

Identifikation robuster Merkmale für die technische
Diagnostik von netzgespeisten Asynchronmotoren und der
angetriebenen Arbeitsmaschinen

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

von
Sebastian Bold

Saarbrücken

2025

Tag des Kolloquiums: 23.07.2025

Dekan: Prof. Dr.-Ing. Dirk Bähre

Berichterstatter: Prof. Dr.-Ing. Matthias Nienhaus

Prof. Dr.-Ing. Sven Urschel

Prof. Dr. Andreas Schütze

Vorsitz: Prof. Dr.-Ing. Michael Vielhaber

Akad. Mitarbeiter: Dr.-Ing. Abdurrahman Irscheid

Danksagung

Ich schreibe diese Zeilen zum Ende meiner nun sechs Jahre dauernden Promotion. Kurz vor Ende dieser langen Reise überblicke ich diese Zeit und kann mich nur wundern, wie ich selbst meine bisher größte Herausforderung bewältigen konnte. Die Antwort ist dabei naheliegend. Neben meinem Ehrgeiz und großem Interesse an Technik und Forschung waren es gute Betreuer, Kollegen, Freunde und Familie, die mich in dieser langen Zeit unterstützt und gestützt haben.

Aus diesem Grund möchte ich zuerst Prof. Dr. Matthias Nienhaus danken, der durch eine kluge Auswahl geforderter Auflagen die Basis dieser Arbeit gelegt hat. Zudem weiß ich die Diskussionsrunden sehr zu schätzen, die wir während der Forschungsphase, aber auch bei der Ausarbeitung der Dissertation hatten.

Für die andauernde Unterstützung im Labor, zum einen bei der Ausführung der Experimente, aber auch bei der Diskussion der Ergebnisse, möchte ich mich bei meinen Kollegen Vincent Becker, Thilo Schwamm, Marco Garbe und Daniel Dieterich bedanken. Daneben haben mich auch viele Studierende mit ihren Arbeiten unterstützt. Herausgeragt haben dabei Frank Noussi, Aslan Ali und Jan Jurkat.

Neben der fachlichen Unterstützung ist bei einer so langen Reise auch die soziale Unterstützung maßgeblich und entscheidet über Gelingen oder nicht Gelingen. Ich bedanke mich daher außerordentlich bei meiner Familie, bei der ich immer einen Rückzugsort hatte. Außerdem bei meinen Freunden aus Neustadt an der Weinstraße, die immer mit einem offenen Ohr für mich da waren.

Last but not least gilt mein ganz besonderer Dank Prof. Dr. Sven Urschel dem ich diese großartige Chance zu verdanken habe. Lieber Sven, vielen Dank für die vielen konstruktiven Gespräche gerade bei den sehr unterschiedlichen Ansichten, die wir beide haben. Für deine andauernde Unterstützung und deinen klugen Rat. Ich schätze mich sehr glücklich, dich als meinen Mentor gefunden zu haben.

Kurzfassung

Technische Diagnostik ist eine Disziplin, die lange Zeit nur für große Anlagen mit hohen Schadenssummen angewendet wurde, jedoch verschieben jüngste Entwicklungen die Anwendungsgrenze auf kleine Anlagen und Aggregate.

Sensorarme Ansätze, die dies ermöglichen, profitieren aktuell von zwei Entwicklungen, dem Data-Mining und der Beschreibung spezieller Maschinenmerkmale. Probleme bei der Anwendung von technischer Diagnostik bleiben Falsch-Positiv-Bewertungen und die Erreichung der notwendigen Fehlerraten bei leicht veränderten Randbedingungen.

Grund dafür ist, dass es derzeit kein Verfahren gibt, das die leistungsstarken Expertenmerkmale im Kontext einer systematischen Wissensgewinnung bewertet und dadurch oft nur partikuläre Lösungen vorhanden sind.

In der vorliegenden Arbeit wird das Knowledge Discovery from Experimental Data als Erweiterung des Knowledge Discovery in Database erarbeitet. In der Praxis erworbene Daten zeigen, dass mit den richtigen Merkmalen eine Klassifizierung der Fehlerzustände auch bei auftretenden Störgrößen möglich ist. Überprüft wurde dies an den exemplarisch betrachteten Fehlern Kavitation, Rotorstabbruch und Fehlaustrichtung.

Mit dem vorgestellten Verfahren wird es somit möglich sein, bei weiteren Kombinationen von Fehlern und Aggregaten effizient nach geeigneten Merkmalsätzen für die technische Diagnostik zu suchen. Gleichzeitig stehen für die genannten Fehler leistungsfähige Merkmalsvektoren zur Verfügung.

Abstract

Technical diagnostics is a discipline that for a long time was only used for large systems with high damage sums, but recent developments are shifting the application limit to small systems and aggregates.

Approaches with few sensors that make this possible are currently benefiting from two developments: data mining and the description of special machine features. Problems with the application of technical diagnostics remain false-positive evaluations and achieving the necessary error rates under slightly different conditions.

The reason for this is that there is currently no method that evaluates the powerful expert characteristics in the context of systematic knowledge acquisition, which means that often only partial solutions are available.

In this thesis, Knowledge Discovery from Experimental Data is developed as an extension of Knowledge Discovery in Database. Data acquired in practice show that, with the right features, it is possible to classify fault states even when disturbance variables occur. This was tested using the faults cavitation, broken rotor bar and misalignment as examples.

With the method presented, it will therefore be possible to efficiently search for suitable feature sets for technical diagnostics for further combinations of faults and aggregates. At the same time, powerful feature vectors are available for the faults mentioned.

Abkürzungsverzeichnis

ACO	Ant Colony Optimization
ASM	Asynchronmotor
ATCSA	Advanced Transient Current Signature Analysis
BG	Baugröße
CNN	Convolutional Neural Network
DFT	Diskrete Fouriertransformation
DNN	Deep Neural Network
ECOC	Error-Correcting Output Coding
FB	Merkmale aus dem Frequenzbereich
FBRZ	Merkmale des Raumzeigers im Frequenzbereich
FT	Fourier-Transformation
GAN	Generative Adversarial Network
KD	Knowledge Discovery
KDD	Knowledge Discovery in Database
KDED	Knowledge Discovery from Experimental Data
KI	Künstliche Intelligenz
KNN	k-nächste Nachbarn
LDA	Lineare Diskriminanz Analyse
LVQ	Learning Vector Quantisation
MCSA	Motor Current Signature Analysis
mRMR	minimale Redundanz maximale Relevanz
NN	Künstliche Neuronale Netze
NPSH	Net Positive Suction Head
PSH	Principal Slot Harmonics
PV	Parallelversatz
RBFN	Radial Basis Function Networks
RH	Rotor Harmonics
RNN	Recurrent Neural Network
SOM	Self-Organizing Maps

SVM	Support Vector Machine
TO	Testobjekt
WT	Wavelet-Transformation
WV	Winkelversatz
WH	Winding Harmonics
ZB	Merkmale aus dem Zeitbereich
ZBRZ	Merkmale des Raumzeiger im Zeitbereich

Formelzeichen und Indizes

- m Anzahl Merkmale im Merkmalsvektor
- \hat{m} Anzahl Merkmale im Merkmalsvorrat
- D Anzahl der Störgrößen des Anwendungsfalls
- n Anzahl der Proben
- k Anzahl der Klassen, Gruppen oder Zustände
- i Allgemeiner Zähler
- j Allgemeiner Zähler
- \underline{M} Merkmalsvektor
- M_i Merkmalsvektor bzw. i -tes Merkmal des Merkmalsvektors
- K Klasse, Gruppe oder Zustand
- p Druck
- T Drehmoment
- R elektrischer Widerstand
- Z Impedanz
- a Abstand
- x Signal
- X Spektrum

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Zielsetzung	2
1.3	Stand der Forschung	4
1.4	Präzisierung der Aufgabenstellung	8
2	Knowledge Discovery from Experimental Data	10
2.1	Vergleich und Definition	10
2.2	Beschreibung des Verfahrens	14
3	Preprozess und Merkmalsextraktion	19
3.1	Virtuelle Sensoren	21
3.2	Transformationen und Kennzahlen	23
4	Data-Mining	28
4.1	Merkmalsselektion	28
4.1.1	Filter-Methoden	29
4.1.2	Wrapper-Methoden	34
4.2	Klassifizierer	38
4.2.1	k-nächste Nachbarn und Learning Vector Quantisation	38
4.2.2	Neuronale Netze	40
4.2.3	Entscheidungsbäume	42
4.2.4	Support Vector Machines	44
4.3	Stabilität der Merkmalsselektion und redundante Merkmale	48
4.4	Fallstudien	52
5	Experimente	55
5.1	Entwurf des Experiments, Zustände und Klassen	55
5.2	Kavitation	59
5.3	Gebrochener Rotorstab	65
5.4	Fehlausrichtung	70
6	Diskussion der Ergebnisse	75
6.1	Kavitation	76
6.2	Gebrochener Rotorstab	83
6.3	Fehlausrichtung	95
6.3.1	Fehlausrichtung bei Last- und Baugrößenänderungen	95
6.3.2	Parallelversatz bei Laständerung – 7,5 kW-Motor	99

6.3.3	Parallelversatz bei Laständerung – 1,1 kW-Motor	105
6.3.4	Winkelversatz bei Laständerung – 7,5 kW-Motor	109
6.3.5	Winkelversatz bei Laständerung – 1,1 kW-Motor	111
7	Schlussbetrachtung und Ausblick	115
8	Anhang	118
8.1	Vollständige Ergebnisse des Data-Mining	118
8.2	Kennzahlen	134
	Literatur	137
	Abbildungsverzeichnis	156
	Tabellenverzeichnis	159
	Glossar	161

1 Einleitung

1.1 Motivation

Die Instandhaltung von technischen Anlagen und Aggregaten ist eine notwendige Maßnahme in industriellen Produktionsstätten und Versorgungseinrichtungen. Das Ziel ist nach [1], die Kosten durch Verschleiß und Ausfall der Komponenten sowie der Instandsetzungsmaßnahmen selbst niedrig zu halten. Maßnahmen der Wartung zielen darauf ab, den Ausfall einer Komponente zu verzögern [2], um die Häufigkeit von Instandsetzungsarbeiten zu reduzieren. Diese Maßnahmen können die degenerativen Prozesse im System nur verlangsamen, nicht jedoch aufhalten.

Zur Bewertung der Restlebenszeit einer Komponente wird dieser ein Abnutzungsvorrat zugeordnet. Dabei handelt es sich nach [3] um den qualitativen Zustand einer Komponente, der für einen zuverlässigen Betrieb benötigt wird und der sich durch den Betrieb stetig verschlechtert, bis es zu Störungen oder dem Ausfall kommt. Nachdem die Ausfallreserve aufgebraucht ist, werden Instandsetzungsmaßnahmen notwendig, um den Betrieb der Komponente fortzuführen. Für den Umgang mit der Ausfallreserve gibt es nach [1] drei Strategien: zeitbasierte Instandhaltung, ausfallbasierte Instandhaltung und zustandsbasierte Instandhaltung. Alle drei Strategien unterscheiden sich hinsichtlich der Bereithaltung von Ersatzkomponenten, der Instandsetzungszeit und des Überwachungsaufwands. Die zustandsbasierte Instandsetzung ist von Interesse, da hierbei die Ausfallreserve durch technische Überwachungsmaßnahmen stärker aufgebraucht werden kann als bei der zeitbasierten Strategie, ohne einen Ausfall wie bei der ausfallbasierten Strategie in Kauf zu nehmen.

Realisiert werden kann die zustandsbasierte Instandhaltung beispielsweise durch den umfangreichen Einsatz von Sensoren an den betroffenen Baugruppen. Der Nachteil dieses Ansatzes ist, dass der Aufwand nur für Anlagen mit einer hohen Schadenssumme oder einem latenten Ausfallrisiko gerechtfertigt ist. Das Pendant dazu sind sensorarme Monitoringverfahren, bei denen die notwendigen Informationen über Algorithmen aus wenigen Sensoren bereitgestellt werden. Mit diesem Ansatz wird die Grenze zur Rentabilität herabgesetzt, sodass auch kleine Anlagen oder einzelne Aggregate überwacht werden können.

Zu dieser Kategorie gehört auch der Asynchronmotor (ASM), der als Teil eines Aggregats häufig Maschinen wie Pumpen und Lüfter antreibt. Aus Kostengründen wird bei dieser Konfiguration oft auf elektronische Systeme wie Sanftstarter oder Frequenzumrichter verzichtet,

was wegen der Netzstartfähigkeit dieser Maschine möglich ist. Aufgrund der großen Bedeutung des ASM und der Vielzahl von Anwendungsmöglichkeiten der technischen Diagnostik liegt der Fokus nachfolgend auf den rotierenden Maschinen und insbesondere auf dem ASM.

Wegen der geringen Anzahl an Sensoren je Aggregat erlaubt der sensorarme Ansatz die Ausweitung der zustandsbasierten Instandhaltung auch auf Maschinenflotten. Werden zudem ausschließlich Sensoren zur Messung von elektrischen Signalen eingesetzt, können die Anwendungsgebiete nochmals erweitert werden. Dies betrifft Bereiche, die aufgrund von beschränkter Zugänglichkeit, geringem Platz, aggressiven Medien und Stäuben oder Explosionsgefahr eine Montage externer Sensoren nicht zulassen. Ausgangspunkt für diesen Ansatz sind die zahlreichen Untersuchungen zu Maschinenfehlern und deren Einfluss auf strombasierte Merkmale, wie in Abs. 1.3 noch verdeutlicht wird.

Selbst mit dem großen Interesse, das die Forschung an diesem Thema zeigt, gibt es weiterhin Forschungsbedarf. Dieser Bedarf besteht zum Beispiel bei der Nutzung des Motorstroms zur Identifikation von Fehlern der angeschlossenen Arbeitsmaschine. Zudem ist die sichere Unterscheidung bei einer Vielzahl von Einflussgrößen und Fehlern nicht eindeutig, da bekannte Merkmale nicht nur von einer Größe beeinflusst werden. Ansätze wie selbstlernende Systeme können diese Probleme für Einzelfälle lösen, der Ansatz ist jedoch wegen der fehlenden Kausalität unbefriedigend. Dieser Mangel führt in der Praxis zu Falsch-Positiv-Bewertungen, die die Akzeptanz der technischen Diagnostik verringern. Ein weiteres Problem, das damit einhergeht, ist die Übertragbarkeit statistischer Modelle auf neue Anwendungen.

1.2 Zielsetzung

In der Forschung zur technischen Diagnostik an rotierenden Maschinen wurden unterschiedliche Methoden erarbeitet, um die Diagnostik auf der Ebene der Software respektive der Algorithmen zu verbessern. Beim analytischen Ansatz werden Modelle aus bekannten physikalischen Gleichungen erstellt, die anschließend durch ein Experiment verifiziert werden. Die Methode setzt ein tiefes Verständnis des betrachteten Systems voraus und eignet sich dafür, grundlegende Wirkmechanismen zu identifizieren oder zu bestätigen. Der Nachteil ist, dass Störeinflüsse oft nicht berücksichtigt werden. Beim datengetriebenen Ansatz werden vorhandene Daten zu einem System nach Zusammenhängen zwischen Merkmalen und Fehlergröße systematisch durchsucht. Dieser Prozess wird als Data-Mining bezeichnet und liefert nutzbare Merkmale auch ohne ein tieferes Verständnis für das System, jedoch ist nicht garantiert, dass die Ergebnisse kausal sind. Für die Auswertung werden Klassifizierer aus dem Bereich maschinelles Lernen (engl. machine learning) eingesetzt, die in der Lage sind, eine Vielzahl von Eingangsgrößen zu verarbeiten. Die Qualität der Ergebnisse

wird von den bereitgestellten Daten bestimmt, die nicht ohne aufwändige Feldmessungen oder Experimente gesammelt werden können. Ziel dieser Arbeit ist die Entwicklung eines Konzepts zur Wissensgewinnung, mit dem es möglich ist, unbekannte Zusammenhänge zu identifizieren. Ausgangspunkt sind dabei Merkmale, die Kausalität zu einem Fehler aufweisen. Damit sollen grundlegende Wirkmechanismen beschrieben oder Klassifizierer verbessert werden. Knowledge Discovery in Database (KDD) ist ein Framework, mit dem diese Zusammenhänge zwischen Ursache und Wirkung entdeckt werden können. Mit der Erweiterung des ursprünglichen Konzepts um (teil-)automatisierte Experimente sollen Daten gewonnen werden, die das reale Systemverhalten umfänglich abbilden. Das setzt voraus, dass neben der Ziel- respektive Fehlergröße auch Variationen von möglichen Störgrößen einfließen. Eine der häufigsten Störgrößen ist die Last, die in vielen Anwendungsszenarien variieren kann [4–10]. Der Ansatz bietet sich für die Untersuchung rotierender Maschinen an, da Spezialprüfstände eine umfangreiche Datenerfassung ermöglichen und somit für jede der zu untersuchenden Klassen, ob Gesund- oder Fehlerfall, die gleiche Anzahl an Daten bereitgestellt werden kann. Aus den Daten werden anschließend Merkmale extrahiert, was zu einer Komprimierung bei gleichzeitig verbesserter Interpretierbarkeit führt. Mit dem vorgestellten Konzept zur systematischen Merkmalsextraktion wird ein Merkmalsvorrat aufgebaut, der neben Merkmalen auf der Grundlage von allgemeinen Kennzahlen auch Merkmale umfasst, die aus Expertenwissen abgeleitet sind. Der erzeugte Merkmalsvorrat wird dann mit einem Data-Mining-Verfahren verarbeitet, das auf das Experiment abgestimmt ist. Konkret ist damit gemeint, dass Auswahl, Anordnung und Erfassung der Zustände derart erfolgen, dass nur kausale Merkmale niedrige Fehlerraten erzielen. Dies ist nur dann möglich, wenn die Streuung der Messgrößen berücksichtigt wird. Zudem sind Eigenheiten des Klassifizierers zu beachten, damit ungeeignete Ergebnisse konsequent ausgeschlossen werden. Für den Umgang mit Fehlern ist eine abschließende Bewertung durch den Experten vorgesehen.

Für die Darstellung der Arbeitsweise und der Leistungsfähigkeit soll das Verfahren auf drei Fehler an ASM und Pumpe angewendet werden: gebrochener Rotorstab, Fehlausrichtung und Kavitation. Bei gebrochenem Rotorstab handelt es sich um einen Fehler des ASM, der bereits ausführlich in der Literatur behandelt wurde [11–15]. Das Ziel ist eine Prüfung, ob mit dem entwickelten Verfahren ebenfalls geeignete Merkmalsvektoren entdeckt werden können. Der Fall Kavitation ist von Interesse, da hierbei der Fehler nicht an dem ASM selbst auftritt, sondern an der angeschlossenen Arbeitsmaschine. Für diesen Fall sollen neue Merkmalsätze auf Basis von Spannung und Strom identifiziert werden, die bisher nicht beschrieben sind. Schließlich wird mit Fehlausrichtung ein Fehler behandelt, der die Verbindung zwischen Motor und Arbeitsmaschine betrifft und daher bei allen Aggregaten ohne gemeinsames Gehäuse auftreten kann. Für den Fehler gibt es bereits leistungsfähige Alternativen, die jedoch teuer sind oder nicht im laufenden Betrieb angewendet werden können. Auch hier sollen neue Merkmalsätze auf Basis von Spannung und Strom gefunden werden. Für

alle Anwendungsfälle werden die durch das Data-Mining aufgezählten Merkmalsvektoren einzeln bewertet, um die geeignetsten Kombinationen auszuwählen. Dazu werden geeignete Kriterien definiert und die Auswahl begutachtet. Die Diskussion wird zeigen, dass nicht alle durch den Algorithmus ausgewählten Merkmale die gesetzten Anforderungen erfüllen und damit den Vorteil des Verfahrens verdeutlichen. Die gewonnenen Zusammenhänge sollen eine transparente Entscheidungsfindung im Prozess der technischen Diagnostik ermöglichen, unabhängig vom Klassifizierer und auf gleichartige Systeme übertragbar sein. Zudem sind die Grenzen der gefundenen Lösungen darzustellen.

1.3 Stand der Forschung

Für die technische Diagnostik von ASM galt in den 1980er-Jahren die Motorstromsignaturanalyse (engl. Motor Current Signature Analysis (MCSA)) als Mittel der Wahl, um wie in [16] die Luftspaltexzentrizität in großen Maschinen zu überwachen. Bei dem Verfahren werden Komponenten des Spektrums berechnet, die mit einem Fehler korrelieren. Der Ansatz wurde vielfach beachtet und auf weitere Fehler des ASM erweitert. Beispiele sind: gebrochene Rotorstäbe [17], Exzentrizität des Rotors [16] sowie Lagerschäden [8]. Schließlich wurde der Ansatz auch auf Fehler der angeschlossenen Arbeitsmaschine ausgeweitet, um Getriebschäden [18], Fehlausrichtung [19] und Kavitation [20] im Spektrum nachzuweisen. Gleichzeitig wurden Gleichungen definiert, mit denen die Komponenten lokalisiert werden können. Neben den Belegen zur Leistungsfähigkeit dieses Verfahrens wurden jedoch auch Probleme identifiziert, die eine Anwendung in der Praxis einschränken. Zuallererst ist die Wirkung auf die Komponenten des Stromspektrums zu nennen, die eine Vielzahl von Ursachen haben kann. In einer Metastudie von [21] konnte gezeigt werden, dass sich Lastschwankungen und variierende Lasten auf die relevanten spektralen Komponenten auswirken. Weitere Untersuchungen zur Wirkung der Last auf spektrale Komponenten, die mit mechanischen Fehlern korrelieren und die Beobachtungen bestätigen, wurden in [9] durchgeführt. Die Auswirkungen unterschiedlicher Fehler auf bestimmte spektrale Komponenten wurden in der Arbeit von [22] als Problem identifiziert. Aus diesen Gründen wurden neue Ansätze erforscht, die unterschiedliche Spektren auswerten, mit dem Ziel, monokausale Komponenten zu identifizieren. In der Arbeit von [23] wurden die Möglichkeiten der Momentanleistung untersucht, während in [24] verschiedene Komponenten des Raumzeigers behandelt wurden. Die Studien zeigen, dass die untersuchten Signale und Komponenten sinnvolle Alternativen zum Stromspektrum darstellen, jedoch sind die Grenzen der Ansätze nicht untersucht. Ein weiterer Ansatz, der ebenfalls auf der Auswertung des Stroms beruht, ist die *Erweiterte Signaturanalyse transientser Ströme* (engl. Advanced Transient Current Signature Analysis (ATCSA)). Bei dem Verfahren wird nicht wie bei der MCSA das Spektrum berechnet,

sondern eine Wavelet-Transformation (WT) durchgeführt [25], womit Frequenzinformationen zu einem bestimmten Zeitpunkt berechnet werden. Wird dieses Verfahren während transients Vorgänge wie dem Anlauf durchgeführt, können charakteristische Verläufe in den Spektrogrammen identifiziert werden, die lastunabhängig sind [26]. In der Arbeit von [27] wurden Zusammenhänge zwischen Unwucht, Fehlausrichtung und den spektralen Linien beschrieben. Die ATCSA ist damit ein leistungsstarkes Verfahren der technischen Diagnostik, jedoch bleibt die Anwendung auf Szenarien beschränkt, bei denen regelmäßig die benötigten Schaltvorgänge an der Maschine auftreten.

Zur weiteren Verbesserung der Zuverlässigkeit sind derzeit drei Trends zu beobachten. Der erste Ansatz beschäftigt sich mit einfachen Sensoren, die zusätzliche Informationen liefern. Hierzu zählen Konzepte, die den Streufluss einer Maschine erfassen. In [28] wird die technische Diagnostik auf Basis von Strom, Vibration und Streufluss verglichen, mit dem Ergebnis, dass Strom- und Vibrationssignale eine robustere Klassifizierung im Falle von Fehlausrichtung liefern. Weiterhin wird auch auf Schwingungssensoren gesetzt, die in Kombination mit einer Fouriertransformation angewendet werden, wie in [29].

Der zweite Ansatz zur Optimierung der technischen Diagnostik setzt auf Algorithmen aus den Bereichen maschinellem Lernen und tiefem Lernen (engl. deep learning), die dem Themenfeld Künstliche Intelligenz (KI) zuzuordnen sind. Eine Übersicht zur Abgrenzung der unterschiedlichen Algorithmen wird in [30] gegeben. Danach werden Algorithmen wie Support Vector Machine (SVM), Künstliche Neuronale Netze (NN), Bayes-Modelle, k-nächste Nachbarn (kNN), Entscheidungsbäume (engl. decision trees) und Regression dem maschinellen Lernen zugeordnet und Convolutional Neural Network (CNN), Recurrent Neural Network (RNN) und Generative Adversarial Network (GAN) dem tiefen Lernen. Für die technische Diagnostik und das Monitoring werden die lernenden Algorithmen als Klassifizierer eingesetzt. Ein Vorteil von diesen Klassifizierern ist, dass Informationen aus unterschiedlichen Quellen verwendet werden können. So wurde in der Arbeit von [22] eine SVM eingesetzt, die mit sechs Merkmalen aus dem Zeitbereich in der Lage war, Unwucht und Fehlausrichtung zu erkennen. Mit der Arbeit von [31] konnte gezeigt werden, dass eine SVM in der Lage ist, fünf Fehler an einer Kreiselpumpe zu erkennen und zu unterscheiden. Eine Besonderheit war, dass Merkmale aus dem Leistungsspektrum verwendet wurden. In [32] wurde gezeigt, dass Fehlausrichtung mit den selbstorganisierenden Karten (engl. Self-Organizing Maps (SOM)) klassifiziert werden kann. Dazu wurden Merkmale verwendet, die aus einem autoregressiven Modell berechnet wurden.

Die Weiterentwicklung der NN aus dem Bereich maschinellem Lernen hin zu tiefen Netzstrukturen und die Verbesserung des Lernverhaltens werden unter dem Begriff tiefes Lernen (engl. deep learning) zusammengefasst [33]. Die Anwendungsmöglichkeiten solcher Algorithmen werden in [34] gezeigt. In der Arbeit werden mit einem CNN in Kombination mit einer automatischen Merkmalsextraktion verschiedene Lagerschäden und gebrochener Rotorstab

detektiert. Die Erkenntnis, dass auch tiefes Lernen qualitativ hochwertige Merkmale benötigt, wird in [35] adressiert. Damit eine Klassifizierung auch ohne Experten und menschliche Interaktion auskommt, wird ein *deep belief network* angewendet.

Die Grundproblematik von datengetriebenen Ansätzen ist die Verfügbarkeit von Daten. Diese Abhängigkeit ist besonders ausgeprägt bei tiefem Lernen, wie in [36] festgestellt wurde. Ursache dafür ist die Aufteilung der Daten für die notwendige Validierung, ohne die Modellierungsfehler nicht ausgeschlossen werden können. Dieses Problem wird in [37] aufgegriffen und die Verbesserung von maschinellem Lernen durch Expertenwissen und daraus abgeleiteten hoch diskriminanten Merkmalen vorgeschlagen. Eine andere Richtung wird in [38] vorgeschlagen. Die Idee ist, Daten aus realen Prozessen zu sammeln, mit einer Anomalieerkennung Trainingsdaten zu generieren und damit einen Algorithmus zu trainieren. Mit dem Konzept treten jedoch auch Herausforderungen auf, wie die Zugänglichkeit von Industrieanlagen, die Datenübertragung aus dem industriellen Umfeld und die Häufigkeit, mit der die gewünschten Ereignisse auftreten. Ein weiteres Problem datengetriebener Ansätze ist die Übertragbarkeit der Modelle. Für dieses Problem wurde in [39] *transfer learning* verwendet, um die Parameter eines bereits angelernten CNN zu übertragen. Auch wenn die Technik erfolgreich angewendet wurde, ist das Wissen nur implizit vorhanden.

Der dritte Ansatz optimiert die technische Diagnostik durch die Verbesserung des Wissensstands von Merkmalen und Merkmalsvektoren. So wurde in [40] ein Modell erstellt, um ein Detail der WT zu analysieren. Über eine Mustererkennung wurden dann Merkmale extrahiert, mit denen ein Klassifizierer trainiert wurde. Ein allgemeiner Ansatz, um Wissen zu Merkmalen, Merkmalsvektoren und den Zusammenhängen zu den Ziel- und Störgrößen zu entdecken, ist das KDD. Wie in [41] beschrieben, geht es darum, Wissen aus Datenbanken zu extrahieren. Ursprünglich wurde dieser Ansatz dazu verwendet, um Zusammenhänge im Finanzmarkt und in Unternehmen zu entdecken, da in diesen Bereichen bereits Informationen systematisch in Datenbanken abgelegt wurden. Eine grundlegende Einordnung von KDD zur Wissensgewinnung im Kontext darstellender Analyse wird in [42] vorgenommen. Auf den Prozess des KDD wird in [43] näher eingegangen, so können drei Stufen identifiziert werden: Datenaufbereitung, Data-Mining und Bewertung/ Interpretation. Das Data-Mining ist hierbei von zentraler Bedeutung, da damit die Zusammenhänge identifiziert werden. Je nach Aufgabe gibt es unterschiedliche Strategien für das Data-Mining, diese sind in [44] beschrieben. Die Ergebnisse des Data-Minings liefern jedoch kein Wissen, sondern Informationen. Dass Data-Mining nicht ausreicht, um innere Zusammenhänge zu identifizieren, wurde in [45] festgestellt. Mit dem angewendeten Konzept konnten nur Merkmalsvektoren identifiziert werden, mit denen Klassifizierer für die technische Diagnostik optimiert werden können. Allgemeine Aussagen zu den inneren Zusammenhängen waren nicht möglich. KDD ist daher mehr als Data-Mining. In der Folge wurde in [46] die Idee des KDD aufgegriffen, um nach interpretierbaren Merkmalen in Daten aus Experimenten zu suchen. Für den Fehler Fehlansrichtung konnten solche

Merkmale gefunden und deren Eignung für neue Motoren bestätigt werden. Weitere Arbeiten wie die von [47] thematisieren ebenfalls die Interpretierbarkeit von Merkmalen, um belastbare Ergebnisse auch bei Experimenten mit geringer Variation von Anlagen und Maschinen zu generieren. In diesem Fall wurde Feature Extraction, Selection, Classification/ Regression (FESC/R) in Kombination mit einem Zeit-Frequenzbereichs-Merkmalsextraktor verwendet. Zur Bestätigung der inneren Zusammenhänge ist in jedem Fall eine Interpretation der Ergebnisse durch den Menschen notwendig. Dazu werden die Aufzählungen aus dem Data-Mining zunächst sortiert und reduziert, wofür ein Kriterium verwendet wird. Ein universelles Kriterium ist die Interessanztheit (engl. interestingness), die in [48] vorgestellt wird. Je nach Zielsetzung kann es vorkommen, dass die Dimension des Merkmalsvektors größer als zwei ist und somit geeignete Mittel zur Darstellung angewendet werden müssen. Ein Beispiel, um hochdimensionale Räume ohne Verluste darzustellen, wird in [49] beschrieben. Das Konzept des KDD wird nur in geringem Umfang im Bereich der technischen Diagnostik eingesetzt. Ein Beispiel ist [50], darin wurde KDD und Data-Mining eingesetzt, um die inneren Zusammenhänge zwischen Merkmalen und dem Verschleiß eines Fräsers zu bestimmen. Weitere Beispiele gibt es aus dem Bereich Medizin. So wurden in [51] verschiedene Data-Mining-Techniken angewendet, um Antworten auf verschiedene medizinische Fragestellungen zu finden. Insgesamt wurden sieben Techniken identifiziert; diese sind: Assoziationsanalyse (engl. association analysis), sequential pattern mining, Clustering, Regression, Klassifikation, Anomalieerkennung und data warehousing.

