbewegung der Kugel [161] in Form einer Drehbewegung um die Normale der Tangentialebene des Berührungspunktes mit der Lauffläche. Sie tritt auf, da die Winkelgeschwindigkeitsvektoren im Kontaktpunkt nicht tangential zur Lauffläche vorliegen. Der Kennwert für diesen Effekt ist das Bohr-Roll-Verhältnis beider Kreisfrequenzen, welches mit höheren Kontaktwinkeln α ansteigt.

$$\tan(\varepsilon) = \frac{\omega_B}{\omega_R} \quad (5.22)$$

Ein zusätzlicher Gleitvorgang entsteht dadurch, dass Mutter und Spindel zwar dieselbe Steigung P , aber aufgrund unterschiedlicher Durchmesser effektiv verschiedene Bahnlängen besitzen (vgl. Abbildung 5-7), sodass für die jeweiligen Steigungswinkel φ gilt

$$\varphi_{Mutter} < \varphi_{Kugel} < \varphi_{Spindel} \quad (5.23)$$

Dies zwingt die Kugel zu einer überlagerten Drehbewegung, deren Drehachse nicht senkrecht zum Bahngeschwindigkeitsvektor verläuft, und somit zu einer weiteren Relativbewegung zwischen Kugel und Laufbahn.

Es lässt sich zusammenfassen, dass beim Betrieb des KGT mehrere parallel ablaufende Verschleißmechanismen überlagert sind. Diese sind teilweise systembedingt (Schwellbelastung, Mikroschlupf, Bohrbewegung, Kugelgleiten und -interaktion in der Rückführung) und somit unvermeidbar, zum Teil dem Lastkollektiv geschuldet (Makroschlupf). Für eine detaillierte mathematische Beschreibung der Vorgänge sei auf Forstmann verwiesen [161]. Abbildung 5-11 stellt in einer Übersicht die Verschleiß- und Schadensentstehung in den Teilsystemen Kugel-Spindel und Kugelrückführung dar.

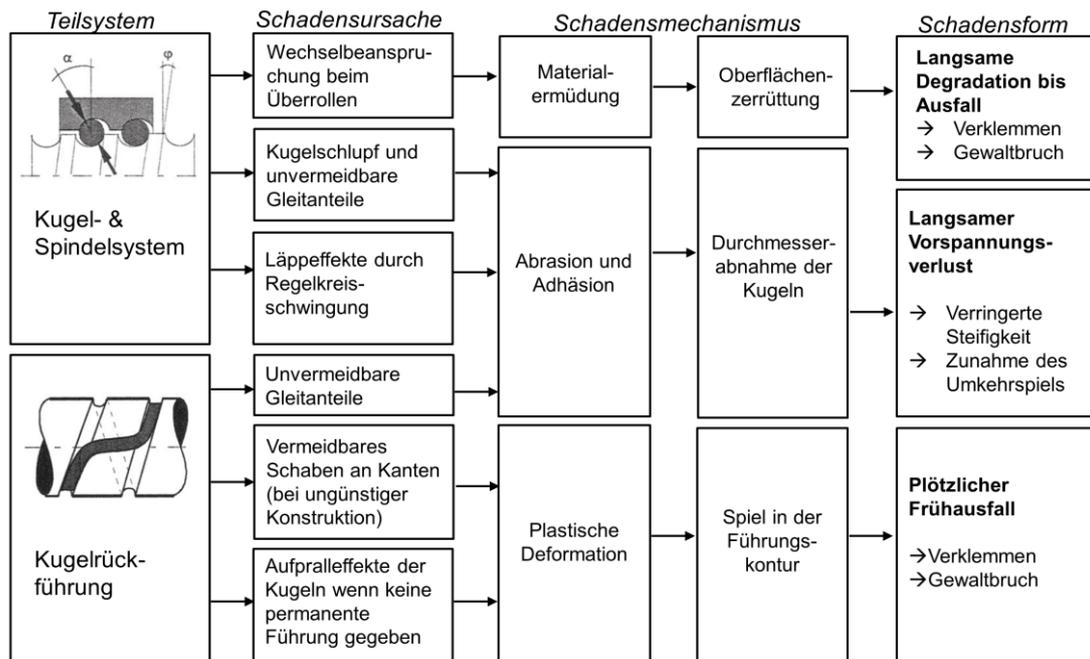


Abbildung 5-11. Schadens- und Verschleißarten und ihre Entstehung am Kugelgewindetrieb nach [161].

5.5.3 Ausfallkriterien

Da nach ISO 13372 [6] ein Ausfall einer Maschine vorliegt, wenn die geforderte Funktion nicht mehr erfüllt werden kann, bestehen je nach Anwendung deutliche Unterschiede bei der Definition des Ausfallkriteriums von KGT; exemplarisch zu nennen sind:

- Austreten von Schmiermittel (Lebensmittelanwendungen) [168]
- Subjektiv wahrgenommene „schlechte“ Laufgeräusche [168]
- Verlust Vorspannung, Positioniergenauigkeit (Werkzeugmaschinen) [164], [166]
- Wirkungsgrad, Bestimmung durch Leerlaufdrehmoment beim EoL-Test [163]
- Totalausfall durch Verklemmen, Gewaltbruch (Spritzgießmaschinen) [161]

In dieser Arbeit wird von einem Ausfall gesprochen, wenn der EMZ den definierten Positioniervorgang bei vorgegebenem Lastkollektiv nicht mehr durchführen kann, sodass eine Sicherheitsabschaltung durch den Motorcontroller erfolgt (typ. Erreichen der Toleranzgrenze von Schleppfehler oder I^2t -Wert [170]). Der Schleppfehler bezeichnet hierbei die Regeldifferenz des Motorcontrollers zwischen der Führungsgröße, also dem Positionssollwert, und dem rückgemessenen Positions-Istwert. Während im normalen Betrieb üblicherweise nur geringe Regeldifferenzen auftreten, deutet ein plötzlich auftretender starker Anstieg des Schleppfehlers auf einen mechanischen Defekt, etwa Verklemmen des KGT, hin.

5.5.4 Prognosemodelle

Die weit verbreitete Lebensdauerprognose auf Basis von DIN 69051 basiert ausschließlich auf dem Verschleißeffekt der Ermüdung durch die Wälzbelastung der Kugeln auf den Laufbahnen und nimmt Bezug auf das Lebensdauermodell von Wälzlagern. Hierbei wird die Lebensdauer L_m (in 10^6 Umdrehungen), die mit einer Wahrscheinlichkeit von 90 % erreicht wird, mit den Einflussgrößen dynamische äquivalente axiale Last F_m und modifizierte dynamische axiale Tragzahl C_{am} , in die wiederum Korrekturfaktoren für die Fertigungstoleranzen und Materialeigenschaften eingehen, berechnet [161]:

$$L_m = \left(\frac{C_{am}}{F_m} \right)^3 \quad (5.24)$$

In der Literatur wird die Aussagekraft des Modells kritisch gesehen, da entscheidende Parameter, etwa die Art der Kugelrückführung, der Einfluss von Schmiermittel und Verschmutzung sowie die Lastorientierung und individuelle Lastverteilung der Kugeln unberücksichtigt bleiben, was dazu führt, dass der Prognosewert für manche Anwendungen unbrauchbar ist. Daneben wurden komplexere Prognosemodelle entwickelt [161], u.a. das lineare Verschleißbetragsmodell für KGT sowie optimierte Modelle, die lokale Einflüsse, Last- und Vorschädigungseinflüsse bei Abrasion und Ermüdung berücksichtigen sowie Modelle, die progressive oder degressive Verlaufsformen annehmen [161]. Zuletzt genannte Modelle finden jedoch keine breite Verwendung in der praktischen Anwendung.

5.6 Experimenteller Aufbau

Zur Charakterisierung des zeitlichen Verschleißverhaltens eines elektromechanischen Zylinders vom Typ Festo ESBF-63-400-5P [160] wurde ein Prüfstand entwickelt und realisiert, dessen mechanischer Aufbau, Steuerung und Datenerfassung im Folgenden beschrieben wird. Dabei wurde auf Erfahrungen aus vorangegangenen Arbeiten [163], [168] zurückgegriffen.

5.6.1 Mechanik

Abbildung 5-12 sowie Abbildung 5-13 zeigen den mechanischen Aufbau des Prüfstands. Die bewegte Mechanik ist hierbei auf einer Aluminium-Grundplatte montiert, die über Gummidämpfer von der Umhausung und den übrigen Komponenten (Pneumatik, Steuerung, Datenerfassung) mechanisch entkoppelt ist.

Hierbei wird die ESBF-Achse von einem Servomotor Festo EMMS-AS [182] betrieben. In axialer Richtung wird mithilfe des Pneumatikzylinders Festo DNC-100 [183] eine Kraft erzeugt, deren Größe und Richtung mittels Proportional-Druck- bzw. Wegeventilen gesteuert werden kann. Der Pneumatikzylinder erlaubt hierbei eine maximale Kraft von ca. 9,6 kN bei 12 bar und somit auch einen Betrieb der ESBF-Achse außerhalb der Spezifikation (max. 7 kN). Die Axialkraft wird während des Prozesses von einem Kraftsensor Typ Lorenz K-25 [184] gemessen. Um einem Druck- und somit Kraftabfall bei hohen Vorschubgeschwindigkeiten entgegenzuwirken, wird Druckluft in zwei Druckbehältern (je 10 l Volumen) für eine schnelle Volumenkompensation bereitgehalten. Eine zusätzliche Versteifung der Konstruktion erfolgt über einen Stahlrahmen, der die Führungsblöcke von Pneumatikzylinder und EMZ verbindet. Unerwünschte laterale Kräfte werden über zwei gekoppelte Linearführungen aufgenommen.

Die Drehmomentmessung zwischen Motor und Spindelachse ist in Abbildung 5-12 dargestellt. Die Sicherheitskupplung schützt hierbei die Drehmomentwelle vom Typ Lorenz DR-2112 [185] vor Überlast, die Balgkupplung dient dem Ausgleich geringer Winkelfehler zwischen Motorwelle und Antriebszapfen der Spindelachse.

Optional erlaubt der Prüfstand auch eine zusätzliche laterale Belastung der Kolbenstange der Spindelachse, was in einer überlagerten Drehmomentbelastung des KGTs resultiert. In den nachfolgenden Versuchen wird jedoch nur eine rein axiale Belastung betrachtet. Für eine detaillierte Beschreibung des Versuchsaufbaus sei auf [186] verwiesen.

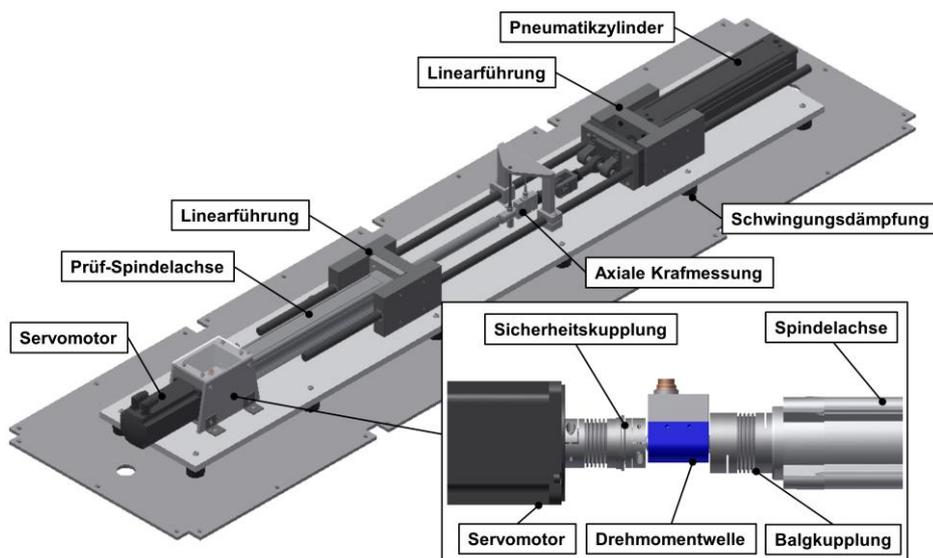


Abbildung 5-12. CAD-Modell nach [186].

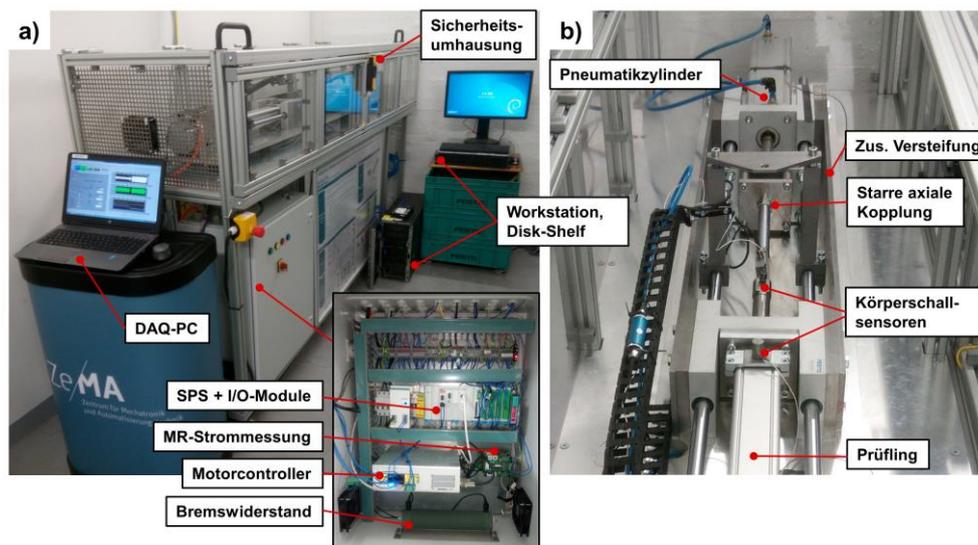


Abbildung 5-13. Realisierung des Spindelachsen-Prüfstands.

5.6.2 Steuerung und Datenerfassung

Die Ablaufsteuerung der Bewegungs- und Lastprofile ist zentral über eine SPS (Festo CECX [187]) und einen Motorcontroller (Festo CMMP [148]) realisiert.

Die Konfiguration des Zyklus erfolgt über eine LabVIEW-Benutzeroberfläche am PC und wird über Ethernet mittels des sog. Easy-IP Protokolls an die SPS übertragen. Ein solcher Zyklus setzt sich aus einem Array von Satzelementen zusammen. Diese definieren jeweils die Bewegung (Verfahrenmethode, Zielposition, Geschwindigkeit, Beschleunigung, Verzögerung, Wartezeit) sowie die Belastung (Richtung und Betrag des geregelten Drucks).

Die LabVIEW-Benutzeroberfläche zur Konfiguration der Prüfabläufe und der Datenerfassung ist in Abbildung 5-14 dargestellt. In (1) erfolgt die Steuerung des Motorcontrollers (Start, Pause, Halt, Fehlerquittierung, Referenzfahrt) sowie des Datenerfassungssystems (getriggerte oder kontinuierliche Aufnahme, Speichern aktivieren, Messung starten). Die Konfiguration der Satzelemente und axialen Belastungsparameter, die in Kombination den Arbeitszyklus ergeben, ist in (2) dargestellt. Die Visualisierung der Sensordaten erfolgt in (3) mit der Darstellung der Motorströme (oben), der Luft- und Körperschallsensoren (Mitte) und der Prozesssensoren (unten, vgl. Tabelle 5-4) des zuletzt aufgenommenen Zyklus.

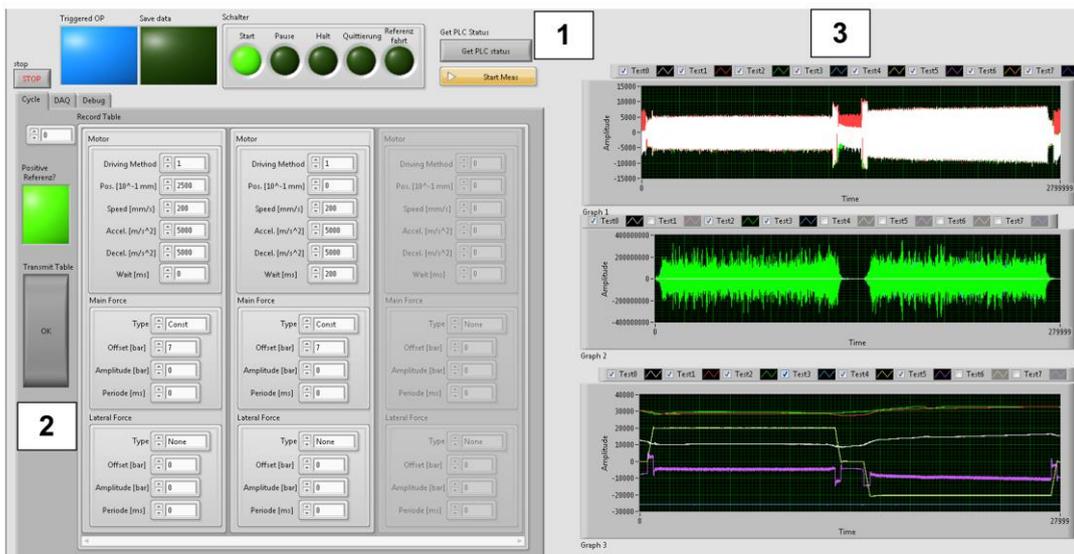


Abbildung 5-14. Prüfablaufgenerierung und Datenerfassung in LabVIEW, (1) Steuerung, (2) Zykluskonfiguration, (3) Visualisierung Sensordaten.

Der konfigurierte Zyklusablauf wird über eine CANopen Schnittstelle mit dem FHPP-Protokoll⁷ zum Motorcontroller weitergeleitet, wo er ebenfalls gespeichert wird. Nach dem Startsignal verfährt der Motorcontroller autonom den vorgegebenen Bewegungszyklus und synchronisiert den aktuellen Zustand (Verfahrelement, Position, etc.) über CANopen mit der SPS. Diese gleicht die vorgegebenen Lastparameter zum individuellen Element ab und setzt die Sollwerte für die Ventile. Die Ablaufsteuerung wurde mit der Programmierumgebung Codesys [147] in Form von strukturiertem Text umgesetzt. Der Gesamtaufbau der Steuerung wird in Abbildung 5-15 dargestellt.

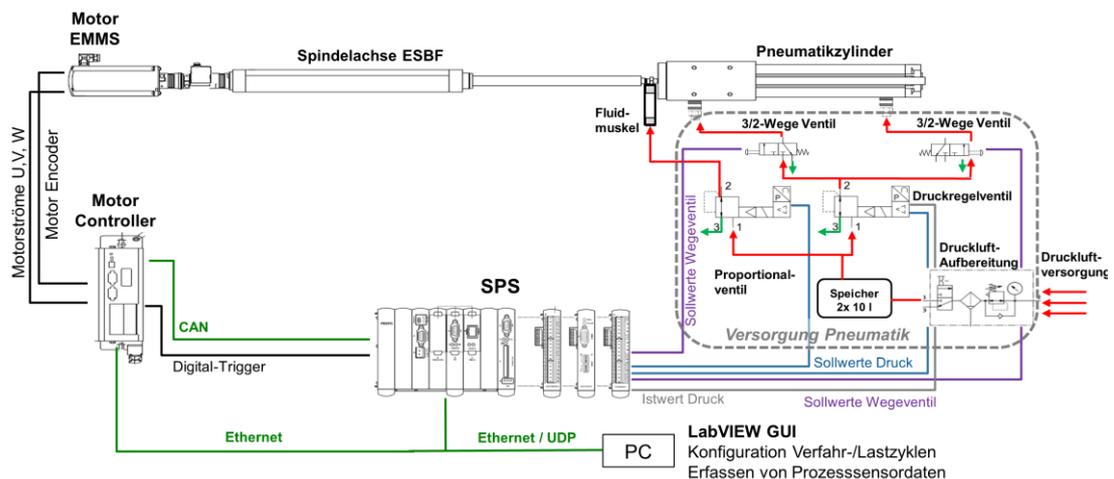


Abbildung 5-15. Steuerung des EMZ-Dauerlaufprüfstands.

⁷ Festo Handling and Position Profile

Grundlegende Sicherheitsfunktionen wie die Steuerung der Schutztürverriegelung sind über das im Motorcontroller integrierte Sicherheitsmodul CAMC-G-S3 [188] realisiert. Eine Beschreibung dieser Funktionen ist in [189] aufgeführt.

Die zyklische Datenaufnahme erfolgt getriggert über einen Digitalausgang des Motorcontrollers, welcher über die proprietäre Software Festo Configuration Tool (FCT) parametrisiert wird und ein Flankensignal beim Start des Bewegungsprofils ausgibt.

Die Datenerfassung erfolgt mithilfe eines PXI-Systems der Fa. National Instruments, in dessen Chassis drei Module installiert sind (Abbildung 5-16):

- Rekonfigurierbares Oszilloskop PXIe-5170R [190] mit 8 synchron abgetasteten Kanälen, maximal 250 MS/s und 14 bit Auflösung
- Schall- und Schwingungsmessmodul PXIe-4492 [191] mit 8 synchron abgetasteten Kanälen, max. 204,8 kS/s, 24 bit Auflösung
- Universalmodul PXIe-6341 [192] mit 8 differentiellen / 16 single-ended Kanälen, max. 500 kS/s gesamt, 16 bit Auflösung

Die Messdatenübertragung zum PC erfolgt über PCI Express mit einer maximalen Datendurchsatzrate von 798 MB/s. Dort werden die ankommenden Datenpakete mit LabVIEW verarbeitet und zyklisch im HDF5-Format [193] abgelegt. Nach Abschluss einer Datei, welche typischerweise 50-100 Zyklen beinhaltet, wird diese via 10 Gb Ethernet zu einer Workstation transferiert und in einem Disk-Array abgelegt, welches über zwölf 6 TB Festplatten verfügt, die im RAID6-Verbund betrieben werden, sodass eine Nettokapazität von 60 TB genutzt werden kann.

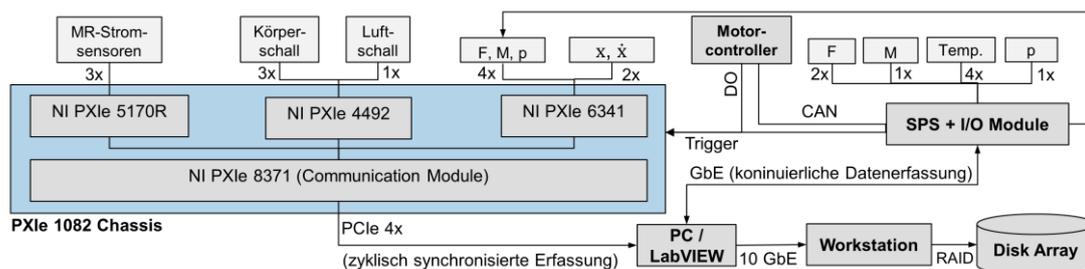


Abbildung 5-16. Sensordatenerfassung Spindelachsenprüfstand.

Tabelle 5-4 zeigt die Konfiguration der im Prüfstand verwendeten Sensoren. Insgesamt 13 Sensorsignale werden entsprechend ihrer zur erwartenden Bandbreite mit 10 kHz bis 1 MHz abgetastet, sodass während der Versuchsdurchführung ca. 8 MB Daten pro Sekunde bzw. 682 GB pro Tag anfallen.

Tabelle 5-4. Verwendete Messgrößen und Signale Spindelachsenprüfstand. Bei der extern durchgeführten Luftschallmessung ist aufgrund des KGT-Gehäuses mit einer starken Dämpfung der höheren Anregungsfrequenzen zu rechnen, sodass eine Abtastrate von 100 kHz als ausreichend bewertet wird.

Messgröße	Sensor	Messbereich / Bandbreite	Abtastung
Motorströme U,V,W	Sensitec CMS 2005 [194]	± 20 A Peak / 200 kHz (-3dB)	1 MHz, 14 bit
Vibration Kugellager	Kistler 8704B50M1 [195]	± 50 g / 0,5 Hz ..10 kHz ($\pm 5\%$)	100 kHz, 24 bit
Vibration Kolbenstange			
Vibration Gleitlager	Kistler 8712A5M1 [196]	± 5 g / 0,5 Hz .. 8 kHz ($\pm 5\%$)	100 kHz, 24 bit
Mikrofon	G.R.A.S. 46BE [197]	35..160 dB/ 4 Hz ..100 kHz (-3dB)	100 kHz, 24 bit
Kraft axial	Lorenz K-25 [184]	± 10 kN / 1 kHz (-3dB)	10 kHz, 16 bit
Kraft lateral	Althen AUMM 50 [198]	± 500 N / 200 Hz	10 kHz, 16 bit
Drehmoment	Lorenz DR2112 [185]	± 15 Nm / 10 kHz	10 kHz, 16 bit
Druck Pneumatik	Festo VPPM [199]	10 bar / k.A.	10 kHz, 16 bit
Position	Motorcontroller Festo	-	10 kHz, 9 bit
Geschwindigkeit	CMMP-C10-11A-AS [170]		

5.7 Ergebnisse

5.7.1 Durchgeführte Lebensdauerermessungen

Im Rahmen der Arbeit wurden drei Lebensdauerermessungen durchgeführt (Tabelle 5-5), die jeweils mit dem Ausfall der Achse endeten. Als Abbruchbedingung wird eine Schleppfehlergrenze von 30 mm verwendet (vgl. Kap. 5.5.3).