Für die Realisierung des Data-Minings werden mehrere Algorithmen und Konzepte kombiniert. Merkmalsselektion ist nach [52] der zentrale Prozess des Data-Minings, der im Feld der technischen Diagnostik eingesetzt wird. Mit der Merkmalsselektion wird in einem Merkmalsvorrat oder Merkmalsraum nach den Merkmalen gesucht, die einen hohen Informationsgehalt aufweisen. Das Verfahren ist daher für die Optimierung, also der Reduzierung von Merkmalen oder der Verbesserung des Klassifizierungsergebnisses [52], von Klassifizierern geeignet, die im Kontext der technischen Diagnostik eingesetzt werden. Zudem ist das Verfahren in der Lage, nach Mustern und Wissen zu suchen, die im Kontext von KDD Anwendung finden [53]. Grundlegend werden Merkmalsselektionsalgorithmen in vier Gruppen eingeteilt: Filter, Wrapper, Embedded und Hybrid, wie in [54] dargestellt. Filter-Verfahren sind ein Schrittverfahren, bei denen alle Merkmale je nach Kriterium einen Wert zugeordnet bekommen und dieser anschließend mit einem Grenzwert verglichen wird oder die N besten Ergebnisse ausgewählt werden. Eine Übersicht über verschiedene Kriterien gibt [55]. Beim Wrapper-Verfahren wird als Kriterium das Klassifizierungsergebnis eines Klassifizierers verwendet, womit es notwendig ist, den Klassifizierer für verschiedene Merkmalskombinationen zu trainieren und zu testen. Eine Übersicht zum Wrapper-Verfahren ist in [56] enthalten. Aufgrund der individuellen Vor- und Nachteile bezüglich des Klassifizierungsergebnisses und der Berechnungsgeschwindigkeit wurden als Abwandlung die Embedded und Hybrid-Verfahren

als Sonderfälle der Filter und Wrapper entwickelt [57].

Aus der praktischen Anwendung der Merkmalsselektion konnten vier Probleme identifiziert werden: erstens die Stabilität, wonach der Algorithmus unterschiedliche Ergebnisse bei kleinsten Änderungen in den Eingangsdaten liefert; zweitens die Redundanz, wodurch die zufällige Anordnung der Merkmale über die Auswahl entscheidet; drittens die hochdimensionalen Suchräume, wodurch die Laufzeiten nicht ausführbare Längen erreichen und viertens die Optimierungsstrategie, durch die gegebenenfalls nur lokale Optima gefunden werden. Das Problem der hochdimensionalen Suchräume wird in [58] behandelt. Als Lösungsansatz wird die Verteilung der Auswertung auf mehrere Systeme vorgeschlagen. Zudem wird in [59] der Vorschlag gemacht, Filter und Wrapper zu kombinieren. Die Auswirkungen von Filtern und Wrappern auf die Stabilität werden dagegen in [60] behandelt. Für die Suche nach globalen Optima wurden weiterentwickelte Suchalgorithmen wie Ant Colony Optimization (ACO) [61] [62] [63] oder simulated Annealing [64] vorgeschlagen.

1.4 Präzisierung der Aufgabenstellung

Die Literaturrecherche zeigt, dass die technische Diagnostik rotierender Maschinen maßgeblich von zwei unterschiedlichen Bereichen vorangetrieben wird: zum einen ist das die Elektrotechnik mit ihrem Fokus auf den elektrischen Maschinen und zum anderen ist es die Informatik mit ihren Algorithmen zur Entdeckung von Zusammenhängen zwischen Merkmalen und Fehlern. Auch wenn beide Bereiche wichtige Erkenntnisse im Bereich der technischen Diagnostik hervorgebracht haben, werden grundlegende Konzepte oft nicht zusammen gedacht. In der Elektrotechnik werden dann Suchräume aufgebaut, die zwar die wichtigen Expertenmerkmale enthalten, aber auf fortschrittliche Konzepte zur Wissensentdeckung verzichten. Oft wird nur eine Merkmalsselektion durchgeführt, die nur ein Teil des KDD ist. Umgekehrt ist in der Informatik das Thema Data-Mining und KDD ausführlich diskutiert. Angewendet werden die Methoden jedoch nur in den Bereichen, in denen bereits umfangreiche Merkmale zur Verfügung stehen. Die technische Diagnostik rotierender Maschinen zählt bisher nicht dazu.

Es fehlt somit ein Ansatz, der die Erkenntnisse aus beiden Bereichen zusammenführt. Konkret muss das Konzept der Wissensentdeckung für die technische Diagnostik rotierender Maschinen angepasst werden, was den Fokus auf die Aspekte Expertenmerkmale und Datengewinnung aus Experimenten lenkt. Aufgrund der Vielzahl von Einflüssen und Wechselwirkungen in einem System wie der ASM reichen grundlegende Wirkmechanismen, wie sie durch einzelne Expertenmerkmale beschrieben werden, nicht aus, um den Gesamtzustand des komplexen Systems zu beschreiben. Es gilt daher, die Kombinationen von Merkmalen zu finden, die diese Beschreibung ermöglichen. Die Kombination von Expertenmerkmalen

untereinander, aber auch mit allgemeinen Merkmalen, soll dies ermöglichen.

Aspekte wie Experimente und Prüfstände wurden ebenfalls bei der Wissensentdeckung bisher vernachlässigt. Dabei verfügen auf rotierende Maschinen spezialisierte Prüflabore über automatisierte Prüfstände, mit denen eine Vielzahl von Zuständen des ASM und anderer Aggregate gezielt angefahren werden können. Diese Fähigkeit und die damit verbundenen Möglichkeiten zur Abstimmung mit dem Data-Mining sind bisher kaum thematisiert, ermöglichen aber neue Fragestellungen wie:

- Ist technische Diagnostik bei gestörten Systemen möglich?
- Welche Merkmale bilden die Dynamik eines komplexen Systems am besten ab?
- Welche Grenzwerte gelten für einen identifizierten Merkmalsvektor?

2 Knowledge Discovery from Experimental Data

Das folgende Kapitel behandelt die Methodik, mit der nach grundlegenden Zusammenhängen zwischen den Merkmalen und der Zielgröße oder auch den Störgrößen unter Beachtung des Stands der Wissenschaft gesucht wird. Im Abs. 2.1 soll zunächst die Methodik mit bekannten Abläufen verglichen werden. Anschließend wird die Methode beschrieben und deren Eigenschaften in Abs. 2.2 diskutiert. Eine tiefgreifende Diskussion über die Ausgestaltung der einzelnen Schritte, insbesondere der Verfahren und Algorithmen, wird in den nachfolgenden Kapiteln geführt.

2.1 Vergleich und Definition

Wie im Stand der Wissenschaft dargestellt, gibt es drei Ansätze, die zur Optimierung der technischen Diagnostik oder des Monitorings für ein ASM und der angeschlossenen Arbeitsmaschinen geeignet sind. Die Ansätze Nutzung der Maschinenkenntnisse, datengetriebene Optimierung von Klassifizierern und KDD.

Jeder der genannten Ansätze zielt darauf ab, die Klassifikation als zentrales Verfahren für die Erstellung der Diagnose zu verbessern. Bei der Klassifikation werden die im laufenden Prozess gesammelten Proben einer Klasse zugeordnet. Im einfachsten Fall gibt es zwei Klassen: die Gesund- und Fehlerklasse. In komplexeren Fällen treten neben der Gesundklasse mehrere Fehlerklassen auf. Technisch wird für die Klassifikation ein Klassifizierer eingesetzt. Dabei handelt es sich um ein technisches System oder einen Algorithmus, der die Proben den Klassen zuteilt [65]. Die Zuteilung wiederum geschieht anhand von Merkmalen, die Eigenschaften von Objekten darstellen. Im Nachfolgenden wird nicht allgemein von Objekten gesprochen, sondern konkret von (Fehler-)Zuständen, da physikalische Zustände zu unterscheiden sind. Kann anhand eines Merkmals eine Unterscheidung der Zustände vorgenommen werden, dann wird von einem Klassifikator gesprochen. Zur Unterscheidung von Klassen oder Zuständen werden häufig mehrere Merkmale benötigt. Nach der Zusammenlegung wird dann von einem Merkmalsvektor gesprochen [66].

Die Klassifizierung kann im Wesentlichen durch zwei Maßnahmen verbessert werden, durch die Auswahl des Klassifizierers und der Auswahl von Merkmalen. Die Auswahl des

Klassifizierers wird im Folgenden nicht weiter behandelt, da damit kein Erkenntnisgewinn über die Fehler und die grundlegenden Zusammenhänge verbunden ist. Im Gegensatz dazu kann über die Auswahl und Interpretation der Merkmale ein tieferes Verständnis gewonnen werden. Zur Bewertung der Optimierung wird bei allen Verfahren am Ende eine Validierung durchgeführt. Ziel ist die korrekte Klassifizierung von Testdaten.

In diesem Zusammenhang wird auch von Ziel- und Störgrößen gesprochen. Beide Größen definieren dabei einen gemessenen Zustand. Als Zielgröße wird die Größe verstanden, deren eingestellte Abstufung fehlerfrei von den Algorithmen unterschieden werden soll. Aufgrund der Tatsache, dass in dieser Arbeit Fehler erkannt werden sollen, wird die Fehlergröße auch als Synonym verwendet. Störgrößen dagegen werden nicht vom Klassifizierer unterschieden. Deren Auftreten beeinflusst jedoch die Auswertung. Die Berücksichtigung ist notwendig, da nur wenige reale Prozesse ohne Störgröße existieren.

Eine Einordnung der genannten Verfahren bezüglich der Auswahl von Merkmalen wird anhand von vier Kriterien in Tab. 2.1 gegeben.

Tabelle 2.1: Einschätzung unterschiedlicher Methoden der Merkmalsidentifikation zur Optimierung der technischen Diagnostik von rotierenden Maschinen.

Kriterium	Analytische Merkmalsbestimmung	Optimierung des Klassifizierers	KDD
Robustheit	0	+	+
Unterscheidbarkeit von Fehlern	0	+	+
Auffindung neuer Merkmale	++	0	+
Interpretierbarkeit	+	0	+
Übertragbarkeit	0	0	+

++: sehr gut; +: gut; 0: neutral

Mit *Robustheit* ist in diesem Kontext gemeint, wie stark das Ergebnis von äußeren Einflussfaktoren abhängt. Die Merkmale selbst korrelieren im optimalen Fall nur mit der Fehlergröße und werden sonst nicht beeinflusst. In der Praxis können jedoch nur selten solche Merkmale für eine definierte Aufgabe gefunden werden. In der Regel werden potenzielle Merkmale sowohl von der Fehlergröße als auch von einer oder mehreren Störgrößen beeinflusst. Bei diesem Kriterium hat die analytische Merkmalsbestimmung den Nachteil, dass die Auswertung isoliert stattfindet. Die Wirkung von Störgrößen kann oft nicht berücksichtigt werden. Hier sind Verfahren vorteilhaft, die für multiple Eingabe konzipiert sind.

Bei der *Unterscheidbarkeit von Fehlern* geht es darum, wie gut der Ansatz mit dem

Auftreten mehrerer Zielgrößen, sprich Fehlern, umgehen kann. Das Kriterium ist relevant, da für die Klassifikation unterschiedlicher Fehler die gleichen Merkmale oder sogar grundlegende Gesetzmäßigkeiten infrage kommen können. Der Ansatz muss daher in der Lage sein, Lösungen für diese Konstellation zu finden. Wie bereits zuvor bei der Robustheit ist für die Unterscheidbarkeit von Fehlern relevant, ob das Verfahren für eine mehrfache Eingabe vorbereitet ist. Im Vergleich zur Robustheit sind zur Unterscheidung von Fehlern jedoch Merkmale mit hoher Korrelation zur Zielgröße relevant.

Das Kriterium *Auffindung neuer Merkmale* beschreibt die Fähigkeit eines Ansatzes, neue Merkmale zur Lösung eines Problems zu finden. Der Vorgang unterscheidet sich dabei von der Auswahl bereits bekannter Merkmale, obgleich diese allgemein oder für ein bestimmtes technisches System definiert sind. Für diese Aufgabe ist der analytische Ansatz die einzige Methode zur Umsetzung dieses Ziels. Grund dafür ist, dass die analytische Betrachtung nur durch die Physik selbst begrenzt ist und somit alle Wirkmechanismen, die einem Merkmal zugrunde liegen, identifizierbar sind. Eingeschränkt ist die Eigenschaft beim KDD vorhanden. Durch die Einbindung von verallgemeinerten Merkmalen können Wirkmechanismen aufgespürt und durch die Prüfung bestätigt werden. Wie beim KDD erlaubt auch die Optimierung eines Klassifizierers die Einbindung verallgemeinerter Merkmale, jedoch sind bei dem Ansatz keine weiteren Maßnahmen vorgesehen, weshalb die Kausalität nicht bestätigt wird und somit die Grundlage zur Definition eines neuen Merkmals fehlt.

Interpretierbarkeit soll gewährleisten, dass der ausgewählte Ansatz Merkmale auswählt, deren Abhängigkeit von der Fehlergröße erklärbar ist. Dieses Kriterium erfüllt der analytische Ansatz bereits durch das Konzept, doch werden Merkmale auf Grundlage der bekannten Wirkmechanismen ausgewählt. Auch das KDD kommt der Forderung mit der Merkmalsextraktion nach. Wichtig ist dabei der abschließende Schritt der Interpretation, bei dem eine automatisch generierte Auswahl von Merkmalsvektoren auf die inneren Zusammenhänge überprüft wird. Das Verfahren Optimierung des Klassifizierers ist ebenfalls in der Lage, interpretierbare Merkmale zu finden, jedoch wird dies in dem Konzept nicht sichergestellt.

Das letzte Kriterium, die *Übertragbarkeit*, beschreibt die Qualität der Ergebnisse eines der Ansätze dahin gehend, dass diese zwischen verschiedenen Systemen ausgetauscht werden können. Im einfachsten Fall ist ein Austausch zwischen baugleichen Systemen möglich. Im Idealfall können die Ergebnisse auch bei diversen Variationen von Parametern übertragen werden, beispielsweise bei unterschiedlicher Polpaarzahl, Leistungsklasse oder Maschinenart. Inwieweit Merkmale übertragbar sind und unter welchen Bedingungen, ist nicht abschließend geklärt. Es wird jedoch davon ausgegangen, dass mehrere Punkte gleichzeitig erfüllt sein müssen. Dazu zählt die Berücksichtigung aller dominanten Einflüsse in den Merkmalen und die Fähigkeit, verschiedene Merkmale geeignet zusammenzuführen. Diese Anforderung kann nur das KDD erfüllen.

Aufgrund der Gegenüberstellung soll KDD weiter verfolgt werden. Der Ansatz verbindet

die Interpretierbarkeit von Merkmalen mit einer systematischen Suche je nach Anwendungsfall, wodurch KDD der Auswertung auf Basis von Maschinenkenntnissen überlegen ist. Im Vergleich zu einer datengetriebenen Optimierung zeigt der gewählte Ansatz Potenzial bei der Übertragbarkeit.

Für eine optimale Auswertung, die auf Basis von Experimenten stattfinden soll, die im Rahmen dieser Arbeit definiert und ausgeführt wurden, muss der Ansatz jedoch weiterentwickelt werden. Abbildung 2.1 gibt eine Übersicht über die Konzepte *Knowledge Discovery in Database* [53], *Knowledge Discovery from Data* [67] und dem vorgestellten Konzept Knowledge Discovery from Experimental Data (KDED). Der ursprüngliche Ansatz (KDD) hatte zum Ziel, Verknüpfungen in Daten zu finden, die bereits in einer Datenbank abgelegt wurden. Mit der systematischen Ablage und Bereitstellung von umfangreichen Daten wurde die Entwicklung von Algorithmen des Data-Minings stark gefördert. Der Erfolg durch die kontinuierliche Weiterentwicklung machte den Ansatz für die Wissensgewinnung auch in anderen Bereichen interessant.

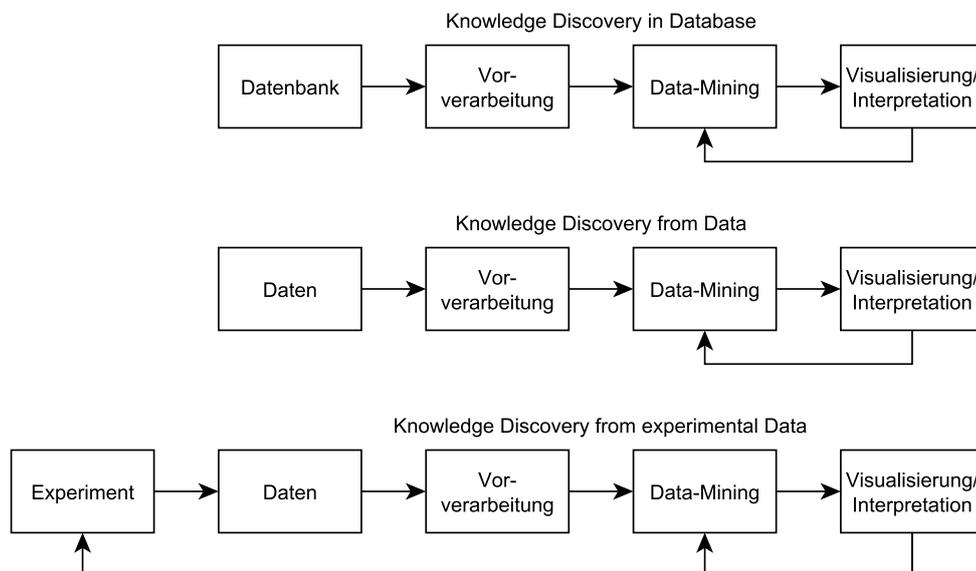


Abbildung 2.1: Vergleich von drei Knowledge Discovery Konzepten.

Mit *knowledge discovery in data* wird das Verfahren vollständig übernommen, lediglich die Quelle wird durch allgemein gehaltene Daten ersetzt. Dieser Ansatz eignet sich bereits für die Anwendung in der Forschung im Bereich technischer Diagnostik, da als Eingangsdaten die zur Diagnostik verwendeten Messwerte verstanden werden können. Der neu vorgeschlagene Ansatz KDED präzisiert den allgemeineren Ansatz, indem das Experiment als Datenursprung angesehen wird. Die Verbindung eines kontrollierbaren Versuchs mit einer systematischen Suche nach den grundlegenden Zusammenhängen bringt einen entscheidenden Vorteil mit

sich. Über die Definition von Form und Lage der Zustände, in denen gemessen wird, können Muster in die Daten gezielt eingebracht werden, die anschließend über das Data-Mining aufzuspüren sind. Im Experiment eingestellte Zustände sollen als Primärklassen in den Dimensionen des gefundenen Merkmalsvektors erscheinen.

Als Primärklasse wird daher eine Repräsentation eines realen Zustands verstanden. Primärklassen können zudem für die Auswertung zu neuen Klassen, den Verbundklassen, kombiniert werden. Wird die vollständige Verarbeitungskette betrachtet, entsteht eine neue Iterationsschleife. Gemeint ist die Rückwirkung aus gewonnenen Informationen auf das Experiment. Je nach Ausgang der Auswertung kann die Untersuchung als erfolgreich eingeschätzt oder Maßnahmen zur Optimierung des Experiments abgeleitet werden. Auf diese Rückkopplung wird im Laufe der Arbeit an verschiedenen Stellen Bezug genommen, da dadurch gewonnene Erkenntnisse in die Experimente sowie die Ergebnisse einfließen können.

2.2 Beschreibung des Verfahrens

Stehen Daten aus dem Experiment bereit, müssen in der *Vorverarbeitung* auf das Konzept KDED abgestimmte Verarbeitungsschritte ausgeführt werden, die in Abb. 2.2 dargestellt sind. In vergleichbarer Weise wird die Vorverarbeitung und insbesondere die Merkmalsextraktion in [68] vorgenommen.

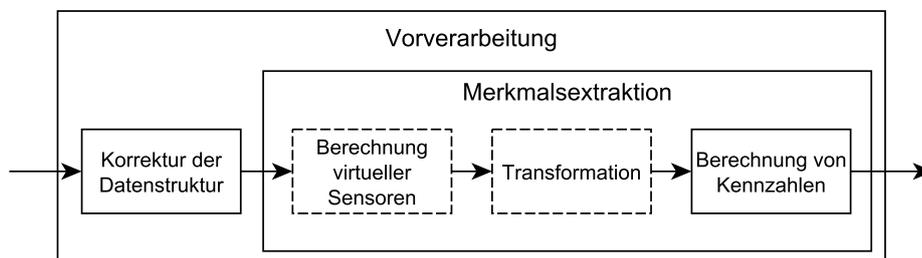


Abbildung 2.2: Vorverarbeitung des KDED Verfahrens.

Zunächst besteht die Möglichkeit, das Datenformat für den weiteren Prozess anzupassen; darunter fällt die Anpassung der Signallänge, Anpassung der Probenanzahl und Aussortierung fehlerhafter Daten. Aus den aufbereiteten Daten werden anschließend Merkmale extrahiert, mit den Zielen:

1. interpretierbare Kennzahlen zu erhalten,
2. den Informationsgehalt zu komprimieren,
3. die relevanten Informationen zu erhalten.

Der erste Punkt ist für das Knowledge Discovery (KD) relevant, um im letzten Schritt *Visualisierung und Interpretation* eine Bewertung vorzunehmen. Praktischerweise können die Ergebnisse aus dem Data-Mining durch den Abgleich mit der vorhandenen Signal- und Drehfeldtheorie auf Plausibilität überprüft werden. Ergebnisse, die nur korrelieren und keine Kausalität aufweisen, können so aussortiert werden. Auf diese Weise gewonnene Ergebnisse sollen unabhängig von einem speziellen Training sein, was einen Vorteil gegenüber Klassifizierungsmodellen darstellt, die mit umfangreichen Daten trainiert werden.

Der zweite Punkt ist für die Analyse irrelevant, hat aber einen Einfluss auf die Leistungsfähigkeit der in der Anwendung befindlichen Klassifizierer, die mit den Ergebnissen des KD arbeiten. Durch die Entfernung überflüssiger Informationen kann nach [69] die Klassifizierung ressourcenschonender ausgeführt werden, da sich die Speicheranforderung und die Ausführungszeit reduziert. Der letzte Punkt soll die Qualität des KD sicherstellen. Aufgrund der vollständigen Verarbeitung der Quelldaten kann nicht ausgeschlossen werden, dass relevante Informationen verloren gehen. Dem soll durch ein transparentes, umfangreiches und systematisches Verfahren entgegengewirkt werden. Der Prozess zur Merkmalsextraktion wird im Detail in Kap. 3 beschrieben. Grundsätzlich geht es in diesem Schritt darum, strukturiert und automatisiert einen Merkmalsvorrat aufzubauen, der anschließend von Merkmalsselektionsalgorithmen durchsucht wird. Dieser Ansatz wird in [70] beschrieben.

Nach der Berechnung der Merkmale folgt das *Data-Mining*. Das Ziel in diesem Schritt ist, aus dem erzeugten Merkmalsvorrat diejenigen Merkmale zu identifizieren, die sich für technische Diagnostik eignen. Für diese Aufgabe haben sich Merkmalsselektionsalgorithmen etabliert [52, 71]. Wird für die Suche ein Klassifizierer verwendet, wird von Wrapper-Verfahren gesprochen [54]. Nach [56] gibt es unterschiedliche Kriterien wie zum Beispiel die Fehlerrate, für deren Bestimmung der Klassifizierer zunächst trainiert und anschließend mit abweichenden Daten geprüft wird. Eine Alternative dazu sind die Filter-Verfahren, bei denen das Kriterium ohne einen Klassifizierer berechnet wird. Es werden die Merkmale ausgewählt, die unterhalb eines Schwellwerts liegen. Zeitintensive Trainings und Validierungen sind daher nicht notwendig. Abbildung 2.3 zeigt den Ablauf des Data-Minings.

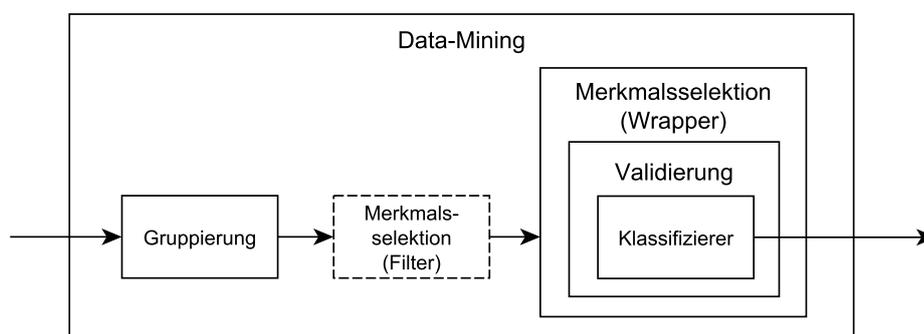


Abbildung 2.3: Ablauf des Data-Minings als Teil von KD.

Das Data-Mining beginnt mit der Gruppierung der Daten, wodurch das Ziel für den Suchalgorithmus definiert wird. Gruppieren werden die Primärklassen, die zuvor mit dem Experiment hergestellt wurden. Das Experiment stellt dabei sicher, dass in den Daten eine festgelegte Anzahl natürlicher Cluster enthalten sind, wie in [66] gefordert. Je nach Umfang des Experiments wurden Zustände aufgezeichnet, bei denen zumindest die Fehlergröße oder zusätzlich verschiedene Störgrößen variieren. Ziel ist es, die Zustände derart zusammenzulegen, dass Klassen entstehen, die sich nur in der Fehlergröße unterscheiden. Diese Forderung entspringt der Definition eines Klassifizierers wie in [72]. Sind in den Klassen zusätzlich variierende Störgrößen enthalten, wird der Merkmalsselektionsalgorithmus gezwungen, nur robuste Lösungen zu akzeptieren.

Für die Suche nach Merkmalsvektoren mit einem geringen Klassifizierungsfehler unter Beachtung von Merkmalskombinationen ist ein Wrapper-Merkmalsselektionsalgorithmus vorgesehen. Jedoch kann es sinnvoll sein, dass ein Filter-Merkmalsselektionsalgorithmus vorgeschaltet wird, um den Suchraum zu verkleinern und so die Suche zu beschleunigen [64]. Zu beachten ist, dass bei Verwendung eines Filters nicht nur Merkmale durchgelassen werden, die mit der Fehlergröße korrelieren, sondern auch die, die mit den Störgrößen korrelieren. Damit der primäre Merkmalsselektionsalgorithmus optimale Ergebnisse liefert, muss sichergestellt werden, dass zuvor nur Merkmale ohne Information ausgeschlossen wurden. Arbeitet der Merkmalsselektionsalgorithmus ausreichend schnell, kann auf den Einsatz eines Filters verzichtet werden.

Abgeschlossen wird das Data-Mining durch einen Wrapper-Merkmalsselektionsalgorithmus. Diese Algorithmen verwenden einen Klassifizierer und ein Kriterium zur Bewertung der Merkmalskombinationen. Aufgrund von Overfitting (dt. Überanpassung) während des Trainingsprozesses wird als Kriterium nicht der Klassifizierungsfehler verwendet, sondern der Validierungsfehler [71]. Nach [52] ist das notwendig, da Wrapper-Verfahren im Vergleich zu Filter-Verfahren eher zu Overfitting neigen. Daher ist ein Validierungsprozess zwischengeschaltet, der ein generalisiertes Ergebnis liefert. Als Klassifizierer können alle Algorithmen aus dem Bereich maschinellem Lernen angewendet werden. Ebenso stehen verschiedene Ansätze für die Merkmalssuche zur Verfügung. Im Detail werden die Komponenten des Data-Minings in Kap. 4 diskutiert.

Im letzten Schritt des KD geht es darum, die Ergebnisse aus dem Data-Mining in einer geeigneten Form darzustellen, zu interpretieren und die Eignung für die technische Diagnostik zu bewerten. Dieser Schritt setzt sich daher aus der Anwendung mehrerer Kriterien zusammen, die für das vorgeschlagene KDED ermittelt wurden:

1. Kennwert Einfachheit [53]: wird angewendet, um die automatisch erstellten Vorschläge aus dem Data-Mining weiter einzuzugrenzen;
2. Kennwert Korrelation: Korrelationen zwischen den identifizierten Merkmalen und den

- Einflussgrößen sollen eine erste Einschätzung der inneren Zusammenhänge liefern;
3. Kennwert Fehlerrate aus unterschiedlichen Klassifizierern: die Eignung der Ergebnisse soll anhand unterschiedlicher Verfahren bestätigt werden. Es wird die Hypothese aufgestellt, dass bei günstiger Lage der Daten mehrere Klassifizierer eine geringe Fehlerrate erreichen;
 4. Anordnung der Primärklassen (Muster): visuelle Bewertung der Form und Lage der Primärklassen. Im Idealfall sind alle Klassen ohne Schneidung erkennbar und in steigender Folge mit den eingestellten Ziel- und Störgrößen angeordnet.