Tabelle 5-5. Durchgeführte Lebensdauerersuche EMZ baugleichen Typs (Festo ESBF-63-400-5P) mit Laufleistungen s , Druck p des Pneumatikzylinders, Verfahrgeschwindigkeit v und Beschleunigung a des EMZ sowie der Art der mechanischen Verbindung zwischen Motor und Spindelachse. Bei Versuch I ging der Ausfall der Achse mit einem Prüfstandsdefekt einher, Versuch II und III wurden aufgrund eines Schleppfehlers abgebrochen.

Nr.	s [km]	Abbruch	p [bar]	Richtung	v [mm/s]	a [m/s ²]	Verbindung
I	441	Defekt	6	Zug/Druck	200	1,0	Kupplung/Drehmomentwelle
II	1.050	Schleppf.	7	Zug	200	1,0	
III	315	Schleppf.	7	Zug	200	5,0	Klauenkupplung

Abbildung 5-17 stellt exemplarisch den Verfahrenzyklus mit Vor- (1-3) und Rückhub (4-6) und qualitativ dessen Intervalleinteilung zur Merkmalsextraktion dar.

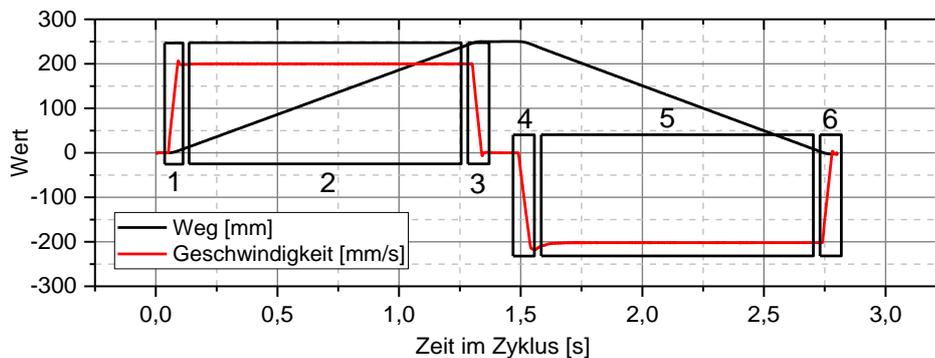


Abbildung 5-17. Bereiche des Verfahrenzyklus.

Abbildung 5-18 zeigt den Verlauf von Drehmoment und Kraft über die drei Versuche. Die Versuche I und II mussten aufgrund von Störungen und erforderlichen Modifikationen am Prüfstand mehrfach pausiert werden, während (III) unterbrechungsfrei durchgeführt werden konnte. Des Weiteren wurde Versuch I im Gegensatz zu (II) und (III) in klimatisierter Umgebung durchgeführt. Die dargestellten Werte werden mit einem zeitlichen Abstand von 1 h (Versuch I), 3 h (Versuch II) und 24 min. (Versuch III) bei konstanter Verfahrensgeschwindigkeit im Rückhub berechnet und über 40 Zyklen gemittelt.

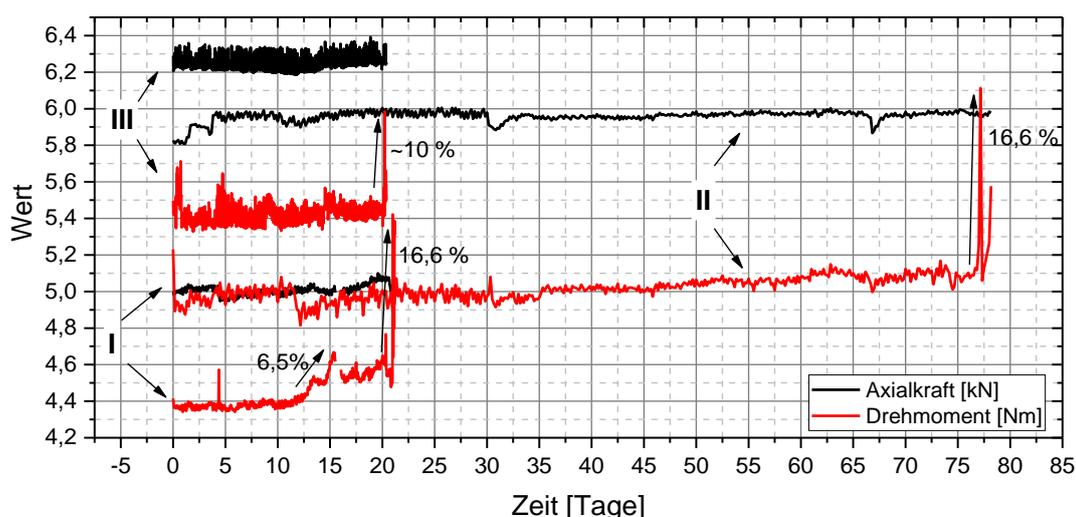


Abbildung 5-18. Gemessene Kraft- und Drehmomentverläufe der drei Lebensdauerexperimente (I), (II), (III).

- (I) Bei Versuch I erfolgte eine beidseitige Belastung des KGT, mit einer über den Zeitraum näherungsweise konstanten (ca. 2 % Abweichung) Axialkraft von 5 kN bei einer Laufzeit von ca. 21 Tagen. Das gemessene Drehmoment weist ebenfalls zunächst einen konstanten Verlauf auf, bis nach etwa 12 Tagen ein Anstieg um 6,5 % mit anschließendem Verharren auf erhöhtem Level zu erkennen ist. Kurz vor dem Ende erfolgt eine rückläufige Bewegung bevor das Drehmoment final stark ansteigt (16,6 %). Hierbei ist zu beachten, dass der tatsächliche Drehmomentanstieg wahrscheinlich wesentlich höher ausgefallen sein wird, aufgrund der geringen zeitlichen Auflösung und Mittelung jedoch nicht vollständig abgebildet wird. Auffällig sind zudem kurzzeitig auftretende Drehmomentpeaks (Tag 4 und 20), die nur zum Teil (Tag 4) durch eine Unterbrechung erklärt werden können.
- (II) Um die mechanische Belastung des Prüfstands zu reduzieren, wurde im zweiten Versuch die Krafrichtung konstant gehalten und ihr Betrag gleichzeitig auf einen mittleren Wert von ca. 6 kN (Rückhub) erhöht, welcher über die Versuchsdauer von ca. 78 Tagen näherungsweise

konstant bleibt. Aufgrund von Umbauarbeiten (Einbau Lüfter, externer Bremswiderstand) sind jedoch Sprünge im Drehmoment- und Kraftsignal im Bereich < 35 Tage sichtbar. Beim Drehmoment lässt sich ein langsamer Anstieg (ca. 2 %) im Bereich Tag 35 bis 63 sowie ein Peak von ca. 16,6 % kurz vor dem Ausfall erkennen. Da nach einer Laufzeit von 60 Tagen keine Symptome einer Schädigung auftraten, wurde ein Ausfall durch gezielte Eingabe von Verschmutzung (ca. 20 Zugaben mit je 1 g SiO_2 ISO 12103 A3 Teststaub ab Tag 60) in das KGT-Gehäuse forciert.

- (III) Die dritte Achse weist eine Laufzeit von knapp 21 Tagen bis zum Ausfall auf bei gegenüber Versuch II erhöhter Beschleunigung ($5 \frac{\text{m}}{\text{s}^2}$) und Verwendung des Axialbausatzes Festo EAAM-A-D60 zur Verbindung von Motor und Spindelachse. Das Drehmoment wird im Vergleich zu den vorangegangenen Versuchen anstelle einer direkten Messung über den Motor-Wirkstrom und die Motorkonstante bestimmt. Der Drehmomentanstieg vor dem Ausfall fällt im Vergleich zu beiden vorangegangenen Versuchen mit ca. 10 % geringer aus.

5.7.2 Durchgeführte multivariate Auswertung

Die Merkmalsextraktion zur multivariaten Sensordatenanalyse (Abbildung 5-19) erfolgt in den Bereichen 4, 5 und 6 des Zyklus (vgl. Abbildung 5-17) im Zeitbereich sowie im Bereich 5 bei konstanter Spindeldrehzahl im Frequenzbereich. Hierbei erfolgt eine Segmentierung des Amplitudenspektrums in 100 Hz Schritten unterhalb von 1 kHz sowie in 5 kHz Schritten im Bereich 1 bis 50 kHz mit anschließender Merkmalsextraktion. Insgesamt wird somit ein Pool mit 672 Merkmalen generiert, die potentiell zur Zustandsüberwachung zur Verfügung stehen.

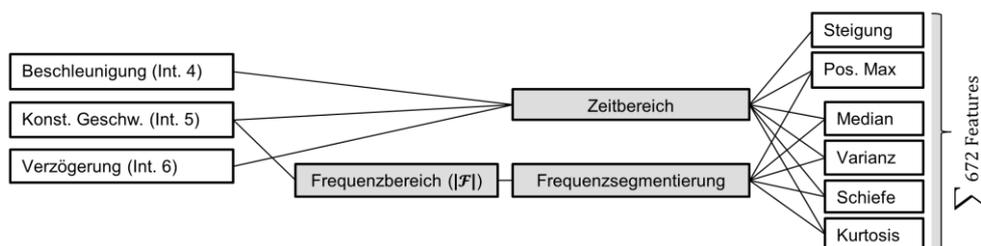


Abbildung 5-19. Vorgehen zur Merkmalsextraktion.

Bei der Auswertung (Tabelle 5-6) werden in festen zeitlichen Abständen jeweils 40 aufeinanderfolgende Zyklen als Stichprobe herausgegriffen und zu Bereichen in einer Klasse (0,8 bis 3 Tage) zusammengefasst, was einer relativen Lebensdauerauflösung von ca. 3,7 bis 4,8 % entspricht. Somit sind in den Daten Streuungen auf unterster (Prozesszyklus), mittlerer (Tagesverlauf) und globaler

Zeitebene (Verschleißprogression) der Lebensdauer repräsentiert. Dadurch optimiert das statistische Modell zum einen die Trennung des globalen Verlaufs und minimiert zum anderen den Einfluss unvermeidbarer Schwankungen von Prozess- und Umgebungsparametern. Die Klasseneinteilung erfolgt auf Basis der Lebenszeit, wobei eine maximale Separierung der Zustände erreicht werden soll. Diese Trennung muss nicht notwendigerweise in chronologischer Reihenfolge erfolgen; dies ist jedoch ein Hinweis auf ein sinnvolles Modell. Im Gegensatz zur Regression muss hierbei somit keine Form des Verschleißverlaufs (vgl. Kap. 5.5.4) vorgegeben werden, diese ergibt sich aus den vorliegenden Daten. Die Merkmalsselektion beeinflusst die Projektion jedoch dahingehend, dass z.B. nur Merkmale mit hoher Rangkorrelation (Spearman) ausgewählt werden, die ein monoton steigendes bzw. fallendes Verhalten mit der Lebensdauer aufweisen, was der Annahme entspricht, dass sich der Zustand nur sukzessive verschlechtern kann.

Tabelle 5-6. Konfiguration der multivariaten Auswertung von Versuch I – III.

Nr.	Stichprobe Zyklen	Zeitl. Abstand Stichproben	Gruppierung Klassenbreite	n gesamt
I	40	1 h	1 Tag (4,8 %)	20.400
II	40	3 h	3 Tage (3,7 %)	18.800
III	40	24 min	0,8 Tage (3,8 %)	50.320

5.7.3 Lebensdauerersuch I

Abbildung 5-20 stellt die Amplitudenverläufe normiert auf die Schwingungsamplitude der Luft- und Körperschallsignale des KGT bei Inbetriebnahme während des ersten Versuchs dar. Deutlich zu erkennen ist eine im Inneren des Prüfstands stark reduzierte Lautstärke ab Tag 4 wegen des Öffnens der Umhausung zur besseren Kühlung, insbesondere des thermisch belasteten Pneumatikzylinders (siehe auch Abbildung 5-22). Grundsätzlich weisen die Signale untereinander einen ähnlichen Trendverlauf auf und steigen ab Tag 11 stetig an bis zu einem Maximum an Tag 15. Nach einem Rücklaufen ist an Tag 20 ein deutlicher abrupter Einbruch der Schwingungsamplituden zu erkennen. Durch den zeitweise deutlichen Anstieg der Vibrationsamplituden erreichen die Schwingungssensoren an Kolbenstange und Kugellager ihr Messbereichsmaximum (5 g), weswegen sie in den nachfolgenden Versuchen gegen die 50 g Variante ausgetauscht wurden.

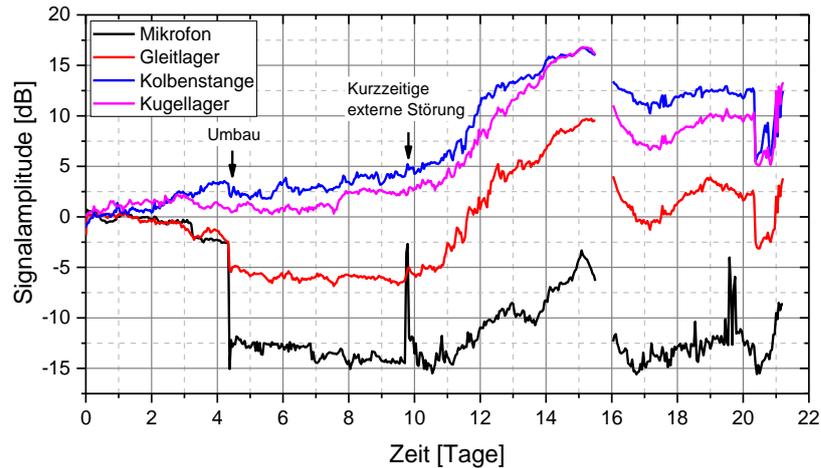


Abbildung 5-20. Amplitudenverläufe Luft-/Körperschall Versuch 1. Im Bereich Tag 15-16 liegen teilweise wegen fehlerhafter Synchronisation keine Daten vor.

Die Schwingungsspektren bei verschiedenen Laufleistungen, jeweils gemittelt über 40 Zyklen, sind in Abbildung 5-21 dargestellt. Darin lassen sich Frequenzbereiche identifizieren, deren jeweilige zeitliche Änderungen mit der Laufleistung korrelieren, etwa im Bereich 600, 900 und 1.760 Hz. Stark dominierende Anteile, etwa 410 Hz und deren Harmonische weisen hingegen kein monoton steigendes Verhalten auf, erreichen das Maximum an Tag 13 und entwickeln sich anschließend rückläufig bis zum Ausfall.

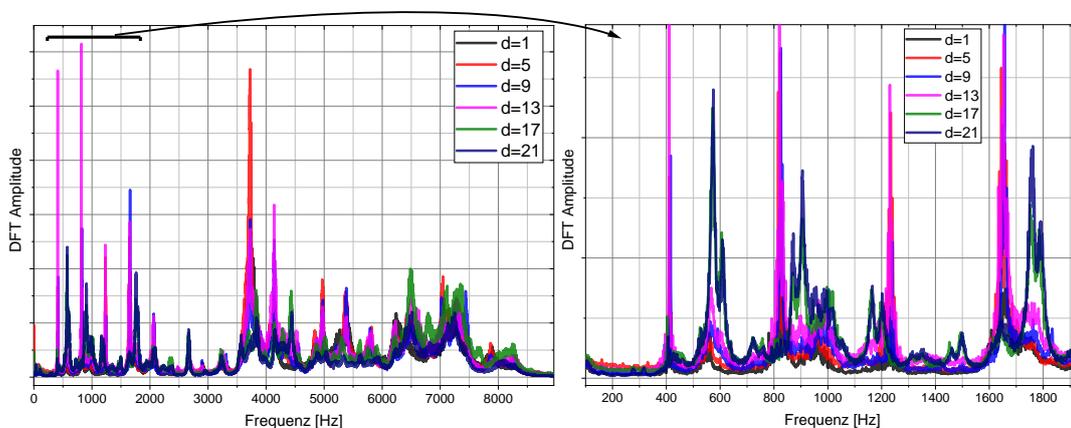


Abbildung 5-21. Verlauf Amplitudenspektrum Kolbenstange Versuch I.

Die Temperaturen (Abbildung 5-22), gemessen an den Gehäusen von Motor, KGT und Pneumatikzylinder sowie in der Umhausung und Leistungsendstufe des Motorcontrollers, reduzieren sich deutlich nach dem Umbau an Tag 4 und sind nachfolgend mit Ausnahme des KGT unauffällig. Die Gehäusetemperatur des KGT weist eine hohe Korrelation zum Drehmoment (Abbildung 5-18) auf, liegt jedoch auf deutlich niedrigerem Niveau als die des Pneumatikzylinders, der aufgrund der Zug-/Druckumschaltung dauerhaft mechanisch und thermisch belastet wird ($T > 90\text{ °C}$).

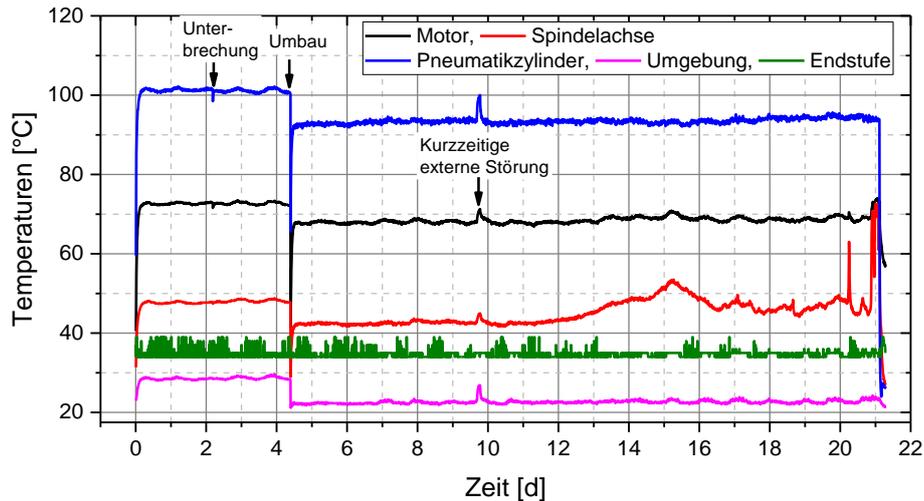


Abbildung 5-22. Temperaturverläufe Versuch I im klimatisierten Labor.

5.7.3.1 Multivariate Auswertung

Betrachtet wird eine stündliche Stichprobe von 40 aufeinanderfolgenden Zyklen, die zu 1-Tages Bereichen klassifiziert werden, was einer Lebensdauerauflösung von ca. 4,8 % bei 20.400 Datenpunkten entspricht. Zum Training wurde nur jeder zweite Tag verwendet, um eine sinnvolle zeitliche Abgrenzung der Klassen zu ermöglichen.

Abbildung 5-23 zeigt die LDA-Projektion von Trainingsdaten (gerade Tage) und Testdaten (Tag 3, 15, 21). In dieser lässt sich das Ansteigen der Amplitudensignale in Form eines „Knicks“ mit einem Umkehrpunkt an Tag 15 (analog zu Abbildung 5-20) erkennen, welcher primär in Richtung DF 2 ausgebildet wird. Änderungen, die über die Lebensdauer akkumulieren und somit relevant für die Verschleißüberwachung sind, spiegeln sich hingegen in DF 1 wider.

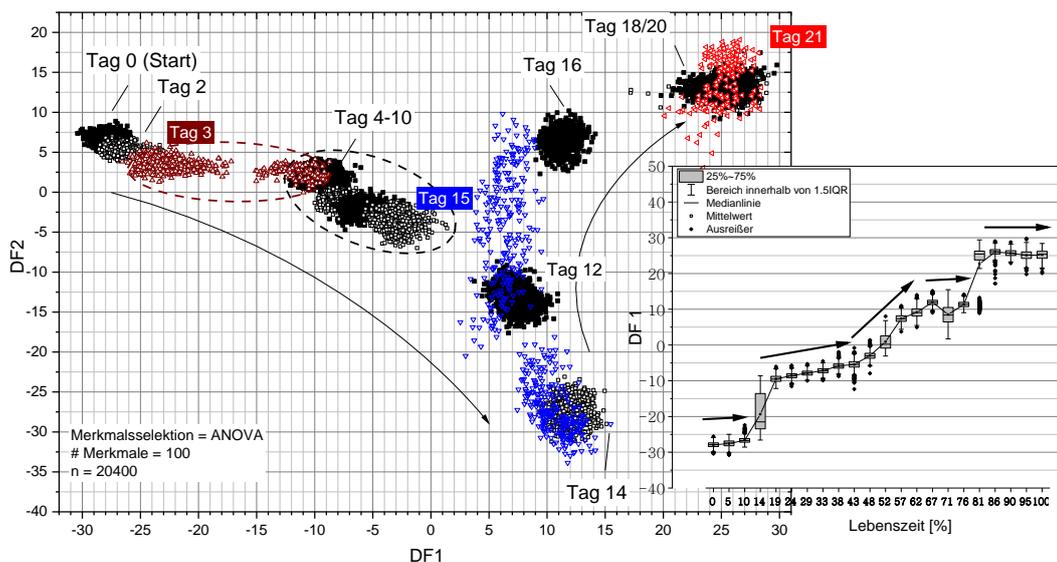


Abbildung 5-23. LDA-Projektion der Trainings- und Testdaten von Versuch I (links), DF 1 über die Lebenszeit (rechts).

Beim Verlauf von DF 1 lassen sich Phasen unterschiedlicher Steigung, der Stagnation sowie sprunghafte Anstiege erkennen, die auf einen stark ungleichmäßigen Degradationsprozess hindeuten.

Bei den ausgewählten Merkmalen (Abbildung 5-24) ist in (a) eine starke Dominanz der Schwingungssignale zu erkennen (über 75 % Anteil an der Gesamtkorrelation), mit den Frequenzbereichen (b) primär < 400 Hz und im Bereich 1 bis 10 kHz bei Verwendung von Median und Varianzmerkmalen (c).

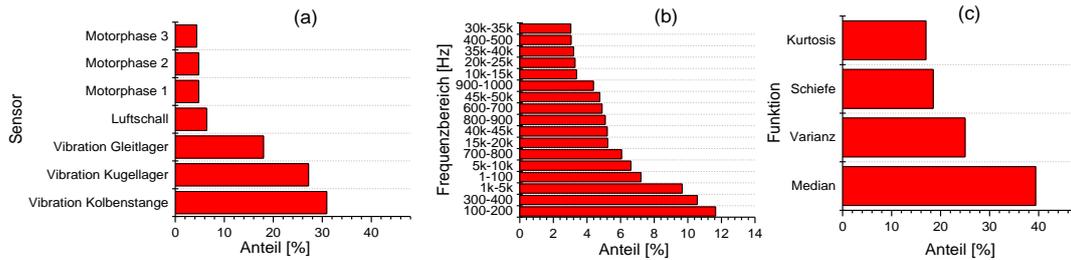


Abbildung 5-24. Verteilung der 100 signifikantesten Merkmale (Versuch I) bezogen auf deren Anteil der relativen Spearman Korrelation.

Zur Beurteilung des Informationsgehalts der einzelnen Sensorgruppen wurden diese aufgeteilt in Luft- und Körperschall (Zeit- und Frequenzmerkmale), Motorstrom (Frequenzbereich) und Prozesssensoren (Zeitbereich) und eine Kreuzvalidierung (Abbildung 5-25a) sowie eine Auswertung des F-Werts von DF 1 als quantitativer Indikator der Klassentrennung (b) auf Basis der unterschiedlichen Merkmalssets durchgeführt.

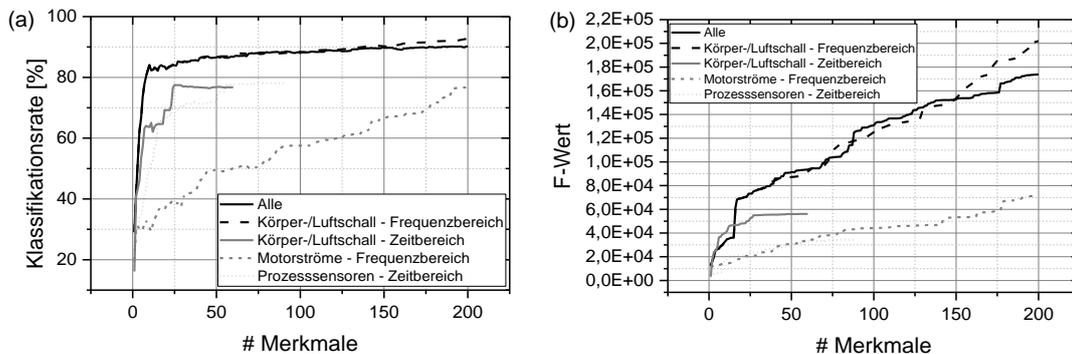


Abbildung 5-25. (a) 10-fold Kreuzvalidierung, (b) korrespondierender F-Wert von DF 1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 1-Tages Abschnitte mit insgesamt 21 Klassen ($n=20.400$), entspricht ca. 4,8 % Lebenszeit.