Insbesondere im letzten Schritt müssen die Ergebnisse auf eine Vielzahl von teils impliziten Gesetzmäßigkeiten geprüft werden, was derzeit nur von einer Person mit einem tieferen Verständnis von Maschinen und Anlagen vorgenommen werden kann. Eine vollständige Automatisierung ist daher nicht möglich. Abbildung 2.4 gibt eine Übersicht zum Ablauf und wie die Kriterien in den Prozess einfließen. Zu bemerken ist, dass die Auswahl nach dem Data-Mining im ersten Schritt reduziert wird. Das Kriterium Einfachheit ist daher in allen weiteren Schritten enthalten. Weiterhin zu beachten ist, dass die Abbildung den Schritt Dimensionsreduktion enthält, womit hochdimensionale Daten an die Ausgabe auf einem Bildschirm angepasst werden. Der Schritt ist optional, da bereits durch den vorhergehenden Schritt die Dimensionen auf zwei begrenzt werden können.

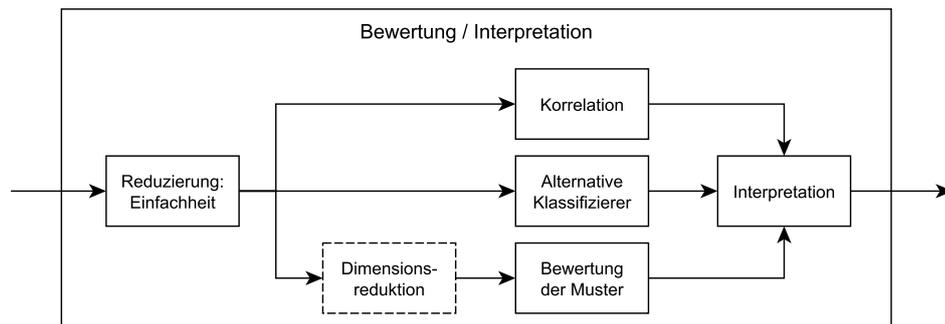


Abbildung 2.4: Ablauf der Interpretation als Teil von KD.

Entsprechend der Informationstheorie [73], wonach ein Ergebnis hochwertiger ist, je einfacher dieses ist [74], kann das Kriterium nach Gl. 2.1 auf die Liste der ausgewählten Merkmalsvektoren nach dem Data-Mining angewendet werden.

$$m \leq D + 1 \quad (2.1)$$

Die Gleichung beschreibt die *Einfachheit* der Lösung, indem die maximal benötigte Anzahl an Merkmalen m für eine definierte diagnostische Aufgabe berechnet wird. Neben der Fehlergröße (+1) werden Störgrößen D erwartet, die das System ebenfalls beeinflussen. Damit

die einfachste Lösung gefunden wird, werden nur die dominanten Einflüsse berücksichtigt. Es kann vorkommen, dass nach einer ersten Auswertung die Festlegung der dominanten Einflüsse überarbeitet werden muss, da die Ergebnisse nicht erklärbares Verhalten zeigen. Wird die Gleichung als Forderung verstanden, müssen die Ergebnisse aussortiert werden, die zu viele Merkmale aufweisen. Es bleiben die Merkmalsvektoren übrig, welche die geforderte Klassifizierungsrate erfüllen und eine der Einflussgrößen repräsentieren. In der Praxis hat sich gezeigt, dass die Gleichung auch mit einer Toleranz von einem Merkmal mehr angewendet werden kann. Dadurch werden keine Lösungen verworfen, die Kausalität zeigen.

Ein weiteres Kriterium zur Bewertung der Eignung eines Merkmalsvektors ist der *Korrelationskoeffizient* nach Pearson. Mit dem Maß kann die Abhängigkeit zwischen den Merkmalen und den Einflussgrößen bewertet werden. Zu beachten ist jedoch, dass die Korrelation einzelner Merkmale nicht die Leistungsfähigkeit kombinierter Merkmale abbilden kann. Viel mehr kann darüber ein tieferes Verständnis gewonnen und geeignete Merkmalsvektoren verglichen werden. Offen bleibt, ob nach Identifikation geeigneter Merkmalsvektoren neue konstruiert werden können, indem Merkmale mit ähnlichen Werten kombiniert werden. Durch diese Maßnahme wären dann deutlich schnellere Lösungen möglich.

Die *Bewertung mit unterschiedlichen Klassifizierungsansätzen* entspringt der Idee, dass Merkmalsvektoren, die eine geeignete Anordnung der Daten repräsentieren, unabhängig vom Klassifizierungsverfahren niedrige Fehlerraten liefern. Dieser Ansatz reduziert die Bedeutung der Klassifizierer und stärkt die der Merkmale und der zugrundeliegenden physikalischen Zusammenhänge. Partikularlösungen bei denen der Klassifizierer auf den Merkmalsvektor abgestimmt ist, sind weiterhin möglich. Die Ergebnisse dieser Bewertung liefern wichtige Aussagen zur Qualität und Randbedingungen der Merkmalsvektoren.

Das bedeutsamste Kriterium bei der Bewertung der Vorschläge ist das *(Daten-)Muster*, das durch die Auswahl der Merkmale sichtbar wird. Anhand des Musters kann geprüft werden, ob die im Experiment eingprägten (Primär-)Klassen in einer geeigneten Weise angeordnet sind. Geeignet bedeutet in diesem Zusammenhang: Die Zustände kondensieren als Cluster ohne Schneidung mit anderen Klassen und die Cluster reihen sich entsprechend dem Grad der Einflussgröße auf. Können diese Eigenschaften erkannt werden, so ist ein Merkmalsvektor im Sinne des KDED für die technische Diagnostik geeignet. Ausgehend von einem optimalen Muster sind beliebige Qualitätsabstufungen denkbar, daher ist die Begutachtung eines Experten notwendig. Das gilt insbesondere dann, wenn die Muster Fehler enthalten, die durch eine fehlerhafte Ausführung des Experiments begründet sind. Mit diesen Informationen kann dann entsprechend dem Konzept eine Optimierung angestoßen werden, in dessen Folge die Eignung eines Merkmalsvektors über alle Kriterien festgestellt werden kann.

3 Preprozess und Merkmalsextraktion

Wie im vorhergehenden Kapitel dargestellt, ist die Merkmalsextraktion eine tragende Komponente im vorgestellten KD. In diesem Kapitel wird auf die Umsetzung der Merkmalsextraktion eingegangen, die im Rahmen des KDED für die technische Diagnostik rotierender Maschinen angewendet wird. Dazu werden die aus der Literatur bekannten Extraktionsverfahren diskutiert und beschrieben, wie diese in das Gesamtkonzept integriert werden.

Ausgangspunkt für die Suche nach Merkmalsvektoren ist ein Merkmalsvorrat, aus dem ein Merkmalsselektionsalgorithmus geeignete Merkmalskombinationen auswählt. Aus der Literatur sind unterschiedliche Verfahren und Techniken bekannt, um ein System für technische Diagnostik auszulegen oder zu optimieren. Damit dieses unterschiedliche Wissen dem Merkmalsvorrat zugeführt werden kann, müssen die Merkmalsextraktoren standardisierte Merkmale liefern wie zum Beispiel in [75] und [76]. In Abb. 3.1 ist der Prozess zur Merkmalsextraktion allgemein und für ausgewählte Realisierungen dargestellt. Der Prozess zur Extraktion von Merkmalen besteht danach aus drei Schritten: der Berechnung virtueller Sensoren, einer Transformation und der Berechnung einer Kennzahl. Ein Merkmalsextraktor wird dadurch definiert, welche Algorithmen in jedem Schritt angewendet werden. Dabei besteht auch die Möglichkeit, einen Schritt zu überspringen. Zudem berechnet ein Merkmalsextraktor verschiedene Kennzahlen, wodurch der Prozess abgeschlossen wird.

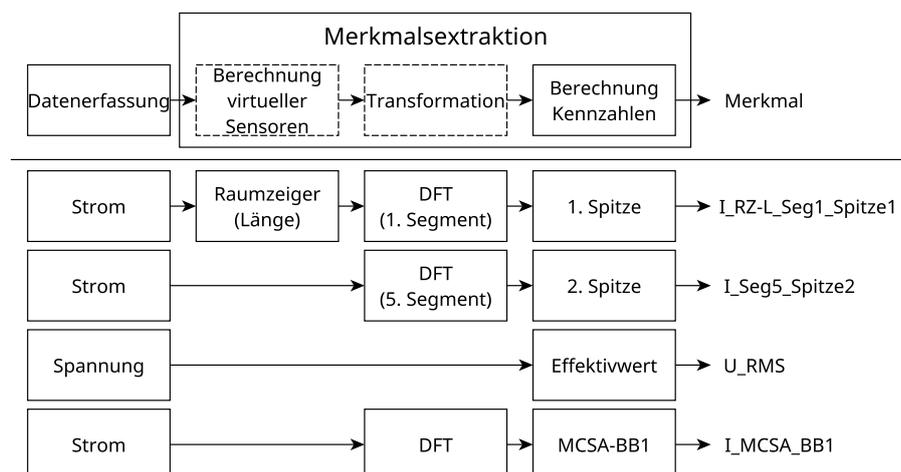


Abbildung 3.1: Prozess der Merkmalsextraktion und ausgewählte Beispiele.

Unter *virtuellen Sensoren* sind Algorithmen zu verstehen, die aus einem gemessenen Signal wie z. B. dem Strom und einem Modell das Signal einer neuen Größe berechnen [75]. Ein Beispiel ist die Drehzahl, die für den Synchronmotor aus der induzierten Spannung berechnet werden kann. Durch diese Maßnahme stehen mit wenigen gemessenen Signalen zusätzliche physikalisch interpretierbare Informationen zur Verfügung. Eine Alternative bleibt die Messung von Signalen mit geeigneter Messtechnik, jedoch wird durch die Verwendung der virtuellen Sensoren der aktuelle Stand der Technik in Bezug auf den sensorarmen Ansatz in die Bewertung eingebunden. Durch die Anwendung von *Transformationen* wird das Signal in einen neuen Darstellungsbereich überführt, wodurch sich Besonderheiten deutlicher oder überhaupt erst erkennen lassen. Als Beispiel ist die MCSA zu nennen, bei der ausschließlich das Spektrum ausgewertet wird. Für diese Arbeit wurde die Diskrete Fouriertransformation (DFT) angewendet. Weitere mögliche Transformationen sind die Hilbert-Transformation oder die WT. Die Hilbert-Transformation berechnet ein orthogonales Signal zu einem gegebenen Signal. Aus den beiden Signalen kann anschließend ein analytisches Signal berechnet werden, dessen Amplitude beispielsweise die Hüllkurve des originalen Signals darstellt. Grundlagen und Anwendungen in der technischen Diagnostik sind in [77], [78] und [79] beschrieben. Bei der WT handelt es sich nach [80] um eine Ergänzung der (gefensterten) Fourier-Transformation (FT), die eine zeitliche Lokalisation ermöglicht. Mit der WT ist es daher möglich, bei auftretenden Ereignissen nicht nur die Frequenz zu bestimmen, sondern auch den Zeitpunkt. Die zusätzliche Information führt dazu, dass das Ergebnis der WT in einem Spektrogramm dargestellt wird. Für die Extraktion von Merkmalen kann in ähnlicher Weise vorgegangen werden, wie bei der FT in Abs. 3.2 beschrieben. Vermittelt werden die Grundlagen zur Wavelet-Theorie in [81], [82] und [83]. Die *Berechnung der Kennzahlen* erfolgt anhand bekannter mathematischer Ausdrücke zur Beschreibung von Signalen, Spektren, statistischen Verteilungen und Oberwellenphänomenen wie bei der MCSA. Die verwendeten Gleichungen können dem Anhang 8.2 entnommen werden. Eine detaillierte Beschreibung der Merkmalsextraktoren wird im Folgenden gegeben.

Für ein erfolgreiches KD müssen die im Merkmalsvorrat befindlichen Merkmale alle relevanten Informationen enthalten. Sichergestellt wird dies, indem der Stand der Forschung über die Merkmalsextraktoren in die Merkmale einfließt. Folgende Ansätze zur Extraktion von Merkmalen wurden in der Literatur identifiziert:

- Merkmale aus dem Zeitbereich (ZB) [22, 84–87],
- Merkmale des Raumzeiger im Zeitbereich (ZBRZ) [88–90],
- Merkmale aus dem Frequenzbereich (FB) [4, 5, 19, 84, 85, 91],
- Merkmale des Raumzeigers im Frequenzbereich (FBRZ) [4, 24],

- Merkmale aus dem Verfahren MCSA [8, 19, 21],
- Merkmale aus dem Verfahren ATCSA [25–27].

Eine Übersicht über die verwendeten Merkmalsextraktoren und für welche Fehler diese angewendet werden, gibt Tab. 3.1. Daraus geht hervor, dass bei der Suche nach geeigneten Merkmalen und Merkmalskombinationen bisher hauptsächlich Merkmale aus dem Zeit- und Frequenzbereich bestätigt sind. Zudem gibt es, wie im Verfahren MCSA vorgesehen, bereits Gleichungen zur Lokalisierung der benötigten Frequenzen. Unklar ist die Informationslage bei der Anwendung des Raumzeigers für die genannten Fehler, auch wenn die Raumzeigerkomponenten für andere Fehler bereits erfolgreich angewendet wurden. Mit dem vorgeschlagenen KDED werden alle Merkmalsextraktoren systematisch zusammengeführt. Zu beachten ist, dass die ATCSA nur zur Vollständigkeit in die Tabelle aufgenommen wurde. Das vorgeschlagene KDED soll zunächst auf stationäre Prozesse angewendet werden, auch wenn die Methode nicht darauf beschränkt ist.

Tabelle 3.1: Eignung der Merkmalsextraktoren für die Fehlererkennung

Fehler	Merkmalsextraktor					
	ZB	ZBRZ	FB	FBRZ	MCSA	ATCSA
Gebrochener Rotorstab	+	o	+	o	+	+
Fehlausrichtung	+	o	o	o	+	+
Kavitation	+	o	+	o	o	o

+ : Eignung bestätigt; - : Nicht Eignung bestätigt; o : Bewertung nicht möglich

3.1 Virtuelle Sensoren

Virtuelle Sensoren erfüllen im Kontext dieser Arbeit zwei Aufgaben. Zum einen sind virtuelle Sensoren dazu geeignet, physische Sensoren durch Algorithmen zu ersetzen, wodurch das Ziel einer sensorarmen technischen Diagnostik gestützt wird. Zum anderen werden zusätzliche Informationen bereitgestellt, die nicht direkt im Experiment erfasst werden können. Damit wird das KD verbessert, da Merkmale mit Bezug auf physikalische Größen eine bessere Deutung der Ergebnisse ermöglichen. Die Anwendung von virtuellen Sensoren im Kontext des ASM bietet dabei viel Potenzial, da aus anderen Bereichen, wie der Steuerungs- und Regelungstechnik, bereits Ansätze bekannt sind, um aus den elektrischen Größen weitere Größen zu berechnen. Mögliche virtuelle Sensoren, die aus Spannung und Strom berechnet werden können, sind:

- Temperatur [92, 93]
- Drehzahl [94–96]
- (Momentan)Leistung [97–100]
- Raumzeigerkomponenten [24, 88, 101]

Eine weitere Übersicht zu den Möglichkeiten wird in [85] gegeben, worin auf die Notwendigkeit des Spektrums, der Leistung und der Raumzeigerkomponenten hingewiesen wird.

Im Nachfolgenden wird die Berechnung von Raumzeigerkomponenten behandelt, die in den Merkmalsvorrat einfließen. Der Raumzeiger ist für die technische Diagnostik aus mehreren Gründen interessant. Einerseits werden die drei Phasen zu einem Zeiger kombiniert, wodurch der Informationsgehalt steigt. In Abb. 3.2 wird gezeigt, wie die Information aus drei Koordinaten auf zwei verdichtet wird. Die Berechnung des Raumzeigers erfolgt durch die Clarke-Transformation [102], wonach die drei Phasen U, V und W auf die Koordinatenachsen α und β projiziert werden. Mit dem Verfahren können sowohl die Ströme als auch die Spannungen transformiert werden. Die in der Literatur häufig vorkommende Bezeichnung *Park's Vector* für den Raumzeiger im statorfesten Koordinatensystem wird nicht übernommen [101].

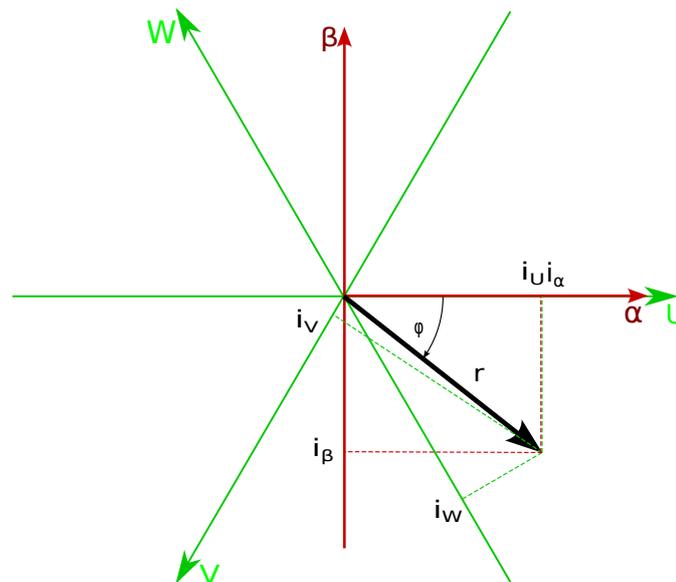


Abbildung 3.2: Konstruktion des Raumzeigers aus drei Phasen.

Andererseits eröffnet die Kombination der Phasen neue Interpretationsmöglichkeiten. In einigen Untersuchungen zu den nutzbaren Eigenschaften des Raumzeigers für die technische Diagnostik wurde das Muster des umlaufenden Zeigers für verschiedene Zustände dargestellt, siehe dazu [89]. Es konnte beobachtet werden, dass die ideale Kreisbahn im Fehlerfall

verlassen wird und sich neue Muster ergeben. Die Auswertung der erzeugten Bilder war jedoch nur durch den Menschen und nicht automatisiert möglich. Zudem war es nicht möglich, die Änderungen zu quantifizieren. Aus diesem Grund ist es sinnvoll, den Zeiger in den Polarkoordinaten r und φ darzustellen und daraus Merkmale abzuleiten. So steht z. B. die mittlere Länge des Zeigers die Amplitude [102]. Zudem kann das Spektrum unter anderem für die Raumzeigerlänge berechnet werden. Abweichungen von der idealen Kreisbahn treten dann als Komponenten im Spektrum auf. Neben der Länge des Raumzeigers wurde ebenfalls der Winkel als mögliche Informationsquelle untersucht. In [24] konnte gezeigt werden, dass die Fluktuation des Raumzeigers charakteristisch ist für Rotorunwucht und Kurzschlüsse in der Statorwicklung.

In den Merkmalsvorrat für die Untersuchungen dieser Arbeit fließen folgende Signale ein:

- Raumzeigerlänge
- Raumzeigerwinkel
- Raumzeigerlängenfluktuation
- Raumzeigerwinkelfluktuation.

Das beschriebene Konzept erlaubt die Einbindung weiterer virtueller Sensoren. Zur Auffindung unbekannter Zusammenhänge ist es empfehlenswert, alle bekannten virtuellen Sensoren einzubeziehen. Es ist darauf hinzuweisen, dass für den Nachweis der Leistungsfähigkeit des vorgestellten Konzepts eine reduzierte Anzahl virtueller Sensoren notwendig ist. Für die Diskussion in Abs. 6 wurden nur die Raumzeigerkomponenten berücksichtigt, die für elektrische Maschinen eine bedeutende Rolle spielen. Grund dafür ist die hohe Kompression von Informationen durch eine einfache Beschreibung des 3-Phasensystems.

3.2 Transformationen und Kennzahlen

Ausgehend von den gemessenen oder berechneten Signalen können Merkmale extrahiert werden. Dazu werden je nachdem, welcher Extraktor eingesetzt wird, Kennzahlen für unterschiedliche Domänen berechnet. Eine Domäne ist dabei das Resultat einer Transformation. Folgende Domänen sind möglich:

- keine Transformation → Zeitbereich (Signal)
- diskrete Fouriertransformation → Frequenzbereich (Spektrum)
- Wavelettransformation → Zeit-Frequenzbereich (Sektorgramm).

Unabhängig davon, welcher Merkmalsextraktor angewendet wird, ist das Ziel immer die Bereitstellung möglichst vieler Merkmalsproben aus der Messzeit respektive des Messspeichers. Unter Beachtung der Anforderungen aus den unterschiedlichen Transformationen und der Berechnungsvorschriften für die Kennzahlen führt die Forderung zu einer Abstimmung von Zykluszeit und Abtastzeit.

Mit der Abtastzeit wird im Zeitbereich die Abbildung der Signale beeinflusst, wodurch je nach Merkmal die Kennzahlen mal stärker, mal schwächer beeinflusst werden. Für den Frequenzbereich entscheidet die Abtastzeit über die Bandbreite des Spektrums und damit bis zu welcher Frequenz Effekte noch berücksichtigt werden. Die gemessenen Signale wurden alle mit 10 kHz abgetastet, wodurch eine Anpassung der Abtastzeit zwischen den Sensoren entfällt. Wie die Auswertung in Kap. 6 zeigen wird, wurden keine Merkmale identifiziert, die eine höhere Abtastung vermuten lassen.

Mit der Zykluszeit oder auch der Fensterbreite wird festgelegt, wie viele Perioden für eine Transformation oder die Berechnung der Kennzahlen zur Verfügung stehen. Im Zeitbereich steht die Zykluszeit vollständig für die Berechnung der Kennzahlen zur Verfügung. Sind mehrere Perioden enthalten, führt das zu einer Mittelwertbildung der Kennzahl. Auf diese Mittelwertbildung kann jedoch zugunsten zusätzlicher Merkmalsproben verzichtet werden. Wird die FT angewendet, dann entscheidet die Zykluszeit über die spektrale Auflösung, die für eine korrekte Berechnung oder Bestimmung von Merkmalen ausreichend gering sein muss. In der praktischen Anwendung haben sich fünf elektrische Perioden bewährt.

Aus der Diskussion wird deutlich, dass eine Festlegung der Zykluszeit am Bedarf der Zeitbereichsextraktoren zu einer zu geringen spektralen Auflösung und eine Festlegung der Zykluszeit am Bedarf der Frequenzbereichsextraktoren zu einem Verlust an Merkmalsproben führt. Zur Auflösung dieses Zielkonflikts wird mit unterschiedlichen Zykluszeiten gearbeitet, wobei die unterschiedliche Probenanzahl durch Klonen ausgeglichen wird. Die beschriebene Anpassung des Stichprobenumfangs für Zeit- und Frequenzbereichsmerkmale wird mit Abb. 3.3 verdeutlicht.

Im einfachsten Fall, dem *Zeitbereich*, werden für die Signale Kennzahlen berechnet, die zur Beschreibung von Signalen (z. B. der Effektivwert) oder statistischer Verteilungen (z. B. der Schiefe) vorgesehen sind.

Für den *Frequenzbereich* ergeben sich im Vergleich zum Zeitbereich mehrere Möglichkeiten für die Datenverarbeitung. Neben der Berechnung von Kennzahlen zur Beschreibung statistischer Verteilungen können auch spezielle Kennzahlen des Spektrums und MCSA-Merkmale berechnet werden. Kennzahlen zur Beschreibung des Spektrums sind verschiedene Ordnungen der Spitzenwerte und deren Position. Die Methode ergänzt die direkt durch die MCSA berechneten Komponenten des Spektrums, wodurch auch nicht beschriebene Phänomene gefunden werden sollen. Der MCSA-Extraktor wird im Folgenden beschrieben.

Aufgrund der hohen Bandbreite, die durch die Messtechnik bereitgestellt wird, ist die

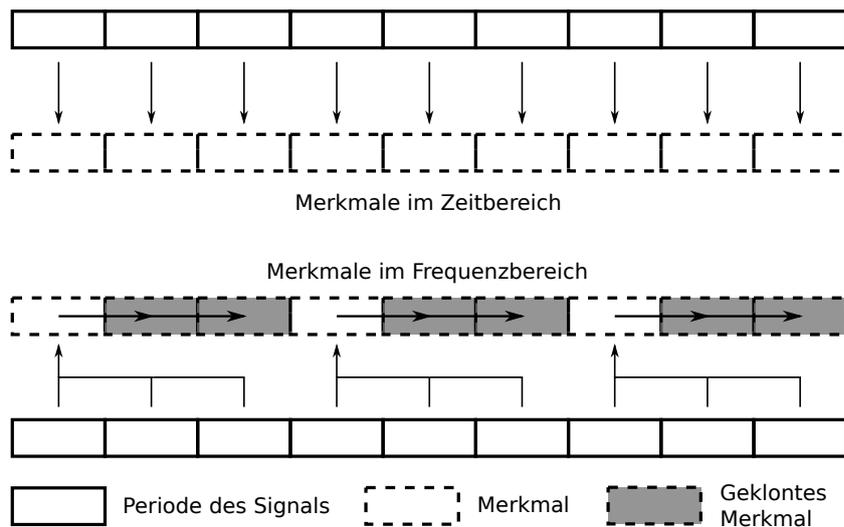


Abbildung 3.3: Anpassung des Stichprobenumfangs für Zeit- und Frequenzbereichsmerkmale.

Beschreibung des Spektrums durch bloße Anwendung des Spitzenwerts unbefriedigend, da ein Großteil des Spektrums nicht berücksichtigt wird. Deutlich wird dieser Sachverhalt durch die Anwendung des ersten Spitzenwerts, der stets die Grundschwingung findet und das abgeleitete Merkmal für die Merkmalsuche wertlos ist. Eine detailliertere Beschreibung des Spektrums kann jedoch durch Segmentierung erreicht werden. Mit der Maßnahme werden Frequenzbänder gewonnen, für die die oben beschriebenen Kennzahlen angewendet werden. Für die Zerlegung des Spektrums kommen verschiedene Techniken infrage:

- Zerlegung mit fester Schrittweite
- Zerlegung um ein Zentrum.

Die Techniken werden in Abb. 3.4 verdeutlicht.

Für einen automatisierten Prozess stellt die Zerlegung mit fester Schrittweite die einfachste Technik dar, da keine zusätzlichen Informationen benötigt werden, um die Lage des Segments zu bestimmen. Der Nachteil ist, dass eine sich mit der Fehlergröße verschiebende Spitze aus dem Betrachtungsbereich fallen kann und damit die Merkmalsselektion beeinträchtigt wird. Dieses Verhalten kann auf Kosten der Gesamtzahl an Merkmalen durch größere Segmente verhindert werden. Eine verminderte Anzahl an Merkmalen bedeutet eine weniger gründliche Suche, da sich Phänomene in einem Segment verdecken können.

Eine Alternative sind dynamische Segmente, die an einer charakteristischen Frequenz ausgerichtet werden. Dabei ist der Entwicklungsursprung und die Entwicklungsrichtung entscheidend für die Ausrichtung des Segments. Grundlage dieses Ansatzes ist die Frequenz der Nutoberwellen (engl. Principal Slot Harmonics (PSH)), die sich ausgehend von den Wicklungsoberwellen (engl. Winding Harmonics (WH)) mit dem Schlupf verschieben. Mit

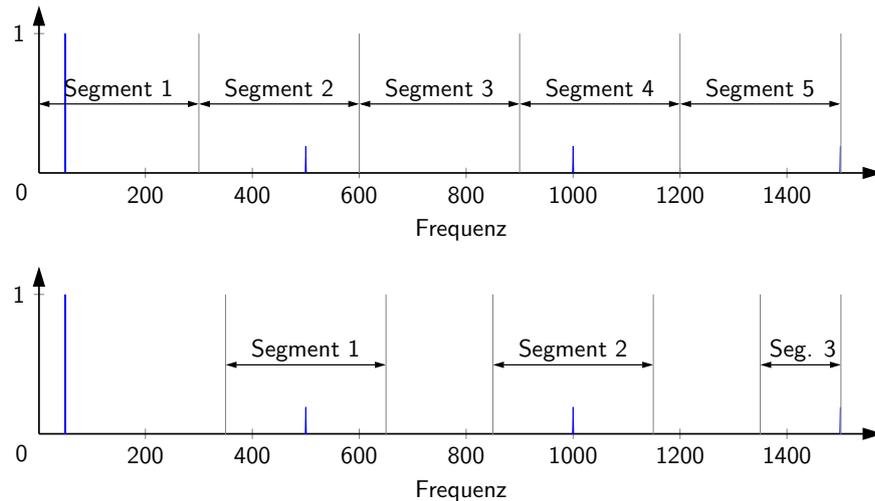


Abbildung 3.4: Techniken zur Segmentierung des Spektrums: oben angrenzende Segmente; unten dynamische Segmente.

diesem Ansatz fließen zusätzliche Informationen aus der Drehfeldtheorie in die Merkmalsextraktion ein. Der Vorteil ist, dass die abgeleiteten Merkmale nicht durch Unterbrechungen gestört werden. Der Nachteil ist, dass das Spezialwissen nicht auf alle technischen Systeme übertragbar ist. Eine weitere Möglichkeit ist die Kombination beider Verfahren, wobei zunächst die angrenzenden Segmente gewählt und nach erfolgter Analyse die Ursprünge ausgemacht werden, um anschließend die dynamische Segmentierung anzuwenden.

Ein Sonderfall zur Extraktion von Merkmalen aus dem Spektrum ist der *MCSA-Extraktor*. Während bei den oben beschriebenen Extraktoren allgemeine Kennzahlen angewendet werden, sind es beim MCSA-Extraktor Kennzahlen, die in der Drehfeldtheorie beschrieben sind und sich nachweislich für die technische Diagnostik eignen. Mit der Anreicherung des Merkmalsvorrats mit diesen Merkmalen kann nach sinnvollen Kombinationen gesucht werden, die die Einschränkungen eines einzelnen Merkmals ausgleichen, wie z. B. Lastabhängigkeit. Weiterhin ist es möglich, für die in der Theorie beschriebenen Merkmale neue Einsatzbereiche zu finden. Als Beispiel sind die Frequenzen für Exzentrizität zu nennen, die auch für Fehler relevant werden können, die erst eine Exzentrizität durch Verschiebung der Welle hervorrufen. Eine Auflistung der angewendeten Gleichungen kann dem Anhang 8.2 entnommen werden. Es ist zu beachten, dass es sich beim MCSA-Extraktor um einen Sonderfall handelt und die berechneten Merkmale nur für die technische Diagnostik rotierender Maschinen sinnvoll sind. Es wird davon ausgegangen, dass in jedem Teilbereich der Technik Wissen ausgemacht werden kann, mit dem spezielle Merkmale extrahiert werden können.

Neben den Merkmalen zur technischen Diagnostik liefert die MCSA weitere Ansätze zur Extraktion von Merkmalen. Grundlage dazu bilden Effekte, die aufgrund der Motorkonstrukti-

on und der Betriebsbedingungen Oberwellen in die Flussdichtewelle im Luftspalt und letztlich in den Strom einprägen. Abhängig von der Ursache sind die Oberwellen der Gruppe der WH oder der Rotor Harmonics (RH) zuzuordnen. Unter den WH werden die Oberwellen zusammengefasst, die durch eine nicht sinusförmige Versorgungsspannung und der Verteilung der Leiter in den Statornuten entstehen [103]. Die RH umfassen alle Einflüsse auf die Flussdichtewelle im Luftspalt, die vom Rotor ausgehen [103]. Zwei Effekte sind dabei dominant, die Änderung der Luftspaltlänge und damit des magnetischen Widerstands durch Exzentrizität und die magnetische Spannung, hervorgerufen durch den Strom in den Rotorstäben. Die zuletzt genannte Ursache führt zu den PSH eine Gruppe von Oberwellen, die im ASM prägnant auftreten [104, 105] und neben der technischen Diagnostik [106] auch für die Drehzahl- oder Schlupfschätzung [107] verwendet werden.

In der vorliegenden Arbeit wurden keine Merkmale aus dem Zeit-Frequenzbereich verwendet, da nur stationäre Prozesse behandelt werden. Für transiente Vorgänge sind Merkmale aus dieser Domäne eine potenzielle Merkmalsquelle [26]. Die Implementierung ist daher für zukünftige Arbeiten vorgesehen.

Aufgrund der systematischen Zusammenstellung des Merkmalsvorrats ist mit dem Aufbau von Redundanzen zu rechnen. Als Beispiel sind die drei Phasenströme zu nennen, aus denen unterschiedliche Merkmale gebildet werden. Zwar können Fertigungstoleranzen der Grund für Unterschiede zwischen den Phasen sein; inwieweit diese Unterschiede durch Fehler verursacht werden, bleibt jedoch offen. Der Umgang mit der Redundanz beim Data-Mining wird in Abs. 4.3 behandelt.

4 Data-Mining

Der zentrale Schritt des KDED, das Data-Mining, soll im folgenden Kapitel behandelt werden. Wie bereits in Abb. 2.3 dargestellt, entsteht für das Data-Mining für die technische Diagnostik eine komplexe Struktur mit ineinander verschachtelten Verfahren, auf die nachfolgend eingegangen werden soll. Neben der Diskussion der Auswahl der Verfahren zur Merkmalsselektion und den Klassifizierern wird zudem auf die Auswahl der Suchparameter und deren Auswirkungen auf die Ergebnisse eingegangen. In einem weiteren Abschnitt wird die Bedeutung redundanter Merkmale und die Stabilität der Selektionsalgorithmen erörtert. Abschließend werden die Fallstudien diskutiert, die aufgrund der Schleife zur Optimierung der Ergebnisse beim vorgeschlagenen KDED sowie der Gruppierung der Daten für das Data-Mining relevant sind.

4.1 Merkmalsselektion

Wie bereits festgestellt wurde, wird für die Optimierung des Merkmalsvektors im Bereich technischer Diagnostik die Merkmalsselektion eingesetzt. Dabei handelt es sich um Algorithmen, die aus einem Merkmalsvorrat, also einer Sammlung von zustandsbeschreibenden Merkmalen, die Merkmale auswählen, die eine Klassifizierungsaufgabe am effizientesten lösen. Mit effizient ist dabei gemeint, dass wenige Merkmale eine niedrige Fehlerrate erzielen. Nach [108] werden mit der Merkmalsselektion zwei Ziele verfolgt: die Minimierung des Klassifizierungsfehlers und die Reduzierung der Merkmalsanzahl. Transformationen, die ebenfalls zur Dimensionsreduktion eingesetzt werden, haben für das KDED keinen Vorteil, da die Möglichkeit zur Interpretation der Merkmale verloren geht [57, 109]. Für Merkmalsselektion wurden verschiedene Verfahren entwickelt, wie:

- Filterung (Filter),
- Sequentielle Merkmalsselektion (Wrapper),
- Ant Colony Optimization (Wrapper),
- Simulated Annealing (Wrapper).

Auch wenn sich die Verfahren im Ansatz unterscheiden, bringen alle die gleiche Schnittstelle mit und erfüllen das gleiche Ziel. Das bedeutet, dass eine Zahl an Klassen übergeben wird,

die sich durch die Zielgröße unterscheiden und durch die gleichen Merkmale aus dem Vorrat beschrieben werden. Der Merkmalsselektionsalgorithmus wählt anschließend die Merkmale, die zur Unterscheidung der Klassen respektive der Zustände am besten geeignet sind. Für die technische Diagnostik repräsentieren die Klassen unterschiedliche Fehlerzustände. Wie diese generiert werden, wird in Abs. 5.1 thematisiert.

4.1.1 Filter-Methoden

Das KDED hat zum Ziel, grundlegende Zusammenhänge in den Daten zu finden. Daher wird die Gründlichkeit bei der Suche und die Fähigkeit, Merkmale zu kombinieren, als entscheidend angesehen. Filtermethoden sind dazu nur bedingt geeignet, da je nach Kriterium oder Verfahren die Merkmale nur einzeln bewertet werden [52]. Aufgrund der Redundanz von Merkmalen kann es so zu ineffizienten Merkmalsvektoren kommen, die sich durch schlechtere Klassifizierungsraten und eine höhere Anzahl an Merkmalen charakterisieren lassen. Die Problematik isolierter Betrachtung von Merkmalen wird in der Arbeit von [110] beschrieben und auf eine einfache Formel gebracht: Die m besten Merkmale sind nicht die besten m Merkmale für eine Klassifizierung. Eine Ursache ist die Redundanz. Nach [111] handelt es sich bei Redundanz um eine Zusatzinformation, die nicht zur eigentlichen Information beiträgt. Von Redundanz muss auch im Fall des KDED ausgegangen werden. Aus diesem Grund sind die Filter-Verfahren nicht für das KDED geeignet. Diese Art von Selektionsalgorithmus kann jedoch in einem vorgeschalteten Verarbeitungsschritt dazu genutzt werden, um den Merkmalsvorrat zu reduzieren und die ausgiebige Suche zu ermöglichen [112]. Der Hintergrund dafür ist, dass für die Wissensentdeckung zunächst alle denkbaren Merkmale in den Vorrat einfließen, wodurch ein großer Suchraum und damit nicht ausführbare Berechnungszeiten entstehen können. Werden Filter- und Wrapper-Verfahren kombiniert, dann wird von Hybrid-Verfahren gesprochen [56, 113].

Mit der Anwendung eines objektiven Ausschlussverfahrens fügen sich die Filtermethoden in das KDED ein. Zudem werden Kennzahlen bereitgestellt, über die ebenfalls eine Bewertung der Auswahl erfolgen kann.

Beim Filteransatz wird für jedes Merkmal eine Güte berechnet und anschließend ein Ranking anhand des Kriteriums vorgenommen. Je nach Vorgehen werden dann die ersten m Merkmale ausgewählt oder alle Merkmale, die einen Schwellwert überschreiten. Als Kriterium für die Auswahl der Merkmale sind in der Literatur mehrere mathematische Gleichungen aufgeführt:

- χ^2 -Koeffizient [66],
- Informationsgewinn [58],
- Pearson-Korrelation [114],

- Fischer-Score [115],
- minimale Redundanz maximale Relevanz (mRMR) [112],
- Relief [116, 117].

Für das Ranking der Merkmale wird in der Literatur auf den χ^2 -Koeffizient verwiesen, der wie in [118] beschrieben ein Zusammenhangsmaß für zwei nominalskalierte Merkmale darstellt. Der Koeffizient nimmt den Wert Null an, wenn Merkmal und Klasseninformation empirisch unabhängig sind:

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^m \frac{\left(h_{ij} - \frac{h_i \cdot h_j}{n}\right)^2}{\frac{h_i \cdot h_j}{n}} = \sum_{i=1}^k \sum_{j=1}^m \frac{(h_{ij} - \tilde{h}_{ij})^2}{\tilde{h}_{ij}} \quad (4.1)$$

In der Gleichung steht h_{ij} für die Häufigkeit in der Kontingenztabelle und h_i respektive j für die Randhäufigkeit und n für den Stichprobenumfang. Das Formelzeichen \tilde{h}_{ij} beschreibt den Erwartungswert der Häufigkeiten bei statistischer Unabhängigkeit zweier Merkmale. Die Kennzahl wird in diesem Fall zwischen der Fehlergröße und den extrahierten Merkmalen berechnet. Dazu muss die Fehlergröße als eigenes Merkmal interpretiert werden. Es ist zu beachten, dass der Koeffizient für diskrete Variablen definiert ist und im Falle von kontinuierlichen Variablen Gruppierungen vorgenommen werden müssen. Ebendarum ist diese Kennzahl weniger für die technische Diagnostik geeignet.

Ein weiteres Kriterium ist der *Informationsgewinn* [58]:

$$G(D, A) = \sum_{i=1}^n \frac{|D_i|}{|D|} I(D_i) - I(D) \quad (4.2)$$

Wobei D die vollständige Datenmenge und D_i eine Teilmenge darstellt. Die Teilmengen entstehen durch die Aufteilung der Werte des Attributs A . Die Information I ist definiert nach (4.3):

$$I(D) = 1 - H(D) \quad (4.3)$$

mit H der Entropie (4.4):

$$H(D) = - \sum_i^n D_i \log_b p_i \quad (4.4)$$

mit p_i der Wahrscheinlichkeit der Realisierung i . Nach [119] handelt es sich bei (4.4) um ein Maß für die Unsicherheit oder mit (4.3) um ein Maß für die Sicherheit eines Zufallsexperiments, das seinen Ursprung im Quellencodierungssatz hat, wie in [119] beschrieben. Codes werden dabei als Fragestrategie interpretiert und die Entropie gibt die mittlere Zahl der Ja-/

Nein-Fragen an, die benötigt wird, um einen unbekanntem Wert zu erfragen. Die Entropie ist dabei für eine Gleichverteilung am höchsten, da jedes Ereignis die gleiche Wahrscheinlichkeit hat. Dagegen ist Entropie für Ereignisse mit der Wahrscheinlichkeit 1 oder 0 am geringsten, da es sich um das sichere Ereignis handelt. Damit gibt die Entropie die Unsicherheit und der Kehrwert, der Informationsgehalt, die Sicherheit einer Realisierung an. Zur Anwendung als Filter kann die Wahrscheinlichkeit nach Aufteilung der Daten durch Auszählung der Labels geschätzt werden. Der Informationsgewinn wird neben dem Einsatz als Kriterium bei den Filter-Methoden auch für die Erstellung von Entscheidungsbäumen und weiteren Verfahren eingesetzt.

Der *Korrelationskoeffizient nach Pearson* [114] ist ein weiteres häufig eingesetztes Kriterium:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.5)$$

Der Koeffizient ist ein Maß für die Verbundenheit zweier Mengen miteinander. Berechnet werden kann der Koeffizient für alle möglichen Paarungen von Merkmalen. Für das KD ist jedoch die Korrelation eines Merkmals mit der Fehlergröße und den Störgrößen relevant. Zu diesem Zweck müssen die Proben aus den Zuständen mit der Information des Fehlergrads beziehungsweise mit dem Grad der Störgröße ergänzt werden. Der Korrelationskoeffizient ist neben der Anwendung als Filterkriterium auch geeignet, um Merkmalsvektoren zu bewerten. Neben einem Merkmal mit starker Korrelation zur Fehlergröße benötigt ein Merkmalsvektor auch Informationen zu den Störgrößen, um fehlerfreie Unterscheidungen vornehmen zu können. Diese Einschätzung ist mit dem Korrelationskoeffizienten möglich.

Der *Fisher-Score* ist eine Kennzahl für das Ranking von Merkmalen, die von der gleichnamigen Fisher-Distanz abgeleitet ist und bei der Lineare Diskriminanz Analyse (LDA) angewendet wird. Dabei handelt es sich um ein Verfahren zur Dimensionsreduktion, das im Unterschied zur Merkmalsselektion die Anzahl der Merkmale durch Transformation reduziert. Beim Fisher-Score werden zwei Abstände bewertet. Der Abstand zwischen Proben einer Klasse, der möglichst gering sein soll und der Abstand zwischen den Proben unterschiedlicher Klassen, der möglichst groß sein soll. Nach [115] wird der Fischer-Score wie folgt berechnet:

$$F(\underline{Z}) = \text{tr} \{ \underline{S}_b (\underline{S}_t + \gamma \underline{I})^{-1} \} \quad (4.6)$$

mit γ als positivem Regulierungsparameter, \underline{S}_b innere Streumatrix und \underline{S}_t der Gesamt-

Streumatrix:

$$\underline{S}_b = \sum_{i=1}^k n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (4.7)$$

$$\underline{S}_t = \sum_{i=1}^n (z_i - \mu)(z_i - \mu)^T \quad (4.8)$$

mit μ_i dem Zentrum des Clusters und μ dem Zentrum aller Daten. Die Lösung der kombinierten Optimierungsaufgabe führt in der Praxis zu Problemen. Aus diesem Grund wird der Score häufig für jedes Merkmal unabhängig berechnet [120], was zu folgendem Ausdruck führt:

$$F(M_i) = \frac{\sum_{j=1}^k n_j (\mu_{ij} - \mu_j)^2}{\sigma_j^2} \quad (4.9)$$

Mit der getroffenen Vereinfachung ist eine einfache Implementierung möglich, die jedoch nur unzureichende Ergebnisse liefert. Wie bereits beim Korrelationskoeffizienten nach Pearson, kann der Fisher-Score für eine weiterführende Bewertung eingesetzt werden. Soll die Kennzahl jedoch für die Merkmalsselektion eingesetzt werden, muss (4.6) gelöst werden. In [120] wird eine Verallgemeinerung vorgeschlagen, die es ermöglicht, den Fisher-Score auch unter Berücksichtigung der Abhängigkeiten der Merkmale untereinander zu berechnen.

Ein Verfahren, das als Reaktion auf die isolierte Betrachtung von Merkmalen entwickelt wurde, ist *minimale Redundanz und maximale Relevanz*. Dabei wird nach [112] neben dem Informationsgehalt zwischen Merkmal und Klasse (4.10):

$$Rel = \frac{1}{|\underline{M}|} \sum_{M_i \in \underline{M}} I(M_i, K) \quad (4.10)$$

auch die Redundanz der Merkmale untereinander berücksichtigt (4.11):

$$Red = \frac{1}{|\underline{M}|^2} \sum_{M_i, M_j \in \underline{M}} I(M_i, M_j) \quad (4.11)$$

Der Operator I ist dabei wie folgt definiert:

$$I(a, b) = \iint p(a, b) \log \frac{p(a, b)}{p(a) \cdot p(b)} da db \quad (4.12)$$

Damit beide Kriterien in einem Wert berücksichtigt werden können, wird folgender Ausdruck verwendet:

$$mRMR = Rel - Red \quad (4.13)$$

Für die praktische Anwendung wird von [112] folgender Ausdruck vorgeschlagen:

$$\max_{M_j \in X - \underline{M}_{m-1}} \left[I(M_j, K) - \frac{1}{m-1} \cdot \sum_{M_i \in \underline{M}_{m-1}} I(M_j, M_i) \right] \quad (4.14)$$

Das *Relief-Verfahren*, das in seiner ursprünglichen Version von [116] beschrieben wird, berücksichtigt ebenfalls die Abhängigkeiten zwischen den Merkmalen. Der Vorteil ist, dass somit die Qualität eines Merkmals für den Merkmalsvektor korrekt bestimmt wird und damit abgestimmte Merkmalsvektoren gefunden werden können. Für die praktische Anwendung wurde das Verfahren unter anderem von [121] weiterentwickelt, damit das Verfahren auch bei Mehrklassenproblemen, Rauschen und unvollständigen Daten angewendet werden kann. Die Erweiterung wird dann als *ReliefF* bezeichnet. Eine ausführliche Untersuchung inklusive der Modifikationen wird in [117] durchgeführt. Die Idee hinter dem Verfahren ist, dass eine zufällige Probe I_0 ausgewählt und anschließend für jedes Merkmal, der Abstand zum nächsten Nachbarn der gleichen Klasse I_1 und der fremden Klasse I_2 bestimmt wird. Mit beiden Abständen wird die Güte des Merkmals bestimmt:

$$G_t(M_i) = G_{t-1}(M_i) - \frac{\text{diff}(M_i, I_0, I_1)}{n} + \frac{\text{diff}(M_i, I_0, I_2)}{n} \quad (4.15)$$

Darin ist $G_t(M_i)$ die aktuelle Güte des i -ten Merkmals und $G_{t-1}(M_i)$ die Güte aus dem vorhergehenden Schritt. Der Parameter n gibt in diesem Fall die Wiederholungen an, mit denen der Wert angepasst wird. Der Operator $\text{diff}()$ ist wie folgt definiert:

$$\text{diff}(M_i, I_0, I_1) = \frac{|I_1 - I_2|}{\max(M_i) - \min(M_i)} \quad (4.16)$$

Aufgrund ihrer Eigenschaften können die Filter-Methoden das vorgeschlagene KDED an zwei Stellen ergänzen. Zum einen zur Reduzierung des Suchraums für aufwändige Suchstrategien und zum anderen zur Prüfung der Ergebnisse über die Kennzahlen. Wird eine Filterstufe vorgeschaltet, müssen neben den Merkmalen, die mit der Fehlergröße korrelieren, ebenfalls die durchgelassen werden, die mit den Störgrößen korrelieren. Nur so kann sichergestellt werden, dass die Wrapper-Algorithmen die geeignetsten Kombinationen finden. In dieser Arbeit werden die Kennzahlen dazu eingesetzt, um die gefundenen Ergebnisse zu überprüfen und vorhandene Redundanz zu identifizieren. Grund dafür ist, dass die Eigenschaften der Wrapper-Methoden zur Kombination von Merkmalen als geeigneter eingestuft werden, was an der direkten Anwendung der Klassifizierer liegt. Zudem wurden erste Untersuchungen zur Kombination von Filter-Methoden mit ausgiebigen Suchstrategien wie der ACO gesammelt, auf die in Abs. 4.1.2 eingegangen wird.

4.1.2 Wrapper-Methoden

Wie im vorhergehenden Abschnitt gezeigt wurde, berücksichtigen die neuesten Entwicklungen der Filter-Methoden die Abhängigkeit zwischen den Merkmalen, um Merkmalsvektoren mit redundanter oder fehlender Information zu vermeiden. Eine weitere Möglichkeit, die Abhängigkeiten zu berücksichtigen, sind die Wrapper-Methoden, bei denen die Klassifizierer verwendet werden, die auch bei einer Klassifikationsaufgabe zum Einsatz kommen [57]. Das Kriterium, das dann für die Optimierung eingesetzt wird, ist die Fehlerrate oder der komplementäre Wert, die Korrektheit, die aus eben der Kombination verschiedener Merkmale berechnet wird. Der Vorteil der gründlichen Suche nach den entscheidenden Merkmalskombinationen wird durch ein aufwändiges Verfahren erkauft, bei dem über viele Schritte immer wieder Klassifizierer trainiert und angewendet werden. Dennoch ist die Bestimmung abgestimmter Merkmalsvektoren für das KDED entscheidend, da das Wissen über die zugrundeliegenden Einflüsse gesucht wird.

Im Folgenden wird auf zwei Suchstrategien eingegangen, die sich in der Idee grundlegend unterscheiden, aber als Wrapper-Verfahren Klassifizierer trainieren und anwenden. Damit fehlerfreie Ergebnisse produziert werden, muss die Eigenschaft der Klassifizierer zur Überanpassung (engl. overfitting) berücksichtigt werden. Von Überanpassung eines Klassifizierers wird gesprochen, wenn dieser den Trainingsdatensatz mit einem geringen Fehler klassifizieren kann, aber der Fehler bei neuen Daten groß ist [75]. Ursache sind freie Parameter, die bei einem zu intensiven Training nicht nur die primären Einflüsse auf ein System berücksichtigen, sondern auch die Streuung der Messwerte, die keine Information enthält. Das KDED sieht verschiedene Strategien zur Vermeidung von Überanpassung bereits bei der Erfassung der Daten vor, siehe dazu Abs. 5.1 und einen idealen Entwurf der Klassifizierer durch Bestimmung der Anzahl dominanter Einflüsse über (2.1). Ferner wird die Generalisierung [66], also die Eigenschaft auch unbekannte Daten korrekt zu klassifizieren, während der Suche berücksichtigt, indem nicht ein einzelnes Klassifizierungsergebnis, sondern ein gemittelter Wert über zehn Testläufe berechnet wird. Dieses Vorgehen wird Validierung genannt, und wird auch dazu verwendet, um die Generalisierungsfähigkeit von Klassifizierern zu bestimmen. Zur Validierung eines Klassifizierers gibt es mehrere Verfahren [66], die sich in der Aufteilung der vorhandenen Daten unterscheiden, siehe dazu Abb. 4.1. Bei der *Kreuzvalidierung* werden alle Daten bis auf ein Datum für das Training des Klassifizierers genutzt. Anschließend wird eine Probe mit dem verbleibenden Datum durchgeführt. In jedem neuen Durchlauf wird das nächste Datum für die Bewertung ausgewählt. Der Validierungsfehler wird durch Mittlung der n Durchläufe bestimmt. Der Nachteil ist die Verarbeitungsdauer, die bei großen Datensätzen nicht mehr ausführbar ist. Eine Abwandlung des Verfahrens ist die x -Fälle Kreuzvalidierung, bei der Daten für die Bewertung zusammengefasst werden, sodass x -Fälle (meist Zehn) entstehen. Die Anzahl der notwendigen Trainings und Bewer-

tungsschritte wird somit limitiert, was jedoch auch die Aussagekraft des Validierungsfehlers vermindert. Bei der *zufälligen Auswahl* werden in jedem Durchlauf zufällige Proben ausgewählt, die für die Bewertung verwendet werden. Die Proben werden nach der Verwendung nicht zurückgelegt, wodurch der Vorrat aufgebraucht wird. Für die Anwendung ist es sinnvoll, eine bestimmte Anzahl an Proben in jedem Durchlauf vorzugeben, damit die Durchläufe vergleichbar bleiben. Eine Abwandlung der zufälligen Auswahl ist *Bootstrap*, das ebenfalls die Proben zufällig auswählt, jedoch mit Zurücklegen. Daraus ergibt sich, dass Proben in den Durchläufen wiederverwendet und nicht immer neue Daten verwendet werden.

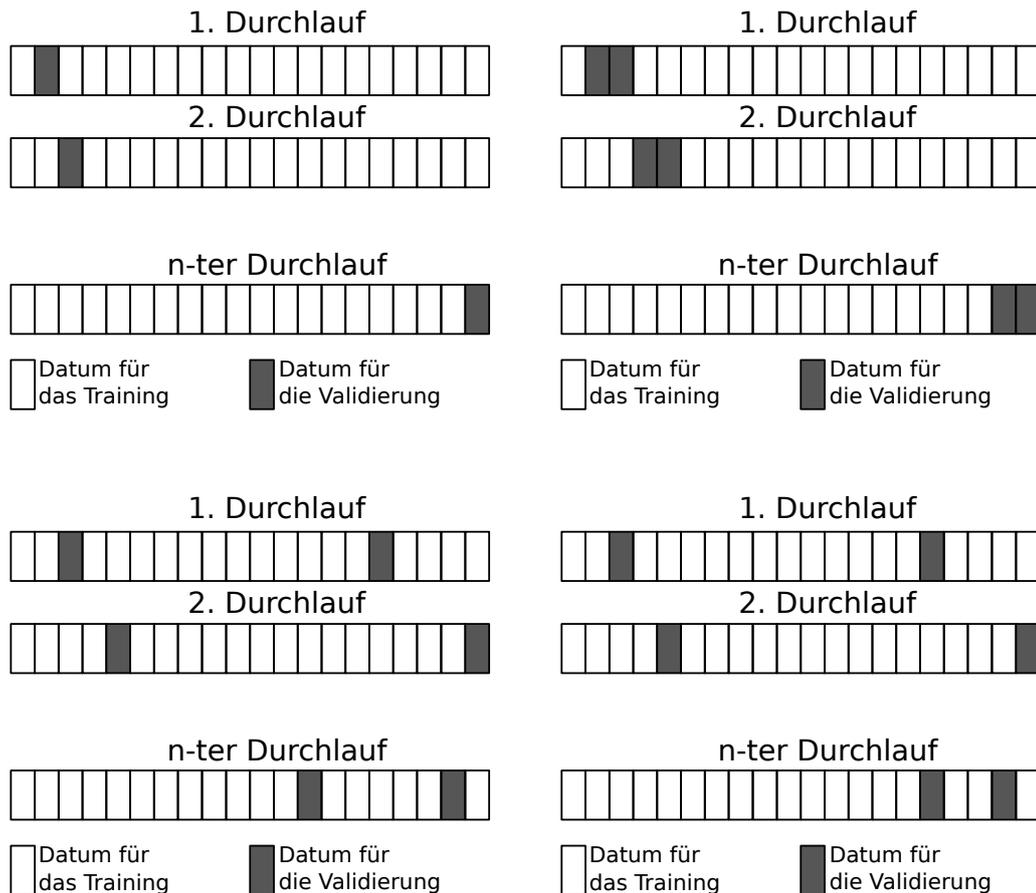


Abbildung 4.1: Konzepte zu den Validierungsverfahren. Oben links: Kreuzvalidierung; oben rechts: x-Fälle Kreuzvalidierung; unten links: zufällige Unterauswahl; unten rechts: Bootstrap.

Für das beschriebene KDED wird für die Validierung das Verfahren *zufällige Auswahl* verwendet. Grund dafür ist die Zufallskomponente, die für gruppenweise zusammengelegte Daten entscheidend ist. Bei x-Fälle Kreuzvalidierung kann es vorkommen, dass verstärkt mit Daten der Klasse bewertet wird, die beim Training unterrepräsentiert war. Zudem wird die Kreuzvalidierung wegen der Ausführungszeit verworfen.

Die *sequenzielle Merkmalsselektion* ist ein einfaches Verfahren, das darauf abzielt, das Klassifizierungsergebnis oder die Anzahl der Merkmale durch Hinzufügen oder Weglassen von Merkmalen zu verbessern [122]. In Abb. 4.2 sind zwei Abläufe zur Optimierung des Merkmalsvektors nach der Beschreibung in [123] dargestellt. Beim *Bottom-Up Ansatz* wird

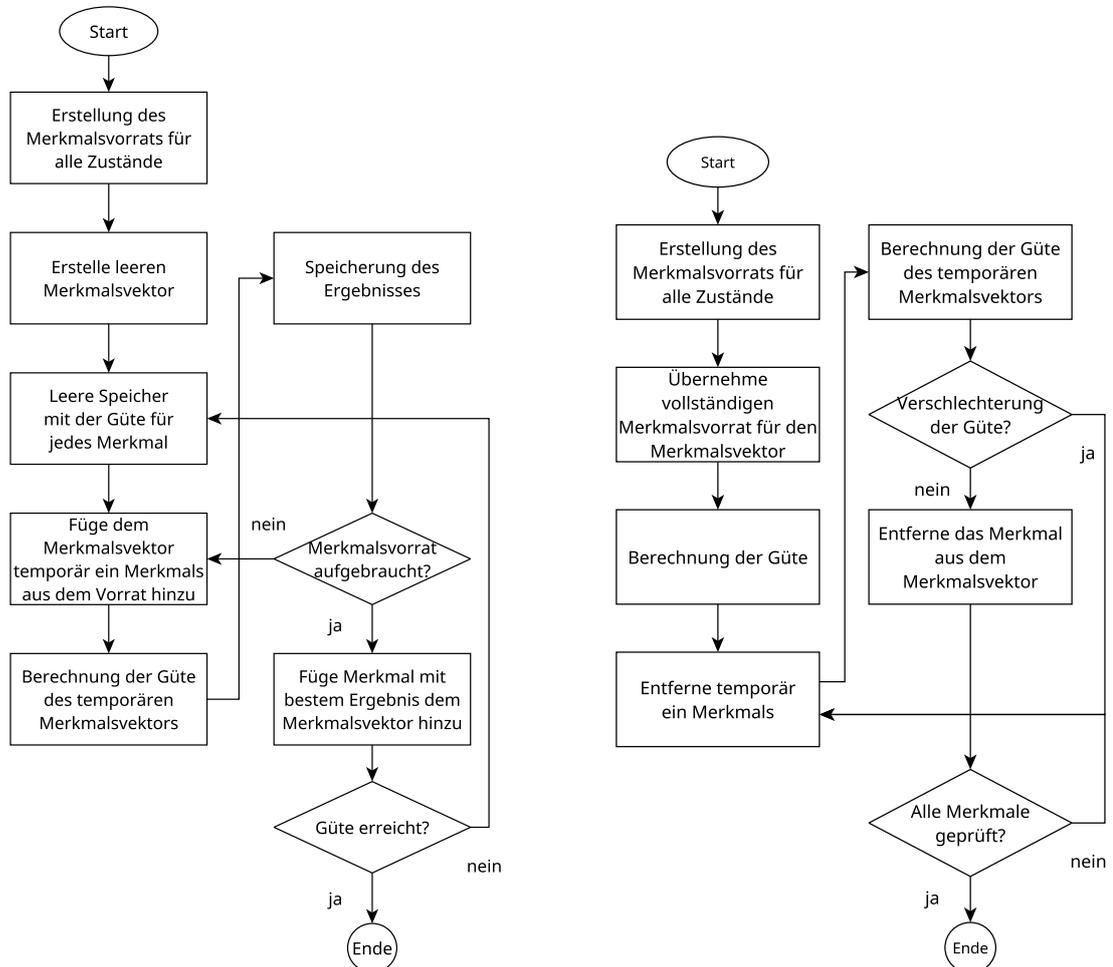


Abbildung 4.2: Ablauf der sequenziellen Merkmalsextraktion: links das Bottom-Up und rechts das Top-Down Verfahren.

der Merkmalsvektor zunächst ohne Merkmal initialisiert. Anschließend wird für jedes Merkmal im Vorrat ein Klassifizierungsfehler berechnet. Das Merkmal mit dem geringsten Wert wird dann in den Merkmalsvektor übernommen. Im nächsten Durchlauf wird für jedes Merkmal im Vorrat in Kombination mit dem Merkmalsvektor ein Klassifizierungsfehler berechnet. Das Merkmal, das die Güte des Merkmalsvektors verbessert, wird anschließend übernommen. Die Suche wird so lange fortgeführt, bis eine Ziel-Fehlerrate unterschritten ist oder kein weiterer Fortschritt erzielt wird.