Hierbei bestätigt sich, dass die spektralen Schwingungsmuster mit Abstand die höchste statistische Signifikanz aufweisen (ca. 90 % erreichbare Kreuzvalidierungsrate (a) und (b) höchste Klassentrennung), gefolgt von Schwingungs- und Prozesssignalen im Zeitbereich. Die Frequenzanalyse des Motorstroms erreicht hingegen keine zufriedenstellende Klassifikation (< 60 % CV-Rate bei 100 Merkmalen).

5.7.4 Lebensdauerversuch II

Bei den Körperschallsignalen von Versuch II (Abbildung 5-26) sind deutlich die bereits erwähnten Unterbrechungen der Messung (Tag 10, 30) zu erkennen. Daneben tritt an Tag 25 ein kurzzeitiger Einbruch der Schwingungsamplituden auf, der keine Korrelation zu den übrigen Messgrößen aufweist. Von Tag 30 bis 60 ist ein kontinuierliches Ansteigen zu erkennen (Gleit-/Kugellager). Nach Beginn der Schmutzeintrags (Tag 60) fallen die Amplituden und bleiben auf niedrigem Niveau (Gleitlager, Luftschall), bzw. steigen nachfolgend wieder an (Kolbenstange, Kugellager). Nach jeder Zudosierung ist ein kurzzeitiges Einbrechen und Zurücklaufen der Amplituden zu erkennen. Eine mögliche Erklärung ist, dass der Teststaub eine dämpfende Wirkung auf die Schwingungsanregung im KGT hat und nach einer gewissen Zeit durch die Kugelkinematik wieder herausgetragen wird. Der Staub akkumuliert an der Innenseite des KGT-Gehäuses und reduziert dadurch die mechanische Kopplung zwischen KGT und Gehäuse. Als Folge dieser „Schalldämmung“ reduziert sich der vom Mikrofon gemessene Schalldruck signifikant und liegt bis zum Ausfall (Tag 63 bis 77) sogar unter dem Anfangsniveau. In diesem Fall bleibt das Laufgeräusch trotz der erheblichen Schädigung durch den Teststaub subjektiv unauffällig. Der Ausfall kündigt sich bei allen Sensoren mit einem starken Anstieg der Amplituden mit etwa einem Tag Vorlaufzeit an.

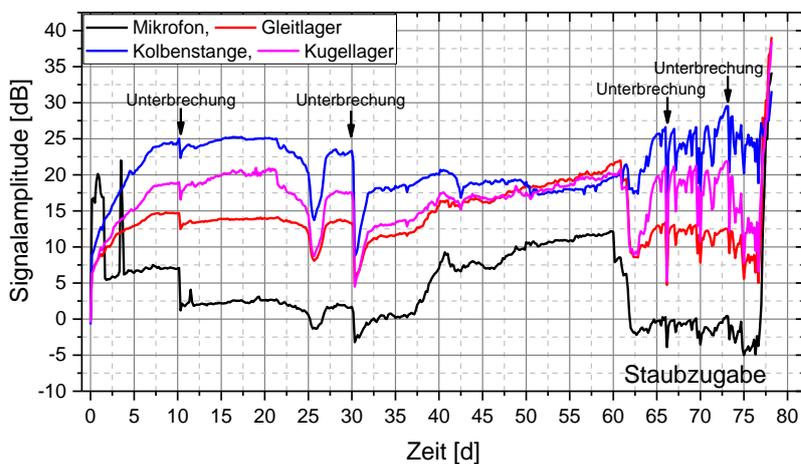


Abbildung 5-26. Amplitudenverlauf Luft-/Körperschall Versuch II.

Im Amplitudenspektrum, Abbildung 5-27, zeichnet sich ein deutlicher Anstieg im breitbandigen Frequenzbereich von 2,5 bis 6 kHz bis Tag 59 ab, der nach der Staubzugabe wieder vollständig, noch unter den Anfangswert ($d = 2$) zurückläuft. Im Gegensatz zum ersten Versuch ist das Entstehen stark ausgeprägter Schwingungsfrequenzen vor dem Ausfall nicht erkennbar; dies erschwert die Identifikation von Merkmalen, die mit der Laufleistung korrelieren.

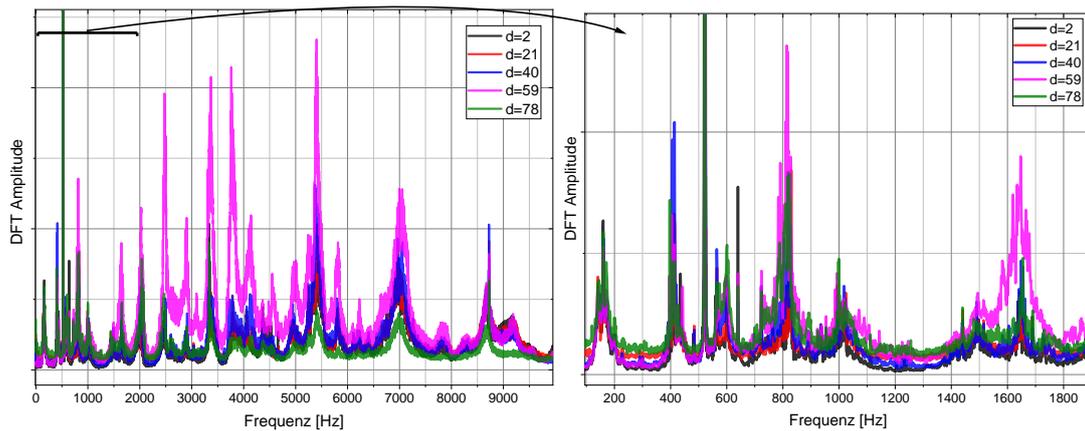


Abbildung 5-27. Verlauf Amplitudenspektrum Kolbenstange Versuch II.

In (II) ist aufgrund der einseitigen axialen Belastung eine Verschiebung der Wärmeentwicklung im Vergleich zu (I) sichtbar (Abbildung 5-28). Durch den teilweise generatorischen Betrieb beim Vorhub erhöhen sich die Temperaturen von Motor und Endstufe, während der Pneumatikzylinder thermisch weniger belastet ist ($\Delta T \approx 30$ K). Daraus resultieren einige Unterbrechungen (Tag 10, 21, 30, 34), bei denen die Kühlung variiert, bzw. ein externer Bremswiderstand zur Entlastung des Motorcontrollers installiert wurde; ab Tag 35 wurden keine Änderungen der Konfiguration mehr vorgenommen, sodass sich im Wesentlichen die Temperaturschwankungen der Versuchsumgebung erkennen lassen. Kurz vor dem Ausfall treten drei kurzzeitige Temperaturpeaks am KGT-Gehäuse mit $\Delta T = 40$ K bzw. 25 K auf.

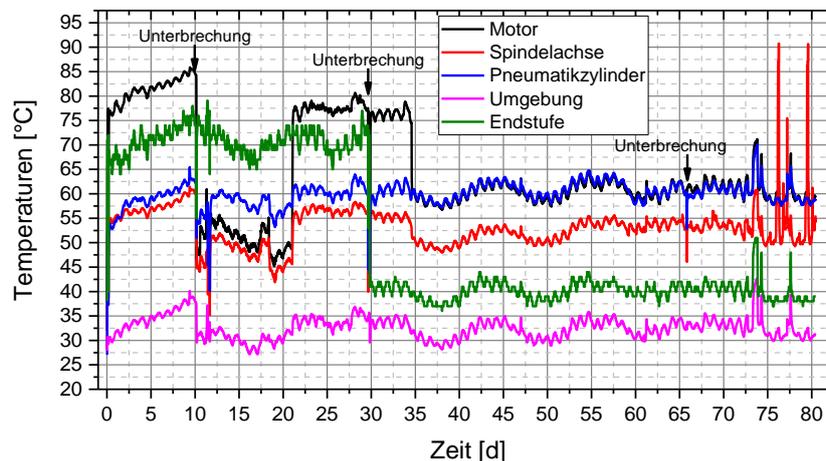


Abbildung 5-28. Temperaturverläufe Versuch II bei nichtklimatisierter Umgebung.

5.7.4.1 Multivariate Auswertung

Abbildung 5-29 zeigt die LDA-Projektion der Trainings- und Testdaten des zweiten Versuchs. Hierbei erfolgt das Zusammenfassen von 40 Zyklen in 3 h-Intervallen zu Klassen über einen Zeitraum von 3 Tagen, wobei wiederum zum Training nur

chronologisch jede zweite Klasse verwendet wird. Es zeigt sich zu Beginn eine Einlaufphase (bis Tag 11) entlang DF 2. Der wesentliche Teil der Lebensdauer (über 70 %) wird im Bereich DF 1 \approx 0 projiziert und weist keine signifikanten Änderungen auf. Erst kurz vor dem Ausfall (95 % Lebensdauer) erfolgt eine Abbildung in den stark negativen DF 1 Bereich. Die Projektion der Testdaten erfolgt an die zu erwarteten Zwischenpositionen der Trainingsdaten, wobei sich innerhalb der Klassen in der Anfangs- und Endphase aufgrund der stichprobenartigen Datenstruktur Subcluster abzeichnen.

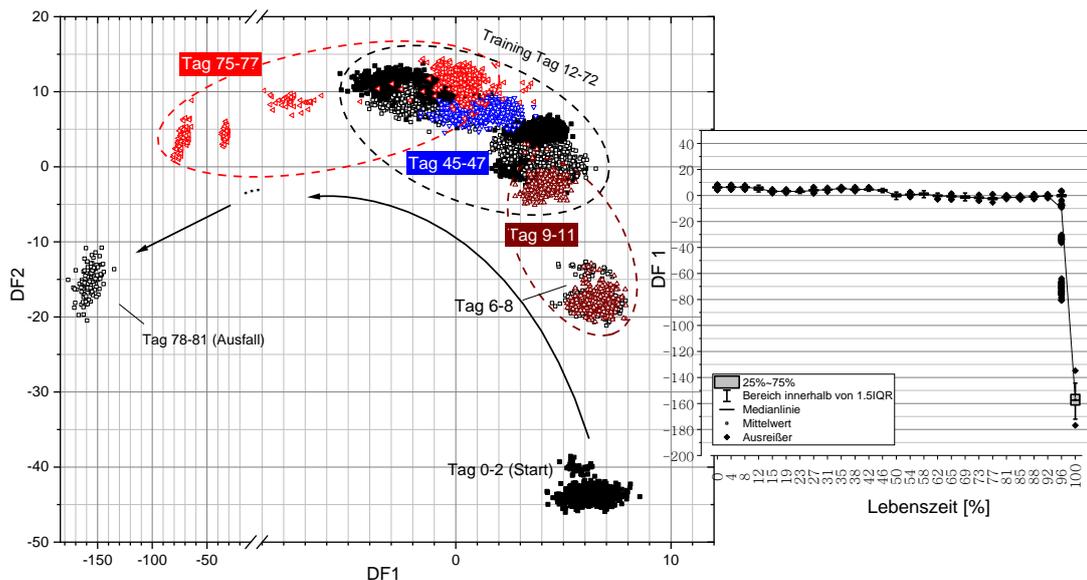


Abbildung 5-29. LDA-Projektion der Trainings- (schwarz-weiß) und Testdaten (farbig) von Versuch II (links) sowie Verlauf DF 1 über die Lebenszeit (rechts).

Die Reihenfolge der Relevanz der Sensoren (Abbildung 5-30a) ist ähnlich zum ersten Versuch, wenngleich die Motorströme eine höhere Gewichtung aufweisen. Die relevanten Frequenzanteile (b) sind die primären mechanischen Frequenzen $<$ 1 kHz sowie der hochfrequente Bereich zwischen 10 und 20 kHz bei etwa gleicher Gewichtung der statistischen Momente (c).

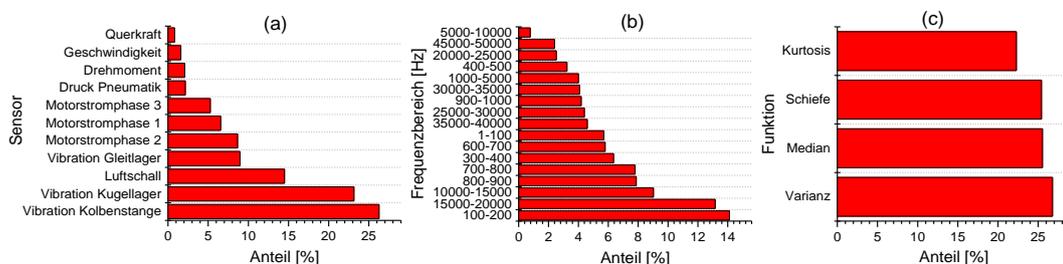


Abbildung 5-30. Verteilung der 100 signifikantesten Merkmale aus dem Zeit- und Frequenzbereich (Versuch II) bezogen auf deren Anteil der relativen Spearman Korrelation.

Bei der sensorselektiven Analyse (Abbildung 5-31) zeigen sich deutlich unterschiedliche Ergebnisse gegenüber vorangegangem Versuch. In diesem Fall

liegen die spektralen Motorstrom- und Vibrationsmerkmale fast gleichauf (a), gefolgt von den Prozess- und Schwingungssensoren im Zeitbereich. Bei Betrachtung des F-Werts erlauben die spektralen Vibrationsmerkmale jedoch gegenüber den Motorstrommerkmalen eine um Faktor 3 bessere Klassentrennung.

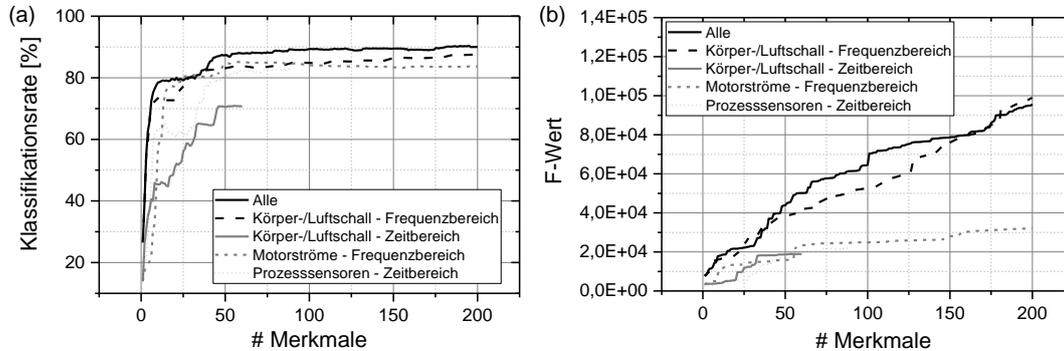


Abbildung 5-31. (a) 10-fold Kreuzvalidierung, (b) korrespondierender F-Wert von DF1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 3-Tages Abschnitte mit insgesamt 27 Klassen ($n=18.880$), entspricht einer Auflösung von ca. 3,7 % Lebensdauer.

5.7.5 Lebensdauerexperiment III

Im dritten Versuch steigen die Körperschallamplituden bereits kurz nach Versuchsstart deutlich auf bis zu 17 dB vom Ausgangswert an (Abbildung 5-32), wohingegen die Geräuschemission auf weitgehend konstantem Level bleibt. Auffällig sind viele kurzzeitige Einbrüche und starke Schwankungen der Vibrationsamplituden von Kolbenstange und Kugellager, besonders deutlich sichtbar etwa der abrupte Rückgang (-12 dB) an Tag 10.

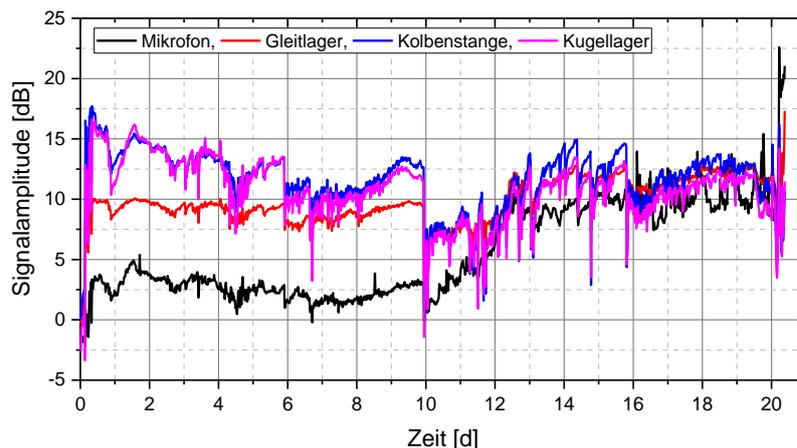


Abbildung 5-32. Amplitudenverlauf Luft-/Körperschall Versuch III.

Bei Betrachtung der Amplitudenspektren (Abbildung 5-33) ist über die Laufzeit ein Abnehmen der niederfrequenten Anteile (< 300 Hz) und ein breitbandiger Anstieg hochfrequenter Schwingungen (> 5 kHz) zu erkennen. Im Spektrum lassen sich

wiederum einige mit der Laufleistung korrelierte Frequenzbereiche (z.B. bei ca. 800 Hz sowie 6, 7 und 12 kHz) identifizieren.

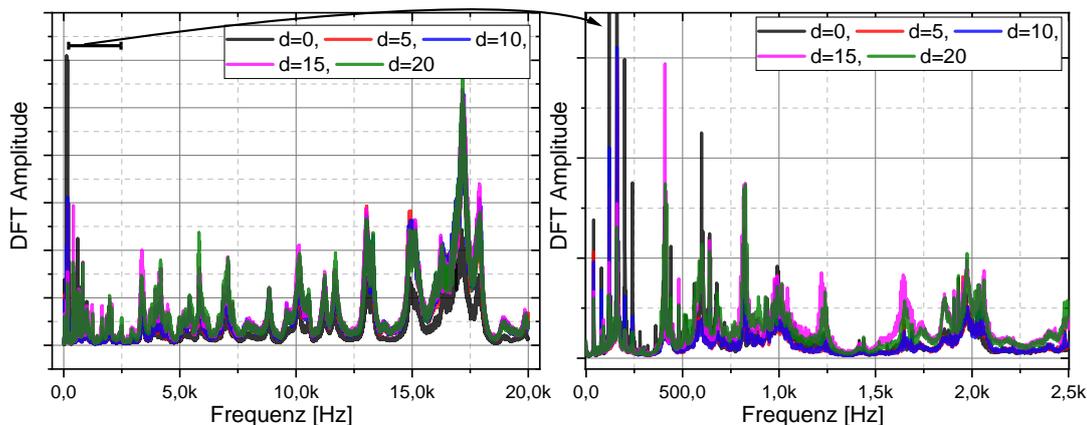


Abbildung 5-33. Verlauf Amplitudenspektrum Kolbenstange Versuch III.

Die Temperaturen des KGT-Gehäuses (Abbildung 5-34) weisen abgesehen von zwei Peaks zu Beginn (ca. 5 K, Tag 0) einen weitgehend unauffälligen Verlauf bis Tag 20 auf, an dem sich drei kurzzeitige Temperaturanstiege (um ca. 10 / 25 / 5 K) abzeichnen, wobei der letzte mit dem Ausfall einhergeht.

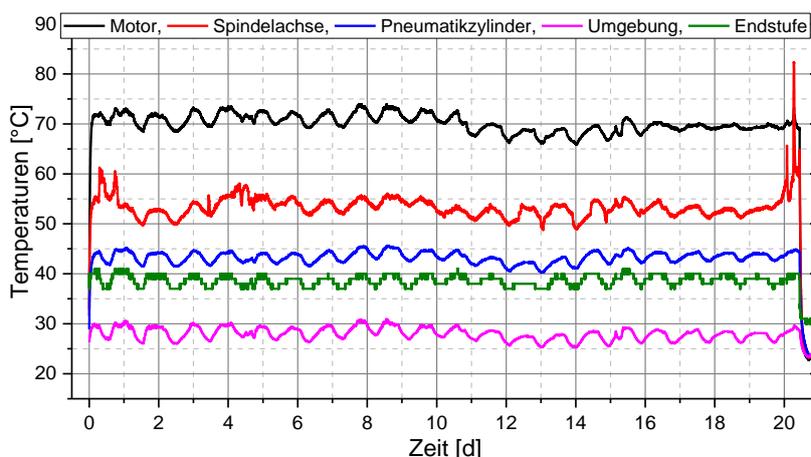


Abbildung 5-34. Temperaturverläufe Versuch III.

5.7.5.1 Multivariate Auswertung

Die LDA-Projektion von Versuch III ist in Abbildung 5-35 dargestellt. Die Daten sind hierbei in Abschnitte zu 0,8 Tagen unterteilt, wobei ca. alle 24 min. eine Stichprobe von 40 Zyklen ausgewertet wird. Eine deutliche Progression in negativer DF 1 Richtung, welche eine Zustandsänderung repräsentiert, zeichnet sich erst ab Tag 10 ab, was mit dem Trendverlauf der Schwingungsamplituden (Abbildung 5-32) übereinstimmt. Die Klasse, die das Verhalten kurz vor dem Ausfall abbildet, setzt sich deutlich von den übrigen ab ($DF\ 1 < -30$, $DF\ 2 < -25$).

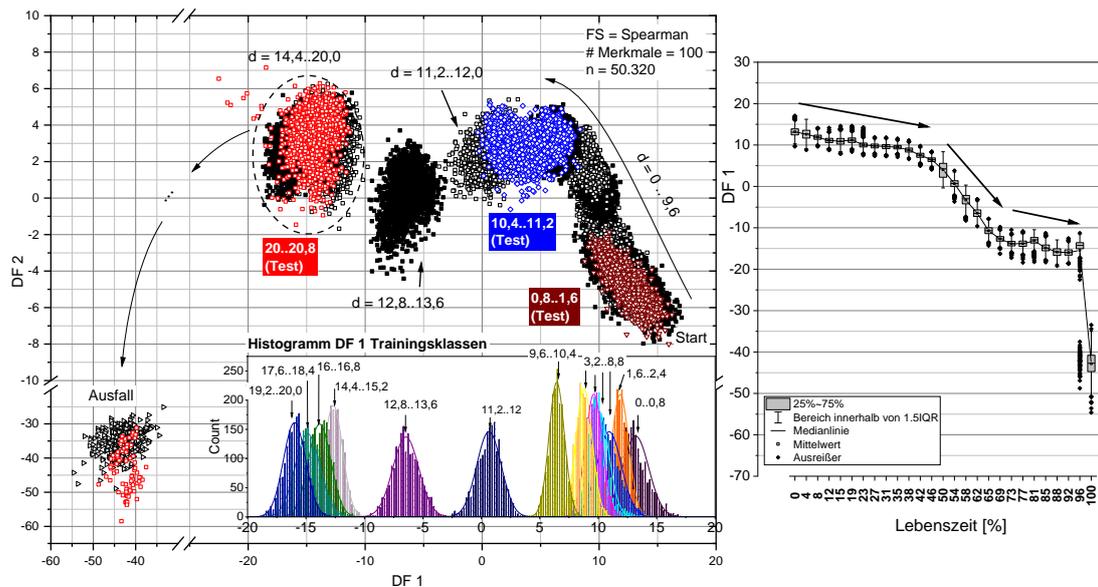


Abbildung 5-35. LDA-Projektion der Trainings- (schwarz-weiß) und Testdaten (farbig) von Versuch III (links). Zum Training wurde chronologisch nur jede zweite Klasse verwendet. Rechts: DF 1 über die Lebenszeit.

Die Merkmalsselektion zeigt bei Versuch 3 eine hohe Gewichtung der Motorströme (Abbildung 5-36a). Dies relativiert sich jedoch bei genauerer Betrachtung: Die höchstkorrelierten 20 Merkmale ($|\rho|=0,95..0,82$) stammen etwa alle von Körper- und Luftschallsensoren, während die Motorstrom-Merkmale nur Korrelationen $< 0,8$ aufweisen, aber in großer Zahl nachfolgend ausgewählt werden, weswegen ihr relativer Korrelations-Anteil nicht als absolutes Maß der Eignung betrachtet werden sollte. Auffällig ist in (b) eine starke Betonung der hochfrequenten Anteile, die sich bereits in Abbildung 5-33 andeutet.

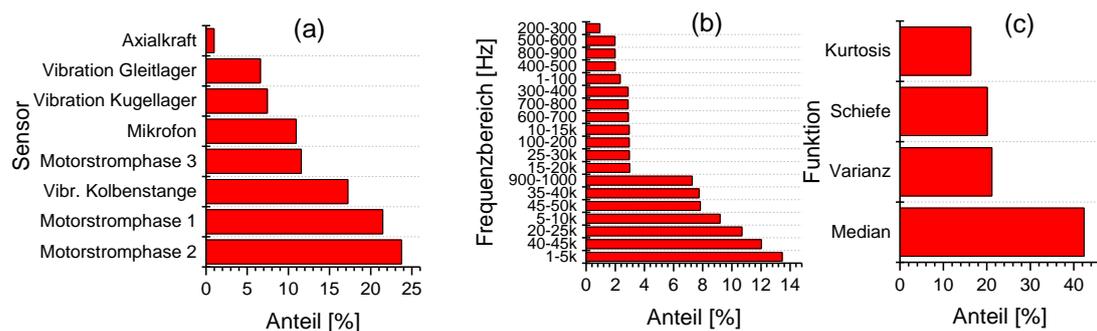


Abbildung 5-36. Verteilung der 100 signifikantesten Merkmale aus dem Zeit- und Frequenzbereich (Versuch III) bezogen auf deren Anteil der relativen Spearman Korrelation.

Die Kreuzvalidierung der Lebensdauerphasen-Identifikation von Versuch III ist in Abbildung 5-37 dargestellt. In (a) wird wiederum deutlich, dass gerade bei geringer Merkmalsanzahl mit Körper- und Luftschallsensorik die besten Ergebnisse erzielt werden, während sich die Ergebnisse bei hohen Merkmalsanzahlen egalisieren. Bemerkenswert ist zudem, dass die Ergebnisse rein auf Basis von spektral ausgewerteter Schwingungssensorik um bis zu 10 % besser ausfallen als bei

Verwendung aller verfügbaren Sensoren; dies zeigt wiederum, dass die korrelationsbasierte Merkmalsselektion nicht notwendigerweise das optimale Merkmalsset für die LDA bereitstellt.

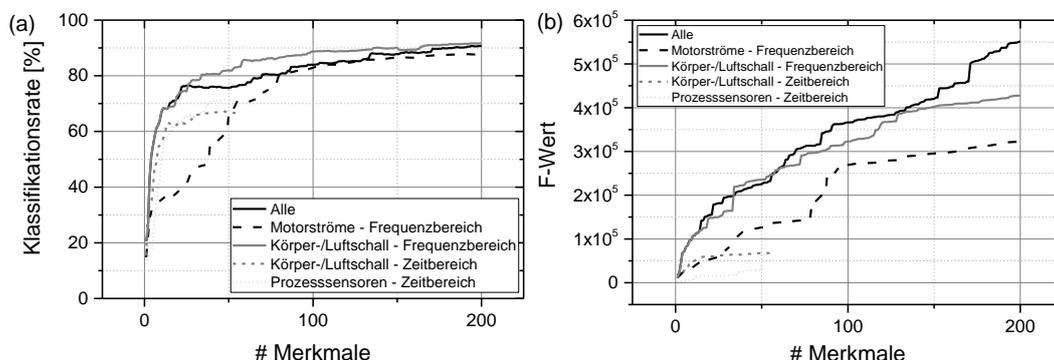


Abbildung 5-37. (a) 10-fold CV, (b) korrespondierender F-Wert von DF1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 0,8-Tages Abschnitte mit insgesamt 26 Klassen ($n=50.320$), entspricht einer Auflösung von ca. 3,8 % Lebensdauer.

5.7.6 Übertragbarkeit der Prognose

In Abbildung 5-38 erfolgt die direkte Projektion der Sensordaten von Versuch III auf Basis des in Versuch II erzeugten Modells. Hierbei werden zur Vergleichbarkeit nur die Schwingungsmerkmale aus der Lastphase bei konstanter Drehzahl (Int. 5) verwendet. Es lässt sich erkennen, dass zwar die Trendinformation qualitativ übertragen werden kann, sich der Verlauf jedoch deutlich unterscheidet. Umgekehrt, von (III) auf (II), ist eine sinnvolle Übertragung nicht möglich. Vermutet wird hierbei, dass die starke Variation der Einflussparameter in (II), v.a. Temperaturen, zu Instabilitäten der in (III) selektierten Merkmale führt.

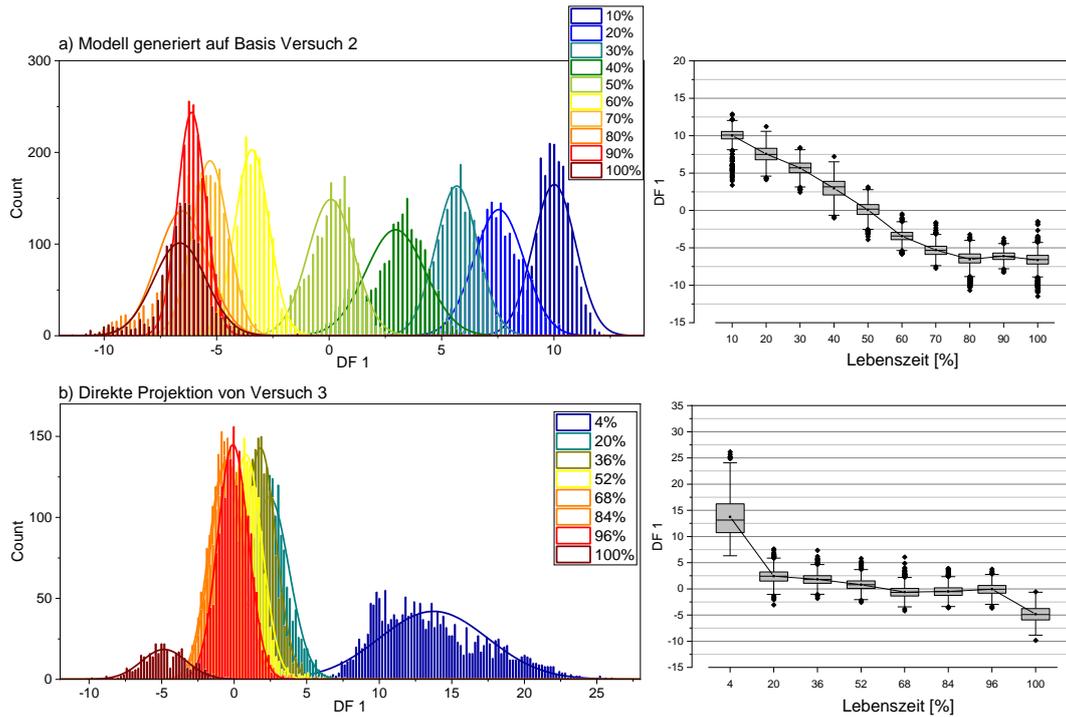


Abbildung 5-38. Direkte LDA-Projektion der Daten von (III) mit dem Modell erzeugt aus (II), Klasseneinteilung nach relativer Lebenszeit, 50 Merkmale.

Zur Generierung eines gemeinsamen Modells werden nachfolgend die beiden Datensätze II und III jeweils in 27 Laufzeit-Klassen unterteilt, welche aufsteigend die relative Lebensdauerphase beschreiben (0 entspricht Neuzustand, 26 beinhaltet den Ausfall), und deren Daten kombiniert. Bei der Merkmalsselektion des kombinierten Datensatzes werden somit primär diejenigen Merkmale ausgewählt, die möglichst unabhängig von den individuellen Charakteristika die relative Lebensdauer indizieren. Abbildung 5-39 stellt die LDA-Projektion auf Basis des kombinierten Datensatzes beider Achsen dar. Zum Training wurden hierbei jeweils die Abschnitte 0, 6, 12, 18, 24, 26 und zum Evaluieren der Projektion die Abschnitte 3, 9, 15, 21 und 25 verwendet. Es ist zu erkennen, dass ein gemeinsames Modell gefunden werden kann, das in beiden Fällen quantitativ die Lebensdauer abschätzen und interpolieren kann. Beide weisen einen fast identischen Verlauf auf, bei dem der Neuzustand in den Bereich $DF\ 1 \approx 10$ und der Ausfall in den Bereich $DF\ 1 \approx -40$ abgebildet wird.

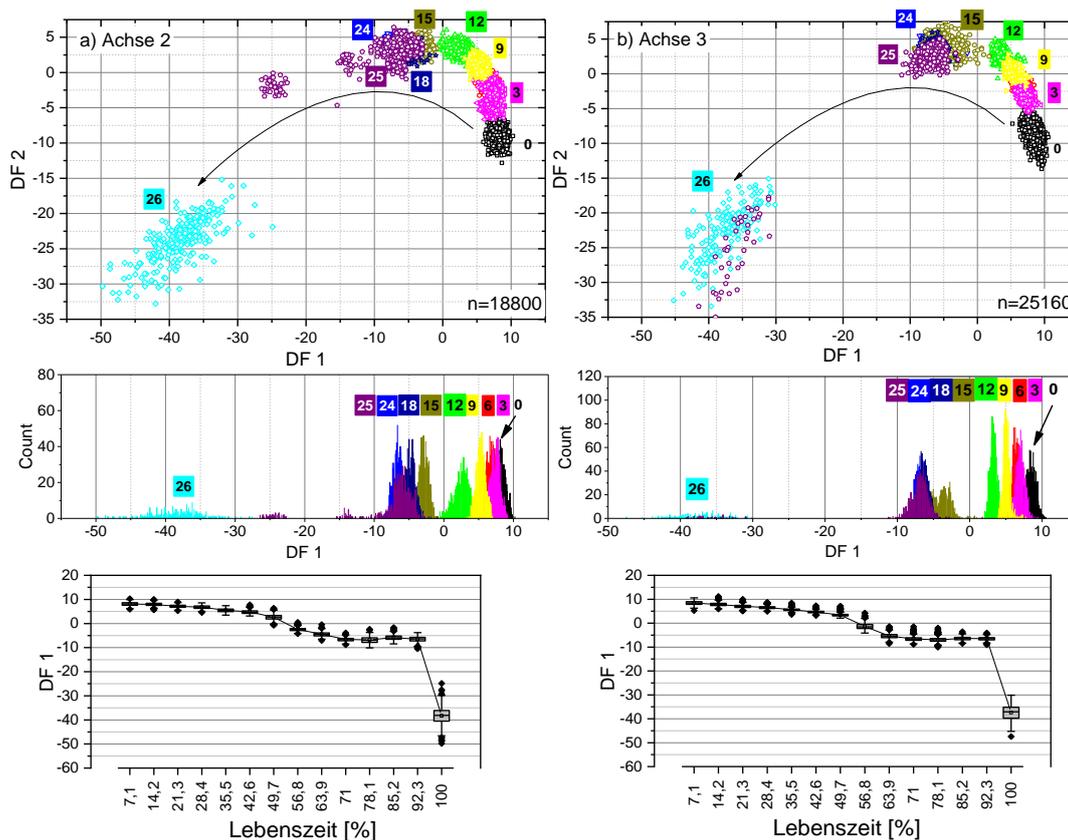


Abbildung 5-39. Kombiniertes statistisches Modell von Versuch II (a) und III (b). Merkmalsselektion auf Basis aller Schwingungsdaten, Auswahl von 100 Merkmalen (Spearman).

Bei Betrachtung der höchstkorrelierten Merkmale (Tabelle 5-7) wird ersichtlich, dass der an der Kolbenstange montierte Schwingungsaufnehmer, der mechanisch an die Spindelmutter gekoppelt ist, übergreifend als wichtigster Sensor zu bewerten ist.

Tabelle 5-7. Selektierte Schwingungs-Merkmale der kombinierten Daten aufgeschlüsselt nach Sensoren (Kolbenstange KS, Kugellager KL und Mikrofon Mi), Frequenzbereich und Funktion (Median Me, Varianz Var, Schiefe Sch, Kurtosis Kur und Steigung St).

Merkmals	1	2	3	4	5	6	7	8	9	10
ρ	0,75	0,74	0,73	0,73	0,72	0,71	0,71	0,71	0,71	0,70
Sensor	KS	KS	KS	KS	KL	KS	KS	KS	Mi	KL
Bereich [Hz]	700-800	1k-5k	500-600	700-800	800-900	800-900	10k-15k	10k-15k	700-800	800-900
Funktion	Me	Me	Me	Var	Me	Me	Kur	Sch	Me	Var

5.7.7 Auswertung ohne zusätzliche Sensorik

Exemplarisch auf Basis von Versuch III wird nachfolgend eine „sensorlose“ Auswertung, d.h. nur auf Basis der vom Motorcontroller zur Verfügung gestellten Messgrößen Wirkstrom und Geschwindigkeit durchgeführt. Die Merkmalsextraktion des Geschwindigkeitssignals erfolgt gemäß Abbildung 5-17 in sechs Intervallen, die

Auswertung des Wirkstroms (Abbildung 5-40) in 16 Intervallen mit der Berechnung von insgesamt 116 statistischen und formbeschreibenden Merkmalen.

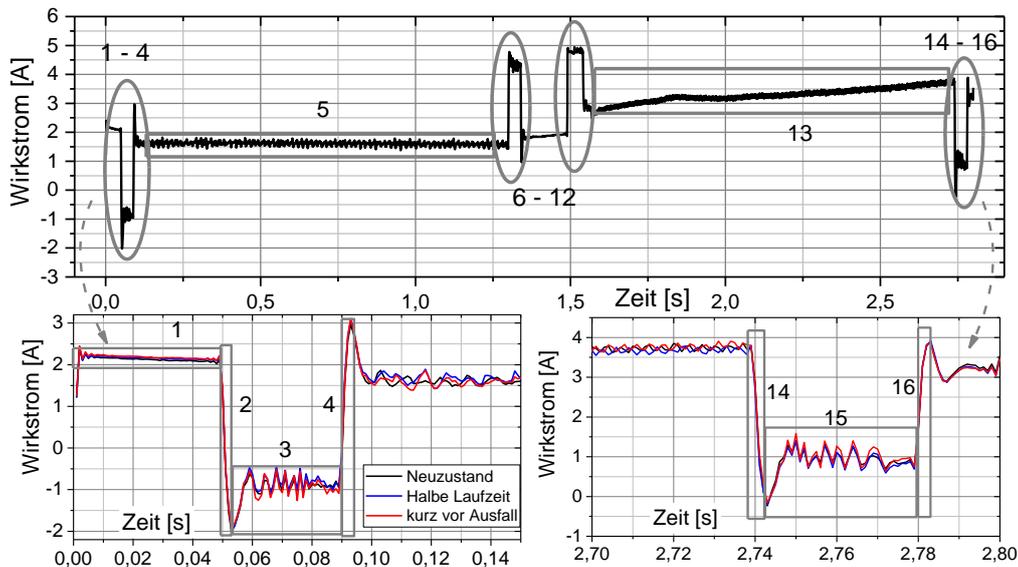


Abbildung 5-40. Wirkstromverlauf während des Arbeitszyklus mit Intervallunterteilung.

Tabelle 5-8 listet die zehn mit der Lauflaufleistung höchstkorrelierten Merkmale auf.

Tabelle 5-8. Selektierte Merkmale (Spearman) der Messgrößen Wirkstrom (I) und Geschwindigkeit (v) mit den Funktionen Median (Me), Varianz (Var), Schiefe (Sch) und Kurtosis (Ku).

Merkmal	1	2	3	4	5	6	7	8	9	10
$ \rho $	0,90	0,87	0,83	0,78	0,74	0,67	0,67	0,66	0,62	0,58
Messgr.	I	I	I	I	I	I	I	I	I	v
Int.	2	15	2	15	1	4	4	2	2	5
Funktion	Sch	Sch	Kur	Kur	Me	St	Var	Me	Var	Var

Der Fokus der Auswahl liegt hierbei klar auf dem Stromsignal bei den Beschleunigungsphasen (mit $0,62 < |\rho| < 0,9$), bei denen generatorischer Betrieb des Motors aufgrund der extern vorgegebenen Kraft durch den Pneumatikzylinder vorliegt. Insbesondere das Überschwingen des Stromreglers an diesen Stellen beinhaltet relevante Information, die mit der Laufleistung korreliert. Walther [167] identifizierte bei seinen Versuchen einen ähnlichen Effekt und schlug das Überschwingverhalten als Indikator für Spiel des KGT vor. Auch Hirschmann [165] beschrieb den Einfluss von Spiel der KGT-Mechanik auf den Drehmoment- bzw. Motorstromverlauf beim Richtungswechsel.

Demgegenüber weist das beste Geschwindigkeitsmerkmal nur eine vergleichsweise geringe Korrelation $|\rho| = 0,58$ auf, sodass der Mehrwert durch das Geschwindigkeitssignal vernachlässigbar ist. Abbildung 5-41 zeigt die LDA-Projektion von Trainings- und Testdaten über Lebensdauerersuch 3, welche die Eignung der genannten Merkmale zur Verschleißidentifikation demonstriert.

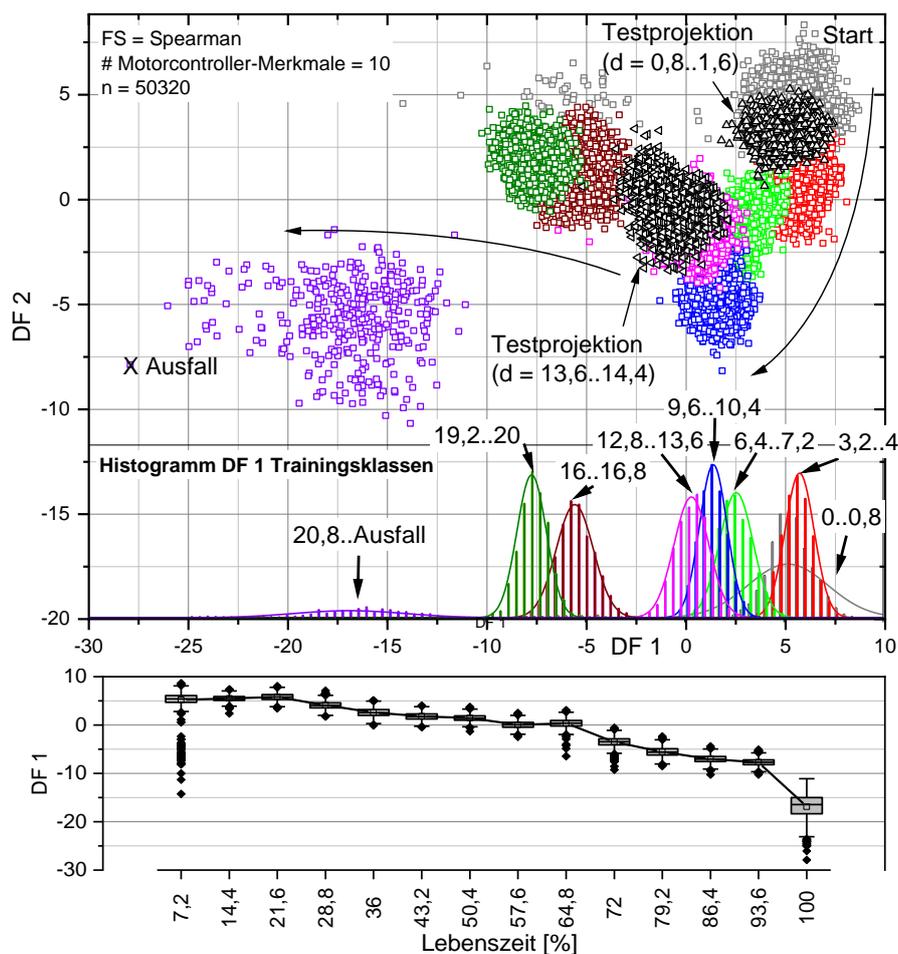


Abbildung 5-41. LDA-Projektion auf Basis der 10 höchstkorrelierten Motorcontroller-Merkmale (Tabelle 5-8), Datensatz Versuch III.

Zusammenfassend lässt sich feststellen, dass auch die vom Motorcontroller zur Verfügung gestellten Messgrößen eine Abschätzung der Restlebensdauer mit DF 1 als Indikator ermöglichen, wobei die Übertragbarkeit in weiteren Versuchen erprobt werden sollte. Die Auswertung wird momentan aufgrund technischer Beschränkungen der herausführbaren Signale (nur zwei Schnittstellen mit je 9 bit Auflösung) des Motorcontrollers begrenzt. Potential bieten die Einbindung weiterer Messgrößen (Position, Regler-interne Größen) sowie eine Erhöhung der Signalauflösung.

5.7.8 Auftretende Verschleißeffekte

Bei den Versuchen lassen sich unterschiedliche Verschleißeffekte identifizieren. Insbesondere bei den Wälzkörpern kann nach der Demontage des ausgefallenen KGT II signifikanter Verschleiß nachgewiesen werden. So weisen die KGT-Wälzkörper im Schnitt ($n = 10$) einen Masseverlust von ca. 24 % und eine Durchmesserreduktion von 3,5 auf 3,2 mm auf. Der Materialabtrag erfolgt insgesamt

weitgehend gleichmäßig, sodass die Kugelform erhalten bleibt. Hierbei ist bemerkenswert, dass trotz des erheblichen Verschleißes der KGT noch bis zum Ausfall funktionstüchtig blieb.

Abbildung 5-42 zeigt Mikroskopaufnahmen der verschlissenen Kugeln (II), die in (a) makroskopische Furchen, in (b) großflächige Abplatzungen oberflächennaher Bereiche und in (c) starke Pitting- und Kratzspuren aufweisen.

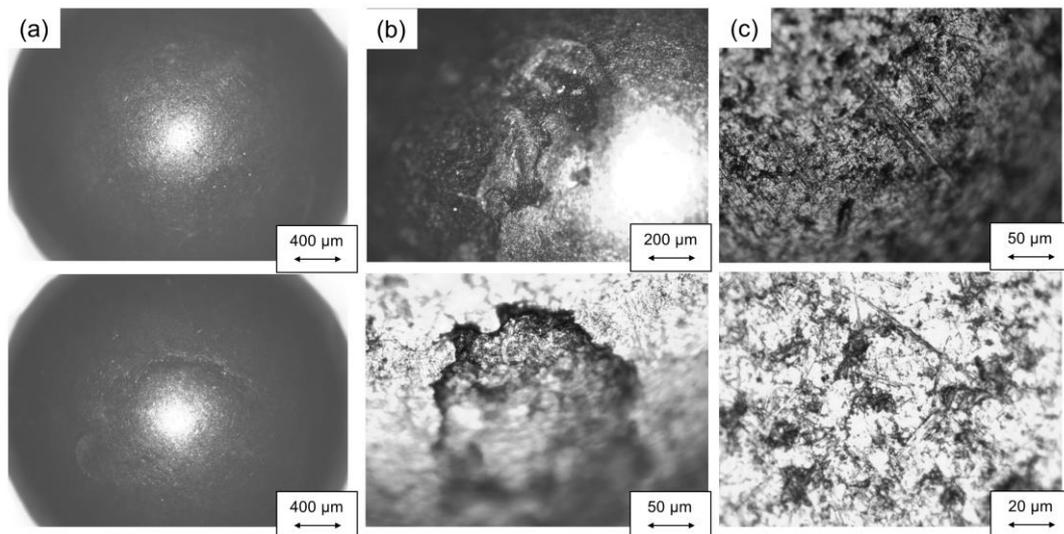


Abbildung 5-42. Verschleißspuren an den Kugeln des KGT nach dem Lebensdauertest II, (a) oben unauffällige Kugeloberfläche, unten makroskopische Furchenbildung (b) großflächige Ausbrüche, (c) Kratzspuren und Oberflächenrauigkeit.

Dies lässt vermuten, dass die auftretenden Mechanismen eine Kombination verschiedener Verschleißformen sind. Relativbewegung bei hoher Flächenpressung, etwa durch Makroschlupf oder Interaktion mit größeren Abrasivpartikeln, können die Furchenbildung (a) verursachen. Die matte Struktur der Oberfläche (a), sowie die Schädigungen in (b,c) weisen darauf hin, dass Oberflächenzerrüttung, begünstigt durch die vom massiven Schmutzeintrag resultierende Mangelschmierung und erhöhte Hertz'sche Pressung im Wälzkontakt [175], der dominante Verschleißmechanismus der Wälzkörper in (II) ist. Auch die Spindel (II) weist deutliche Zeichen von Oberflächenzerrüttung mit Grübchenbildung entlang der Laufflächen auf (Abbildung 5-43a). Zudem sind Anlassverfärbungen der Spindel zu erkennen, die teilweise auf lokal auftretende Temperaturen oberhalb von 280 °C (violette Verfärbung) hindeuten. Bei den Laufflächen der Mutter zeichnen sich an der belasteten Flanke Spurrillen ab (b).

Der durchschnittliche Materialverlust der Wälzkörper nach Versuch III beträgt hingegen nur 1,2 %, bzw. 13 µm Durchmesserreduktion, sodass hier der Wälzkörperverschleiß wahrscheinlich nicht für den Ausfall verantwortlich ist. Der KGT III (Abbildung 5-44) weist jedoch Spuren einer massiven Hitzeentwicklung (> 320 °C) im Hubbereich der Spindel auf. In der Folge ist die Kunststoff-

Verdrehsicherung an der Adapterhülse vollständig geschmolzen und somit nicht mehr funktionsfähig.

Bei den Schrägkugellagern konnten Versuchs-übergreifend keine sichtbaren Verschleißspuren festgestellt werden.

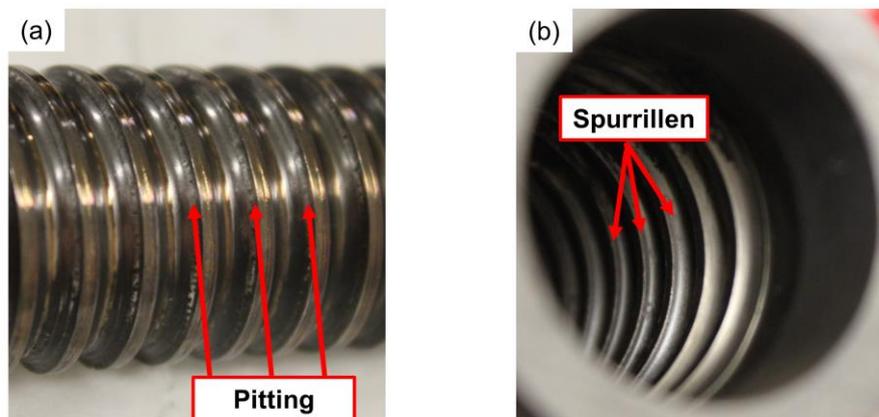


Abbildung 5-43. (a) Spindel und (b) Spindelmutter nach Versuch II.