Das umgekehrte Vorgehen wird beim *Top-Down* Verfahren durchlaufen. Dabei wird der

Merkmalsvektor mit dem vollständigen Merkmalsvorrat initialisiert und der Klassifizierungsfehler berechnet. Anschließend wird ein Merkmal gelöscht und wieder der Klassifizierungsfehler berechnet. Verschlechtert sich das Ergebnis nicht, bleibt das Merkmal gelöscht. Der Vorgang wird mit den übrigen Merkmalen wiederholt. Die Suche ist abgeschlossen, wenn kein Merkmal mehr entfernt werden kann, ohne dass sich das Ergebnis verschlechtert.

Aufgrund der fortschreitenden Optimierung des Merkmalsvektors ist eine schnelle Suche möglich. Dieser Vorteil bringt jedoch den Nachteil, dass der Algorithmus in einem lokalen Optimum fest fahren kann. Das hat zur Folge, dass nicht zwangsläufig die besten Merkmalskombinationen gefunden werden.

Die ACO ist ein Merkmalsselektionsverfahren, das auf dem gleichnamigen Optimierungsalgorithmus aufbaut. Der Algorithmus wurde ursprünglich für die Routenplanung entwickelt, wonach verschiedene Orte nacheinander auf dem kürzesten Weg besucht werden sollen, siehe dazu [61]. Inspiriert von einer Ameisenkolonie werden Arbeiter losgeschickt, um Ressourcen zu finden. Dabei hinterlassen die Arbeiter ständig Duftstoffe, die andere Arbeiter bei der Routenplanung beeinflussen. Stoßen weitere Arbeiter auf eine Duftspur, die zu einer Nahrungsquelle führt, wird diese verstärkt, während andere Routen verblassen. Dieses Zusammenspiel sorgt für die Optimierung und kann auf die technische Diagnostik übertragen werden. Dies geschieht, indem die Merkmale als Orte interpretiert werden. Anschließend werden Arbeiter auf einen zufälligen Weg geschickt, wobei diese durch die Duftspur der Vorgänger beeinflusst werden. Der durchlaufene Weg erzeugt dabei den Merkmalsvektor, der anschließend mit einem Klassifikator getestet wird. Unter den Arbeitern wird so das beste Ergebnis ermittelt und der Weg, der dazu führt, mit einer Duftspur aufgefrischt. Neben dieser Variante zur Aktualisierung der Duftspur gibt es weitere, wie in [124] und [62] behandelt.

Im Gegensatz zur sequenziellen Merkmalsselektion gehört die ACO nach [125] nicht der Kategorie *greedy*, sondern der *exhaustive* an. Bei Algorithmen der Kategorie *greedy* findet die Optimierung immer ausgehend vom aktuellen Optimierungsschritt statt. Eine mögliche Folge ist, dass der Algorithmus in einem lokalen Optimum endet [126]. Dieser Nachteil kann durch Algorithmen der Kategorie *exhaustive* vermieden werden, indem der vollständige Lösungsraum durchsucht wird. Aufgrund der Vielzahl von Merkmalen und möglicher Kombinationen können schnell nicht ausführbare Rechenzeiten entstehen. Die ACO verwendet aus diesem Grund die beschriebene Duftspur, durch die wenig chancenreiche Merkmalskombinationen noch vor der Berechnung ausgeschlossen werden können. Damit bleibt die Rechenzeit ausführbar, mit dem Vorteil, dass das globale Optimum gefunden werden kann.

Aufgrund der Anpassungen der ACO an die Merkmalsuche und der Eigenschaften von Algorithmen der Kategorie *exhaustive*, wird der Algorithmus als wertvolle Ergänzung des KDED gesehen. Dennoch stehen für diese Arbeit keine Ergebnisse mit dem Optimierer zur Verfügung, da eine intensive Prüfung der Ergebnisse zeitlich nicht machbar war.

4.2 Klassifizierer

Die vorgestellten Merkmalsselektionsalgorithmen verwenden für die Berechnung des Kriteriums einen Klassifizierer aus dem Bereich des maschinellen Lernens. Zur Bewertung der ausgewählten Merkmalsvektoren sollen die Ergebnisse mit unterschiedlichen Ansätzen klassifiziert werden, um die Unabhängigkeit vom Ansatz zu bestimmen. Folgende Verfahren werden berücksichtigt:

- k-nächste Nachbarn,
- Neuronale Netze,
- Entscheidungsbäume,
- Support Vector Machine.

4.2.1 k-nächste Nachbarn und Learning Vector Quantisation

Der kNN Klassifizierer ist, was das Training und die Approximation anbelangt, ein einfacher Algorithmus. Für das Training werden lediglich Proben der zu unterscheidenden Klassen abgespeichert. Die Approximation, also die Zuordnung eines unbekanntes Datums zu einer Klasse, erfolgt nach der Abstandsbestimmung durch den nächsten Nachbarn, wie in Abb. 4.3 durch D1 dargestellt. Der Nachteil dieses einfachen Ansatzes, dass auch Proben im Zentrum einer Klasse A durch einen Ausreißer einer Klasse B der Klasse B zugeordnet werden, wird durch Auswertung der k-nächsten Nachbarn vermieden. In diesem Fall wird durch ein Votum die Klassenzugehörigkeit bestimmt. Im Radius D2 befinden sich vier Referenzwerte. Ein Votum fällt mit 3:1 für die Klasse 1 aus, womit das neue Datum dieser Klasse zugeordnet wird.

Der zweite Parameter des Verfahrens ist das Abstandsmaß [127, 128]. Folgende Ausdrücke sind üblich:

$$\text{dist}(\underline{x}, \underline{y}) = \sum_{i=1}^m |x_i - y_i| \quad \text{Manhattan} \quad (4.17)$$

$$\text{dist}(\underline{x}, \underline{y}) = \sqrt{\sum_{i=1}^m (x_i - y_i)^2} \quad \text{Euklidisch} \quad (4.18)$$

$$\text{dist}(\underline{x}, \underline{y}) = \sqrt{(\underline{x} - \underline{y})^T C^{-1} (\underline{x} - \underline{y})} \quad \text{Mahalanobis} \quad (4.19)$$

$$\text{dist}(\underline{x}, \underline{y}) = \lim_{p \rightarrow \infty} \left(\sum_{i=1}^m |x_i - y_i|^p \right)^{\frac{1}{p}} \quad \text{Chebychev} \quad (4.20)$$

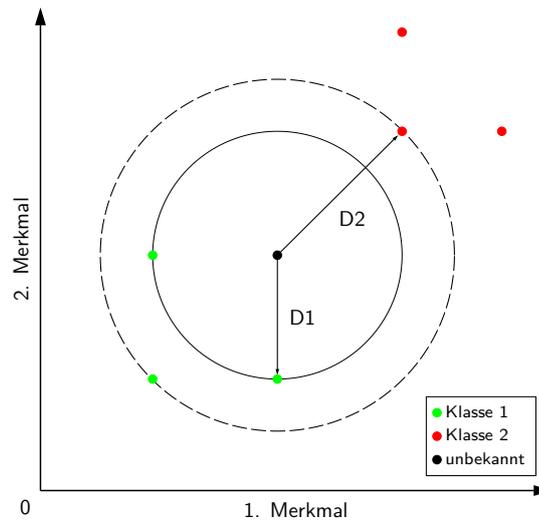


Abbildung 4.3: Approximation einer Klasse durch k-nächste Nachbarn.

mit C als Kovarianzmatrix. Außerdem kann auch die Korrelation als Maß verwendet werden, siehe dazu (4.5).

Aufgrund des Konzepts hat das Verfahren mehrere Nachteile. Der erste Nachteil ist, dass eine große Anzahl von Proben gespeichert werden muss, um komplex geformte Cluster korrekt abzubilden. Der zweite Nachteil kommt durch die Bestimmung der nächsten Nachbarn durch Abstandsmaße zum Tragen. Durch den Fluch der Dimensionalität (engl. curse of dimensionality) verringert sich der Beitrag einer Dimension oder auch eines Merkmals zum berechneten Abstand [75], siehe dazu (4.18). In der Folge sinkt die Klassifizierungsleistung des kNN Klassifizierers mit steigender Dimension. Aus diesem Grund müssen Merkmale mit geringem Beitrag aussortiert werden.

Für das KD stellen sich die Nachteile als untergeordnet heraus. Die Verfügbarkeit von ausreichend Speicher und Rechenleistung ist im Analyseschritt von Problemen der technischen Diagnostik gegeben. Nach der Bestimmung der effizientesten Merkmale können bei der Durchführung der technischen Diagnostik andere Verfahren eingesetzt werden. Eine weitere Option ist die Verwendung geeigneter Abstandsmaße, die die Besonderheiten der Cluster berücksichtigen, wie z. B. die Streuung durch die Mahalanobis-Distanz. Den Fluch der Dimensionalität betreffend, muss eine Einschätzung bei jeder Analyse vorgenommen werden. Ist nach (2.1) mit wenigen Merkmalen zu rechnen und wird zudem ein Bottom-Up-Algorithmus beim Data-Mining verwendet, wirkt sich dieses Problem nicht auf die Analyse aus.

Für die Merkmalssuche wird der Klassifizierer mit dem euklidischen Abstand ausgeführt. In Arbeit [129] wurden die oben aufgeführten Maße an unterschiedlichen Datensätzen getestet. Das Ergebnis der Studie war geringe Fehlerraten bei gleichzeitig geringer Rechenzeit bei

Verwendung des euklidischen Maßes. Insbesondere die konstanten Werte über verschiedene Datensätze machen das Maß für das KDED interessant. Untersuchungen an den eigenen Datensätzen haben zudem ergeben, dass für 11 bis 101 Nachbarn die geringsten Fehlerraten erreicht werden. Deswegen werden nachfolgend immer 11 Nachbarn zur Entscheidungsfindung verwendet.

Eine Weiterentwicklung der kNN ist die Learning Vector Quantisation (LVQ). Das Verfahren unterscheidet sich beim Training von den kNN. Anstatt die Referenzdaten vollständig zu speichern, werden wenige sogenannte Codebook-Vektoren erzeugt, die ein Cluster repräsentieren [130], siehe dazu Abb. 4.4. Mit der Maßnahme verschiebt sich der Ressourceneinsatz von der Approximation weg und hin zum Training, mit der Folge, dass Speicher eingespart und die Approximation schneller durchgeführt wird. Für das beschriebene KDED ist dieser Vorteil nicht relevant, da der Prozess stets Training und Approximation umfasst.

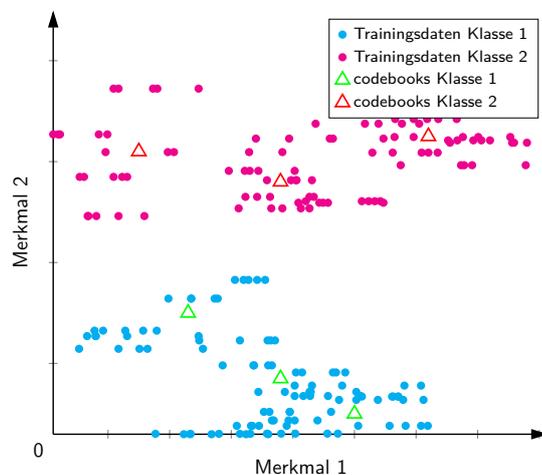


Abbildung 4.4: Substitution von Clustern durch Codebook-Vektoren bei der Learning Vector Quantisation.

4.2.2 Neuronale Netze

Die künstlichen neuronalen Netze oder einfach neuronale Netze stehen als Sammelbegriff für verschiedene Modelle der Neuronen und daraus gebildeten Netztopologien [65]. Durch die Kombination der vielen Parameter lassen sich NN für die unterschiedlichsten Aufgaben einsetzen. Im einfachsten Fall können mit den Netzen logische Schaltelemente wie And, Or, XOR etc. nachgebildet werden. Darüber hinaus sind die Netze auch für die Mustererkennung [65] geeignet. Je nach Interpretation können auch die LVQ und die SOM als einschichtige Netzwerke interpretiert werden [130].

In dieser Arbeit werden unter NN Anordnungen verstanden, wie in Abb. 4.5 dargestellt.

Das Netzwerk besteht aus vielen Neuronen (Kreise), die über Synapsen (Linien) verbunden sind. Bei dem dargestellten Netzwerk handelt es sich zudem um ein vorwärts gerichtetes Netz, was bedeutet, dass es keine Rückkopplungen gibt und die Signalverarbeitung vom Eingang zum Ausgang hin abläuft. Das Netzwerk kann weiterhin in drei Schichtarten unterteilt werden. Die Ein- und Ausgabeschicht dient dabei der Skalierung der Ein- und Ausgabe. Für diese Aufgabe werden im Gegensatz zur verdeckten Schicht lineare Aktivierungsfunktionen eingesetzt. Die verdeckten Schichten können aus einer oder mehreren Reihen von Neuronen bestehen. Werden für das Netzwerk eine oder zwei verdeckte Schichten verwendet, werden die Netze dem maschinellen Lernen zugeordnet. Steigt die Zahl der verdeckten Schichten auf mehr als zwei an, dann werden die Netze den *tiefen neuronalen Netzen* (engl. Deep Neural Network (DNN)) zugeordnet. Der Grund dafür ist, dass sich die Eigenschaften der Netzwerke verändern und ein größerer Aufwand für das Training aufgebracht werden muss. In den verdeckten Schichten können folgende Aktivierungsfunktionen Anwendung finden: logistische Funktion, Sinus bis Sättigung oder Tangens hyperbolicus. Nicht verwendet werden radialsymmetrische Aktivierungsfunktionen, die Anwendung in speziellen einschichtigen Netzen haben (engl. Radial Basis Function Networks (RBFN)).

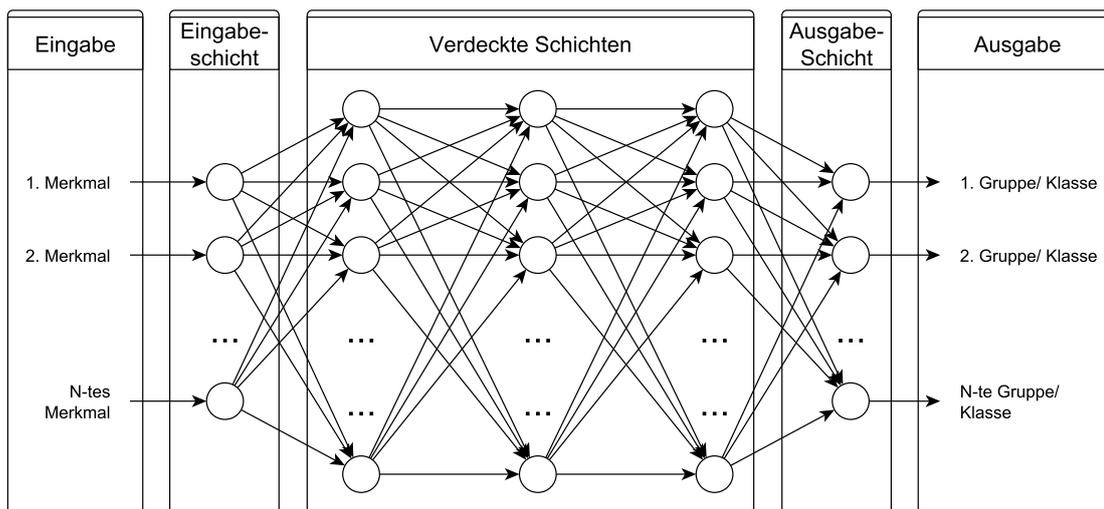


Abbildung 4.5: Vernetzung von Neuronen zur Klassifikation von Daten.

Die Information zur Unterscheidung der Klassen wird in den verdeckten Schichten gespeichert. Dazu werden die Kanten, also die gewichteten Verbindungen zwischen den Neuronen, während des Trainings optimiert. Durch diese Abstraktionsebene ist die Information zur Klassifikation nur implizit, also verdeckt vorhanden. Trainiert werden die beschriebenen Netze mit einem Gradientenabstiegsverfahren, der *Back Propagation* [130]. Dabei werden dem Netzwerk mehrfach markierte Daten präsentiert und auf Basis des Fehlers die Gewichte ausgehend von der letzten Sicht angepasst. Für das Verfahren stehen Varianten bereit, um

Probleme wie Festlaufen in einem lokalen Minimum, langsames Lernen (Plateau), Oszillation in einem Minimum oder Überspringen eines Minimums zu lösen.

Neuronale Netze sind ein hilfreiches Werkzeug im Baukasten des KD. Im Vergleich zu kNN können NN auch bei hochdimensionalen Problemen weiterhin eingesetzt werden [131], da das Verfahren nicht auf der Abstandsbestimmung basiert. Des Weiteren haben NN in der Auswertung die gleichen oder bessere Klassifizierungsraten wie kNN erreicht, was auf die guten Approximationseigenschaften zurückzuführen ist. Der Nachteil des Verfahrens ist die längere Trainingszeit und die Parametrierung des Verfahrens. Für optimale Ergebnisse muss das Netzwerk bezüglich der Topologie abgestimmt werden. Ein weiterer Nachteil ist, dass die Entscheidungsfindung intransparent ist. Dies ist auf die verdeckten Schichten zurückzuführen. Dieser Nachteil ist jedoch nur bei der Applikation relevant und wird bei der Analyse durch das Konzept des KD vollständig kompensiert, da die gefundenen Zusammenhänge stets überprüft werden.

Aufgrund der Eigenschaften werden die NN zur Bewertung der Ergebnisse aus der Merkmalsselektion verwendet. Als Aktivierungsfunktion kommen Sigmoidfunktionen infrage [127], die sich aufgrund ihrer Eigenschaften wie: Beschränktheit, Reelwertigkeit und Differenzierbarkeit besonders eignen. Erst die Differenzierbarkeit der Aktivierungsfunktion ermöglicht die Anwendung von Lernverfahren, wie der *Back Propagation*. Aus der Gruppe der Sigmoidfunktionen sind mehrere grundsätzlich geeignet wie die Sinusfunktion, der Tangens hyperbolicus oder die logistische Funktion. Exemplarisch wird die logistische Funktion für die Auswertung verwendet. Die Anzahl und Aufteilung der Neuronen wird anhand der Einflussgrößen und deren Abstufung bestimmt. Das bedeutet, dass für jede Einflussgröße eine verdeckte Schicht angelegt wird, in der sich für jede aufgezeichnete Abstufung ein Neuron befindet.

4.2.3 Entscheidungsbäume

Der Entscheidungsbaum ist ein Verfahren, das neben der Klassifizierung von Daten zusätzliche Vorteile bei der Darstellung und Interpretation der Daten bietet [65]. Demzufolge werden die Entscheidungsbäume nicht für die Merkmalsselektion eingesetzt, sondern für die Überprüfung der Ergebnisse. Damit werden zum einen die Ergebnisse aus der Suche durch einen weiteren Klassifizierer bestätigt und gleichzeitig die Ergebnisse visuell aufbereitet. Bei der Konstruktion eines Entscheidungsbaums werden die Merkmale und Grenzwerte für kontinuierliche Merkmale in einem Baumdiagramm so angeordnet, dass die Arbeitsweise vom Menschen interpretiert werden kann.

Wie in [65] beschrieben, gibt es zur Erzeugung eines Entscheidungsbaums mehrere Verfahren wie ID3, C4.5 und CART. Die Liste ist dabei unvollständig, da die Entwicklung stetig voranschreitet. Im Folgenden wird der C4.5-Algorithmus näher behandelt, der auch für die Aufbereitung der Daten verwendet wird. Als Weiterentwicklung von ID3 ist der C4.5-

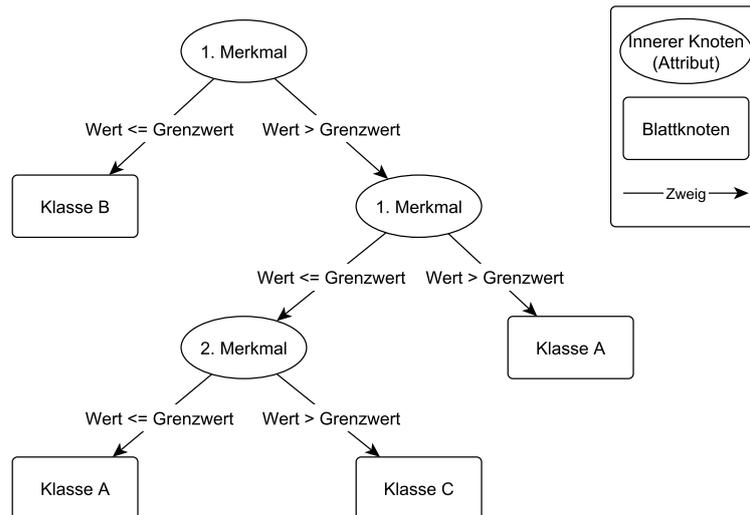


Abbildung 4.6: Beispiel eines automatisch konstruierten Entscheidungsbaums.

Algorithmus in der Lage, neben kategoriellen auch kontinuierliche Merkmale zu verarbeiten [65], was für die Anwendung auf Fragestellungen der technischen Diagnostik entscheidend ist. Ein Beispiel eines solchen Baums zeigt Abb. 4.6. Der Baum besteht aus einem Wurzelknoten, von dem aus Zweige wegführen.

Die Anzahl der Zweige ist äquivalent zu den Werten eines diskreten Merkmals. Für den Fall, dass es sich um ein kontinuierliches Merkmal handelt, werden zwei Zweige erstellt, die jeweils eine Hälfte des durch den Grenzwert geteilten Wertebereichs repräsentieren. Für die Bestimmung des Grenzwertes wird die Güte mit allen Proben berechnet und der Grenzwert auf den Wert gesetzt, der das beste Ergebnis erzielt. Dabei handelt es sich um ein rudimentäres Verfahren, das weiter optimiert werden kann, um Rechenzeit einzusparen. Es ist zu beachten, dass über dieses Vorgehen weitere Grenzwerte identifiziert werden können, da das Merkmal für die weitere Suche nicht ausgeschlossen wird. Zur Berechnung der Güte können unterschiedliche Kriterien definiert werden [65]. Unabhängig von dieser Auswahl teilt der Algorithmus die Daten entsprechend der Zweige ein und berechnet für die so entstandenen Teilmengen die Güte. Zweige können an zwei unterschiedlichen Arten von Knoten enden. Ist über die Verkettung eine Klasse eindeutig bestimmbar, dann wird am Ende des Zweigs ein Blattknoten erstellt, der eine Klasse repräsentiert. Werden weitere Informationen benötigt, dann endet der Zweig in einem weiteren inneren Knoten, von dem aus der Baum weiter wächst.

Im Gegensatz zu anderen Verfahren wie NN wird beim Trainieren der Entscheidungsbäume nicht die Fehlerrate oder die Korrektheit ausgewertet. Dadurch kommt es vor, dass zu viele Verzweigungen entstehen und der Baum auf eine Größe wächst, die nicht mehr vom Menschen interpretiert werden kann. Zudem kann der Entscheidungsbaum aufgrund der

vielen Freiheitsgrade schnell überangepasst sein. Der Baumschnitt (engl. pruning), wurde entwickelt, um zu groß geratene Entscheidungsbäume zu verkleinern [65]. Bei dem Verfahren werden die Daten nach einem Validierungsverfahren in Training und Testdaten eingeteilt. Anschließend werden beliebige Knoten entfernt und die Auswirkung auf den Fehler beobachtet. Steigt der Fehler an, wird der Schnitt rückgängig gemacht. Dieses Vorgehen ist für die Auswahl der Merkmale nicht optimal, da Wechselwirkungen nicht berücksichtigt werden. Aus diesem Grund wird die Erzeugung von Entscheidungsbäumen nicht für die Merkmalsselektion, sondern für die Auswertung vorgeschlagen.

4.2.4 Support Vector Machines

Die *Support Vector Machines* sind eines der meist betrachteten Verfahren aus dem Bereich maschinellem Lernen. Grund dafür ist ein eingängiges Konzept, das im Laufe der Zeit immer wieder mit Erweiterungen an neu identifizierte Probleme angepasst werden konnte. Die entscheidenden Aspekte für den Erfolg der SVM werden ausführlich in [125] behandelt, diese sind:

- Die Trennung von Daten mit einer Hyperebene (Grundkonzept),
- die Einführung des Seitenrands zur Generalisierung der Lösung,
- Transformation von Daten in einen höherdimensionalen Raum mit Kernels zur Erreichung linearer Trennbarkeit,
- Berücksichtigung von Streuung und Ausreißern bei der Optimierung der Hyperebene durch einen weichen Seitenrand (engl. soft margin),
- Überführung des Verfahrens vom binären Klassifizierer zum Mehrklassen-Klassifizierer.

Das zugrundeliegende Konzept der SVM ist die Trennung von Daten mit einer Hyperebene, die eine Verallgemeinerung der Ebene für m -dimensionale Räume darstellt. Die Hyperebene leitet sich für die SVM aus der linearen Entscheidungsfunktion ab [125]:

$$K(\underline{M}) = \text{sgn}(\langle \underline{w}, \underline{M} \rangle + b) = \pm 1 \quad (4.21)$$

Darin ist $K()$ die Funktion zur Bestimmung einer der zwei möglichen Klassen ± 1 , \underline{M} ein beliebiger Merkmalsvektor, \underline{w} der Stützvektor der Entscheidungsebene und b der Offset oder Schwellwert der Entscheidungsebene. Ein Beispiel für die Konstruktion der Entscheidungsebene über die Entscheidungsfunktion ist in Abb. 4.7 links gegeben. Die Hyperebene zur Trennung der Daten ist gegeben für:

$$\langle \underline{w}, \underline{M} \rangle + b = 0 \quad (4.22)$$

Ist der Abstand entlang des Vektors w größer als b , wird die Probe der Klasse $+1$ zugeordnet und sonst der Klasse -1 . Die Werte ± 1 stehen dafür repräsentativ für beliebige Klassenbezeichnungen.

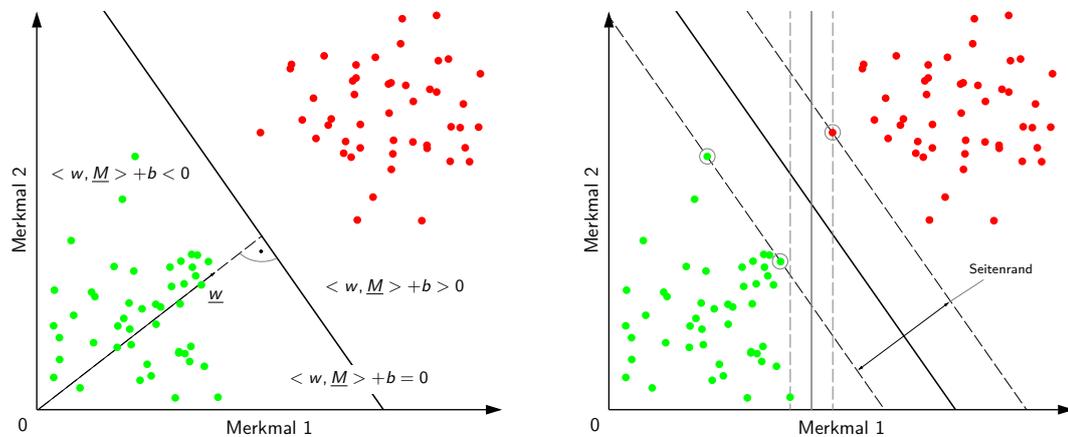


Abbildung 4.7: Konzepte der SVM zur Datentrennung. Links: resultierende Entscheidungsebene aus dem Entscheidungskriterium; rechts: optimale Entscheidungsebene durch Bestimmung der Support Vektoren.

Damit die Unterscheidung wie dargestellt vorgenommen werden kann, muss zunächst die Entscheidungsebene bestimmt werden. Für eine Ebene, die im gegebenen Beispiel die Daten trennt, gibt es unendlich viele Lösungen. Zur Auffindung der optimalen Trennebene wird eine weitere Bedingung definiert, die zu einer eindeutigen Lösung führt. Der Seitenrand bestimmt die Eigenschaft zur Generalisierung und soll daher maximal sein [125]. Durch diese Forderung ist die Wahrscheinlichkeit am geringsten, dass neue Daten falsch klassifiziert werden, sofern die Streuung des Prozesses korrekt in den Trainingsdaten abgebildet ist. Mit dem Optimierungsansatz nach Lagrange und den zwei Bedingungen *korrekte Klassifizierung* und *maximaler Seitenrand* kann die optimale Hyperebene zur Trennung der Daten gefunden werden [125]. Durch Lösen der Optimierungsaufgabe zeigt sich, dass die Bestimmung der Hyperebene am Ende von wenigen Proben abhängt, den Support Vectors. Die Auswahl unterschiedlicher Hyperebenen, der resultierende Seitenrand sowie die Support Vectors sind in Abb. 4.7 rechts dargestellt.

Es ist an dieser Stelle zu beachten, dass das beschriebene Verfahren nur auf linear trennbare Daten angewendet werden kann. Die Ersetzung der Hyperebene durch aufwändigere mathematische Beschreibungen hat sich ebenfalls nicht durchgesetzt. Damit dennoch nicht linear trennbare Daten klassifiziert werden können, werden *Kernels* eingesetzt [125]. Mit Kernels werden die Eingangsdaten in einen höherdimensionalen Raum transformiert, mit dem Effekt, dass meist eine Hyperebene zur Trennung gefunden werden kann. Die wichtigsten

Kernel sind [125]:

$$k(x, x_i) = \langle x, x_i \rangle^d \quad \text{Polynom inkl. linear} \quad (4.23)$$

$$k(x, x_i) = \exp\left(\frac{-\|x, x_i\|^2}{c}\right) \quad \text{Gauß} \quad (4.24)$$

$$k(x, x_i) = \tanh(\kappa \langle x, x_i \rangle + \Theta) \quad \text{Tangens hyperbolicus} \quad (4.25)$$

Für die Anwendung der Kernel ist zu wissen, dass es verschiedene Optimierungsstrategien gibt, um diesen an unbekannte Daten anzupassen. Überdies führen die unterschiedlichen Kernel zu Netzwerken, die wie im Falle von (4.24) identisch mit einem RBFN oder im Falle von (4.25) identisch mit einem einschichtigen NN sind [125]. Interessant ist, dass in [132] gezeigt werden konnte, dass die Optimierungsstrategie zu besseren Ergebnissen führt im Vergleich zur Anwendung des originalen Verfahrens. Erst bei idealer Auslegung durch den Anwender liefern die Ansätze gleichwertige Ergebnisse.

Die bisherige Betrachtung der SVM verlief unter der Annahme vollständig trennbarer Daten. Dies bedeutet, dass keine Ausreißer auftreten oder die Trainingsdaten sich schneiden. Der Ansatz, den Klassifizierungsfehler zu optimieren, hat sich dabei nicht durchgesetzt, da dieses Kriterium zu einem Zielkonflikt mit dem Kriterium der Generalisierung führt, also dem maximalen Seitenrand [125]. Deswegen wurde nach Alternativen gesucht, um dennoch ein Training durchführen zu können. In einem ersten Schritt wurde die Schlupfvariable eingeführt, durch die einer bestimmten Anzahl von Proben erlaubt wird, die Bedingung für korrekte Klassifizierung zu verletzen. Der Ansatz führte schließlich zur C-SVM, bei der die Straffunktion mit dem Parameter C in die Optimierung aufgenommen wird [125]. Der Vorteil dabei ist, dass nicht mehr die Anzahl an Proben angegeben werden muss, die den Rand verletzen und von Fall zu Fall unterschiedlich ist. Über den Parameter C kann der Kompromiss zwischen minimalem Trainingsfehler und größtem Rand vorgegeben werden. Eine weitere Optimierung wird in [133] vorgenommen und der Parameter ν eingeführt. Der Vorteil dabei ist das Intervall $[0, 1]$ des Parameters ν , der den freien Parameter C ersetzt.

Nativ ist die SVM ein binärer Klassifizierer. Zur Anpassung an Mehrklassenprobleme gibt es mehrere Strategien [125]:

- Eine-gegen-den-Rest (engl. one versus the rest),
- Paarweise-Klassifizierung (engl. pairwise classification),
- Fehlerkorrigierte-Ausgabecodierung (engl. Error-Correcting Output Coding (ECOC)),
- Mehrklassen-Zielfunktionen (engl. multi-class objective functions).

Bei dem Verfahren *Eine-gegen-den-Rest* wird ein Satz von k Klassifizierern trainiert, wobei die Daten aller Klassen bis auf eine, gegen die geprüft wird, zusammengelegt werden. Für

die Approximation wird im ersten Schritt der Abstand der nicht klassifizierten Probe zu allen Hyperebenen bestimmt. Im zweiten Schritt wird die Hyperebene ausgewählt, zu der die Proben den größten Abstand haben, um im dritten Schritt über die Signum-Funktion die Klassenzugehörigkeit zu bestimmen. Der Ansatz zeichnet sich durch eine geringe Anzahl von binären Klassifizierern aus, jedoch wird die fehlende Symmetrie der Daten beim Training bemängelt.

Das Komplementär ist die *Paarweise-Klassifizierung*, bei der für jede Klassenkombination ein binärer Klassifizierer trainiert wird, also $\frac{(k-1)k}{2}$. Für die Bestimmung der Zielklasse muss nach Auswertung aller binären Klassifizierer ein Votum durchgeführt werden. Der Ansatz führt je nach Klassifizierungsaufgabe zu einer langsameren Approximation, jedoch gibt es Vorteile beim Lernen, da die Teilaufgaben weniger Daten aufweisen und die Teilprobleme meist weniger überlappen.

Die Idee hinter der *Fehlerkorrigierten-Ausgabecodierung* ist die Darstellung der Ergebnisse mehrerer binärer Klassifizierer in einem neuen Raum, in dem durch Abstandsbestimmung eine Klassifizierung vorgenommen werden kann. Beim Training dieses Verfahrens müssen mindestens k Klassifizierer trainiert werden. Für die Approximation wird eine Probe durch alle Klassifizierer bewertet. Die Reihung der Ergebnisse führt zu dem Ausgabecode, der die Position der Probe im Referenzraum repräsentiert. Eine Besonderheit des Ansatzes ist, dass die Fehlerrate durch Hinzufügen zusätzlicher Klassifizierer und damit eine Verlängerung des Ausgabecodes verbessert werden (error correction) [125]. Ursprünglich wurde das Verfahren für beliebige binäre Klassifizierer entwickelt, daher wird in der ursprünglichen Variante keine Rücksicht auf den Rand bei Verwendung der SVM genommen. Neuere Ansätze, die auf die SVM angepasst sind, berücksichtigen dies.

Die *Mehrklassen-Zielfunktion* ist eine Optimierung des Verfahrens *Eine-gegen-den-Rest*, bei der alle binären Klassifizierer in einem Schritt bestimmt werden. Möglich wird dies durch Anpassung der Zielfunktion für die Optimierung. Durch die Anpassung steigt die Trainingszeit deutlich an und die Präzision ist vergleichbar mit der von *Eine-gegen-den-Rest*.

Durch die Kombination der behandelten Ansätze sind die SVM zu einem der viel beachteten Klassifizierer geworden. Mit dem Konzept der Kernels kann auf unterschiedlichste Probleme oder Daten-Muster reagiert werden, wodurch Verfahren vielfältig einsetzbar ist. Zudem verfügt das Verfahren über ein effizientes Konzept für das Training und der Approximation neuer Daten. Im vorgestellten KDED werden die SVM trotz der Stärken nur zur Überprüfung der gefundenen Merkmalsvektoren eingesetzt, da die Auswahl des geeigneten Kernels der Automatisierung entgegensteht. Dieser Aspekt ist gerade zu Beginn der Suche relevant, wenn noch wenig über die Muster in den Daten bekannt ist.

Das Verfahren SVM wird wegen der genannten Eigenschaft zur Generalisierung als wichtiges Kriterium zur Überprüfung der gefundenen Muster gesehen. Für die Prüfung wird über alle Muster ein linearer Kernel verwendet, da die individuelle Auswahl zu aufwändig ist

und mit dem KDED nach möglichst einfachen Mustern gesucht wird. Darüber hinaus können interessante Muster mit schlechter Fehlerrate separat angepasst werden. Für den Straffaktor wurde $\nu = 0,5$ gewählt. Für das Mehrklassenproblem wurde die Strategie fehlerkorrigierte Ausgabecodierung mit paarweiser Klassifizierung verwendet, da das Verfahren robuster auf unbekannte Daten reagiert und somit variierende Muster in einem automatisierten Prozess verarbeitet werden können.

4.3 Stabilität der Merkmalsselektion und redundante Merkmale

Die Stabilität der Merkmalsselektion wird nach [134] definiert als: Sensitivität eines Algorithmus zur Merkmalsselektion auf Variation in den Trainingsdaten. Hintergrund für diese Definition und die damit verbundenen Untersuchungen ist, dass bei wiederholter Anwendung der Merkmalsselektion mit neuen Trainingsdaten, die unter gleichen Versuchsbedingungen gewonnen wurden, unterschiedliche Merkmalsvektoren gefunden werden. Für die Klassifikation sind diese Unterschiede irrelevant, da die Merkmale gleichwertige Ergebnisse darstellen. Ist das Ziel jedoch die Beschreibung der grundlegenden Zusammenhänge zwischen Fehler-/ Störgröße und den Merkmalen, wie im Falle des KDED, dann erschwert die Variation die Interpretation des Ergebnisses. Zudem vermindern die Abweichungen das Vertrauen in die Methodik. Aus diesem Grund müssen die Ursachen dieser Variationen verstanden und gegebenenfalls mit geeigneten Maßnahmen kompensiert werden, damit die Anforderung an Wiederholbarkeit und Interpretierbarkeit erfüllt werden. Für die objektive Bewertung wurden verschiedene Kennzahlen und Konzepte zur Bestimmung vorgeschlagen, siehe dazu [135].

Die Ursache für die Variation der Merkmalsauswahl ist im Zusammenspiel der Daten, der Merkmalsextraktion und dem Auswahlverfahren begründet. In die empirisch erfassten Daten fließt immer die Unsicherheit der Stell- und Messtechnik ein. Zudem ist aufgrund der Systematik der Merkmalsextraktion nicht auszuschließen, dass redundante oder identische Merkmale im Merkmalsvorrat enthalten sind. Zwei Merkmale sind dann redundant, wenn diese die gleiche Abhängigkeit von den Einflussgrößen aufweisen. Die Abhängigkeit von unbekanntem Einflüssen spielt keine Rolle. Zwei Merkmale sind identisch, wenn die Metrik äquivalent ist, sich die Bezeichnung aber unterscheidet. Laut [134] und [136] sind die Einflussfaktoren auf die Stabilität:

- Anzahl der gewählten Merkmale,
- Dimension des Merkmalsvorrats,
- Anzahl der Stichproben,
- Die zugrundeliegende Verteilung der Daten.

Der erste Einflussfaktor auf die Stabilität bei der Merkmalsselektion ist die *Anzahl der Merkmale* m im resultierenden Merkmalsvektor. Nach [134] kann folgende Abschätzung über die Wahrscheinlichkeit zur gemeinsamen Auswahl von Merkmalen in zwei Suchläufen mit neuen Daten gemacht werden. Zunächst wird die Wahrscheinlichkeit zur Auswahl eines Merkmals angenommen:

$$p(M) = \frac{1}{\hat{m}} \quad (4.26)$$

Die Wahrscheinlichkeit, dass ein Merkmal in einem Merkmalsvektor enthalten ist, kann folgendermaßen berechnet werden:

$$p(\hat{M}) = \frac{1}{\binom{\hat{m}}{m}} \quad (4.27)$$

Und schließlich kann die Wahrscheinlichkeit, dass mindestens ein Merkmal in zwei resultierenden Merkmalsvektoren enthalten ist, mit:

$$p(|\underline{M}_1 \cap \underline{M}_2| \geq 1) = \frac{\binom{\hat{m}}{\hat{m}-m}}{\binom{\hat{m}}{m}} \quad (4.28)$$

angegeben werden. Daraus ergibt sich, dass die Wahrscheinlichkeit für den Fall, dass zwei Merkmalsvektoren ein gleiches oder mehrere gleiche Merkmale enthalten, mit m steigt.

Wie in (4.28) ersichtlich, ist für die Auswahl identischer Merkmalsvektoren nicht nur die Anzahl der Merkmale in den resultierenden Merkmalsvektoren entscheidend, sondern auch die Größen des *Merkmalsvorrats* \hat{m} . Wird nach der Wahrscheinlichkeit für zwei identische Merkmalsvektoren gefragt, dann gilt nach [134]:

$$p(\underline{M}_i = \underline{M}_j) = \frac{1}{\binom{\hat{m}}{m}} \quad (4.29)$$

Die optimale Anzahl an Merkmalen m_{opt} , die zur Lösung eines Klassifikationsproblems benötigt werden, wird beim KDED mit (2.1) bestimmt und ist für die untersuchten Fälle gleich zwei. Zudem werden über die Systematik der Merkmalsextraktion eine große Anzahl ca. 4000 an Merkmalen generiert, sodass gilt $m \ll \hat{m}$. Möglich wäre die Verkleinerung des Merkmalsvorrats durch Filterung, sodass $m < \hat{m}$ erreicht wird. Die Wahrscheinlichkeit, dass zwei gleiche Merkmalsvektoren gewählt werden, für das betrachtete Konzept gering.

Der *Stichprobenumfang* ist ein weiterer Faktor, der Auswirkungen auf die Stabilität der Merkmalsselektion hat, wie in [134] überprüft wurde. Wie bereits in Abs. 4.1.2 thematisiert, ist ein ausreichend großer Stichprobenumfang für das Data-Mining notwendig, um mehrere Fälle zu betrachten und die Ergebnisse auf Überanpassung zu überprüfen. Aufgrund dessen,

dass der Stichprobenumfang für diese Aufgabe ausreichend groß ausgelegt wurde, wird nicht von Problemen bei der Stabilität ausgegangen.

Schließlich wirkt sich auch die *Verteilung der Daten* auf die Stabilität der Merkmalsselektion aus. Dieser Aspekt wurde in [134] untersucht und diskutiert. Wie sich bei der Durchführung der Experimente und der anschließenden Auswertung nach dem Konzept des KDED gezeigt hat, steht dieser Aspekt im Vordergrund. Eine Auswahl der aufgetretenen Probleme, die sich aus der Verteilung der Daten ergaben, ist in Abb. 4.8 dargestellt.

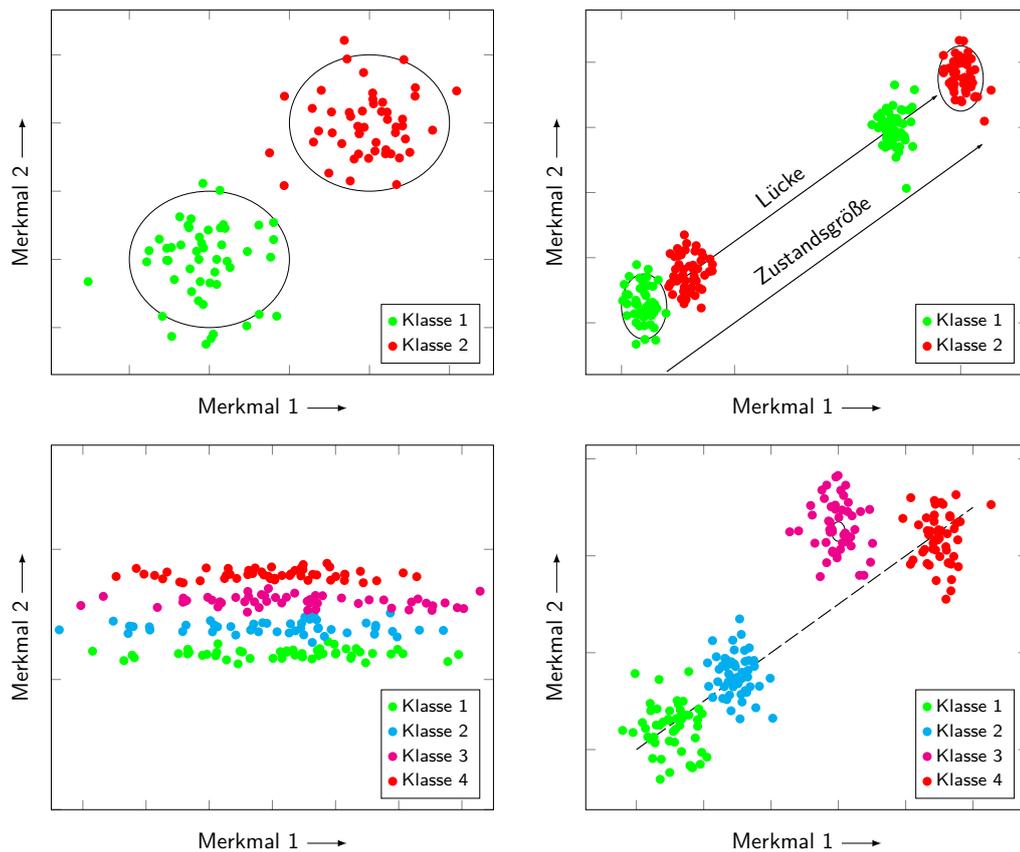


Abbildung 4.8: Einfluss der Verteilung der Daten auf die Stabilität der Merkmalsselektion. Oben links: Cluster mit idealer Form und Lage; oben rechts: lückende Cluster; unten links: schmale Cluster; unten rechts: fehlplatziertes Cluster.

Der erste dargestellte Fall zeigt den Idealfall bei der Datenauswertung. Die Daten sind in den ausgewählten Dimensionen um ein Zentrum verteilt. Die Dichte der Proben ist um das Zentrum am größten und nimmt nach außen hin ab. Die Klassengrenze verläuft scharf, jedoch liegen vereinzelt Proben außerhalb der Klassengrenze. Die zweite Klasse zeigt die gleichen Eigenschaften und liegt mit einem Abstand in der Umgebung der ersten Klasse. Sind die Daten derart angeordnet, beeinflussen Störungen die Merkmalsselektion nicht.

Im zweiten dargestellten Fall kommt es zur Lückenbildung in den Clustern, auf deren Ursachen in Abs. 5.1 eingegangen wird. Diese Verteilung der Daten ist vergleichbar mit dem Idealfall, jedoch bilden sich für jede Klasse mehrere Cluster. Zudem liegen die Cluster der zweiten Klasse in den Lücken und nahe an den Zentren der ersten Klasse. Merkmalsvektoren, die solche Muster ausbilden, sind keine gültige Lösung im Sinne des KDED, da die Richtung, in der sich eine Einflussgröße fortsetzt, von einer anderen Klasse unterbrochen wird. Zudem ist das Ergebnis instabil, da es kein gemeinsames Zentrum gibt und somit kleinste Änderungen zur Schneidung der Klassen und damit zur Ablehnung in der Suche führen. Anfällig für diese Art von Fehlern sind abstands-basierte Klassifizierer wie kNN. Das Ergebnis kann im Interpretationsschritt verworfen werden. Zur Unterstützung bei der Auswertung eignen sich die Klassifizierungsergebnisse anderer Klassifizierer wie den SVM, da diese nicht anfällig für diese Art von Fehlern sind.

Der dritte Fall zeigt lange, schmale Cluster, die parallel verlaufen. Bei der Anordnung der Daten handelt es sich zunächst um eine gültige Lösung im Sinne des KDED. Wie im zweiten Fall ist die Anordnung aber auch instabil, wenn die Parameter des Experiments nicht ideal gewählt werden. Rücken die Cluster durch geringfügige Änderungen zusammen, kann über die Bestimmung des Abstandes nicht mehr zwischen den Klassen unterschieden werden, weshalb die entsprechenden Merkmale verworfen werden. Bei dieser Anordnung wird davon ausgegangen, dass SVM robuster reagiert im Vergleich zu den kNN.

Der vierte Fehler im Kontext der Verteilung der Daten ist die Fehlplatzierung von Clustern. Wie bereits diskutiert, soll im Schritt Experiment eine Reihenfolge in die Daten eingepreßt werden. Bei der Einprägung kann es jedoch zu Fehlern kommen, wodurch die Reihung gestört wird. Ursache dafür sind z. B. Drifts in Folge von Erwärmung oder sonstigen Ausgleichsvorgängen, die nicht durch einen Regler konstant gehalten werden. Die Fehlplatzierung aufgrund eines Drifts kann daher nicht für die erste Auswertung abgeschätzt werden. Betroffene Cluster können so verschoben werden, dass der Klassifizierungsfehler für einen bestimmten Klassifizierer ansteigt und damit Merkmale nicht berücksichtigt werden.

Probleme in der Verteilung der Daten müssen auf der Ebene des Experiments korrigiert werden. Aufgrund dessen können mehrere Zyklen des KDED notwendig werden, da die Probleme erst bei der Darstellung am Ende der Auswertung auffallen. Anschließend muss das Experiment angepasst und wiederholt werden, was einen großen Aufwand bedeutet. Im Folgenden werden Handlungsempfehlungen für den Versuchsentwurf gegeben, mit denen die Anzahl an Wiederholungen begrenzt werden kann.

Die Diskussion um die Stabilität bei der Merkmalsselektion verdeutlicht die Problematik bei isolierter Anwendung solcher Algorithmen. Was fehlt, ist die abschließende Einordnung der Teilergebnisse, wie im Schritt Interpretation beim vorgestellten KDED. Mit der Anerkennung redundanter und identischer Merkmale sowie dem Auftreten von Rauschen wird deutlich, dass mehrere Merkmalskombinationen und Merkmale als Lösung akzeptiert werden müssen.

Das Ziel des KDED ist somit, alle Merkmale mit starker Abhängigkeit zu den Einflussgrößen zu identifizieren und die Austauschbarkeit von Merkmalen zu bestimmen.

Realisiert wird dieser Ansatz dadurch, dass mehrere Suchläufe durchgeführt werden, um alle relevanten Merkmale zu bestimmen. Die Strategie zur Entdeckung neuer Kombinationen ist, die bereits gefundenen Merkmale von der Suche auszuschließen. Die Suchstrategie ist in Abb. 4.9 dargestellt. Der Zyklus wird so lange wiederholt, bis die gefundenen Merkmalsvektoren die notwendige Fehlerrate nicht mehr unterschreiten oder zu viele Merkmale benötigt werden.

Ein Nachteil dieser Strategie ist, dass ein einzigartiges Merkmal, das erstmalig einen bestimmten Einfluss beschreibt, aus der Suche herausgenommen wird und gegebenenfalls alle weiteren Merkmalskombinationen das Kriterium nicht mehr erfüllen. In diesem Fall würden redundante oder identische Merkmale zur Berücksichtigung der weiteren Einflussgrößen nicht gefunden werden. Es ist jedoch denkbar, den Algorithmus mit einer Haltefunktion auszustatten, um bestimmte Merkmale nicht zu verwerfen. Ein Vorteil der Strategie ist, dass durch das Ausscheiden von Merkmalen auch identische Merkmale gefunden werden können, die sonst durch Beachtung der Anordnung oder einer Reihung nicht gewählt werden, da das erst beste Merkmal gewählt wird.

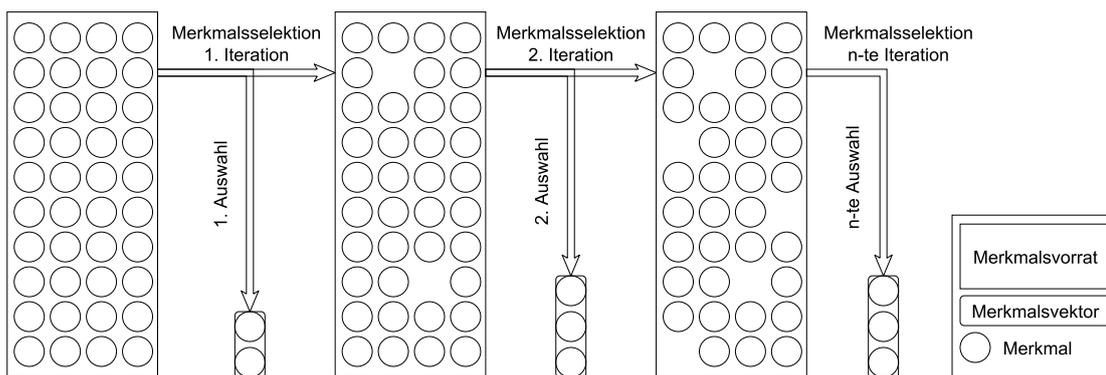


Abbildung 4.9: Strategie zur Suche redundanter Merkmale.

4.4 Fallstudien

In den vorangegangenen Abschnitten wurde hauptsächlich auf die Merkmalsselektion eingegangen, die nur ein Teil des Data-Minings oder des KDED ist und es wurden die Algorithmen zur Auswahl der Merkmale beschrieben. Auf der übergeordneten Ebene sind jedoch Fragen der folgenden Art zu beantworten:

1. Anhand welcher Merkmale können die Zustände unterschieden werden, die von Größe A beeinflusst werden?

2. Anhand welcher Merkmale können die Zustände unterschieden werden, die von Zielgröße A und einer Störgröße B beeinflusst werden?
3. Anhand welcher Merkmale können die Zustände unterschieden werden, die von Zielgröße A und einer Störgröße B beeinflusst werden, während Störgröße C den Wert X annimmt?

Damit die Merkmalsselektion diese Art von Fragen beantworten kann, müssen die Daten, die über die eingestellten Zuständen gewonnen wurden, entsprechend sortiert werden.

Wie in Abs. 5.1 beschrieben, werden während des Experiments Proben aus verschiedenen Zuständen gezogen und mit einem Klassenlabel versehen, wodurch Primärklassen entstehen. Das Label für diese Klassen wird nach folgendem Schema generiert:

```
<Kuerzel-Zielgröße><Indikator für Wert/ Wertebereich>_ ...
<Kuerzel-Störgröße-1><Indikator für Wert/ Wertebereich>_ ...
<Kuerzel-Störgröße-i><Indikator für Werte/ Wertebereich>
```

Beispiel für Realisierungen dieses Schemas ist für Fehltausrichtung (Parallelversatz) mit Fehlergrad 1: *PV1*. Wurden weitere Störgrößen im Experiment berücksichtigt, wie der Lastbereich von 72 % bis 80 %, die Nennlast und Testobjekt (TO) 1, dann ergibt sich folgendes Label: *PV1_L80_TO1*. Zur Formulierung der einfachsten Frage müssen immer mehrere Abstufungen der Zielgröße vorliegen (*PV1*, *PV2*, *PV3*), die dann an die Merkmalsselektion übergeben werden. Für die Durchführung der Auswertung haben sich drei Abstufungen für jede Einflussgröße bewährt, die Anzahl muss jedoch am Problem orientiert sein.

Grundlegend ist das Ziel des KDED immer die Identifikation der Zusammenhänge zwischen den Merkmalen und den Einflussgrößen. Dabei ist zu beachten, dass mehrfache Abhängigkeiten von Merkmalen nicht auszuschließen sind. In der Folge müssen neben der Zielgröße auch die Störgrößen als Bedingung in die Fragen aufgenommen werden, wodurch komplexere Fragen entstehen. Für den Selektionsalgorithmus werden durch weitere Variationen und Abhängigkeiten die Anforderungen an die Suche verschärft, wodurch dieser gezwungen wird, nur hochwertige Ergebnisse im Sinne der komplexeren Frage auszugeben. In Abb. 4.10 ist das Konzept zur Zusammenlegung der Primärklassen für komplexere Fragestellungen dargestellt. Wie zu sehen ist, werden Variationen der Störgrößen zusammengefasst, die alle die gleiche Stufe der Zielgröße und gegebenenfalls eine Stufe weiterer Störgrößen repräsentieren. Die zusammengelegten Daten bekommen im Anschluss ein neues Label, das die nicht variierenden Einflüsse kennzeichnet.

Die Formulierung der Frage an den Merkmalsselektionsalgorithmus wird mit der Übergabe der Primärklassen oder der Verbundklassen abgeschlossen. Zur eindeutigen Kennzeichnung der Frage und den übergebenen Daten wird jede Anfrage nach folgendem Schema gekennzeichnet:

<ZG> _ <Kürzel der Zielgröße>__ ...
 <Para> _ <Kürzel der Störgröße><Indikator für Wert/ Wertebereich>__ ...
 <StG> _ <Kürzel der Störgröße>

Nach diesem Schema werden die oben formulierten Fragen folgendermaßen codiert:

1. ZG.A
2. ZG.A..StG.B
3. ZG.A..Para.CX..StG.B

Die Verwendung von Parametern ist dann relevant, wenn komplexe Fragen nicht zu sinnvollen Ergebnissen führen. In diesem Fall kann die Menge der vorhandenen Daten eingeschränkt werden.

Welche Auswirkungen die Zusammenlegung der Daten auf die Merkmalsselektion hat, wird im Abs. 4.1.2 unter der Auswahl des Validierungsverfahrens diskutiert.

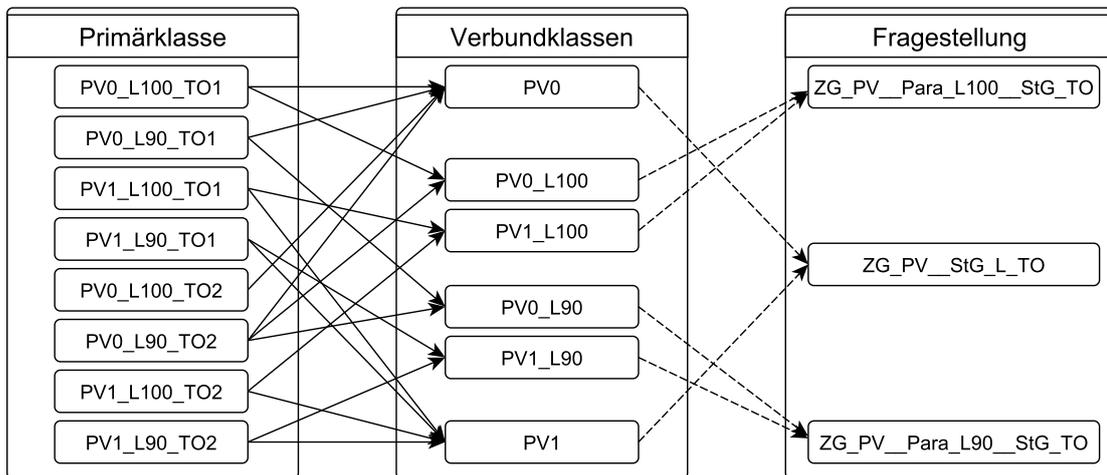


Abbildung 4.10: Konstruktion von Verbundklassen aus Elementarklassen und Ableitung der Fragestellung an den FS-Algorithmus.

5 Experimente

Das nachfolgende Kapitel behandelt die Experimente, für die Untersuchungen angestrengt wurden. Zunächst wird der Versuchsentwurf auf einer konzeptionellen Ebene diskutiert. Dabei geht es um die Abstimmung des Data-Minings mit den Experimenten und den damit verbundenen Anforderungen. Anschließend werden die durchgeführten Experimente beschrieben. Mit Kavitation [137], gebrochenem Rotorstab [138] und Fehlaustrichtung [139] wurden relevante und häufige Fehler gewählt, die einmal aufseiten der Arbeitsmaschine, einmal an der ASM selbst und einmal zwischen den Teilsystemen auftreten. Zunächst sollen die Aspekte besprochen werden, die allgemein für den Entwurf des Experiments gelten. Anschließend wird die Theorie zu den Fehlern behandelt, die die Grundlage zur realistischen Nachstellung der Fehlerszenarien darstellt. Schließlich wird der Aufbau und Ablauf des Experiments für jedes Fehlerszenario beschrieben.

5.1 Entwurf des Experiments, Zustände und Klassen

Wie bereits zuvor beschrieben, werden beim Data-Mining gekennzeichnete Daten verarbeitet, um Merkmale zu finden, die eine Trennung der Zielgröße ermöglichen. In diesem Abschnitt wird beschrieben, wie diese Daten aus realen Fehlerzuständen gewonnen werden und nach welchen Regeln ein Experiment zu entwerfen ist, mit dem diese Fehlerzustände generiert und mit der nachfolgenden Merkmalsselektion abgestimmt werden. Die Regeln adressieren die Aspekte:

- Automatisierung,
- Formulierung der Aufgabe als Klassifikation oder Regression,
- Betrachtungsbereich,
- Anzahl und Abstand der Schritte,
- Erfassung der dominanten Einflüsse.