Abbildung 5-44. Kugelgewindetrieb nach Versuch III.

5.7.9 Diskussion

5.7.9.1 Versuchsreihe

Bei der durchgeführten Versuchsreihe haben sich deutlich unterschiedliche Werte der Lebensdauer der Spindelachsen ergeben, was zum einen mit den wechselnden Versuchsbedingungen, zum anderen den individuellen Streuungen des Betriebsverhaltens zu erklären ist. Neben den Lastparametern Axialkraft und Beschleunigung wird als Einflussfaktor die mechanische Verbindung zwischen Motor und Spindel, insbesondere deren thermisches Übertragungsverhalten, vermutet, welches die Grundtemperatur von KGT und Wälzlagern und deren tribologische Eigenschaften beeinflusst. Aufgrund der geringen Zahl von Messungen, bedingt durch die lange Dauer der einzelnen Versuche, lassen sich nur schwer allgemeine Aussagen treffen.

Grundsätzlich ist ein ansteigendes Drehmoment (bei (I) frühzeitig, bei (II) langsam über gesamte Messung) ein Indikator für erhöhte Reibung und somit Verschleiß, da

bei gleich bleibendem Belastungskollektiv eine erhöhte mechanische Leistung aufgebracht werden muss, um die zusätzlichen Reibmomente bei gleichem Bewegungsprofil zu überwinden. Ähnlich wie in anderen Arbeiten [161] sind zwischenzeitlich Rücklaufbewegungen zu sehen, die einen streng monotonen Zusammenhang zwischen Verschleiß und Drehmoment erschweren. Der Ausfall kündigt sich bei allen Achsen mit einem starken Drehmomentanstieg (10 -17 %) mit einer Vorlaufzeit von 1 bis 2 Tagen an. Des Weiteren treten kurzzeitige Drehmomentpeaks (I) auf, die in ähnlicher Form schon zuvor beschrieben wurden [161], wobei von einem häufigeren Auftreten der Peaks v.a. bei hohen dynamischen Belastungen des KGT berichtet wird. Mögliche Ursache sind kurzzeitige Störungen der Kugelkinematik durch Verklemmen, welches sich bei erhöhtem Drehmoment aber selbstständig wieder löst.

Insbesondere bei (I) lässt sich eine deutliche Korrelation zwischen Drehmoment und Körperschall erkennen, was zum einen mit einer erhöhten mechanischen Anregung, zum anderen durch Schwingungsanteile, aufgrund von entstehenden Schädigungs- und Verschleißeffekten der Kontaktpartner im KGT, erklärt werden kann. Eine Untersuchung des Schwingungsamplitudenspektrums deutet eher auf eine breitbandige Anregung von Resonanzfrequenzen und weniger auf die in der Literatur beschriebenen charakteristischen Überrollfrequenzen des KGT (Kap. 5.4.5) hin.

Gleichzeitig lassen die Ergebnisse in (II) erkennen, dass eingebrachte Verschmutzung sich weder unmittelbar im Drehmoment- noch im Temperaturverlauf, wohl aber im Schwingungsverhalten erkennen lässt. Erst die Auswirkungen der verminderten Schmierwirkung mit resultierender tribologischer Degradation führen längerfristig, kurz vor dem Ausfall, zu den charakteristischen Anstiegen von Temperatur und Drehmoment.

5.7.9.2 Multivariate Auswertung

Die statistische Analyse aller drei Versuche ergab, dass die Lebensdauerphase einer individuellen Achse mit einer zeitlichen Auflösung von 3,7 - 4,8 % der Gesamtlebenszeit bei 90 % Klassifikationsrate auf Basis aller Sensorgrößen zugeordnet werden kann. Eine hohe statistische Signifikanz weisen hierbei übergreifend vor allem die spektralen Merkmale von Körper- und Luftschallsensoren auf, sodass deren alleinige Auswertung bereits zu einem vergleichbar guten Ergebnis führt. Die Schwingungsspektren der Achsen unterscheiden sich jedoch teilweise deutlich in auftretenden Frequenzen und vor allem in ihrer Amplitude. So ist beispielsweise bei (III) ein starker Anteil der mechanischen Grundfrequenz und deren Harmonischen zu erkennen, der bei den übrigen Versuchen nicht auftritt.

Demzufolge unterscheiden sich auch die durch Korrelation selektierten Frequenzbereiche zwischen den Versuchen stark. Während in (I) die Bereiche der mechanischen Primärfrequenzen (< 1 kHz) selektiert werden, erfolgt bei (III) die stärkste Gewichtung bei hochfrequenten Schwingungsanteilen (> 1 kHz).

Eine Aussage zur Übertragbarkeit der individuellen Modelle kann nur begrenzt getroffen werden, da sich die Lastparameter in allen drei Versuchen unterscheiden. Aufgrund einer notwendig gewordenen Änderung der Instrumentierung nach Versuch I ist letztlich nur ein Vergleich der Modelle aus Versuch II und III sinnvoll. Hierbei konnte gezeigt werden, dass die direkte Übertragung des statistischen Modells von Versuch II auf III eine qualitative Trendabschätzung erlaubt. Umgekehrt ist die Übertragung jedoch nicht sinnvoll möglich, was durch die vergleichsweise hohen Änderungen der Einflusstemperaturen (Umgebung, Motor) bei (II) erklärt werden kann. Die Erzeugung eines übergreifenden Prognosemodells konnte durch die Kombination der Daten zweier Versuche (II, III) erfolgreich demonstriert werden, obwohl der primäre Verschleißmechanismus an unterschiedlichen Komponenten (II: Wälzkörper, III: Spindel / Mutter) festgestellt wurde. Da eine übergeordnete Zustandsbewertung unabhängig von Komponentenspezifischen Symptomen angestrebt wird, ist dieses Ergebnis im Hinblick auf die Generalisierbarkeit vielversprechend.

Die vorgestellte Auswertung von (I)-(III) erfolgte in der Lastphase mit der Segmentierung von Beschleunigung, konstanter Geschwindigkeit und Verzögerungsphase im Zeitbereich und bei konstanter Geschwindigkeit im Frequenzbereich. Als möglicher Ansatzpunkt für eine Optimierung wird eine Merkmalsextraktion individuell für jede Messgröße betrachtet. So zeigt etwa die Analyse der Messgröße Wirkstrom über den gesamten Verfahrenszyklus, dass deren Flankensteigung während der Ruckphase bei Richtungsumkehr ein mit der Lebensdauer hochkorreliertes Merkmal und somit potentieller Indikator für Verschleiß ist. Des Weiteren ist die Untersuchung weiterer Merkmalsextraktionsmethoden vielversprechend, hier seien etwa Wavelet- und Cepstrum-basierte Verfahren [200] genannt.

Für die Lebensdauer-Prognose ist nicht zuletzt die Verwendung von Regressionsmodellen (z.B. PLSR [201]) sinnvoll. Damit kann die willkürliche Kategorisierung der Lebensdauerphasen, die für die Verwendung von Mustererkennungsverfahren nötig ist, umgangen werden, und stattdessen ein Modell für die kontinuierliche Quantifizierung des Verschleißgrads erstellt werden.

5.8 Zusammenfassung der Anwendung

In diesem Kapitel wurde die Lebensdauerprognose von elektromechanischen Zylindern mithilfe von multivariater Auswertung von Prozess-, Körper- und Luftschall- sowie Motorstromsensoren untersucht.

Mit einem entwickelten Dauerlaufprüfstand, der die automatisierte zyklische Belastung der Zylinder bis zum Ausfall erlaubt, wurde im Rahmen dieser Arbeit die experimentelle Basis für die Generierung von Trainingsdaten geschaffen. Es wurden drei Lebensdauermessungen durchgeführt, die stark unterschiedliche Laufzeiten von ca. 3 Wochen bis 3 Monaten bzw. Laufleistungen von 315 km bis über 1000 km aufwiesen. Die Prozesskonfiguration spiegelte hierbei Applikationen im Hochlastbereich und deren tribologische Bedingungen wider. Als Ausfallursache konnte u.a. der Verschleiß der Wälzkörper mit einem Materialverlust von bis zu 24 % identifiziert werden.

Aufgrund der hohen Sampling-Raten von bis zu 1 MS/s fielen bei den einzelnen Experimenten hohe Datenmengen bis zu 45 TB an, die in dieser Arbeit nur stichprobenartig ausgewertet wurden. Für eine vollständige Analyse werden die Punkte Skalierbarkeit und Parallelisierung der Auswerteverfahren, speziell bei der Merkmalsextraktion, zukünftig in den Fokus rücken.

Das Ziel, universell nutzbare Zustandsindikatoren mithilfe der statistischen Auswertung zu identifizieren, konnte mit den untersuchten Verfahren nicht vollständig erreicht werden. Zwar konnte auf Basis der individuellen Achsen jeweils ein Zustandsmodell erstellt und erfolgreich evaluiert werden, jedoch ist dieses nicht oder nur begrenzt auf die übrigen untersuchten Achsen übertragbar. Dies lässt sich zum einen auf die wechselnden experimentellen Parameter, zum anderen durch die Streuungen der individuellen Prüflinge erklären, erkennbar an den Körperschallspektren und den subjektiv wahrnehmbaren unterschiedlichen Laufgeräuschen.

Übergreifend über alle drei Versuche konnte die statistische Signifikanz der Körperschallspektren festgestellt werden, wohingegen die spektrale Auswertung der Motorströme keinen wesentlichen Mehrwert bei der Modellbildung für die Klassentrennung der Lebensdauerphasen ergab. Gleichwohl ist an dieser Stelle zu ergänzen, dass erhebliches Potential bei der Optimierung der Merkmalsextraktion vorliegt. So konnten etwa statistische Merkmale des zeitlichen Wirkstromverlaufs während der Ruck- und Beschleunigungsphasen identifiziert werden, die stark mit der Laufleistung korrelieren.

Im Ausblick sind weitere experimentelle Untersuchungen notwendig. So sollten weitere Lebensdauerversuche bei gleichen Lastkollektiv- und Prozessbedingungen durchgeführt werden, um die Übertragbarkeit der statistischen Modelle weiter zu verifizieren. Zudem ist die Untersuchung gezielt eingebrachter Schädigungen der Achsen sinnvoll, etwa durch Verwendung von Wälzkörpern mit reduziertem Durchmesser, um die bisherigen Ergebnisse der Lebensdauerversuche zu bestätigen. Auch eine systematische hubabhängige Modalanalyse des Zylinders und Prüfstands könnte weitere Rückschlüsse zur Identifikation von relevanten Schwingungsmerkmalen erlauben. Des Weiteren sollten sukzessive die Prozessparameter Geschwindigkeit, Beschleunigung sowie definierte Umgebungstemperaturänderungen ausgeweitet werden, um deren Störeinfluss für die Zustandsbewertung systematisch abschätzen zu können.

Perspektivisch ist die End-of-Line-Prüfung mit der Erkennung typischer Montagefehler anhand eines definierten Prüfzyklus als sinnvolle Anwendung zu nennen, bei der die überwachten Lernverfahren ideal zur Klassifikation genutzt werden könnten. Gegebenenfalls ließen sich durch die Kopplung der generierten EoL- und Lebensdauermodelle auch weitere Rückschlüsse über entstehende Schädigungen und deren Lokalisierung ableiten.

Bezüglich der Signalverarbeitung könnte das Pre-Processing der Schwingungsspektren zielführend sein, um individuelle Charakteristika des Schwingungsverhaltens zu minimieren und ein vergleichbares und übertragbares Referenzspektrum zu erhalten. Zudem wird für diese Anwendung tendenziell eine physikalisch motivierte Merkmalsextraktion als sinnvoll angesehen, da die breitbandige Generierung von Merkmalen die Gefahr birgt, zufällig mit der Versuchsdauer korrelierte Merkmale auszuwählen. Dies ist insbesondere problematisch, da die Zielgröße Verschleiß nicht definiert variiert und zurückgemessen werden kann.

Zuletzt legen die bisherigen Ergebnisse nahe, dass eine Platzierung von Sensorik an der Spindelmutter, etwa in Form eines integrierten kostengünstigen Multisensor-Systems, eine weitere Steigerung der Sensitivität erlaubt. In [202], [203] wird der Prototyp eines solchen Systems beschrieben, bei dem u.a. MEMS-g-Sensoren direkt an der KGT-Mechanik und somit der Anregungsquelle auftretende Schwingungen messen. Vielversprechend ist zudem die Verwendung von MR-Sensoren, etwa zum Abgleich rotatorischer und linearer Wegmessung [166] zur Detektion von Spiel oder zur Überwachung der Wälzkörper beim Durchlaufen der Kugelrückführung anhand der Magnetfeldsignaturen.

6 Zusammenfassung und Ausblick

In dieser Arbeit wurde ein teilautomatisiertes Vorgehen zur Merkmalsextraktion, -selektion und Klassifikation zur Zustandsüberwachung von industriellen Anwendungen mit zyklischem Prozessablauf untersucht. Hierbei wurden aus verschiedenen Sensorsignalen breitbandig statistische und formbeschreibende Merkmale extrahiert, die auf Basis von statistischen Kriterien gefiltert und mittels überwachter Dimensionsreduktion in niedrigdimensionale Darstellungsräume überführt wurden, die eine Zustandsbewertung erlauben. Dieses Vorgehen wurde anhand zweier Anwendungen erprobt.

In einem generischen hydraulischen System erfolgte hierbei die Detektion diskret eingebrachter emulierter Schadenszustände auf Basis von typischerweise installierten Prozesssensoren mit niedrigen Abtastraten bis 100 S/s. Gezeigt werden konnte, dass

- ✓ die untersuchten Schadenszustände von Öl-Luft Kühler, Wegeventil, Pumpe, Hydrospeicher mit hoher Sensitivität quantifiziert werden können
- ✓ gleichzeitig auftretende Schäden selektiv unterscheidbar sind, jedoch untereinander als Störgröße agieren und somit die Unschärfe der Detektion erhöhen
- ✓ die Klassifikationsgenauigkeit bei randomisierten Arbeitszyklen signifikant reduziert wird, diese jedoch durch zyklenübergreifende sekundäre Merkmalsextraktion wiederum deutlich verbessert werden kann
- ✓ eine Aufweitung des Öltemperatur- und Lufteintragbereichs die Klassifikation erschwert, aber gleichzeitig die Auswahl stabiler Merkmale fördert, während eine Nichtberücksichtigung von Störgrößen zu einer Extrapolation durch das Modell und instabilen Projektionen führen kann
- ✓ statistische Modelle zwischen zwei baugleichen hydraulischen Systemen übertragen werden können und diese über längere Zeiträume (1 Monat) stabil sind
- ✓ die Qualität der Merkmale und der Zustandsbewertung durch überlagerte Sensorstörungen erheblich reduziert wird
- ✓ einzelne Sensorfehler, etwa Offset, Drift, überlagertes Rauschen und Störpeaks durch Analyse der Signalrelationen der Prozesssensoren erkannt und quantifiziert werden können

- ✓ bis zu fünf ausgefallene Sensoren durch systematisches Verwerfen der betroffenen Sensordaten und Neuanlernen des Modells zur Aufrechterhaltung der Zustandsüberwachung ($> 80\%$ Klassifikationsrate) kompensiert werden können

Die Praktikabilität eines solchen Condition Monitoring Ansatzes wird in diesem Kontext als hoch eingeschätzt. Insbesondere bei Anlagen, die sich aus vielen homogenen Maschinen und einheitlichen Arbeitszyklen zusammensetzen, könnten effizient Trainingsdaten gesammelt werden, die Degradationszustände und typische Fehler repräsentieren. In der Anlernphase bietet sich hierbei die Kombination mit Verfahren zur Anomalieerkennung an, um neue Zustände der Maschine erkennen und deren Ursache analysieren zu können um wiederum daraus die Zielgröße für das überwachte Lernen abzuleiten. Auf Basis dieser Information könnte mit einem leistungsfähigen Rechner zentral die Generierung des Modells erfolgen, sodass nachfolgend die Online-Zustandsbewertung mit relevanter Merkmalsextraktion und LDA-Dimensionsreduktion auf der jeweiligen SPS der einzelnen Maschinen implementierbar und effizient durchführbar wäre.

In der zweiten Anwendung wird die Verschleißerkennung elektromechanischer Zylinder untersucht. Die experimentelle Grundlage bildet ein im Rahmen dieser Arbeit entwickelter Lebensdauerprüfstand, der die Linearantriebe bei Verfahrenzyklen mit bis zu 9,6 kN axial belastet und die Charakterisierung des Verhaltens über die relative Laufleistung anhand von Prozess-, Körper-/Luftschall- und Motorstromsignalen mit im Vergleich zur ersten Anwendung hohen Abstraten bis zu 1 MS/s erlaubt. Hierbei konnte gezeigt werden, dass

- ✓ je nach Lastkonfiguration die erreichte Laufleistung bis zum Ausfall im Bereich von 315 bis 1.050 km (bzw. 0,63 bis 1,75 Mio. Hüben) in drei Versuchen variiert
- ✓ individuell für jeden Zylinder ein Analysemodell erstellt werden kann, das eine Interpolation erlaubt
- ✗ die auf Basis eines einzelnen Versuchs erzeugten Modelle nicht direkt zur Lebensdauerprognose der übrigen Zylindern genutzt werden können
- ✓ durch Kombination von Versuchsdaten übergreifend nutzbare Schwingungsmerkmale bei identischem Lastkollektiv identifiziert und in einem Modell zusammengefasst werden können
- ✓ aus den Messgrößen, die durch den Motorcontroller zur Verfügung stehen, Merkmale mit hoher Korrelation zur Laufleistung extrahiert werden können, die potentielle Zustandsindikatoren darstellen

Dennoch ist festzustellen, dass bis zum praktischen Einsatz der Zustandsüberwachung für elektromechanische Zylinder noch einige Untersuchungen notwendig sind, etwa die systematische Einflussanalyse von Last, Geschwindigkeit und Beschleunigung sowie die Untersuchung der mechanischen Ankopplung an das übergeordnete System.

Anwendungsübergreifend ist ein hohes Potential des vorgestellten Ansatzes zur Optimierung der Instandhaltung industrieller Anwendungen zu erkennen. Die derzeitige Limitierung auf zyklische Abläufe könnte auf nichtzyklische bzw. nichtdeterministische Prozesse etwa durch Event-basierte Merkmalsextraktion überwunden werden. Des Weiteren existiert eine Vielzahl von Merkmalsextraktions- und -selektionsverfahren, welche durch geschickte Kombination die bestehende Methodik weiter optimieren und automatisieren könnte, wie von Schneider vorgeschlagen [31]. Gleichwohl liegen im Produktionsumfeld in den seltensten Fällen annotierte Daten vor, die für eine Zustandsüberwachung auf Basis überwachter Lernverfahren und Mustererkennung genutzt werden können. Hier wäre ergänzend die Einbindung von unüberwachten Verfahren, etwa zum Clustering oder zur Anomaliedetektion, sinnvoll.

Die derzeit im Projekt MoSeS-Pro laufende Forschung zielt darauf ab, die Merkmalsextraktion als ersten, unüberwachten Schritt des maschinellen Lernens [31] direkt am Sensor mittels DSP/FPGA-Technologie, wie von Selke et al. [204] beschrieben, durchzuführen, sodass nur relevante und stark komprimierte Information im Produktionsnetz übertragen werden muss, was zukünftig zu einer Entlastung von letzterem beitragen könnte.

Nicht zuletzt ermöglicht die statistische Analyse keine oder nur eine stark eingeschränkte Erläuterung der Entscheidungsfindung. Hier könnte die statistisch-semanticische Analyse neben einer Zustandsdetektion auch die Möglichkeit einer Erläuterung möglicher Ursachen erlauben [205] und damit die Nachvollziehbarkeit und somit Akzeptanz des datenbasierten Ansatzes fördern.

Literaturverzeichnis

- [1] J. Fleischer, J. Wieser, H. Hennrich, M. Schopp und A. Broos, „Optimization of maintenance activities through maintenance-relevant design,“ in *18th CIRP Design Conference*, University of Twente, Enschede, 2008.
- [2] Roland Berger GmbH, „Predictive Maintenance,“ München, 2017.
- [3] J. Schreier, „70 Milliarden Euro Verschwendung durch Instandhaltung,“ www.maschinenmarkt.vogel.de, 17.06.2011. [Online]. Available: <https://www.maschinenmarkt.vogel.de/70-milliarden-euro-verschwendung-durch-instandhaltung-a-320136/>.
- [4] W. Becker und F. Brinkmann, „Kostenrechnung für die Instandhaltung - Ergebnisse eine empirischen Untersuchung,“ Otto-Friedrich-Universität Bamberg, 2000, ISBN: 3931810194.
- [5] B. Rao, „Condition Monitoring and the Integrity of Industrial Systems,“ in *Handbook of Condition Monitoring: Techniques and Methodology*, Tullamore, Ireland, A. Davies, Springer Science, 1998, ISBN: 9789401060653, pp. 3-33.
- [6] International Organization for Standardization (ISO), „13372, Condition monitoring and diagnostics - Vocabulary,“ Geneva, Switzerland, 2004.
- [7] S. Dienst, „Analyse von Maschinendaten zur Entscheidungsunterstützung bei der Produktverbesserung durch die Anwendung eines Feedback Assistenz Systems,“ Dissertation, Naturwissenschaftlich-Technische Fakultät, Universität Siegen, 2014.
- [8] J. Kolerus, „Aktueller Stand, Tendenzen und Stellenwert der Normen zur Schwingungsüberwachung im industriellen Umfeld,“ in *VDI-Berichte 2151, VDI-Fachtagung Schwingungsüberwachung*, Düsseldorf, VDI-Verlag, 2011, ISBN: 978-3-18-092151-8.
- [9] N. Tandon, „A comparison of some vibration parameters for the condition monitoring of rolling element bearings,“ *Measurement*, pp. 285-289, 12.3 1994.
- [10] Rüdiger Heim, „Am Puls der Maschine: Condition Monitoring,“ VDMA Verlag GmbH, Frankfurt, 2015.
- [11] R. Werthschützky (Hrsg.), „Sensor Technologien 2022,“ AMA Verband für

- Sensorik und Messtechnik e.V., 2017.
- [12] P. Reimann, "Gasmesssysteme basierend auf Halbleitergassensoren für sicherheitskritische Anwendungen mit dem Ansatz der Sensorselbstüberwachung," Dissertation, A. Schütze und H. Seidel, Hrsg., Shaker Verlag, 2011, ISBN: 978-3-8440-0232-4.
- [13] M. Schüler, "Methoden zur Funktionsüberwachung von Gassensoren mit Hilfe multimodaler Signale," Dissertation, A. Schütze und H. Seidel, Hrsg., Aachen: Shaker-Verlag, 2017, ISBN: 978-3-8440-5068-4.
- [14] C. Bur, "Selectivity Enhancement of Gas Sensitive Field Effect Transistors by Dynamic Operation," Dissertation, A. Schütze und H. Seidel, Hrsg., Shaker Verlag, 2015, ISBN: 978-3-8440-3758-6.
- [15] M. Klusch, A. Meshram, P. Kapahnke und A. Schütze, „ICM-Wind: Semantics-Empowered Fluid Condition Monitoring of Wind Turbines,“ in *Proc. 29th ACM Symposium on Applied Computing (SAC); ACM Press. ERA: B*, Korea, 2014.
- [16] ZeMA gGmbH, „MoSeS-Pro: Modulare Sensorsysteme für die Echtzeit-Prozesssteuerung und smarte Zustandsbewertung,“ 2016. [Online]. Available: www.moses-pro.de. [Zugriff am 25. 09. 2017].
- [17] F. Adunka, *Messunsicherheiten: Theorie und Praxis*, Vulkan-Verlag, 2007, ISBN: 3802722051.
- [18] M. Krystek, *Berechnung der Messunsicherheit*, DIN Deutsches Institut für Normung, Hrsg., Beuth Verlag, 2015, ISBN: 978-3-410-25556-7.
- [19] H.-R. Tränkler, *Sensortechnik - Handbuch für Praxis und Wissenschaft*, Berlin: Springer Vieweg, 2014, ISBN: 978-3-642-29941-4.
- [20] Fachausschuss Deutscher Kalibrierdienst (DKD), „Leitfaden Praxisgerechte Ermittlung der Messunsicherheit,“ 2012. [Online]. Available: <https://www.ptb.de/cms/fileadmin/internet/dienstleistungen/dkd/Leitfaden-Messunsicherheit.pdf>. [Zugriff am 10 08 2017].
- [21] R. J. Hansman, „Characteristics of Instrumentation,“ in *The Measurements, Instrumentation and Sensors Handbook*, John G. Webster, 1999, ISBN: 3-540-64830-5.
- [22] G. Lewis, *Newnes Communications Technology Handbook*, Elsevier, 2013,

- ISBN: 1483101029.
- [23] J. Marques de Sá, Pattern Recognition - Concepts, Methods and Applications, Berlin Heidelberg: Springer-Verlag, 2001, ISBN: 3-540-42297-8.
- [24] T. Runkler, Information Mining - Methoden, Algorithmen und Anwendungen intelligenter Datenanalyse, Braunschweig / Wiesbaden: Verlag Vieweg, 2000, ISBN: 3-528-05741-6.
- [25] W. Krzanowski, Principles of Multivariate Analysis, New York: Oxford University Press, 2003, ISBN: 0198507089.
- [26] S. Horras, "Adaptierbares Messsystem zur Detektion von Gasen und Gerüchen basierend auf Halbleitersensoren im temperaturzyklischen Betrieb," Dissertation, Bd. 13, A. Schütze und H. Seidel, Hrsg., Aachen: Shaker-Verlag, 2011, ISBN: 978-3-8440-0101-3.
- [27] L. Al Shalabi, Z. Shaaban und B. Kasasbeh, „Data Mining: A Preprocessing Engine,“ *Journal of Computer Science*, pp. 735-739, 2 (9) 2006.
- [28] I. Mohamad und D. Usman, „Standardization and Its Effects on K-Means Clustering Algorithm,“ *Research Journal of Applied Sciences, Engineering and Technology*, pp. 3299-3303, 6(17) 2013.
- [29] A. Schütze, A. Gramm und T. Rühl, „Identification of Organic Solvents by a Virtual Multisensor System With Hierarchical Classification,“ *IEEE Sensors Journal*, pp. 857-863, 4.5 2004.
- [30] N. Helwig, T. Schneider und A. Schütze, „Modular sensor systems for real time process control and smart condition monitoring using XMR technology,“ *Proceedings 14th xMR-Symposium Magnetoresistive Sensors and Magnetic Systems*, pp. 15-22, 21-22 03 2017.
- [31] T. Schneider, N. Helwig und A. Schütze, „Automatic feature extraction and selection for classification of cyclical time series data,“ *tm - Technisches Messen*, 1 2017, doi: 10.1515/teme-2016-0072.
- [32] MathWorks Inc., „Matlab Documentation 'polyfit',“ [Online]. Available: <https://de.mathworks.com/help/matlab/ref/polyfit.html>. [Zugriff am 27. 07. 2017].
- [33] T. Butz, Fouriertransformation für Fußgänger, Wiesbaden: Vieweg+Teubner, 2009, ISBN: 978-3-8348-0538-6.

- [34] V. Oklobdzija, *The Computer Engineering Handbook*, CRC Press, Taylor & Francis Group, 2011, ISBN: 978-1-4200-4154-5.
- [35] T. Sauer, „Vorlesungsmanuskript Wavelets,“ Lehrstuhl für Numerische Mathematik, Justus-Liebig-Universität Gießen, 2012.
- [36] O. Pertz, "Anwendung von waveletbasierten Verfahren bei der Simulation von Millimeter- und Mikrometerwellenschaltungen mit der Methode der Geraden," Dissertation, Gerhard-Mercator-Universität Duisburg: Fachbereich Elektrotechnik, 2001.
- [37] C.-H. Shen, „Acoustic Based Condition Monitoring, Dissertation,“ Graduate Faculty of The University of Akron, USA, 2012.
- [38] Z. Peng, „Vibration signal analysis and feature extraction based on reassigned wavelet scalogram,“ *Journal of Sound and Vibration*, pp. 1087-1100, 253.5 2002.
- [39] J. Lin und L. Qu, „Feature extraction based on Morlet Wavelet and its Application for Mechanical Fault Diagnosis,“ *Journal of Sound and Vibration*, pp. 135-148, 234.1 2000.
- [40] J. Vass und C. Cristalli, „Optimization of Morlet wavelet for mechanical fault diagnosis,“ in *12th International Congress on Sound and Vibration (ICSV'05)*, Lisbon, Portugal, 2005.
- [41] Z. Peng und F. L. Chu, „Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography,“ *Mechanical systems and signal processing*, pp. 199-221, 18.2 2004.
- [42] S. Goswami und A. Chakrabarti, „Feature Selection: A Practitioner View,“ *I.J. Information Technology and Computer Science*, pp. 66-77, 11 2014, doi: 10.5815/ijitcs.2014.11.10.
- [43] I. Guyon und A. Elisseeff, „An Introduction to Variable and Feature Selection,“ *Journal of Machine Learning Research*, pp. 1157-1182, 3 2003.
- [44] T. Schneider, „Methoden der automatisierten Merkmalsextraktion und -selektion von Sensorsignalen,“ Masterarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, Saarbrücken, 2015.
- [45] M. Nussbaum, *Categorical and Nonparametric Data Analysis*, NY, USA: Taylor & Francis, 2015, ISBN: 978-1-84872-603-1.

- [46] K. Backhaus, B. Erichson, W. Plinke und R. Weiber, *Multivariate Analysemethoden*, Springer-Verlag Berlin Heidelberg, 2008, ISBN: 978-3-662-46075-7.
- [47] C. H. Brase und C. P. Brase, *Understandable Statistics - Concepts and Methods*, USA: CENGAGE Learning, 2016, ISBN: 978-1-337-11991-7.
- [48] G. Bontempi, „Structural feature selection for wrapper methods,“ *Proc. of 13th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, pp. 405-410, 2005.
- [49] K. Dunne, P. Cunningham und F. Azuaje, „Solutions to instability problems with sequential wrapper-based approaches to feature selection,“ *Journal of Machine Learning Research*, pp. 1-22, 2002.
- [50] P. Baraldi, R. Canesi, E. Zio und R. Chevalier, „Genetic algorithm-based wrapper approach for grouping condition monitoring signals of nuclear power plant components,“ *Integrated computer-Aided engineering*, pp. 221-234, 18.3 2011.
- [51] C. Varun, A. Banerjee und V. Kumar, „Anomaly detection: A survey,“ *ACM computing surveys (CSUR)*, pp. 1-72, 41.3 2009.
- [52] D. Luo, C. Ding und H. Huang, „Linear Discriminant Analysis: New Formulations and Overfit Analysis,“ *Proceedings of the Twenty-Fifth AAAI Conference on Artificial Intelligence*, 2011.
- [53] M. Welling, „Fisher Linear Discriminant Analysis,“ Report, 2000. [Online]. Available: <https://www.ics.uci.edu/~welling/teaching/273ASpring09/Fisher-LDA.pdf>. [Zugriff am 08. 03. 2018].
- [54] W. Klecka, *Discriminant Analysis*, CA, USA: Sage Publications, 1980, ISBN: 0-8039-1491-1.
- [55] D. Vásquez, R. Gruhn, R. Brueckner und W. Minker, „Comparing Linear Feature Space Transformations for Correlated Features,“ *Proceedings of PIT 2008: Perception in Multimodal Dialogue Systems*, pp. 176-187, 2008.
- [56] K. Weinberger und L. Saul, „Distance Metric Learning for Large Margin Nearest Neighbor Classification,“ *Journal of Machine Learning Research*, pp. 207-244, 10 2009.
- [57] K. Chompoon, „An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm,“ *Proceedings of the 3rd International Conference on*

- Industrial Application Engineering*, pp. 280-285, 2015, doi: 10.12792/iciae2015.051.
- [58] R. Duda, P. Hart und D. Stork, *Pattern Classification*, Wiley Interscience, 2000, ISBN: 0471056693.
- [59] G. McLachlan, „Mahalanobis distance,“ *Resonance*, pp. 20-26, 4.6 1999.
- [60] F. Maselli, C. Conese, L. Petkov und R. Resti, „Inclusion of prior probabilities derived from a nonparametric process into the maximum-likelihood classifier,“ *Photogrammetric Engineering and Remote Sensing*, pp. 201-207, 58.2 1992.
- [61] L. Perlovsky und M. McManus, „Maximum likelihood neural networks for sensor fusion and adaptive classification,“ *Neural Networks*, pp. 89-102, 4.1 1991.
- [62] MathWorks Inc., „Matlab Documentation 'Neural Network Toolbox',“ [Online]. Available: <https://de.mathworks.com/products/neural-network.html>. [Zugriff am 05 10 2017].
- [63] R. Rojas, *Neural Networks - A systematic introduction*, Berlin: Springer-Verlag, 1996.
- [64] D. Nauck, F. Klawonn und R. Kruse, *Neuronale Netze und Fuzzy-Systeme*, Braunschweig/Wiesbaden: Verlag Vieweg, 1996, ISBN: 3-528-15265-6.
- [65] G. Mesnil, X. He, L. Deng und Y. Bengio, „Investigation of recurrent-neural-network architectures and learning methods for spoken language understanding,“ *Interspeech*, pp. 3771-3775, 2013.
- [66] A. Zell, *Simulation neuronaler Netze*, De Gruyter, 1997, ISBN: 978-3-486-24350-5.
- [67] A. Scherer, *Neuronale Netze*, Braunschweig/Wiesbaden: Vieweg Verlag, 1997, pp. 73-75.
- [68] J. K. Basu, D. Bhattacharyya und K. Tai-hoon, „Use of artificial neural network in pattern recognition,“ *International journal of software engineering and its applications*, 4.2 2010.
- [69] J. Sanz, R. Perera und C. Huerta, „Gear dynamics monitoring using discrete wavelet transformation and multi-layer perceptron neural networks,“ *Applied Soft Computing*, pp. 2867-2878, 12.9 2012.
- [70] O. Geramifard, „Data-driven approaches in health condition monitoring - a

- comparative study," *Proceedings of 8th IEEE International Conference on Control and Automation (ICCA)*, pp. 1618-1622, 2010.
- [71] MathWorks, „Matlab Documentation 'Neural Network Toolbox',“ [Online]. Available: <https://de.mathworks.com/help/nnet/>. [Zugriff am 02. 08. 2017].
- [72] S. Abe, *Support Vector Machines for Pattern Classification*, London: Springer-Verlag, 2010, ISBN: 978-1-84996-097-7.
- [73] R. Fisher, „Iris Data Set,“ UCI - Machine Learning Repository, ursprünglich 1936 veröffentlicht. [Online]. Available: <http://archive.ics.uci.edu/ml/datasets/Iris>. [Zugriff am 28. 05. 2018].
- [74] M. Hussain, S. Wajid, A. Elzaart und M. Berbar, „A comparison of SVM kernel functions for breast cancer detection,“ *Proceedings of Eighth IEEE International Conference on Computer Graphics, Imaging and Visualization (CGIV)*, pp. 145-150, 2011.
- [75] N. Garcia-Pedrajas und D. Ortiz-Boyer, „Improving multiclass pattern recognition by the combination of two strategies,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28.6, pp. 1001-1006, 2006.
- [76] MathWorks Inc., „Matlab Documentation 'fitcecoc',“ [Online]. Available: <https://de.mathworks.com/help/stats/fitcecoc.html>. [Zugriff am 09. 08. 2017].
- [77] C. Bur, M. Bastuck, A. Spetz, M. Andersson und A. Schütze, „Selectivity enhancement of SiC-FET gas sensors by combining temperature and gate bias cycled operation using multivariate statistics,“ *Sensors and Actuators B: Chemical*, 193, pp. 931-940, 2014.
- [78] T. Schneider, „Klassifikation von Gassensordaten mit Support Vector Machines,“ Bachelorarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, Saarbrücken, 2013.
- [79] U. Schmid, "Entwicklung chemometrischer Methoden für die Klassifikation von Bakterien mittels Mikro-Raman-Spektroskopie," Dissertation, Braunschweig: Fakultät für Lebenswissenschaften, Technische Universität Carolo-Wilhelmina, 2009.
- [80] M. McHugh, „The chi-square test of independence,“ *Biochemia medica* 23.2, pp. 143-149, 2013.
- [81] S. Shapiro und M. Wilk, „An Analysis of Variance Test for Normality

- (Complete Samples),“ *Biometrika* , Vol. 52, No. 3, pp. 591-611, 1965.
- [82] C. Jarque und A. Bera, „Efficient tests for normality, homoscedasticity and serial independence of regression residuals.,“ *Economics letters* 6.3, pp. 255-259, 1980.
- [83] N. Razali und Y. Wah, „Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests,“ *Journal of Statistical Modeling and Analytics Vol. 2 No. 1*, pp. 21-33, 2011.
- [84] H. Lilliefors, „On the Kolmogorov-Smirnov Test for Normality with Mean and Variance Unknown,“ *Journal of the American Statistical Association*, Vol. 62, No. 318, pp. 399-402, 1967.
- [85] N. Helwig, S. Klein und A. Schütze, „Identification and quantification of hydraulic system faults based on multivariate statistics using spectral vibration features,“ *Procedia Engineering*, 120, pp. 1225-1228, 2015, doi: <https://doi.org/10.1016/j.proeng.2015.08.835>.
- [86] Y. Bengio und Y. Grandvalet, „No Unbiased Estimator of the Variance of K-Fold Cross-Validation,“ *Journal of Machine Learning Research*, p. 1089–1105, 5 2004.
- [87] S. Arlot und A. Celisse, „A survey of cross-validation procedures for model selection,“ *Statistics Surveys*, p. 40–79, 4 2010, doi: 10.1214/09-SS054.
- [88] R. Kohavi, „A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection,“ *Proceedings of the International Joint Conference on Artificial Intelligence (IJCAI)*, 1995.
- [89] M. Bastuck, T. Baur und A. Schütze, „DAV³E - a comprehensive toolbox for multisensor data fusion not only for gas sensors,“ in *Proceedings, 6th EuNetAir scientific meeting*, Prague, 2016.
- [90] MathWorks Inc., „Statistics and Machine Learning Toolbox,“ [Online]. Available: <https://de.mathworks.com/products/statistics.html>. [Zugriff am 05. 10. 2017].
- [91] Mannesmann Rexroth GmbH, *Der Hydraulik Trainer - Projektierung und Konstruktion von Hydroanlagen*, Lohr am Main: Mannesmann Rexroth GmbH, 1988, ISBN-10: 3981487958.
- [92] Hydac International GmbH, „Condition Monitoring für ein effizientes Life

- Cycle Cost Management,“ Sulzbach, 2007.
- [93] Eaton Industries GmbH, „Condition monitoring and analysis of hydraulic and lubrication fluids,“ Tinton Falls, NJ, USA, 2017.
- [94] Parker Hannifin Corporation, „Diagnostic tools and condition monitoring solutions,“ Cleveland, Ohio, USA, 2010.
- [95] M. Kulkarni, „Fault Detection in Hydraulic System Using Fuzzy Logic,“ in *Proceedings of the World Congress on Engineering and Computer Science 2009 Vol II*, San Francisco, USA, October 20-22, 2009.
- [96] X. He und S. He, „A Fault Diagnosis Approach for the Hydraulic System by Artificial Neural Networks,“ in *Sensors & Transducers, Vol. 171, Issue 5, pp. 239-244*, 2014.
- [97] J. Liniger, N. Sepehri, M. Soltani und H. Pedersen, „Signal-Based Gas Leakage Detection for Fluid Power Accumulators in Wind Turbines,“ *Energies* 2017, 10, 331 2017, doi:10.3390/en10030331.
- [98] S. Adams, „Condition Based Monitoring for a Hydraulic Actuator,“ in *Annual Conference of the Prognostics and Health Manangement Society 2016*, Denver, USA, 2016.
- [99] H.-J. Dittmer, "Condition Monitoring für HFA Hydraulik mit ölhydraulischen Geräten," Dissertation, Fakultät für Maschinenwesen, Rheinisch-Westfälische Technische Hochschule Aachen, 2008.
- [100] Y. Tian, „Fault diagnosis based on LMD-SVD and information-geometric support vector machine for hydraulic pumps,“ *Transactions of the Canadian Society for Mechanical Engineering, Vol. 39 No. 3*, pp. 569-580, 2015.
- [101] B. Zhang, „Rolling element bearing feature extraction and anomaly detection based on vibration monitoring,“ *Proceedings 16th Mediterranean Conference on Control and Automation*, pp. 1792-1797, 2008.
- [102] Y. Burennikov, „Mechatronic Hydraulic Drive with Regulator, Based on Artificial Neural Network,“ in *International Conference on Innovative Research — ICIR EUROINVENT 2017*, Romania, 2017, doi:10.1088/1757-899X/209/1/012071.
- [103] M. Khoshzaban-Zavarehi, „On-Line Condition Monitoring And Fault Diagnosis in Hydraulic System Components Using Parameter Estimation And Pattern Classification,“ PhD Thesis, Department of Mechanical Engineering,

- University of British Columbia, Canada, 1997.
- [104] J. Schaab, „Identification of a hydraulic servo-axis using support vector machines,“ in *IFAC Proceedings Volumes 38.1*, 722-727, 2005.
- [105] A. Ridluan, M. Manic und A. Tokuhiko, „EBaLM-THP – A neural network thermohydraulic prediction model of advanced nuclear system components,“ in *Nuclear Engineering and Design 239*, Elsevier, 2009.
- [106] L. Liang, „Neural Network PID Control Application of Hydraulic position Servo System for Precision Improvement,“ *Advanced Science and Technology Letters Vol.77 (UNESST 2014)*, pp. 83-87, 2014, <http://dx.doi.org/10.14257/astl.2014.77.16>.
- [107] C. Otto, „Modeling a Hydraulic Drive Using Neural Networks,“ Bericht, Lehrstuhl für Mess- und Regelungstechnik, Universität Duisburg, 2001.
- [108] L. Shiqiang, J. Tongmin und L. Xiaoyang, „Fault Diagnosis for Electrohydraulic Servo Valve Based on Support Vector Machine,“ in *The 2nd International Conference on Computer Application and System Modeling*, China, 2012.
- [109] R. S. Beebe, Predictive Maintenance of Pumps Using Condition Monitoring, Elsevier Science & Technology, 2004, ISBN: 1856174085.
- [110] H. Mannebach und J. Kleber, Interviewees, *Persönliche Mitteilung, Projekttreffen ICM-Hydraulik*. [Interview]. 11 10 2013.
- [111] D. Will, Hydraulik - Grundlagen, Komponenten, Schaltungen, Pirna, Großhain: Springer-Verlag, 2014, ISBN: 978-3-662-44402-3.
- [112] H. Watter, Hydraulik und Pneumatik: Grundlagen und Übungen - Anwendungen und Simulation, Vieweg+Teubner Verlag, 2008, ISBN: 978-3-658-07860-7.
- [113] Dr.-Ing. Paul Christiani GmbH & Co. KG - Technisches Institut für Aus- und Weiterbildung, „Hydraulik,“ [Online]. Available: http://www.hochschule-technik.de/pdf/72108_probe.pdf. [Zugriff am 02. 11. 2017].
- [114] P. Pietkiewicz, „Typical failure of gear pumps - defects classification,“ *Technical Sciences*, pp. 219-228, 2009.
- [115] E. Hlawitschka, „Schadensanalytische Untersuchungen an Zahnradpumpen,“ *agrartechnik 09*, pp. 424-427, 1976.

- [116] B. Lamoureux, J.-R. Massé und N. Mechbal, „An Approach to the Health Monitoring of a Pumping Unit in an Aircraft Engine Fuel System,“ in *Proceedings European Conference of Prognostics and Health Management Society 2012*, Dresden, Germany, 2012.
- [117] H.-J. Lohrentz, „Mikro-Dieseleffekt als Folge der Kavitation in Hydrauliksystemen,“ *Ölhydraulik und Pneumatik* 18, pp. 3-8, 1974.
- [118] J. R. Branco und V. J. De Negri, „Online fault detection for servoproportional valves,“ in *Proceedings of COBEM 2009*, Gramado, Brazil, 2009.
- [119] H. Willebrand, „Hydraulische Steuerungen mit 2-Wege-Einbauventilen - Systematik, Entwurf und Untersuchung des Systemverhaltens,“ Dissertation, Fakultät für Maschinenwesen der RWTH, Aachen, 1980.
- [120] W. Backé und H. Tatar, Untersuchung des Einflusses von Störkräften auf den Schaltvorgang bei Wegeventilen der Hydraulik, Opladen: Westdeutscher Verlag GmbH, 1975, ISBN: 3-531-02497-3.
- [121] Hydac Fluidtechnik GmbH, „Datenblatt 2/2-Wege Sitzventil WSM06020W-01,“ Sulzbach, 2012.
- [122] HydraForce, „HydraForce Training,“ 2017. [Online]. Available: www.hydraforce.com/svtraining/files/sdjskjf_Chap8.pdf. [Zugriff am 08 07 2017].
- [123] S. Pültz, „Aufbau und Inbetriebnahme eines Fluidtechnik-Prüfstandes zur Charakterisierung hydraulischer Ventile,“ Bachelorarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, Saarbrücken, 2017.
- [124] E. Kallenbach, Elektromagnete - Grundlagen, Berechnung, Entwurf und Anwendung, Wiesbaden: Vieweg+Teubner, 2008, ISBN: 978-3-8351-0138-8.
- [125] N. Michaelis, „Untersuchung des Einflusses von freier Luft auf das Verhalten von Proportionaldruckregelventilen,“ Masterarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, Saarbrücken, 2015.
- [126] Parker Hannifin Corporation, Hydraulic Accumulator Division, „How To Deal With Pre-Charge Loss In Bladder Accumulators Due To Gas Permeation,“ Parker Hannifin Corporation, Rockford, IL, USA, 2007.
- [127] Hydac International GmbH, „Datenblatt Öl-Luft-Kühler- Standard Ausführung OK-EL Baureihe,“ Sulzbach.

- [128] H.-D. Baehr, Verfahren der Kälteerzeugung und Grundlagen der Wärmeübertragung, Karlsruhe: Springer-Verlag Berlin Heidelberg GmbH, 1959, ISBN: 3662133679.
- [129] E. Specht, „Grundlagen der Wärme- und Stoffübertragung, Vorlesungsmanuskript,“ Institut für Strömungstechnik und Thermodynamik, Otto-von-Guericke-Universität, Magdeburg, 2008.
- [130] V. Wöhrmann, „Ist der Wärmetauscher noch ganz sauber?,“ *Process - Chemie Pharma Verfahrenstechnik*, Nr. 7/8, 2010.
- [131] H. J. Matthies und K. T. Renius, Einführung in die Ölhydraulik, Wiesbaden: Vieweg+Teubner Verlag, 2008, ISBN: 978-3-8351-0238-5.
- [132] Hydac International GmbH, Filtration von Schmierölen und Hydraulikflüssigkeiten, Training Center, Sulzbach, 2011.
- [133] Hydac Filtrertechnik GmbH, Partikelmesstechnik in der Praxis - Von der Theorie zur Anwendung, Sulzbach, 2007.
- [134] T. Bley, "Integriertes Multisensorsystem zur Zustandsüberwachung von Schmierflüssigkeiten," Dissertation, A. Schütze und H. Seidel, Hrsg., Aachen: Shaker-Verlag, 2013, ISBN: 978-3-8440-2198-1.
- [135] F. Findeisen und D. Findeisen, Ölhydraulik, Springer-Verlag Berlin Heidelberg, 1978, ISBN: 978-3-662-09054-1.
- [136] B. Wiesent, "Miniaturisiertes Infrarot-Spektrometer zur Online-Ölzustandsüberwachung in Offshore-Windkraftgetrieben", Dissertation, München: Technische Universität München, Fakultät Elektrotechnik und Informationstechnik, 2012.
- [137] Meguin GmbH & Co. KG, „Datenblatt Meguin Hydraulikoel HLP 32,“ Saarlouis, 2009.
- [138] N. Helwig, E. Pignanelli und A. Schütze, „Condition monitoring of a complex hydraulic system using multivariate statistics,“ *Proceedings of International Instrumentation and Measurement Technology Conference (I2MTC)*, pp. 210-215, 2015, doi: 10.1109/I2MTC.2015.7151267.
- [139] N. Helwig und A. Schütze, „Intelligentes Condition Monitoring von hydraulischen Anlagen,“ *Tagungsband XXVIII. Messtechnisches Symposium des Arbeitskreises der Hochschullehrer für Messtechnik e.V.*, 2014, ISBN:

978-3-8440-2994-9.