Ziel des Experiments ist die Bereitstellung von Informationen, in diesem Fall der elektrischen Größen Spannung und Strom, aus unterschiedlichen Zuständen. Damit die Ergebnisse auf praktische Anwendungen übertragen werden können, sind die Fehler(-zustände)

realistisch nachzustellen. Dies betrifft zum einen die Einbringung des Fehlers und zum anderen die Kombination der Zielgröße mit weiteren Einflussfaktoren, den Störgrößen. Bei der Durchführung des Experiments ist der steigende zeitliche Aufwand mit jedem Detaillierungsgrad zu beachten. Dieser steigt z. B. mit der Abstufung der Einflussgrößen (Diskretisierung) und der Breite des betrachteten Anwendungsbereichs, aber auch mit der benötigten Messzeit zur Generierung des notwendigen Stichprobenumfangs je Zustand. Aus diesem Grund können die Experimente nur (teil-)automatisiert durchgeführt werden. Wobei zu beachten ist, dass in der Praxis oft keine vollständige Automatisierung möglich ist. Das ist der Fall, wenn Fehler Schäden an Komponenten des Testobjekts darstellen. In diesem Fall müssen diese Komponenten oder das ganze Testobjekt für die Herstellung der unterschiedlichen Zustände getauscht werden. Können verschiedene Fehlergrade oder Fehlertypen nicht an einem Aggregat durchgeführt werden, so müssen mehrere Testobjekte mit dem gleichen Fehler einbezogen werden, damit auch Toleranzen der Testobjekte in den Daten enthalten sind. Sonst besteht die Möglichkeit, dass die Unterscheidung an einem nicht berücksichtigten Einfluss vorgenommen wird. Im Gegensatz dazu können externe Einflüsse wie Laständerungen über entsprechende Prüfstände vollständig automatisiert werden.

Für den Entwurf des Experiments ist zudem entscheidend, ob Algorithmen zur Klassifikation oder Regression eingesetzt werden. Bei kontinuierlichen Systemen ist die Regression angezeigt und bei diskreten die Klassifikation. Kontinuierliche Systeme können jedoch auch diskretisiert werden, um die Klassifikation anzuwenden. An den Stand der Forschung anknüpfend, werden in dieser Arbeit die Aufgaben als Klassifikationsaufgaben interpretiert. Dies hat zur Folge, dass für jede Klasse ein Intervall definiert werden muss, aus dem Proben gezogen werden. Die Breite und Dichte dieses Intervalls sind dabei entscheidend, um Diskretisierungsfehler [123] und Scheinlösungen zu vermeiden. Scheinlösungen sind dadurch charakterisiert, dass diese niedrige Fehlerraten erzielen, jedoch nicht in realen Anwendungen eingesetzt werden können. Ein Beispiel dazu sind Lücken wie in Abs. 4.3 und Abb. 4.8 beschrieben. Weitere Parameter, die bei der Abtastung der Zustände beachtet werden müssen, um aussagekräftige Ergebnisse zu erzielen und die Durchführbarkeit zu gewährleisten, sind:

- Betrachtungsbereich: werden nicht lineare Effekte berücksichtigt?
- Schrittweite: werden Überschneidungen und Lücken vermieden?

Der *Betrachtungsbereich* kann über zwei Parameter beschrieben werden: der Lage und der Breite. In Kombination entscheiden die Parameter darüber, ob und wie stark nicht lineare Effekte in den Zuständen berücksichtigt werden. Technische Systeme wie ASM, Pumpe oder Lüfter und Verbundsysteme sind grundsätzlich nicht lineare Systeme und können nur in engen Grenzen als linear angenommen werden. Ziel des Experiments muss es daher sein, die Nichtlinearität in den Daten abzubilden. Als sinnvoll wird zudem angenommen, dass

der Betrachtungsbereich den Nennpunkt beinhaltet, da wegen der Betriebssicherheit und des Wirkungsgrades Aggregate meist in der Nähe dieses Punktes betrieben werden [140]. Der Nennpunkt ist dabei der Punkt, auf den das Aggregat für den Dauerbetrieb ausgelegt ist. Dieser wird über mehrere Größen definiert [140]. Von Teillast wird gesprochen, wenn eine der Größen zur Berechnung der mechanischen Leistung, ausgehend vom Nennpunkt, reduziert wird. Eine vollständige Einbeziehung des Teillastbereichs ist auch nicht sinnvoll, da der Umfang des Experiments sowie die Messzeit steigen und nur ein Teil der Anwendungen in diesem Bereich dauerhaft betrieben wird. Für die praktische Anwendung muss daher auch bei einem automatisierten Experiment zwischen der Anzahl der Zustände und der Messzeit abgewogen werden. Ein weiterer Aspekt, der ausgehend vom Nennpunkt die Breite des Betrachtungsbereichs bestimmt, ist der Signal-Rauschabstand, der sich im Teillastbereich verschlechtert. Damit sich ein unzureichender Signal-Rauschabstand nicht negativ auf die Auswertung auswirkt, werden in der unteren Hälfte des Anwendungsbereichs keine Messungen durchgeführt. In nachgelagerten Untersuchungen kann anschließend geklärt werden, wie weit und mit welchen Mitteln die Ergebnisse auf den unteren Teillastbereich übertragen werden können.

Wie auch bei den bisherigen Parametern nimmt die *Schrittweite* sowohl Einfluss auf die Qualität der Auswertung als auch auf die Messzeit. Für das Data-Mining muss die Schrittweite so gewählt werden, dass sich die Cluster nicht schneiden und sich keine Lücken bilden. Wird die Schrittweite zu klein gewählt, schneiden sich die Cluster großflächig, wodurch der Algorithmus keine Unterscheidung zwischen geeigneten und ungeeigneten Merkmalen vornehmen kann. Schneiden sich die Cluster im Grenzbereich, wird eine Unterscheidung wahrscheinlicher. Es muss jedoch darauf geachtet werden, dass geeignete Merkmalsvektoren nicht aufgrund schlechterer Klassifizierungsergebnisse in Kombination mit einem Schwellwert aussortiert werden. Im optimalen Fall liegen die Cluster so, dass diese sich nicht berühren und nur Ausreißer Fehler produzieren. Wird die Schrittweite zu groß gewählt, können Lücken entstehen. Probleme mit Lücken wurden bereits diskutiert. Wurde die Breite des Betrachtungsbereichs festgelegt, dann entscheidet die Schrittweite über die Anzahl der Messpunkte, die zur Berechnung der Messzeit beiträgt. Die Anzahl der Messpunkte ist darüber hinaus auch für die Erfassung der Nichtlinearität entscheidend. Für die Durchführung muss ein Kompromiss aus der Länge der Messzeit, der Auswertbarkeit und der Erfassung nicht linearer Effekte getroffen werden. Für die durchgeführten Experimente wurden jeweils vier Schritte für die Fehlergröße gewählt, daraus resultieren ein Gesundheitszustand und drei Zustände mit steigendem Fehlergrad. Die Variation der Störgrößen unterscheidet sich je nach Untersuchung.

Die bisher beschriebenen Regeln wirken sich auf die Lage und Verteilung der Proben im m -dimensionalen Merkmalsraum aus. Die Maßnahmen sind notwendig, um zu gewährleisten, dass die Klassen unterscheidbar sind. Im Folgenden werden Maßnahmen beschrieben,

um Abhängigkeiten zwischen den dominanten Einflussfaktoren zu berücksichtigen. Sollen Korrelationen zwischen den Merkmalen und den Klassen identifiziert werden, müssen diese durch die Daten abgebildet sein. Wie bereits in der Einleitung dargestellt, wurden im Bereich der technischen Diagnostik Merkmale, die mit den Störgrößen korrelieren, als Problem identifiziert, da bei mehrfach korrelierten Merkmalen der Klassifizierer keine zuverlässige Unterscheidung vornehmen kann.

Die für das KDED notwendigen Zustände können über eine Zustandstabelle systematisch erzeugt werden. Tabelle 5.1 zeigt eine Verallgemeinerung einer solchen Zustandstabelle. Für die Erstellung der Tabelle müssen im ersten Schritt die dominanten Einflussfaktoren, also die Fehlergröße und die Störgrößen, bestimmt oder festgelegt werden. Anschließend müssen wie oben beschrieben die Wertebereiche oder die Stützstelle für jede Größe definiert werden, dann können alle Permutationen eingetragen werden. Aus den Permutationen kann wie in Abs. 4.4 beschrieben das Label für den Zustand oder auch die Primärklasse abgeleitet werden. Für die Fehlergröße hat sich bei der Auswertung gezeigt, dass es ausreichend ist, Stützstellen anstatt Wertebereiche vorzugeben. Die Klassifizierer sind in der Lage, Zwischenwerte in einer Dimension zu interpolieren.

Tabelle 5.1: Beispiel einer Zustandstabelle zur Erfassung aller Kombinationen.

# Zustand	Fehlergröße in %	Störgröße 1 in %	Störgröße 2 in %
1	100	[100, 92]	[100, 92]
2	100	[100, 92]	[90, 82]
3	100	[90, 82]	[100, 92]
4	100	[90, 82]	[90, 82]
5	50	[100, 92]	[100, 92]
6	50	[100, 92]	[90, 82]
7	50	[90, 82]	[100, 92]
8	50	[90, 82]	[90, 82]
9	0	[100, 92]	[100, 92]
10	0	[100, 92]	[90, 82]
11	0	[90, 82]	[100, 92]
12	0	[90, 82]	[90, 82]

Für alle nachfolgenden Experimente wird nach dem beschriebenen Schema eine Zustandstabelle erstellt. Aufgrund der großen Zahl von Zuständen, die bereits bei wenigen Störgrößen entsteht, dient die Zustandstabelle auch zur Automatisierung der Prüfstände. Es ist jedoch zu berücksichtigen, dass nicht jede Einstellung automatisiert vorgenommen werden kann.

In diesen Fällen muss der Ablauf derart optimiert werden, dass eine Teilautomatisierung effizient umgesetzt werden kann.

5.2 Kavitation

Kavitation ist ein Phänomen, das bei allen hydraulischen Strömungsmaschinen und hydraulischen Stelleinrichtungen vorkommen kann [141, 142]. Dazu zählen Pumpen und Stellventile, aber auch Schiffsschrauben und Wasserturbinen. Kavitation wird begleitet von drei Problemen, die das Monitoring von Pumpen interessant machen. Dazu zählen der Abfall der Förderhöhe respektive des Wirkungsgrades, die Materialerosion und das Auftreten von Schwingungen [143]. Der Abfall des Volumenstroms sowie Schwingungen von naheliegenden Komponenten sind proportional zum Grad der Kavitation und treten unmittelbar in Erscheinung [86]. Hält Kavitation über einen längeren Zeitraum an, kann es zudem zu Erosion der Oberfläche nahegelegener Komponenten kommen [142]. Ist die Oberfläche angegriffen, kann sich der Schaden durch Korrosion ausweiten. Grund dafür ist, dass Komponenten mit Kontakt zu einem korrosiven Medium oft einer Schutzschicht umhüllt werden. Der Materialabtrag kann bis zur Lochbildung oder der Abtragung der Kanten fortschreiten, wodurch sich der Wirkungsgrad der Maschine dauerhaft verschlechtert. Durch eine sorgfältige Auslegung von Maschinen und Anlagen kann Kavitation vorgebeugt werden. Über die Lebensdauer einer Anlage mit sich verändernden Betriebsbedingungen und Arbeitspunkten kann Kavitation jedoch nicht vollständig ausgeschlossen werden [86].

Kavitation entsteht, wenn der Druck im Medium unter den Dampfdruck fällt [137]. In hydraulischen Armaturen kommt es an Verjüngungen und an Schaufelrädern zur Geschwindigkeitserhöhung des Mediums, in deren Folge es zu einem Druckabfall kommt. Kritisch ist das auf der *Saugseite*, da an dieser Stelle ein ausreichender Vordruck anstehen muss. Dieser Zusammenhang wird mit der Bernoulli-Gleichung [144] beschrieben:

$$\text{const.} = p + \underbrace{\frac{\rho \cdot v^2}{2}}_{\text{dynamischer Druck}} + \underbrace{\rho \cdot g \cdot h}_{\text{Schweredruck}} \quad (5.1)$$

darin steht p für den statischen Druck, ρ für die Dichte v für die Geschwindigkeit des Mediums, g für die Erdbeschleunigung und h für die Höhe einer Wassersäule. Mit $h_1 = h_2$ und $v_2 > v_1$

folgt:

$$p_1 + \frac{\rho \cdot v_1^2}{2} = p_2 + \frac{\rho \cdot v_2^2}{2} \quad \Leftrightarrow \quad (5.2)$$

$$p_2 = p_1 - \underbrace{\frac{\rho \cdot (v_2^2 - v_1^2)}{2}}_{>0} \quad ! > p_D \quad (5.3)$$

und damit, dass bei steigender Geschwindigkeit der statische Druck abfällt. Sinkt der Druck im Medium an einer Stelle unter den Dampfdruck p_D , geht das Medium in den gasförmigen Zustand über, wobei sich Dampfblasen bilden. Steigt der Druck wieder an, implodieren die Blasen, wodurch ein Massenstrom entsteht. Die kinetische Energie der Teilchen ist dabei so groß, dass beim Aufprall auf eine feste Oberfläche Schwingungen entstehen, die sich als prasselndes Geräusch äußern und Material abgetragen wird. Mit dem Experiment ist zu klären, ob die Schwingungen des Schaufelrads bei Kavitation oder sonstige Änderungen des Zustands charakteristische Merkmale im Strom des ASM verursachen. Der Druckabfall, der mit Kavitation einhergeht, ist für die technische Diagnostik nicht geeignet, da dieser auch durch eine Änderung des Arbeitspunktes auftreten kann.

Wie aus (5.2) abgeleitet werden kann, wird Kavitation durch folgende Konstruktions- und Betriebsparameter beeinflusst:

- die Drehzahl,
- den Durchmesser des Pumpenrads,
- Vordruck.

Drehzahl und Durchmesser beeinflussen die Umfangsgeschwindigkeit des Pumpenrads $v = \pi \cdot d \cdot f_{\text{mech}}$ und über das Newtonsches Reibungsgesetz [145] die Geschwindigkeit des Mediums und schließlich den Druckabfall in der Pumpe. Der Vordruck auf der Saugseite bildet eine Reserve und kann durch eine Wassersäule über $p_1 = \rho \cdot g \cdot h$ eingestellt werden. Zur Verdeutlichung der Bedingungen, die zur Kavitation führen, zeigt Abb. 5.1 den Druckverlauf entlang einer Stromlinie in einem einfachen System. Das System besteht aus einem Tank mit einer Wassersäule h und einer Luftblase, in der Umgebungsdruck vorherrscht. Von dem Tank mit unendlich großem Volumen strömt das Medium durch eine Rohrleitung, die einen Druckverlust verursacht, zur Saugseite der Pumpe. Effekte beim Übergang zwischen den Teilbereichen sind vernachlässigt. In der Pumpe wird das Medium beschleunigt, wodurch der Druck abfällt. Ist die Pumpe nicht auf das System abgestimmt, dann sinkt an dieser Stelle der Druck unter dem Dampfdruck und es entsteht Kavitation. Ist die Druckreserve für den Betriebspunkt der Pumpe ausreichend groß (gestrichelte Linie), entsteht keine Kavitation.

Der Nachweis von Kavitation kann nach [141] über folgende Kriterien erbracht werden:

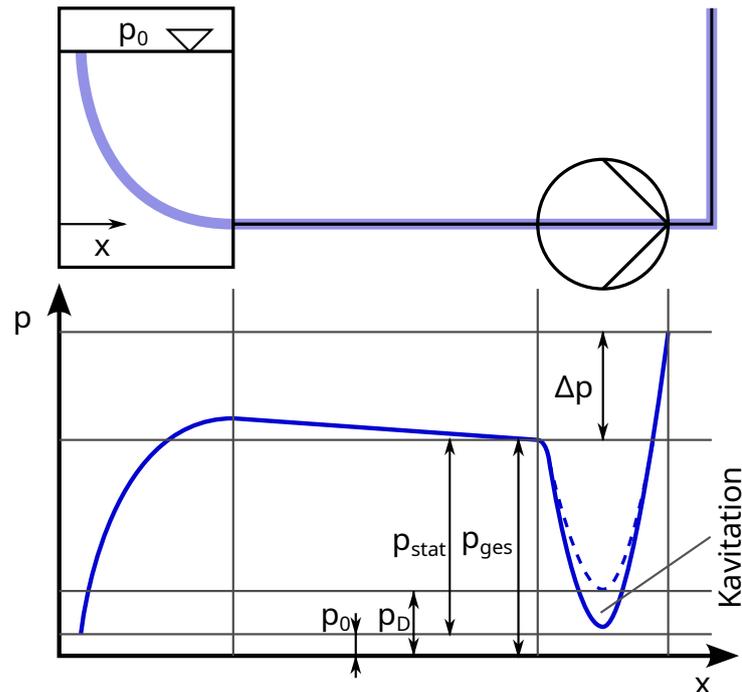


Abbildung 5.1: Druckverlauf in einem einfachen hydraulischen System entlang einer Strömungslinie zur Beschreibung der Entstehung von Kavitation in einer Pumpe.

- Net Positive Suction Head (NPSH),
- Blasenlänge,
- Abfall der Förderhöhe Δp respektive ΔH und des Wirkungsgrads $\Delta \eta$,
- Schalldruckpegel,
- Materialverschleiß.

Als Kriterium im (teil-)automatisierten Experiment eignen sich NPSH, Δp und $\Delta \eta$, wie im Folgenden erläutert wird. Für die Anwendung des NPSH müssen nach [137] zwei Angaben unterschieden werden: erstens der Kennwert der Pumpe NPSHR und zweitens der Kennwert zur Anlage NPSHA. Der Pumpenkennwert wird vom Hersteller bestimmt und gibt an, ab wann Kavitation auftritt. Der Anlagenkennwert beschreibt den Ist-Zustand im Betrieb. Kavitation tritt dann auf, wenn $NPSHA < NPSHR$. Der NPSH wird nach [143] kann wie folgt berechnet werden:

$$NPSH = \frac{p_{ges} - p_D}{\rho g} \quad (5.4)$$

Darin ist p_{ges} der Gesamtdruck, p_{D} der Dampfdruck, ρ die Dichte des Mediums. Wird der Differenzdruck verwendet, muss lediglich die Abweichung zum Referenzzustand berechnet werden. Der Druck kann mit einem geeigneten Messgerät zur Messung des Differenzdrucks direkt gemessen werden. Nach der Norm wird anerkannt, wenn der Differenzdruck um 3 % zum Normalzustand abfällt. Vergleichbar mit der Bestimmung der Kavitation aus dem Differenzdruck ist die Bestimmung aus dem Wirkungsgradabfall. Neben der Messung des Differenzdrucks muss in diesem Fall auch der Volumenstrom gemessen werden. Kavitation wird anerkannt, wenn der Wirkungsgrad um 1 % abfällt. Alle anderen Kriterien wurden verworfen, da der Aufwand für den Nachweis zu groß ist oder dieser nicht im laufenden Betrieb durchgeführt werden kann. Unter den angedachten Kennzahlen hat sich der NPSH als geeignet für die Auslegung des Experiments erwiesen, da die konstruktiven Parameter des Prüfstands einfließen. Für die Durchführung des Experiments ist jedoch wegen der einfachen Bestimmung der Differenzdruck am geeignetsten.

Für den Entwurf des Experiments sind die Einflussfaktoren, die Kavitation begünstigen, und die Verfahren für den Nachweis ausschlaggebend. Aufgrund der Einschränkung, dass sich die Untersuchungen auf netzgeführte ASM beziehen sollen, entfällt die Drehzahl als Parameter.

Wie bereits in Abs. 4.4 diskutiert, müssen für das Data-Mining Proben aus Zuständen gewonnen werden, die in den dominanten Einflussgrößen variieren. Tabelle 5.2 listet diese Zustände und die zugehörigen Einflussgrößen auf. Durch die Vielzahl an Zuständen ist auch der Austausch des Laufrads nicht praktikabel. Für ein teilautomatisiertes Experiment bleibt somit nur der hydrostatische Druck als Einflussgröße.

Abbildung 5.2 zeigt den Aufbau des Prüfstands. Wie in der Abbildung dargestellt, besteht der Prüfstand aus einem Tank mit angeschlossenem Rohrleitungssystem. In dem Rohrleitungssystem befindet sich die Messtechnik zur Erfassung der Prozessgrößen: Medientemperatur TI100, absoluter Druck des Mediums PI102, Differenzdruck PDI100, Drehzahl SI100, Volumenstrom FI100, absoluter Druck der Gasblase PI100) und die Stelleinrichtung (V100, V101). Das TO wird an Position P100 installiert.

Der Druck auf der Saugseite, im Folgenden Position 2, kann für den statischen Fall aus (5.1) mit $v_1 = v_2$ und

$$p_2 = p_1 + \rho \cdot g(h_1 - h_2) \quad (5.5)$$

berechnet werden. Als Position 1 wird im Folgenden die Oberfläche der Wassersäule im Tank angenommen. Bei p_2 handelt es sich um den hydrostatischen Druck und bei p_1 um den atmosphärischen Druck. Daraus ergeben sich zwei Stellschrauben zur Einstellung von Kavitation: erstens über den Füllstand im Behälter und zweitens über die Absenkung des Drucks in der Luftblase im abgeschlossenen Behälter. Die Reduzierung der Wassersäule

Tabelle 5.2: Zustandstabelle für das Experiment Kavitation

Nr. Zustand ¹⁾	Kavitation in $-\Delta\%$ von p	Durchfluss in $\frac{\text{m}^3}{\text{h}}$
1	0	110
2	0	100
3	0	90
7	1,5	110
8	1,5	100
9	1,5	90
10	3	110
11	3	100
12	3	90
13	10	110
14	10	100
15	10	90

1) für je eins von drei TO

wird verworfen, da die Maßnahme dazu führt, dass beim Rücklauf des Wassers in den Tank Luft oder Gas in das Medium eingezogen wird, wodurch das Medium keinen Dampf bildet. Stattdessen kommt es verstärkt zur Gaskavitation, die jedoch in ihrer Wirkung deutlich schwächer ausfällt als die Dampf-Kavitation, siehe dazu [143]. Es bleibt die Absenkung des Drucks in der Luftblase des Tanks. Für diese Maßnahme wird eine Vakuumpumpe (P200) an den Tank angeschlossen, mit der das Gas über der Wassersäule evakuiert werden kann.

Das gewählte Konzept zur Erzeugung von Kavitation hat jedoch Grenzen, die über den NPSHR definiert sind. Die Kennlinie der Kennzahl wird in den Datenblättern der Pumpe angegeben. Abbildung 5.3 zeigt den Verlauf für das TO wie im Datenblatt *KSB In-Line Pump Etaline / Etaline-R* dargestellt. Zu beachten ist, dass im Datenblatt die Kurven für Laufräder mit 114 mm und 174 mm Durchmesser angegeben sind und die Kurve für den Durchmesser 150 mm geschätzt ist. Es ist zu erkennen, dass die Pumpe im Bereich des Nennpunkts eine größere Reserve des NPSH benötigt. Aufgrund der Pumpengeometrie kann in diesem Bereich Kavitation bereits mit einer geringeren Absenkung des Drucks erreicht werden. Mit dem verfügbaren Prüfstand war Kavitation unterhalb von $Q = 0,8 \cdot Q_N$ nicht möglich, wodurch die Auswahl der Zustände in Tabelle 5.2 resultiert.

Der Nachweis der Kavitation wird über den Druckabfall im Vergleich zu den Referenzpunkten Zustand 1 bis 3 erbracht. Die Vorgehensweise hat sich bewährt, da keine Informationen zur Geometrie des Rohrleitungssystems benötigt werden, wie das beim NPSH notwendig ist.

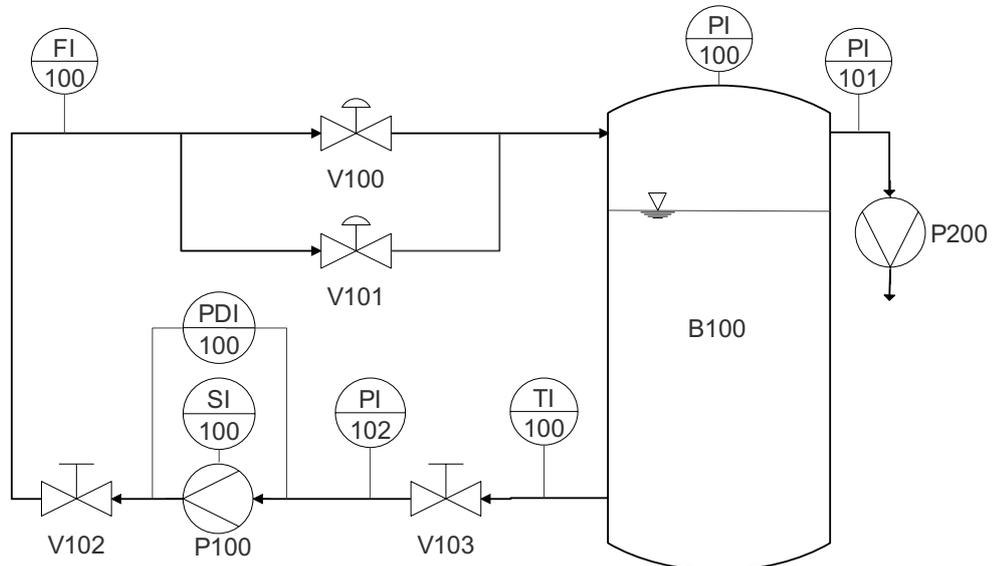


Abbildung 5.2: Rohrleitungs- und Instrumentenschaubild des Pumpenprüfstands. Oben: reale Ansicht (ohne Vakuumpumpe); unten: schematische Darstellung.

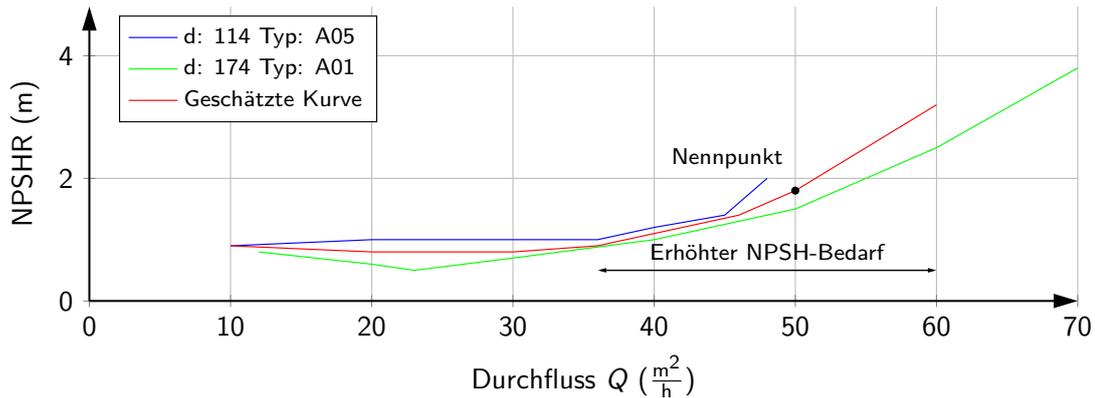


Abbildung 5.3: NPSHR-Kennlinie der ausgewählten Pumpe. Für die ausgewählte Pumpe mit einem Pumpenraddurchmesser von 150 mm wurde die Kurve geschätzt.

Entgegen den Empfehlungen zur Erstellung der Zustandstabelle wurden für den Durchfluss keine Wertebereiche definiert, sondern Arbeitspunkte. Dieser Umstand ist dem technischen Stand des Prüfstands zum Zeitpunkt der Messung geschuldet. Für optimale Ergebnisse sind Bereiche anzugeben.

5.3 Gebrochener Rotorstab

Gebrochene Rotorstäbe sind ein Schadensbild, das bei ASM mit Käfigläufern auftritt und nach [138] 5-15% der Fehler ausmacht. Betroffen sind Ausführungen des Käfigs mit gelöteten Rotorstäben [138]. Die Ausführungen kommen nach [146] überwiegend im oberen Leistungsbereich ab mehreren hundert Kilowatt zum Einsatz, da die alternative Fertigung mit gespritzten Käfigen in dieser Kategorie nicht ausführbar ist. Motoren aus diesem Leistungsbereich werden z. B. für Pumpen in Pumpwerken, sowie bei Pumpen für die Entzunderung in der Stahlindustrie oder für die Bereitstellung von Druckluft mittels Kompressoren verwendet. Ein Rotorstabbruch äußert sich zunächst in einem asymmetrischen Fluss, lokaler Erwärmung und pulsierendem Drehmoment [138]. Die möglichen Auswirkungen eines Rotorstabbruchs wurden von [87] über ein analytisches Modell untersucht. Festgestellt wurde eine Reduzierung des mittleren Drehmoments und der Stromgrundschwingung zugunsten von erhöhten Drehmomentrippel beziehungsweise von Stromoberschwingungen. Zudem wurde eine Abnahme der Verlustleistung wegen der insgesamt verminderten Ströme festgestellt. Die beschriebenen Frühfolgen wirken sich selten auf den Prozess aus, weshalb in diesem Stadium eines Rotorstabbruchs noch keine Maßnahmen ergriffen werden. Bleibt der Fehler unerkannt, kann sich im Laufe des Betriebs der Rotorstab jedoch verformen oder (ab-)brechen. Die Folgeschäden am Rotor und Stator sind dabei schwerwiegend und

können eine sofortige Abschaltung erzwingen. Der Fehlerfall ist für das Monitoring über Spannung und Strom interessant, da eine frühe Erkennung im Betrieb eine Ausweitung des Fehlers verhindern kann [138]. Zudem rechtfertigt die mögliche Schadenssumme den Einsatz zusätzlicher Maßnahmen.