- [140] Hydac International GmbH, „Datenblatt Medium Pressure Serie Baugröße 2,“ Sulzbach, 2013.
- [141] Hydac Technology GmbH, „Datenblatt Hydro-Membranspeicher,“ Sulzbach, 2011.
- [142] ASCO Numatics GmbH, „Datenblatt Proportionalventil Posiflow Baureihe 202,“ Ölbronn-Dürrn, 2012.
- [143] Beckhoff Automation GmbH & Co. KG, „Datenblatt EL2535 2-Kanal-Pulsweitenstromklemmen 24 V,“ Verl, 2015.
- [144] L. Bensch und M. Puliur, „Impact of Test Dust Changes on Particle Size, Particle Count, and Fluid Cleanliness Classes,“ Pall Corporation, Washington, New York, USA, 1998.
- [145] Saier Dosiertechnik GmbH, „Datenblatt Concept Serie,“ Gundelfingen, 2017.
- [146] Beckhoff Automation GmbH & Co. KG, „TwinCAT - PLC and Motion Control on the PC,“ [Online]. Available: www.beckhoff.com. [Zugriff am 16 10 2017].
- [147] 3S-Smart Software Solutions GmbH, „User Manual for PLC Programming with CoDeSys 2.3,“ Kempten, 2010.
- [148] Open Source Community for Automation Technology, „OSCAT-LIB,“ [Online]. Available: <http://www.oscat.de/>. [Zugriff am 19 07 2017].
- [149] STMicroelectronics, „Datasheet LIS352AR,“ 2010.
- [150] S. Klein, „Multivariate Auswertung spektraler Beschleunigungsdaten für das Condition Monitoring,“ Bachelorarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, Saarbrücken, 2015.
- [151] MathWorks Inc., „Matlab Documentation 'resample',“ [Online]. Available: <https://de.mathworks.com/help/signal/ref/resample.html>. [Zugriff am 11. 04. 2018].
- [152] N. Helwig und A. Schütze, „Data-based condition monitoring of a fluid power system with varying oil parameters,“ *Proceedings of 10th International Fluid Power Conference*, pp. 425-436, 2016.
- [153] V. Roth, „Outlier detection with one-class kernel fisher discriminants,“

- Advances in Neural Information Processing Systems*, pp. 1169-1176, 2005.
- [154] A. Vetter, L. Steinke und S. Ripperger, „Testverfahren zur Bewertung von Partikelabscheidern,“ *F & S Filtrieren und Separieren*, pp. 15-20, 1 2012.
- [155] N. Helwig und A. Schütze, „Statistische Analyse von Schwingungs- und Prozesssensordaten zur Zustandsbewertung - Perspektive modularer Sensorlösungen in der Industrie 4.0,“ *VDI-Bericht 2259*, pp. 61-75, 2016.
- [156] M. Engel, "Untersuchung zur Kalibrierbarkeit von Gassensoren im temperaturzyklischen Betrieb," Dissertation, Bd. 5, A. Schütze und H. Seidel, Hrsg., Shaker Verlag, 2008, ISBN: 978-3-8322-7446-7.
- [157] N. Helwig, E. Pignanelli und A. Schütze, „Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System,“ *Proceedings SENSOR 2015*, pp. 641 - 646, 2015, doi: 10.5162/sensor2015/D8.1.
- [158] MathWorks Inc., „Matlab Documentation 'awgn',“ [Online]. Available: <https://de.mathworks.com/help/comm/ref/awgn.html>. [Zugriff am 26. 07. 2017].
- [159] W. Beitz und K.-H. Küttner, DUBBEL - Taschenbuch für den Maschinenbau, Berlin / Heidelberg: Springer-Verlag, 1995.
- [160] Festo AG & Co. KG, „Datenblatt Elektrozyylinder ESBF, mit Spindelantrieb,“ 2017. [Online]. Available: https://www.festo.com/cat/en-gb_gb/data/doc_DE/PDF/DE/ESBF_DE.PDF. [Zugriff am 21. 08. 2017].
- [161] J. Forstmann, "Kugelgewindetriebe im Einsatz an Kunststoffspritzgießmaschinen - Lebensdauerprognose und Optimierung," Dissertation, Universität Duisburg-Essen: Fakultät für Ingenieurwissenschaften, Abteilung Maschinenbau und Verfahrenstechnik, 2010.
- [162] K. Kühn, „Protokoll zum MoSeS-Pro Projekttreffen 14.01.2016,“ Festo AG & Co. KG, Esslingen / Berkheim, 2016.
- [163] M. Siegwart, „Optimierung der Endprüfung elektrischer Spindelachsen mit dem Ansatz multivariater Verfahren und Erarbeitung eines Konzeptes zur Prozessintegration,“ Masterarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, 2014.
- [164] B. Denkena, A. Harms, J. Jacobsen, H.-C. Möhring und H. Noske, „Lebenszyklus-orientierte Werkzeugmaschinenentwicklung,“ *wt*

Werkstattstechnik online, pp. 441-446, 96 2006.

- [165] J. Hirschmann, "Ein Beitrag zur Fehlerfrüh- und Fehlerdiagnose von elektromechanischen Antriebseinheiten in der Automatisierungstechnik," Dissertation, Institut für Industrielle Fertigung und Fabrikbetrieb, Universität Stuttgart, 2006.
- [166] D. Maier, „Sensorlose online Zustandserfassung von Vorschubantriebskomponenten in Werkzeugmaschinen,“ Dissertation, Fakultät Konstruktions-, Produktions- und Fahrzeugtechnik, Universität Stuttgart, 2015.
- [167] M. Walther, „Antriebsbasierte Zustandsdiagnose von Vorschubantrieben,“ Dissertation, Fakultät Konstruktions-, Produktions- und Fahrzeugtechnik, Universität Stuttgart, 2011.
- [168] M. Theobald, „Entwicklung möglicher Schädigungsindikatoren für die Körperschallanalyse elektromechanischer Spindelachsen,“ Masterthesis, Hochschule für Technik und Wirtschaft des Saarlandes, Saarbrücken, 2012.
- [169] A. Huf, "Kumulative Lastermittlung aus Antriebsdaten zur Zustandsbewertung von Werkzeugmaschinen," Dissertation, Heimsheim: Jost-Jetter Verlag, 2012, ISBN: 978-3-939890-96-6.
- [170] Festo AG & Co. KG, „Datenblatt Motorcontroller CMMP-AS, für Servomotoren,“ 2015.
- [171] Nadella - Linear and Motion Solutions, „Kugelgewindetriebe Katalog 2014,“ 2014. [Online]. Available: https://www.nadella.de/fileadmin/data/04_Downloads/Kataloge/nadella-downloads-kataloge-kugelgewindetriebe.pdf. [Zugriff am 21. 08. 2017].
- [172] H.-J. Dennig, "Entwicklung einer schnell schaltenden Bremse und Kupplung für Linearbewegungen zum Überlastschutz in Werkzeugmaschinen," Dissertation, Universität Stuttgart: Fakultät Konstruktions-, Produktions- und Fahrzeugtechnik, 2009.
- [173] J. Imiela, „Verfügbarkeitssicherung von Werkzeugmaschinenachsen mit Kugelgewindetrieb durch modellbasierte Verschleißüberwachung,“ Dissertation, Fachbereich Maschinenbau, Universität Hannover, 2006.
- [174] THK - Technical Support, „Kugelgewindetriebe - Merkmale und Typen,“ [Online]. Available: https://tech.thk.com/de/products/pdf/de_b15_006.pdf. [Zugriff am 21. 07. 2018].

- [175] W. Klein, "Zustandsüberwachung von Rollen-Profileschienenführungen und Kugelgewindetrieben," Dissertation, Aachen: Apprimus-Verlag, 2011, ISBN: 978-3-86359-029-1.
- [176] Dr.-Ing. Paul Christiani GmbH & Co. KG - Technisches Institut für Aus- und Weiterbildung, „Wälzlager und Wälzlagerungen,“ [Online]. Available: http://www.christiani.de/pdf/84539_probe.pdf. [Zugriff am 23. 08. 2017].
- [177] G. Bate, „Application Notes - Vibration Diagnostics for Industrial Electric Drives,“ Brüel & Kjaer, Naerum, Denmark, abgerufen 2017.
- [178] K. Sommer, R. Heinz und J. Schöfer, Verschleiß metallischer Werkstoffe, Springer-Verlag, 2014, ISBN: 383482464X.
- [179] H. Czichos und K.-H. Habig, Tribologie-Handbuch, Vieweg+Teubner Verlag, 2010, ISBN: 978-3-8348-0017-6.
- [180] H. Hertz, „Über die Berührung fester elastischer Körper,“ *Journal für die reine und angewandte Mathematik* 92, pp. 156-171, 1881.
- [181] H. Nguyen-Schäfter, Numerische Auslegung von Wälzlagern, Berlin: Springer-Vieweg Verlag, 2017, ISBN: 978-3-662-54988-9.
- [182] Festo AG & Co. KG, „Bedienungsanleitung Servomotor EMMS-AS-100-S“.
- [183] Festo AG & Co. KG, „Datenblatt Normzylinder DNC, ISO 15552,“ 2017.
- [184] Lorenz Messtechnik GmbH, „Datenblatt Zug - und Druckkraftsensor K-25“.
- [185] LORENZ MESSTECHNIK GmbH, „Datenblatt DR-2112 - Berührungsloser Drehmomentsensor, rotierend,“ [Online]. Available: http://www.lorenz-messtechnik.de/pdfdatbl/m/080174zh_dr-2112.pdf. [Zugriff am 05 11 2017].
- [186] S. Zand-Vakili, „Mechanische Konzeption, Simulation und Umsetzung eines Lebensdauer-Prüfstands für elektromechanische Achsen,“ Bachelorarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, 2016.
- [187] Festo AG & Co. KG, „Datasheet Modular controllers CECX,“ 2015.
- [188] Festo AG & Co. KG, „Datenblatt Sicherheitsmodul CAMC-G-S3“.
- [189] A. Ohanessian, „Konzeption und Umsetzung der Ablaufsteuerung und Datenerfassung eines Lebensdauer-Prüfstands für elektromechanische Achsen,“ Bachelorarbeit, Lehrstuhl für Messtechnik, Universität des Saarlandes, 2017.

- [190] National Instruments, „PXIe-5170 Specifications,“ 2017.
- [191] National Instruments, „NI 449x Specifications,“ 2012.
- [192] National Instruments, „NI 6341 Specifications,“ 2016.
- [193] The HDF Group, „What is HDF5?,“ 27. 01. 2017. [Online]. Available: <https://support.hdfgroup.org/HDF5/whatishdf5.html>. [Zugriff am 15. 09. 2017].
- [194] Sensitec GmbH, „Datasheet CMS2005,“ 2015.
- [195] Kistler Instrument Corporation, „K-Shear® Accelerometers Type 8702B..,8704B..,“ 2008.
- [196] Kistler Instrument Corporation, „K-Shear® Accelerometer Type 8712A5M1,“ 2008.
- [197] G.R.A.S. Sound & Vibration, „Datasheet 46BE 1/4" CCP Free-field Standard Microphone,“ 2015.
- [198] ALTHEN Meß- und Sensortechnik GmbH, „Datenblatt Wägezellen AUMM und AUMMA,“ 2015.
- [199] Festo AG & Co. KG, „Datenblatt Proportional-Druckregelventile VPPM,“ 2017.
- [200] L. R. Rabiner und R. W. Schafer, *Introduction to Digital Speech Processing*, Hanover, MA, USA: now Publishers Inc., 2007.
- [201] M. Bastuck, M. Leidinger, T. Sauerwald und A. Schütze, „Improved Quantification of Naphthalene Using Non-Linear Partial Least Squares Regression,“ in *16th International Symposium on Olfaction and Electronic Nose*, Dijon, France, 2015.
- [202] N. Helwig, P. Merten, T. Schneider und A. Schütze, „Integrated Sensor System for Condition Monitoring of Electromechanical Cylinders,“ *Proceedings of Eurosensors 2017 Conference*, 1, 626 2017, doi:10.3390/proceedings1040626.
- [203] P. Merten, „Entwicklung und mechanische Integration eines Multiparameter-Sensorsystems zum Condition Monitoring elektromechanischer Achsen,“ Bachelorarbeit, Hochschule für Technik und Wirtschaft, Saarbrücken, 2017.
- [204] M. Selke, C. Nienhaus, D. Laumann und J. Doerr, „Universal Sensor Interface for High Performance Signal Processing Based on FPGA Technology,“ in

Proceedings Sensor 2017, Nuremberg, Germany, 2017.

- [205] M. Klusch, A. Meshram, A. Schuetze und N. Helwig, „iCM-Hydraulic: Semantics-Empowered Condition Monitoring of Hydraulic Machines,“ *Proceedings SEMANTiCS*, 2015, doi: <http://dx.doi.org/10.1145/2814864.2814865>.

I Anhang

I.1 Danksagung

An erster Stelle möchte ich Prof. Dr. rer. nat. Andreas Schütze danken, der mir die Möglichkeit zur Promotion in der Arbeitsgruppe Messtechnik am Zentrum für Mechatronik und Automatisierungstechnik gegeben und diese stets hilfreich begleitet und unterstützt hat. Es war eine außerordentlich schöne und spannende Aufgabe, am Aufbau des interdisziplinären Themenfelds „Datengetriebenes Condition Monitoring“ am ZeMA mitzuwirken.

Herrn Prof. Dr.-Ing. Dirk Bähre danke ich sehr für die Übernahme des Zweitgutachtens.

Des Weiteren möchte ich meinen Kollegen am ZeMA für die tolle Zusammenarbeit und schöne gemeinsame Zeit danken, allen voran meinem langjährigen Tischnachbarn Eliseo Pignanelli sowie Tizian Schneider, Nicolas Michaelis und Marco Schott. Danken möchte ich auch Steffen Klein, Tizian Schneider, Philip Merten, Sina Zand-Vakili und Ara Ohanessian, deren Abschlussarbeiten ich betreuen durfte und die somit zum Gelingen dieser Arbeit beigetragen haben.

Allen aktuellen und ehemaligen Kollegen vom Lehrstuhl für Messtechnik an der Universität des Saarlandes danke ich für die gute Zusammenarbeit, speziell sei hier Dr. Marco Schüler genannt, der meine Diplomarbeit betreute.

Nicht zuletzt haben auch die Projektpartner mit inhaltlichen Anregungen und wertvollen Diskussion wichtige Punkte beigetragen. Danken möchte ich hierbei Dr. Horst Mannebach und Jörg Kleber von Hydac (Sulzbach), Ankush Meshram und Dr. Matthias Klusch vom DFKI (Saarbrücken), Jörg Traute von Sensitec (Lahnau) sowie Dr. Karsten Kühn und Michael Siegwart von Festo (Werk St. Ingbert).

Luise, Dir danke ich für Deine Geduld und Dein Verständnis bei der Fertigstellung dieser Arbeit.

Abschließend möchte ich meiner Familie herzlich für ihre immerwährende Unterstützung danken!

I.2 Abkürzungen

Abk.	Beschreibung
ADC	Analog Digital Converter
ANN	Artificial Neural Network
ANOVA	Analysis of Variance
CE	Cooling Efficiency
CP	Cooling Power
CV	Cross Validation
CMS	Condition Monitoring System
DAQ	Data Acquisition
DF	Discriminant Function
DFT	Diskrete Fourier-Transformation
EMZ	Elektromechanischer Zylinder
FCT	Festo Configuration Tool
FE	Feature Extraction
FFT	Fast Fourier Transformation
FS	Feature Selection
FWT	Fast Wavelet Transformation
IR	Infrarot
KGT	Kugelgewindetrieb
k-nn	k nächste Nachbarn
LDA	Linear Discriminant Analysis
LOOCV	Leave One Out Cross Validation
MEMS	Microelectromechanical Systems
MLP	Multilayer Perceptron
MR	magnetoresistiv
OVA	One-vs-All
OVO	One-vs-One
PC	Principal Component
PCA	Principal Component Analysis
PLSR	Partial Least Squares Regression
PS	Pressure Sensor
PWM	Pulsweitenmodulation
QDA	Quadratic Discriminant Analysis
RFESVM	Recursive Feature Elimination SVM
RBF	Radial Basis Function
RMS	Root Mean Square, Effektivwert

SBE	Sequential Backward Elimination
SE	System Efficiency, Wirkungsgrad
SFS	Sequential Forward Selection
SNR	Signal-to-noise Ratio
SPS	Speicherprogrammierbare Steuerung
SOM	Self-organizing Map
SSB	Sum of Squares between the Groups
SSW	Sum of Squares within the Group
SVM	Support Vector Machines
TP	Tiefpass
TS	Temperature Sensor
WEA	Windenergieanlage
WT	Wavelet Transformation

I.3 Abbildungsverzeichnis

Abbildung 1-1. Ökonomische Auswirkungen von Anlagenstörungen aufgeschlüsselt nach Branchen [4].	2
Abbildung 2-1. Multivariate Methoden, zusammengefasst aus [23], [24], [25].	10
Abbildung 2-2. Verteilungsfunktionen bei verschiedenen Werten von a) statistischer Schiefe (3. Moment) und b) Kurtosis (4. Moment).	12
Abbildung 2-3. Under- und Overfitting am Beispiel der Performanz in Abhängigkeit der Merkmalsanzahl (10-fold CV, n=1134). Underfitting (linker Bereich) beschreibt hierbei die Verwendung einer zu geringen Anzahl von Merkmalen, welche die Klassifikation in Kombination nur unzureichend zuverlässig ermöglichen. Overfitting (rechter Bereich) hingegen entsteht bei einer Überanpassung an die Trainingsdaten, etwa bei Verwendung einer zu großen Anzahl von Merkmalen.	16
Abbildung 2-4. Methoden der Merkmalsselektion basierend auf [44].	17
Abbildung 2-5. Projektionsrichtungen PCA und LDA bei zwei Merkmalen (x_1 , x_2) und Klassen (c_1 , c_2).	23
Abbildung 2-6. Beispiel für ein einfaches künstliches neuronales feed-forward Netz mit einer verdeckten Schicht und Aufbau des künstlichen Neurons nach [66].	26
Abbildung 2-7. a) Soft-Margin-SVM in zwei Dimensionen [72], b) Hyperebene der SVM mit RBF-Kernel am Beispiel des Datensatzes Iris flower [73].	28
Abbildung 2-8. Beispiel für ein valides statistisches Modell: Projektion der Trainings- und Testdaten mit quantitativer Abbildung der Zielgröße entlang DF 1 [85].	32
Abbildung 2-9. Vorgehen der k-fold Kreuzvalidierung mit k=10 nach [13].	33
Abbildung 3-1. Vorgehen zur Datengenerierung.	36
Abbildung 3-2. Vorgehen zur Sensordatenanalyse.	38
Abbildung 3-3. Ablauf der Sensordatenanalyse und Evaluierung in Matlab.	40
Abbildung 4-1. Hydraulisches System und dessen Einflussgrößen.	42
Abbildung 4-2. (a) Zahnradpumpe mit Innenverzahnung [113]: 1 Ritzelwelle, 2 Hohlrad, 3 Stift, 4 Füllstück/Dichtkeil, 5 Hydrostatisches Lager, 6 Sauganschluss, 7 Druckanschluss, (b) AMESim-Simulation interner Pumpenleckage: Pumpenvolumenstrom und -leistung in Abhängigkeit des Gegendrucks und der Verschleiß-Geometrie, simuliert als Bypass-Blende (Ölmodell FP04 bei 40°C, $\eta=51\text{cP}$).	46
Abbildung 4-3. a) Aufbau Sitzventil nach [121], b) überlagerte Kräfte beim Schalten über den Hubweg nach [122], c) zeitlicher Verlauf des Spulenstroms und Fluiddrucks beim Be- und Entstromen der Spule nach [122].	48
Abbildung 4-4. (a) Aufbau und Betriebszustände Membranspeicher, (b) qualitatives p-V-Diagramm nach [111].	50

Abbildung 4-5. Simulierte Prozessgrößen beim Hydrospeicher beim Lade- und Entladevorgang in Abhängigkeit des Gasvorfülldrucks p_0 mit den Druckstufen 90, 100, 110, 120 und 130 bar mit dem Öldruck, dem Volumenstrom in den Speicher, dem Gasvolumen sowie der gespeicherten Energie. Zustandsbeschreibung als reales Gas nach dem Modell von Peng-Robinson in AMESim.	51
Abbildung 4-6. Kühler: (a) verwendetes Wärmewiderstandsnetzwerk, (b) Wärmestrom vs. Schichtdicke s_2 der Verschmutzung sowie Wärmeleitfähigkeit der Ablagerung. Angenommen wird eine Rohrwandstärke von 2 mm (Edelstahl, $\lambda_{Rohr} \approx 20 \text{ Wm} \cdot \text{K}$), eine Isolationsschicht variabler Dicke ($\lambda_{is} = 0,05 \text{ Wm} \cdot \text{K}$ bei Staub, $3 \text{ Wm} \cdot \text{K}$ bei Kalk), bei einer Austauschfläche $A = 1 \text{ m}^2$ und $\Delta T = 40 \text{ K}$. Der Wärmeübergangskoeffizient wurde mit $\alpha = 500 \text{ Wm}^2 \cdot \text{K}$ (Fluid mit erzwungener Konvektion) bzw. $\alpha = 50 \text{ Wm}^2 \cdot \text{K}$ (Luft bei erzwungener Konvektion) angenommen [129].	53
Abbildung 4-7. a) Versuchsaufbau zur Bestimmung der dynamischen Viskosität [131], b) Ubbelohde-Diagramm für Hydrauliköle ISO VG 10 bis 100, VI 100, $p_0 = 1 \text{ bar}$ [131].	56
Abbildung 4-8. a) Einteilung der Fluidkontaminationsarten, b) kritische Partikelgrößen unterschiedlicher Komponenten nach [132].	57
Abbildung 4-9. Hydraulikschaltplan Prüfstand nach [138], [139].	60
Abbildung 4-10. Prüfstände zur Schadens- und Dauerlauf-Charakterisierung. Prüfstand 1 verfügt insgesamt über fünf Speicher, von denen vier mit unterschiedlichen Gasvordrücken p_0 befüllt sind und zur Auswertung verwendet werden.	61
Abbildung 4-11. a) Boxplot Tastgrad Lüfter vs. Kühlleistung und Öltemperatur, b) Zeitliches Temperaturverhalten an den Messstellen im Hydrauliksystem.	62
Abbildung 4-12. Leakage-Boxplot in Abhängigkeit von Öltemperatur und Blendendurchmesser, gemessen von FS1 und referenziert auf den Volumenstrom bei $40 \text{ }^\circ\text{C}$ Öltemperatur.	63
Abbildung 4-13. Gemessene Ventil-Schaltverzögerung in Abhängigkeit.	63
Abbildung 4-14. Gemittelter Druckverlauf (PS1) bei konstantem Arbeitszyklus (a) unter Einwirkung isolierter Schäden, (b) Ladephase Speicher (vgl. Abbildung 4-5), (c) Ventilschaltvorgang.	64
Abbildung 4-15. (a) Lufteintrag in den Arbeitskreislauf, (b) Teststaubzugabe in den Kühl-Filtrier-Kreislauf.	65
Abbildung 4-16. Konzept Steuerung und Datenerfassung.	66
Abbildung 4-17. Umsetzung Schaltschrank.	67
Abbildung 4-18. Positionierung der 3-Achsen Beschleunigungsaufnehmer an MP1 (links) und SP1 (rechts) mit eingezeichneter Motor-Drehrichtung [150].	69
Abbildung 4-19. LabVIEW Benutzeroberfläche während laufender Messung (konstanter Arbeitszyklus) mit (1) Versuchssteuerung (2) Reiter	

Visualisierung/Ablaufkonfiguration (3/4) Graph Sensordaten und (5) Fortschrittsanzeige.	71
Abbildung 4-20. Konfiguration des Messablaufs in LabVIEW mit den Ablaufstufen (1) und (2).	71
Abbildung 4-21. a) Konfiguration der Schadenszustände, b) resultierende Charakterisierungsmessung.	71
Abbildung 4-22. LDA-Plot und Boxplot DF 1 der Schadensstufen (a) Öl-Luft Kühler (10 Merkmale, n=780), (b) Ventilzustand (10 Merkmale, n=697), (c) Pumpenleckage (10 Merkmale, n=1.136), (d) Fülldruck Hydrospeicher (10 Merkmale, n=1.163), (e) DF 1 Kennlinien auf Basis der Gruppenzentroide (schwarz: Training, rot: Evaluierung).	73
Abbildung 4-23. PCA-Plot und Boxplot PC 1 (Preprocessing: Z-Score Standardisierung) der Schadensstufen (a) Öl-Luft Kühler (10 Merkmale, n=780), (b) Ventilzustand (10 Merkmale, n=697), (c) Pumpenleckage (10 Merkmale, n=1.136), (d) Fülldruck Hydrospeicher (10 Merkmale, n=1.163).	74
Abbildung 4-24. Interaktion der Komponentenzustände.	75
Abbildung 4-25. Klassifikationsraten bei konstantem Arbeitszyklus in Abhängigkeit der Merkmalsselektion und -anzahl (LDA mit Mahalanobis-Distanz-Klassifikator, 10-fold Kreuzvalidierung).	76
Abbildung 4-26. Klassifikationsraten bei randomisiertem Arbeitszyklus in Abhängigkeit der Merkmalsselektion und -anzahl (LDA mit Mahalanobis-Distanz Klassifikator, 10-fold Kreuzvalidierung).	78
Abbildung 4-27. Hydrospeicherklassifikation bei randomisiertem Zyklus (20140801) mit alternativen Klassifikatoren: a) Neuronales Netz (Multilayer Perceptron mit 5 Neuronen, eine verdeckte Schicht), Multiclass-SVM mit b) linearem und c) RBF Kernel (,KernelScale'='auto', $\sigma=3,7...5,2$) mit jeweils one-vs-one Klassifikation, C = 1 und ,Standardize' = 1 und jeweils 10-fold CV.	79
Abbildung 4-28. Parametervariation von (a) der Anzahl der verdeckten Schichten des MLP (jeweils 5 Neuronen) und (b) des RBF-Radius der SVM, 10-fold CV.	80
Abbildung 4-29. a) Speicher- und b) Pumpen-Klassifikationsrate in Abhängigkeit der Anzahl involvierter Zyklen und Merkmale (randomisierter Zyklus, 10-fold CV).	81
Abbildung 4-30. Verbesserte Klassentrennung der LDA Projektionen (Speicher-Vordruck) bei zunehmender Zyklenzahl, jeweils 20 Merkmale.	81
Abbildung 4-31. Anlernen der Komponentenschäden mit Prüfstand 1, Projektion der Langzeitdaten über einen Monat von Prüfstand 2. Verwendet wurden 20 (a,b,c) und 50 (d) Merkmale.	82
Abbildung 4-32. Einfluss der Samplingrate auf die Klassifikationsrate mit und ohne Tiefpass (TP) unterteilt nach Schadenstyp und Arbeitszyklus (konstant, randomisiert). 20 Merkmale, Spearman FS, 10-fold CV.	84

Abbildung 4-33. Klassifikationsrate gegenüber Samplingrate und Anzahl der Merkmale ohne Antialiasing bei a) Hydrospeicher bei konstantem Arbeitszyklus und b) Ventil bei randomisiertem Arbeitszyklus.....	84
Abbildung 4-34. Erhöhung der Detektions-Unsicherheit bei Erweiterung des Öltemperaturbereichs, Datensatz Const. 2 mit $n = 405$ bei 1 K / 800 bei 10 K / 1.195 bei 20 K, 20 Merkmale. Zur Vergleichbarkeit erfolgt die Skalierung von DF 1 anhand der äußeren Zentroide im Bereich 0 bis 1.	87
Abbildung 4-35. Charakterisierungsmessung der Störparameter Lufteintrag und Öltemperatur.....	88
Abbildung 4-36. Detektion Ventilzustand bei freier Luft und Ausweitung des Öltemperaturbereichs mit (a) dem Streuverhalten von DF1 und (b) der zugehörigen LDA-Projektion nach [152], 20 Merkmale.	88
Abbildung 4-37. Detektion Pumpenleckage vs. freie Luft und Ausweitung des Öltemperaturbereichs mit (a) Streuverhalten von DF1, (b) zugehörige LDA-Projektion nach [152], 20 Merkmale.	89
Abbildung 4-38. Wirkungsgradverlauf bei Störgrößeneinfluss.	89
Abbildung 4-39. (a) Pumpenleckage trainiert bei normaler Öltemperatur, Projektion der übrigen Klassen, (b) Training bei normaler und hoher Temperatur, Projektion der Zwischenklasse, jeweils 20 Merkmale.	91
Abbildung 4-40. Vergleich der Selektion auf Basis des Datensatzes Const. 1 bei konstanter (ohne Störgröße) und variierter (mit Störgröße) Öltemperatur aufgeschlüsselt nach Sensoren, Intervallen und Funktionen der 50 relevantesten Merkmale (Spearman).	92
Abbildung 4-41. Charakterisierungsmessung mit (a) Partikelkontamination gemessen mit Hydac CS1000 mit Partikel $> 14 \mu\text{m}$ unterhalb des Detektionslimits, (b) Differenzdruck über Filterelement F2, (c) Boxplot der Reinheitsklassen nach ISO 4406 hinter dem Filter, extrahiert aus (a), nach [152].	94
Abbildung 4-42. Abschätzung der Partikelbelastung [152] aus Basis von 50 Langzeit-Merkmalen über 60 Zyklen; (a) LDA-Projektion der vier Kontaminationsklassen und (b) gruppenbezogenes Histogramm von DF 1.	95
Abbildung 4-43. Überwachung Filterbeladung [152] mit (a) Histogramm des Mittelwerts von Δp , (b) Histogramm DF 1 auf Basis der 50 höchstkorrelierten Merkmale, jeweils mit angeglicherer Skalierung, (c) LDA-Projektion zu (b).	95
Abbildung 4-44. Arbeitszyklus analog zu Abbildung 4-14: (a) Rohsignal Beschleunigung in x-Richtung von MP1, (b) Spektrogrammdarstellung von (a) mit den erkennbaren Laststufen des Zyklus.	97
Abbildung 4-45. Training auf Basis der Schwingungsdaten von Hydraulikaggregat 1, Projektion Langzeitdaten Aggregat 2 von (a) Ventil, (b) Pumpe, (c) Speicher, (d) zeitlicher Verlauf DF 1 nach [85]. Zum Zeitpunkt $t = 0$ Start der Projektionsphase (dargestellt	

ist der Zeitraum Tag 30 bis 43 nach dem Training), zuvor ($t < 0$) Generieren der Trainingsdaten.....	98
Abbildung 4-46. (a) Verlauf der Charakterisierungsmessung, (b) LDA-Projektion auf Basis der Prozesssensoren, (c) LDA-Projektion der Zustände auf Basis des 3-Achsen MEMS g-Sensors an SP1 mit 20 Merkmalen.	99
Abbildung 4-47. Einfluss der Frequenzbreite bei der Merkmalsextraktion auf die Klassifikation (oben: 10-fold Mahalanobis-Distanz Kreuzvalidierung, unten: ANOVA F von DF 1; FS = PCA).....	100
Abbildung 4-48. Beispiel für (a) Heteroskedastizität und (b) nicht normalverteilte Merkmale.	103
Abbildung 4-49. Vergleich der 10-fold Kreuzvalidierung mit und ohne Einbeziehung der Merkmalsselektion (Spearman FS, 20 Merkmale, Mahalanobis-Distanz Klassifikator).....	104
Abbildung 4-50. Berechnungsdauer (a) im Gesamtkontext, (b) nach Merkmal, (c) nach Selektionsverfahren, (d) nach Klassifikationsverfahren. Die Berechnungen wurden sequentiell auf einem HP EliteBook 8540w Laptop (Core i5 M560 @ 2,67 GHz, 8 GB RAM, MATLAB R2016b, Windows 7 Professional SP1) durchgeführt.	105
Abbildung 4-51. In MATLAB simulierte Sensorfehler bei PS1 nach [157].....	106
Abbildung 4-52. Einfluss von überlagertem Rauschen und Drift (alle Sensoren) auf die Klassifikation: a) Pumpe, b) Speicher (20 Merkmale).	107
Abbildung 4-53. LDA-Projektion zum Erkennen von Sensorfehlern am Beispiel von PS1: a) SNR Degradation, b) Signaldrift, c) Signaloffset, d) Anzahl zufälliger Ausreißer pro Zyklus.	108
Abbildung 4-54. Resilienzverhalten: Klassifikationsrate in Abhängigkeit der Anzahl ausgeschlossener relevantester Sensoren (10 Merkmale, Spearman FS, 10-fold CV, Mahalanobis-Distanz Klassifikator bei LDA).....	110
Abbildung 5-1. Betriebsverhalten elektromechanischer Zylinder.	114
Abbildung 5-2. Aufbau elektromechanischer Zylinder (vereinfachte Darstellung).	117
Abbildung 5-3. Kaskadenregelung nach [167], [170].....	117
Abbildung 5-4. Interne (links) und externe (rechts) Kugelrückführung [171].....	118
Abbildung 5-5. Kräftebilanz am Gewindetrieb [173] (entnommen aus [161]).	120
Abbildung 5-6. Wirkungsgrad in Abhängigkeit des Reibungskoeffizienten μ und des Steigungswinkels φ bei (a) der Umwandlung einer Rotationsbewegung in eine Linearbewegung, (b) vice versa [174].	121
Abbildung 5-7. Relevante Maße beim Kugellager (a,b), und beim Kugelgewindetrieb (b,c) nach DIN 69051 [167].	121
Abbildung 5-8. Gemessene Kugelpassierfrequenz am Rückführsystem bei einem neuen KGT.	125
Abbildung 5-9. Gemittelte Schwingungsanteile < 500 Hz an der Kolbenstange in Abhängigkeit der Verfahrensgeschwindigkeit bei verschlissenen KGT ohne axiale Last.	125

Abbildung 5-10. Lastabhängigkeit des Schwingungsspektrums bei verschlissenenem KGT (200 mm/s), (a) bis 20 kHz und (b) Ausschnitt bis 500 Hz.	126
Abbildung 5-11. Schadens- und Verschleißarten und ihre Entstehung am Kugelgewindetrieb nach [161].	129
Abbildung 5-12. CAD-Modell nach [186].	131
Abbildung 5-13. Realisierung des Spindelachsen-Prüfstands.	132
Abbildung 5-14. Prüfablaufgenerierung und Datenerfassung in LabVIEW, (1) Steuerung Messung, (2) Zykluskonfiguration, (3) Visualisierung Sensordaten.	133
Abbildung 5-15. Steuerung des EMZ-Dauerlaufprüfstands.	133
Abbildung 5-16. Sensordatenerfassung Spindelachsenprüfstand.	134
Abbildung 5-17. Bereiche des Verfahrenzyklus.	135
Abbildung 5-18. Gemessene Kraft- und Drehmomentverläufe der drei Lebensdauerversuche (I), (II), (III).	136
Abbildung 5-19. Vorgehen zur Merkmalsextraktion.	137
Abbildung 5-20. Amplitudenverläufe Luft-/Körperschall Versuch 1. Im Bereich Tag 15-16 liegen teilweise wegen fehlerhafter Synchronisation keine Daten vor.	139
Abbildung 5-21. Verlauf Amplitudenspektrum Kolbenstange Versuch I.	139
Abbildung 5-22. Temperaturverläufe Versuch I im klimatisierten Labor.	140
Abbildung 5-23. LDA-Projektion der Trainings- und Testdaten von Versuch I (links), DF 1 über die Lebenszeit (rechts).	140
Abbildung 5-24. Verteilung der 100 signifikantesten Merkmale (Versuch I) bezogen auf deren Anteil der relativen Spearman Korrelation.	141
Abbildung 5-25. (a) 10-fold Kreuzvalidierung, (b) korrespondierender F-Wert von DF 1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 1-Tages Abschnitte mit insgesamt 21 Klassen (n=20.400), entspricht ca. 4,8 % Lebenszeit.	141
Abbildung 5-26. Amplitudenverlauf Luft-/Körperschall Versuch II.	142
Abbildung 5-27. Verlauf Amplitudenspektrum Kolbenstange Versuch II.	143
Abbildung 5-28. Temperaturverläufe Versuch II bei nichtklimatisierter Umgebung.	143
Abbildung 5-29. LDA-Projektion der Trainings- (schwarz-weiß) und Testdaten (farbig) von Versuch II (links) sowie Verlauf DF 1 über die Lebenszeit (rechts).	144
Abbildung 5-30. Verteilung der 100 signifikantesten Merkmale aus dem Zeit- und Frequenzbereich (Versuch II) bezogen auf deren Anteil der relativen Spearman Korrelation.	144
Abbildung 5-31. (a) 10-fold Kreuzvalidierung, (b) korrespondierender F-Wert von DF1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 3-Tages Abschnitte mit insgesamt 27 Klassen (n=18.880), entspricht einer Auflösung von ca. 3,7 % Lebensdauer.	145
Abbildung 5-32. Amplitudenverlauf Luft-/Körperschall Versuch III.	145

Abbildung 5-33. Verlauf Amplitudenspektrum Kolbenstange Versuch III.	146
Abbildung 5-34. Temperaturverläufe Versuch III.	146
Abbildung 5-35. LDA-Projektion der Trainings- (schwarz-weiß) und Testdaten (farbig) von Versuch III (links). Zum Training wurde chronologisch nur jede zweite Klasse verwendet. Rechts: DF 1 über die Lebenszeit.	147
Abbildung 5-36. Verteilung der 100 signifikantesten Merkmale aus dem Zeit- und Frequenzbereich (Versuch III) bezogen auf deren Anteil der relativen Spearman Korrelation.	147
Abbildung 5-37. (a) 10-fold CV, (b) korrespondierender F-Wert von DF1 in Abhängigkeit der Anzahl der Merkmale. Gruppierung in 0,8-Tages Abschnitte mit insgesamt 26 Klassen (n=50.320), entspricht einer Auflösung von ca. 3,8 % Lebensdauer.	148
Abbildung 5-38. Direkte LDA-Projektion der Daten von (III) mit dem Modell erzeugt aus (II), Klasseneinteilung nach relativer Lebenszeit, 50 Merkmale.	149
Abbildung 5-39. Kombiniertes statistisches Modell von Versuch II (a) und III (b). Merkmalsselektion auf Basis aller Schwingungsdaten, Auswahl von 100 Merkmalen (Spearman).	150
Abbildung 5-40. Wirkstromverlauf während des Arbeitszyklus mit Intervallunterteilung.	151
Abbildung 5-41. LDA-Projektion auf Basis der 10 höchstkorrelierten Motorcontroller-Merkmale (Tabelle 5-8), Datensatz Versuch III.	152
Abbildung 5-42. Verschleißspuren an den Kugeln des KGT nach dem Lebensdauertest II, (a) oben unauffällige Kugeloberfläche, unten makroskopische Furchenbildung (b) großflächige Ausbrüche, (c) Kratzspuren und Oberflächenrauigkeit.	153
Abbildung 5-43. (a) Spindel und (b) Spindelmutter nach Versuch II.	154
Abbildung 5-44. Kugelgewindetrieb nach Versuch III.	154

I.4 Tabellenverzeichnis

Tabelle 1-1. Wartungsstrategien und deren Vor- und Nachteile.....	1
Tabelle 1-2. Exemplarische Auswahl von Messgrößen zur Zustandsüberwachung nach [5], [7].	3
Tabelle 1-3. Gegenüberstellung der Anwendungsszenarien.	6
Tabelle 3-1. Gegenüberstellung der verwendeten Klassifikatoren (+ gut, o neutral, - schlecht)	39
Tabelle 3-2. Verwendete Matlab Funktionen.....	40
Tabelle 4-1. Einsatzbedingungen und Parameter hydropneumatischer Speicher nach [91], [111].	51
Tabelle 4-2. ISO 4406: Auszug der Reinheitsklassen nach Anzahl der Partikel pro 100 ml.	57
Tabelle 4-3. Generierbare Schadenszustände an Prüfstand 1.....	61
Tabelle 4-4. Physische und virtuelle Sensoren im ICM-Hydraulik System.....	68
Tabelle 4-5. Test auf Normalverteilung DF 1 nach Klassen aufgeschlüsselt (grau hinterlegt: Projektion) nach Shapiro-Wilk (SW), Lilliefors (Lill), Kolmogorov-Smirnov (KS). Markierung (x), wenn Normalverteilung nicht zurückgewiesen werden kann (Signifikanzniveau 0,05).	74
Tabelle 4-6. Untersuchte Datensätze mit jeweiligen Prozess-/Schadensparametern. Zyklen mit Übergangszuständen bzw. Ausreißern wurden vorab aus den Datensätzen entfernt.	75
Tabelle 4-7. Höchstkorrelierte Merkmale (Spearman) nach Zielgröße für den Datensatz Const.1 mit zugehörigem Ranking-Wert $ \rho $. Die Merkmals-Funktionen sind Median (Med), Varianz (Var), Schiefe (Sch), Kurtosis (Ku), Steigung (St) sowie Position des Maximums (Pos). Sensorbezeichnungen (Sns) nach Abbildung 4-9, Intervallbezeichnungen (Int) nach Abbildung 4-14.....	77
Tabelle 4-8. Ausgewählte Schwingungsmerkmale von MP1 nach Schadenstyp (beste 5 aus 20, Spearman-Korrelation).....	98
Tabelle 4-9. LDA-Kreuzvalidierungsrate (10-fold, 20 Merkmale) der Pumpenzustände in Abhängigkeit der Merkmalsselektion und des Klassifikators (3-nächste-Nachbarn, 3-NN, und Mahalanobis-Distanz).	100
Tabelle 4-10. Einfluss der Signalvorverarbeitung auf die Kreuzvalidierungsrate [%] (10-fold CV, Mahalanobis-Distanz Klassifikator, 20 Merkmale, Spearman FS).....	102
Tabelle 4-11. Pearson Korrelationsmatrix der 5 höchstkorrelierten Merkmale zur Ventilüberwachung.	103
Tabelle 5-1. Relevante Arbeiten im Bereich Zustandsüberwachung von KGT mit den verwendeten Messgrößen Temperatur (T), Drehmoment (M), Vibration (Vib.), Position (s), Geschwindigkeit (v), Motorstrom (I), Drehzahl (n) und Kraft (F).....	116
Tabelle 5-2. Geometriedaten der verwendeten Komponenten nach [168]. Die Anzahl z der Kugeln pro Umdrehung im KGT muss hierbei nicht ganzzahlig vorliegen.	124

Tabelle 5-3. Charakteristische mechanische Frequenzen des elektromechanischen Zylinders, berechnete Werte bei $f_n = 40 \text{ Hz}$. Nach [175], [176].	124
Tabelle 5-4. Verwendete Messgrößen und Signale Spindelachsenprüfstand. Bei der extern durchgeführten Luftschallmessung ist aufgrund des KGT-Gehäuses mit einer starken Dämpfung der höheren Anregungsfrequenzen zu rechnen, sodass eine Abtastrate von 100 kHz als ausreichend bewertet wird.....	135
Tabelle 5-5. Durchgeführte Lebensdauerversuche EMZ baugleichen Typs (Festo ESBF-63-400-5P) mit Laufleistungen s , Druck p des Pneumatikzylinders, Verfahrgeschwindigkeit v und Beschleunigung a des EMZ sowie der Art der mechanischen Verbindung zwischen Motor und Spindelachse. Bei Versuch I ging der Ausfall der Achse mit einem Prüfstandsdefekt einher, Versuch II und III wurden aufgrund eines Schleppfehlers abgebrochen.	135
Tabelle 5-6. Konfiguration der multivariaten Auswertung von Versuch I – III.	138
Tabelle 5-7. Selektierte Schwingungs-Merkmale der kombinierten Daten aufgeschlüsselt nach Sensoren (Kolbenstange KS, Kugellager KL und Mikrofon Mi), Frequenzbereich und Funktion (Median Me, Varianz Var, Schiefe Sch, Kurtosis Kur und Steigung St).....	150
Tabelle 5-8. Selektierte Merkmale (Spearman) der Messgrößen Wirkstrom (I) und Geschwindigkeit (v) mit den Funktionen Median (Me), Varianz (Var), Schiefe (Sch) und Kurtosis (Ku).	151

I.5 Eigene Veröffentlichungen und Vorträge

Jahr	Art	Autor	Titel	Journal / Konferenz / Veranstaltung
2018	Vortrag / Artikel	T. Schneider, S. Klein, N. Helwig, A. Schütze, M. Selke, C. Nienhaus, D. Laumann, M. Siegwart, K. Kühn	Big Data Analytik mit automatisierter Signalverarbeitung für Condition Monitoring	Sensoren und Messsysteme 2018, 19. ITG/GMA-Fachtagung, Vortrag, Session Sensorik für die Industrie 4.0, 26. - 27. Juni 2018, Nürnberg, D. in: ITG-Fachbericht 281: Sensoren und Messsysteme, VDE-Verlag Berlin (2018), ISBN 978-3-8007-4683-5, S. 259-262.
2018	Conference Paper	T. Schneider, N. Helwig, A. Schütze	Automatic Feature Extraction and Selection for Condition Monitoring and related Datasets	I ² MTC-2018 - The IEEE 2018 International Instrumentation and Measurement Technology Conference, poster, Proc. pp. 429-434 (ISBN: 978-1-5386-2222-3), May 14-17, Houston, TX, US
2018	Journal Paper	T. Schneider, N. Helwig, A. Schütze	Industrial condition monitoring with smart sensors using automated feature extraction and selection	IOP Meas. Sci. Technol. (2018), (accepted, in press; published online 09 July 2018) doi: 10.1088/1361-6501/aad1d4
2018	Journal Paper	A. Schütze, N. Helwig, T. Schneider	Sensors 4.0 – smart sensors and measurement technology enable Industry 4.0	J. Sens. Sens. Syst. (2018), 7, 359–371 (open access) doi: 10.5194/jsss-7-359-2018
2017	Journal Paper	A. Schütze, N. Helwig	Sensorik und Messtechnik für die Industrie 4.0 - (Sensors, instrumentation and measurement science for “Industrie 4.0”)	tm - Technisches Messen (2017), 83(4), 208–218 doi: 10.1515/teme-2016-0047
2017	Poster	T. Schneider, N. Helwig, A. Schütze	Modular Sensor Systems for real time Process Control and Smart Condition Monitoring – MoSeS-Pro	IEEE Sensors Conference 2017, open poster, Glasgow, Scotland, Oct 30 - Nov 1, 2017.
2017	Artikel	N. Helwig	Intelligente Sensorsysteme für Industrie 4.0	Industrial Quality, Ausgabe 3 2017, accura-medien UG
2017	Conference Paper	N. Helwig, P. Merten, T. Schneider, A. Schütze	Integrated Sensor System for Condition Monitoring of Electromechanical Cylinders	31st Eurosensors Conference, Paris, France, 3-6 September, 2017(accepted for Lecture presentation)
2017	Journal Paper	T. Schneider, N. Helwig, A. Schütze	Automatic feature extraction and selection for classification of cyclical time series data	tm – Technisches Messen (2017), 84(3), 198–206. doi: 10.1515/teme-2016-0072
2017	Conference Paper	A. Schütze, N. Helwig	Sensors 4.0 – Smart sensors and measurement technology enable Industry 4.0	14th xMR-Symposium “Magnetoresistive Sensors and Magnetic Systems”, Sensitec GmbH (ed.), Wetzlar, Germany, March 21-22, 2017; Proceedings page 2-8
2017	Conference Paper / Vortrag	N. Helwig, T. Schneider, A. Schütze	Modular sensor systems for real time process control and smart condition monitoring using XMR technology	14th xMR-Symposium “Magnetoresistive Sensors and Magnetic Systems”, Sensitec GmbH (ed.), Wetzlar, Germany, March 21-22, 2017.; proceedings page 15-22.

2017	Vortrag	N. Helwig	Smarte Zustandsbewertung: Was Sensorsignal-Muster über Maschinenzustände verraten	Forum Industrial Automation, Hannover Messe 2017, Hannover, Germany, 24. April 2017
2017	Poster	A. Schütze, T. Schneider, N. Helwig	Modular Sensor Systems for real time Process Control and Smart Condition Monitoring – MoSeS-Pro	IEEE Sensors Conference 2017, open poster, Glasgow, Scotland, Oct 30 - Nov 1, 2017.
2016	Vortrag	N. Helwig, T. Schneider, A. Schütze	Modulare Sensorsysteme für Echtzeit-Prozesssteuerung und smarte Zustandsbewertung	1. VDI-Fachkonferenz Intelligente Sensoren für Industrie 4.0, Nürtingen bei Stuttgart , 20./21. September 2016
2016	Vortrag	N. Helwig	Zustandsbewertung durch statistische Datenanalyse mit preiswerten Beschleunigungssensoren	2. Tag der Fluidtechnik „Smart Fluid Power Systems“, ZeMA gGmbH, Saarbrücken, 11.10.2016
2016	Conference Paper / Vortrag	N. Helwig, A. Schütze	Statistische Analyse von Schwingungs- und Prozesssensordaten zur Zustandsbewertung	4. VDI-Fachtagung Schwingungsanalyse & Identifikation 2016, Fulda, Germany, 15.-16. März 2016
2016	Vortrag	N. Helwig	Multiparameter-Sensorsysteme zur Online-Zustandsbewertung von Produktionsanlagen und -prozessen	Forum Industrial Automation, Hannover Messe 2016, Hannover, Germany, 25. April 2016
2016	Conference Paper / Vortrag	N. Helwig, A. Schütze	Data-based condition monitoring of a fluid power system with varying oil parameters	10. Internationales Fluidtechnisches Kolloquium (IFK) "Smart FluidP Power Systems", Dresden, Germany, March 8-10, 2016
2015	Artikel	N. Helwig, A. Schütze	Erkennen von Maschinenfehlern	SPS-Magazin 7/2015
2015	Conference paper / Vortrag	N. Helwig, E. Pignanelli, A. Schütze	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
2015	Conference Paper / Poster	N. Helwig, E. Pignanelli, A. Schütze	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
2015	Conference Paper	N. Helwig, S. Klein, A. Schütze	Identification and quantification of hydraulic system faults based on multivariate statistics using spectral vibration features	Procedia Engineering, 2015. DOI:10.1016/j.proeng.2015.08.835
2015	Conference Paper	M. Klusch, A. Meshram, A. Schuetze, N. Helwig	ICM-Hydraulic: Semantics-Empowered Condition Monitoring of Hydraulic Machines	Proc. 11th International Conference on Semantic Systems (SEMANTiCS); Vienna, Austria; ACM, 2015.
2014	Conference Paper	N. Helwig, A. Schütze	Intelligentes Condition Monitoring mit automatisierter Merkmalsgenerierung und -bewertung	XXVIII. Messtechnisches Symposium des Arbeitskreises der Hochschullehrer für Messtechnik, Tagungsband, Shaker Verlag, Aachen (2014), ISBN 978-3-8440-2994-9, S. 121-128

2014	Journal Paper	N. Helwig, M. Schüler, C. Bur, A. Schütze, T. Sauerwald	Gas mixing apparatus for automated gas sensor characterization	Measurement Science and Technology, 25(5), 055903.
2013	Conference Paper	M. Schüler, N. Helwig, A. Schütze, G. Ventura	Detecting trace-level concentrations of volatile organic compounds with metal oxide gas sensors	SENSORS, 2013 IEEE, 3-6 Nov. 2013, Baltimore, MD, USA. DOI: 10.1109/ICSENS.2013.6688276
2013	Conference Paper	C. Bur, M. Andersson, A. Lloyd Spetz, N. Helwig, A. Schütze	Detecting Volatile Organic Compounds in the ppb Range With Gas Sensitive Platinum Gate SiC- Field Effect Transistors	SENSORS, 2013 IEEE, 3-6 Nov. 2013, Baltimore, MD, USA. DOI: 10.1109/ICSENS.2013.6688279