Für die Erzeugung eines Drehmoments werden bei ASM auf dem Stator als auch auf dem Rotor eine Drehfeldwicklung aufgebracht, für die es grundsätzlich zwei Ausführungen gibt. Beim Schleifringläufer wird die Wicklung vergleichbar mit der Statorwicklung mit Kupferdraht realisiert und die Verschaltung erfolgt über einen Schleifring, der unterschiedliche Verschaltung der Stränge ermöglicht. Der Kurzschlussläufer dagegen ist aus massiven Leiterstäben aufgebaut, die permanent über einen Endring kurzgeschlossen sind [146]. Im Gegensatz zur Wicklung des Schleifringläufers kann die des Kurzschlussläufers beliebige Polzahlen ausführen [146]. Eine Übersicht zu den Ausführungen und weiteren konstruktiven Details gibt Abb. 5.4. Für die technische Diagnostik sind die Ausführungen des Rotors als Kurzschlusskäfig interessant, da insbesondere bei hartgelöteten und geschweißten Käfigen die Stäbe oder die Verbindungsstellen brechen können. Zur vollständigen Übersicht sind auch die Schleifringläufer und die Druckguss-Käfige aufgeführt. Nach [146] besteht der Kurzschlussläufer aus vier Komponenten: der Welle, dem Kern, den Rotorstäben und dem Kurzschlussring. Abhängig von der Baugröße und weiteren Auslegekriterien werden die Komponenten unterschiedlich ausgeführt und auch die Technik zur Verbindung der Rotorstäbe mit dem Endring sowie der Rotorstäbe mit dem Kern variieren. Für kleinere Leistungsklassen kann der Käfig durch Druckguss aus Aluminium oder Kupfer gefertigt werden. Steigt mit der geforderten Leistung das Volumen des Rotors an, so kann der Druckguss wegen des Abkühlverhaltens des Materials nicht mehr angewendet werden. In dieser Größenordnung wird der Käfig durch Verlöten der Stäbe mit den Endringen aufgebaut, wobei die Stäbe von einem Eisenkern getragen werden. Ein weiteres Unterscheidungsmerkmal ist die Position des Kurzschlussrings zu den Kurzschlussstäben. Die Stäbe können innenliegend, außenliegend oder stirnseitig angebracht werden, siehe dazu die Abbildungen in [138]. Die Anordnung entscheidet darüber, wie im Betrieb die Kräfte auf die Stäbe abgeleitet werden. Weitere Details zu den Ausführungen können in [147] und [148] gefunden werden.

Bis es zu einem gebrochenen Rotorstab und den damit verbundenen Folgeschäden kommt, durchläuft der Rotor einen umfangreichen Degenerationsprozess, der durch mechanische Spannungen verursacht wird. In der Arbeit [149] werden folgende Schritte genannt:

1. Zyklische Erhärtung oder Erweichung des Materials
2. Entstehung von Mikrorissen im Material
3. Ausweitung der Risse
4. Ermüdungsbruch.

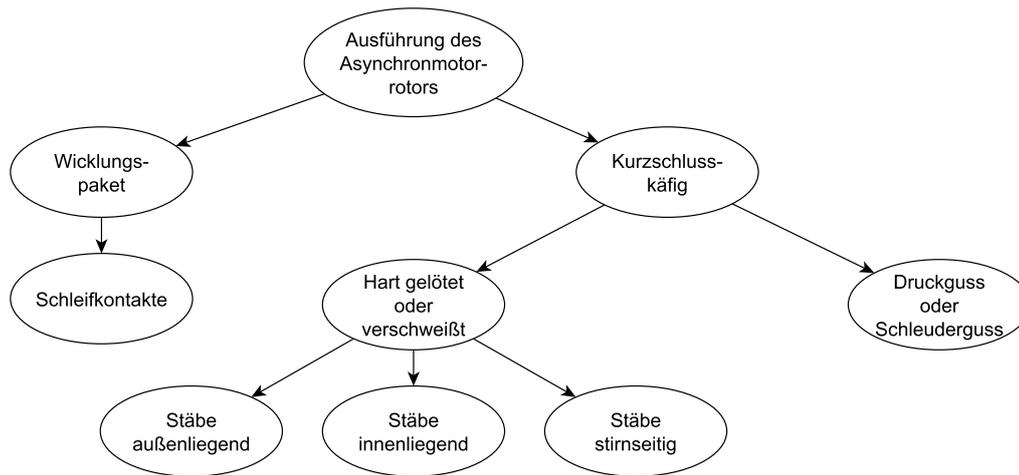


Abbildung 5.4: Ausführungen des Rotors bei Asynchronmotoren.

Die mechanischen Spannungen im Material sind nach [150] auf zwei Ursachen zurückzuführen: erstens Zug- und Druckspannungen aufgrund der unterschiedlichen thermischen Ausdehnung zwischen Rotorstab und Eisenkern, insbesondere beim Hochlauf und zweitens durch die Fliehkräfte. Nach [149] ist die Region, in der Rotorstab und Kurzschlussring verbunden sind, den größten mechanischen Spannungen ausgesetzt. Neben Brüchen an der Verbindungsstelle sind auch Brüche im Nutschlitz möglich.

Für die technische Diagnostik eines Rotorstabbruchs ist entscheidend, dass die Veränderungen im Rotor Auswirkungen auf den Statorstrom haben. Dass dieser Zusammenhang gegeben ist, geht aus den Spannungsgleichungen für den Stator und den Rotor eines vereinfachten Maschinenmodells hervor [14]:

$$\underline{U}_S = \underline{R}_S \cdot \underline{I}_S + \frac{d}{dt} \underline{\Phi}_S \quad (5.6)$$

mit

$$\underline{\Phi}_S = \underline{L}_{SS} \cdot \underline{I}_S + \underline{L}_{SR} \cdot \underline{I}_R \quad (5.7)$$

und

$$\underline{L}_{SR} = \begin{bmatrix} L_{SR11} & L_{SR12} & \cdots & L_{SR1j} \\ L_{SR21} & L_{SR22} & \cdots & L_{SR2j} \\ \vdots & \vdots & \ddots & \vdots \\ L_{SRi1} & L_{SRi2} & \cdots & L_{SRij} \end{bmatrix} \quad (5.8)$$

Dabei ist \underline{L}_{SS} die Matrix der Selbstinduktivitäten für jeden Strang und \underline{L}_{SR} die Matrix der

Gegeninduktivitäten, die die Kopplung zwischen den Strängen $i = 1$ bis 3 des Stators und den einzelnen Windungen des Rotorkäfigs beschreibt. Die Kopplung zwischen Stator und Rotor ist damit beschrieben und es wird deutlich, dass eine Änderung im Rotorkreis z. B. durch einen unterbrochenen Rotorstab Auswirkungen auf den Statorstrom haben. Auf Basis dieser grundlegenden Zusammenhänge wurde in [11] und [14] ein Modell aufgebaut, um die Auswirkungen durch gebrochene Rotorstäbe zu untersuchen. Die Zusammenhänge aus dem Modell konnten zudem durch Messungen bestätigt werden.

In der Praxis können jedoch weitere Effekte auftreten, die von dem beschriebenen Modell nicht berücksichtigt werden und die eine zuverlässige Erkennung von gebrochenen Rotorstäben verhindern. In [151] wird ein Modell des Rotors beschrieben, das die tatsächliche Stromverteilung im Schadensfall berücksichtigt, siehe Abb. 5.5. Wie in der Abbildung zu erkennen, verteilt sich der einfließende Strom auf die benachbarten Stäbe, wie in [11] bestätigt wird. Grund dafür ist die nicht ideale Isolierung der Rotorstäbe im Kern. Unter Berücksichtigung dieser Ausgleichsströme kann der Strom in einem geschädigten Stab mit (5.9) berechnet werden.

$$I_{\text{Stab}}(x) = \frac{I_N}{2} \left(1 - \frac{\cosh \lambda x}{\cosh \lambda l_{\text{Stab}}} \right) \quad (5.9)$$

Dabei ist I_N der Referenzstrom im gesunden Zustand, l_{Stab} die Länge der Stäbe und λ ein Korrekturfaktor, der das Verhältnis von Stabimpedanz zu Kontaktwiderstand berücksichtigt, siehe (5.10).

$$\lambda = \sqrt{3 \left| \frac{Z_{\text{Stab}}}{R_{\text{Stab}}} \right|} \quad (5.10)$$

Ausgehend von dem Modell weicht der Strom nach dem Bruch eines ersten Rotorstabs auf die benachbarten Stäbe aus, wodurch die Störung im Feld gedämpft wird. Eine frühe Diagnose über das Magnetfeld oder den Statorstrom wird dadurch erschwert. Der ausweichende Strom führt zu einer Überlastung der benachbarten Stäbe, die dadurch ein erhöhtes Schadensrisiko tragen. Erst wenn durch Funkenbildung der Übergangswiderstand zwischen Stab und Eisenkern erhöht ist, sinkt der Strom im geschädigten Stab ab, wodurch die Form des Statorstroms beeinflusst wird und die entsprechenden Komponenten im Spektrum ansteigen.

Zusätzlich zur Dämpfung durch die Zwischenströme können weitere Einflüsse wie Fehlausrichtung [12] und Fertigungseinflüsse [11] das Feld in gleicher Weise beeinflussen. Damit ist nicht abschließend geklärt, inwieweit die technische Diagnostik von gebrochenem Rotorstab auf Basis von Spannung und Strom und unter Beachtung der dominanten Einflüsse möglich ist.

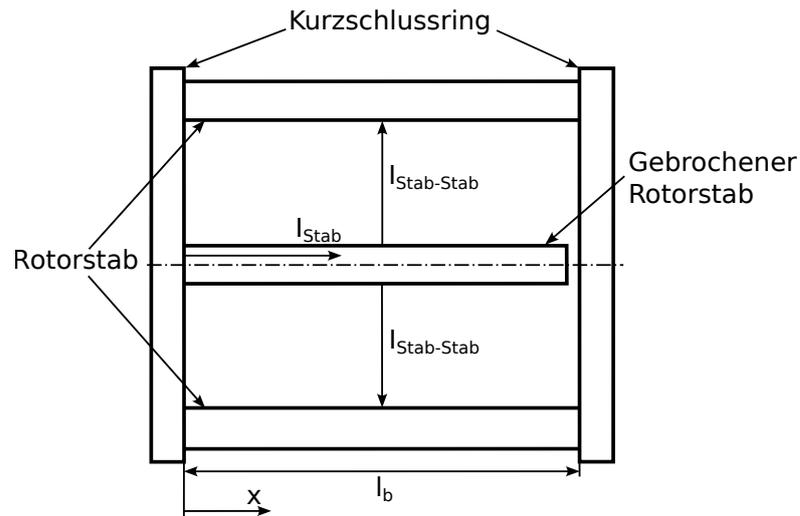


Abbildung 5.5: Modell des Rotorkäfigs mit gebrochenem Rotorstab und Zwischenströmen.

Die Experimente im Labormaßstab werden mit einem ASM Y 3x400 V der Nennleistung 7,5 kW durchgeführt. Der Käfig dieses Motors ist mittels Kupfer-Druckguss gefertigt. Das Experiment umfasst die Zustände nach Tab. 5.3. Für die Untersuchung wurden zwei Fehlerzustände ausgewählt: Motor ohne Fehler und Motor mit einem gebrochenen Stab. Jeder Fehlerzustand wird mit Lastvariationen aufgezeichnet, für die drei Bereiche definiert wurden. Die Angabe für die Last bezieht sich auf das Nenndrehmoment. Es ist zu beachten, dass das Nenndrehmoment aufgrund des Prüfstands, der eine Dauerleistung von 7 kW hat, auf 38 Nm reduziert wurde.

Tabelle 5.3: Zustandstabelle für das Experiment gebrochener Rotorstab

Nr. Zustand	Anzahl gebr. Stäbe in 1	Last in % von T_N
1	0	[100, 92]
2	0	[90, 82]
3	0	[80, 72]
4	1	[100, 92]
5	1	[90, 82]
6	1	[80, 72]

Zur Herstellung des gebrochenen Stabs wurde der Rotor ausgebaut und ein Stab im Bereich des Kurzschlussrings vollständig durchbohrt. Das Bohrloch wurde inspiziert, um die vollständige Trennung des Stabs zu bestätigen. Anschließend wurde der Rotor gewuchtet,

um einen möglichen Einfluss der Unwucht auf das Experiment zu unterbinden. Somit wurden im Experiment zwei gleiche Motoren verwendet, die sich nur in den Fertigungstoleranzen und dem Fehler unterscheiden.

5.4 Fehlausrichtung

In industriellen Betrieben und Anlagen werden Antriebe und Arbeitsmaschinen separat auf Fundamenten oder Aufhängungen montiert und über entsprechende Kupplungen verbunden. Durch diese Art der Verbindung besteht im Gegensatz zu integrierten Antrieben ein höheres Maß an Flexibilität bei der Auswahl und dem Austausch der Komponenten. Der Nachteil ist jedoch ein erhöhter Aufwand bei der Montage, um Fehlausrichtung zu reduzieren. In realen Aggregaten besteht zwischen Antrieb und Arbeitsmaschine immer ein Grad von Fehlausrichtung. Je nach Anwendung werden daher unterschiedliche Grenzwerte definiert, um Schäden an den Kupplungen durch Reibung und Überhitzung zu vermeiden. Grenzwerte sind in der Norm *ANSI ASA S2.75-2017* angegeben. Diese richten sich nach dem Wellendurchmesser und der Drehzahl. Üblich ist hierbei, dass beim Winkelversatz die Klaffung angegeben wird. Dabei handelt es sich um die Öffnung am äußeren Umfang einer Referenzkupplung mit einem Durchmesser von 100 mm. Die Öffnung bei Winkelversatz wird dann in Millimeter angegeben. Nach [152] ist Fehlausrichtung der zweithäufigste mechanische Fehler im industriellen Umfeld. Fatale Schäden können wegen Fehlausrichtung bei Hochgeschwindigkeitsanwendungen auftreten, wenn die Belastung die Kupplung ermüdet und es zu einem Bersten der Kupplung kommt und Mensch sowie Maschine durch herumfliegende Teile geschädigt werden können. Zusätzlich zu dem Fall, dass Fehlausrichtung immer bei der Einrichtung von zwei separat aufgestellten Maschinen korrigiert werden muss, kann Fehlausrichtung auch während des Betriebs durch Vibration oder thermische Ausdehnung von Materialien verursacht werden [152]. Die Schäden sind dabei identisch zum ersten Fall, jedoch können während des Betriebs nicht alle Verfahren zur Erkennung und Korrektur eingesetzt werden.

Das Ziel bei der Kopplung von zwei Maschinen über eine Welle ist, die Rotationsachsen übereinanderzulegen. Aufgrund von Toleranzen bei der Fertigung der Maschinen, der Fundamente und der Distanzplatten, die zur Korrektur verwendet werden, ist dies nicht vollständig möglich. In der Folge entsteht Fehlausrichtung, die sich abhängig von der Lage und Ausrichtung der Rotationsachsen zueinander in Parallelversatz (PV) und Winkelversatz (WV) unterscheiden lassen [152]. Die ideale Ausrichtung sowie die Fehlerfälle sind in Abb. 5.6 dargestellt. Bei Parallelversatz liegen die Rotationsachsen der Maschinen parallel zueinander, sind jedoch um den Abstand a verschoben. Ist die Kupplung nicht in der Lage, diesen Versatz auszugleichen, kommt es in der Folge zu Spannungen in der Kupplung, in der Welle und den Lagern [139]. Beim Winkelversatz liegen die Achsen nicht parallel, sondern schneiden

sich, wodurch sich ein Öffnungswinkel φ zwischen den Achsen definieren lässt. Kann die Kupplung den Winkelversatz nicht ausgleichen, kommt es ebenfalls zu Spannungen an Kupplung, Welle und Lagern. Je nach Art der Fehlausrichtung unterscheiden sich jedoch die Spannungsverläufe. Zudem treten die Arten nicht unabhängig voneinander auf und können infolgedessen die resultierenden Spannungen verstärken, aber auch kompensieren.

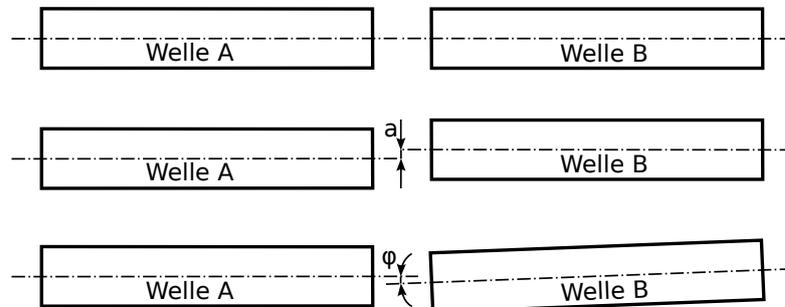


Abbildung 5.6: Verschiedene Arten von Fehlausrichtung. Oben: keine; mitte: Parallelversatz; unten: Winkelversatz.

Ob Spannungen auftreten, hängt neben der Art der auftretenden Fehlausrichtung auch von der Kupplungsart ab. Tabelle 5.4 listet verschiedene Kupplungsarten auf und bewertet deren Eigenschaften zur Kompensierung der Fehlausrichtung.

Tabelle 5.4: Bewertung von Kupplungsarten auf deren Eigenschaft zur Kompensation von Verspannungen infolge von Fehlausrichtung.

Kupplungstyp	T_{\max}	Kompensation	
		Parallelversatz	Winkelversatz
Klaue	++	0	0
Metallbalk	+	+	+
Kardanisch	0	0	+
Doppel kardanisch	0	+	+

++: sehr gut; +: gut; 0: neutral

Eine Übersicht zu möglichen Kräfteinwirkungen und den damit verbundenen Spannungen und Verformungen wird in [153] gegeben. Die Verformungsarbeit kann demnach zur Materialermüdung führen, die 25 % der Schäden an der Welle ausmachen.

Der Aufbau ist in Abb. 5.7 dargestellt. Das DUT ist auf einer Montageplatte befestigt, die mit der Grundplatte verschraubt wird. Durch Unterbauung der Montageplatte kann der Grad an Parallel- und Winkelversatz eingestellt werden. Die Distanzplatten sind in den Abstufungen 0,025, 0,05, 0,1 und 0,2 mm verfügbar. Der Grad der Fehlausrichtung wird

mit einem optischen Wellenausrichtsystem geprüft, das die Fehlausrichtung an der Welle bestimmt. Das Experiment beschränkt sich auf Klauenkupplungen, da diese bei Motoren mit großem Drehmoment eingesetzt werden. Der Anschlag dient dazu, den Motor nach der Unterbauung wieder in die gleiche Position zu bringen. Über die Bremse ist es möglich, verschiedene Lasten einzustellen.

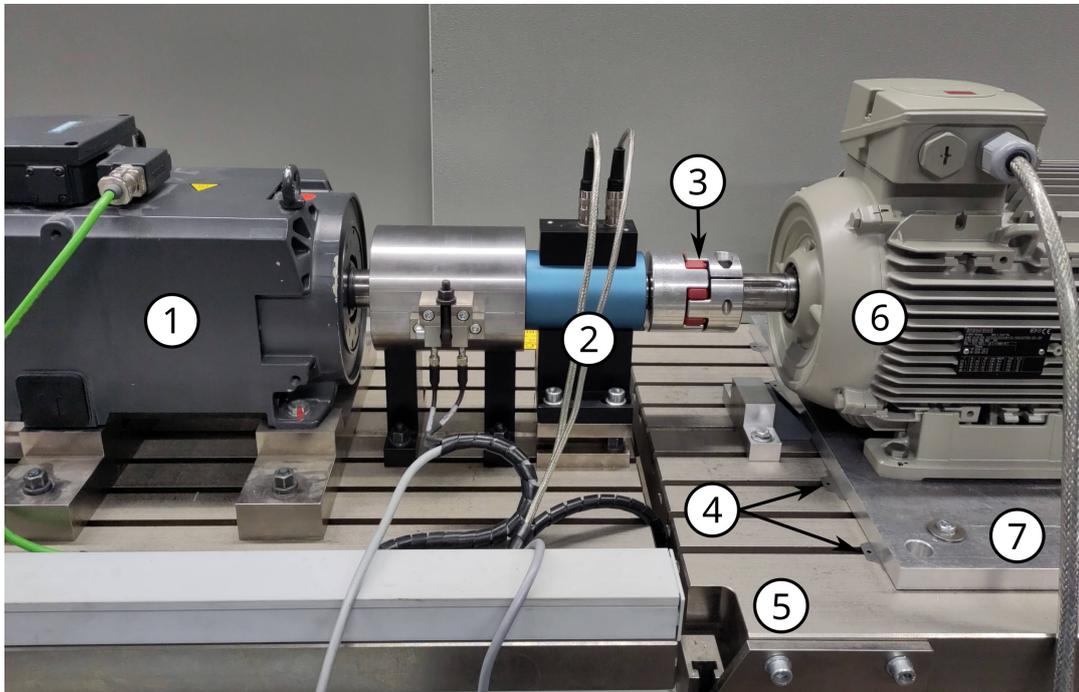


Abbildung 5.7: Aufbau des Experiments Fehlausrichtung. 1) Lastmaschine 2) Drehmomentmesswelle 3) Kupplung 4) Distanzplatten 5) Grundplatte 6) Testobjekt (Motor) 7) Montageplatte.

Für das Experiment Fehlausrichtung wurden vier TOs zweimal mit 1,1 kW und zweimal mit 7,5 kW auf einem Motorenprüfstand vermessen. Die Zustände für jeden Motor können Tab. 5.5 und Tab. 5.6 entnommen werden. Es ist zu beachten, dass Parallelversatz und Winkelversatz unabhängig voneinander aufgezeichnet wurden. Demzufolge ist es nicht möglich, nach unterscheidenden Merkmalen zu suchen. Das Experiment zielt darauf ab, Fehlausrichtung mit der Last als Störgröße zu erkennen. Für das Data-Mining wird jeweils ein Motor jeder Leistungsklasse vermessen. Im Anschluss wird das Experiment mit den baugleichen Motoren, aber geringerem Umfang bei der Messzeit und den Schritten im Definitionsbereich wiederholt.

Die Datensätze mit geringerem Umfang dienen der Bestätigung der Ergebnisse und wurden in [46] ausgewertet. In der Zustandstabelle bezieht sich die angegebene Last in Prozent auf das Nenndrehmoment oder im Fall des 7,5 kW-Motors auf das korrigierte Nenndrehmoment,

Tabelle 5.5: Zustandstabelle für das Experiment Fehlansrichtung (7,5 kW-Motor)

Nr. Zustand	TO	Fehler		Unterbau		Last in % von $T_N^{1)2)}$
		PV	WV	vorne	hinten	
		in mm	in mm	in mm	in mm	
1	1	0-0,02	0-0,02	0	0	[100, 92]
2	1	"	"	0	0	[90, 82]
3	1	"	"	0	0	[80, 72]
4	1	0,05	0,02	0,225	0,3	[100, 92]
5	1	0,05	0,02	"	"	[90, 82]
6	1	0,05	0,02	"	"	[80, 72]
7	1	0,08	0,02	0,375	0,525	[100, 92]
8	1	0,08	0,02	"	"	[90, 82]
9	1	0,08	0,02	"	"	[80, 72]
10	1	0,11	0,02	0,5	0,7	[100, 92]
11	1	0,11	0,02	"	"	[90, 82]
12	1	0,11	0,02	"	"	[80, 72]
13	1	0,02	0,05	0,1	0,225	[100, 92]
14	1	0,02	0,05	"	"	[90, 82]
15	1	0,02	0,05	"	"	[80, 72]
16	1	0,02	0,08	0,125	0,325	[100, 92]
17	1	0,02	0,08	"	"	[90, 82]
18	1	0,02	0,08	"	"	[80, 72]
19	1	0,02	0,11	0,125	0,4	[100, 92]
20	1	0,02	0,11	"	"	[90, 82]
21	1	0,02	0,11	"	"	[80, 72]

wie oben beschrieben. Die Schrittweiten für Parallel- und Winkelversatz sind ebenfalls in Prozent angegeben und beziehen sich auf die Grenzwerte, die im Gerät hinterlegt sind:

- Parallelversatz: 0,09 mm (akzeptabel), 0,06 mm (exzellent);
- Winkelversatz: 0,07 mm (akzeptabel), 0,05 mm (exzellent).

Tabelle 5.6: Zustandstabelle für das Experiment Fehlansrichtung (1,1 kW-Motor)

Nr. Zustand	TO	Fehler		Unterbau		Last in % von $T_N^{1)2)}$
		PV	WV	vorne	hinten	
		in mm	in mm	in mm	in mm	
22	2	0-0,02	0-0,02	0	0	[100, 92]
23	2	"	"	0	0	[90, 82]
24	2	"	"	0	0	[80, 72]
25	2	0,05	0,02	0,1	0,1	[100, 92]
26	2	0,05	0,02	"	"	[90, 82]
27	2	0,05	0,02	"	"	[80, 72]
28	2	0,08	0,02	0,125	0,125	[100, 92]
29	2	0,08	0,02	"	"	[90, 82]
30	2	0,08	0,02	"	"	[80, 72]
31	2	0,11	0,02	0,225	0,225	[100, 92]
32	2	0,11	0,02	"	«	[90, 82]
33	2	0,11	0,02	"	"	[80, 72]
34	2	0,02	0,05	0,05	0,175	[100, 92]
35	2	0,02	0,05	"	"	[90, 82]
36	2	0,02	0,05	"	"	[80, 72]
37	2	0,02	0,08	0,075	0,275	[100, 92]
38	2	0,02	0,08	"	"	[90, 82]
39	2	0,02	0,08	"	"	[80, 72]
40	2	0,02	0,11	0,075	0,375	[100, 92]
41	2	0,02	0,11	"	"	[90, 82]
42	2	0,02	0,11	"	"	[80, 72]

6 Diskussion der Ergebnisse

Nachfolgend werden für die Anwendungsfälle Kavitation, gebrochener Rotorstab und Fehlausrichtung die Ergebnisse des Data-Minings dargestellt und diskutiert. Jeder Anwendungsfall wird dabei aufgeteilt, um Teilergebnisse zu diskutieren, bei denen der Datenumfang reduziert ist.

Für jeden der betrachteten Fälle ist die Auflistung der potenziellen Merkmalsvektoren aus dem Data-Mining als Tabelle dem Anhang beigelegt. Von potenziellen Merkmalsvektoren wird hierbei gesprochen, wenn diese die Grenzwerte für Fehlerrate und Anzahl der Merkmale einhalten. Eine reduzierte Auswahl je Fall, die sich nach einer Prüfung der Muster ergibt, wird im Folgenden dargestellt. Im Sinne einer ersten Bewertung werden alle gelisteten Merkmale mit der Zielgröße und den Störgrößen korreliert, dazu wird das Verfahren nach Pearson angewendet. Zudem wird für den gesamten Merkmalsvektor die Fehlerrate des Klassifizierers angegeben, der für die Suche verwendet wurde. Für diesen Schritt wurde lediglich das Verfahren kNN angewendet. Mit den Kennzahlen kann bereits eine erste Bewertung der Merkmalsvektoren und der Merkmale vorgenommen werden.

Interessante Muster, die sich direkt für die technische Diagnostik eignen oder zur Verbesserung des KDED beitragen, werden als Streudiagramm dargestellt und diskutiert. Aufgrund der Randbedingungen, die für das KDED definiert wurden, ist eine Darstellung aller Ergebnisse in der Ebene möglich. Durch diese Darstellung ohne Transformation können die Muster direkt bewertet werden. Das Ziel ist, in den resultierenden Mustern die im Experiment eingestellten Zustände respektive die davon abgeleiteten Primärklassen zu erkennen. Im Sinne des KDED müssen die Primärklassen zusätzlich proportional zu den Eingangsgrößen angeordnet sein. Im Gegensatz dazu sind in der technischen Diagnostik auch Merkmalsvektoren zulässig, die die schärfere Bedingung nicht erfüllen. Nicht geeignet sind Muster, die topologische Fehler wie Lücken oder Fehlplatzierung (siehe Abs. 4.3) aufweisen. Diese Fehler können bisher nicht durch die Algorithmen bewertet werden und sind daher bei der Begutachtung herauszufiltern. Eine Analyse ungeeigneter Muster kann jedoch wichtige Hinweise zur Optimierung der Experimente und des Data-Minings liefern. Deswegen werden im Folgenden auch Ergebnisse diskutiert, die nicht den Kriterien des KDED entsprechen. Durch Bewertung der Lage der Cluster und der Abstände zueinander können Rückschlüsse über die Grenzen der Diagnostik gezogen werden. Zudem erlaubt die Anordnung der Cluster eine Aussage darüber, welche Klassifizierer für Fehler und Merkmalsvektor besonders geeignet sind.

Zur Beurteilung der Leistungsfähigkeit der gefundenen Merkmalsvektoren wurden diese in Kombination mit den zusätzlichen Klassifizierern kNN, NN, Entscheidungsbäume und SVM erneut auf die Daten angewendet. Zur Auswertung wurde das Validierungsverfahren zufällige Auswahl mit jeweils zehn Wiederholungen durchgeführt und die Fehlerrate, die Sensitivität, die Spezifität und die Präzision berechnet. Die gemittelten Werte für die genannten Kennzahlen werden durch den minimalen und maximalen Wert aus den zehn Durchläufen ergänzt. Die berechneten Werte sind im Folgenden zu jedem Muster angegeben. Mit der Maßnahme soll verdeutlicht werden, dass nicht der Klassifizierer im Vordergrund steht. Stattdessen liegt der Fokus auf den Merkmalen und Merkmalsvektoren, die in der Lage sein sollen, das betrachtete Problem zu lösen. Für praktische Anwendungen kann so der geeignetste Klassifizierer ausgewählt werden.

Zur korrekten Interpretation der Daten ist darauf hinzuweisen, dass diese zum Zeitpunkt der Auswertung unterschiedlichen Entwicklungsständen des KDED entsprachen. Unterschiede sind die Auslegung des Problems als Klassifikation diskreter oder kontinuierlicher Größen oder als Regression, die Anzahl der Klassen je Einflussgröße, die absolute und relative Lage der Klassen sowie die Schrittweite der Einflussgrößen. Eine Übersicht zum Stand der Experimente und der Daten gibt Tab. 6.1. Aus der Tabelle geht hervor, dass das Experiment für den Fehler Kavitation weiterhin optimiert werden muss. Insbesondere bei der Schrittweite wurde festgestellt, dass keine Merkmalsvektoren gefunden werden können, wenn die Primärklasse mit 1,5 % Kavitation in die Auswertung einfließt. Wie zu sehen sein wird, können die Cluster dieser Klasse nicht ohne Schneidung eingefügt werden.

Tabelle 6.1: Übersicht zum Stand der Experimente und der Daten.

Experiment	Auslegung	Anzahl Klassen	Lage	Schrittweite
Fehlausrichtung	Klassifizierung (intervall)	optimiert	optimiert	optimiert
Gebrochener Rotorstab	Klassifizierung (intervall)	optimiert	optimiert	optimiert
Kavitation	Klassifizierung (konzentriert)	optimiert	optimiert	nicht optimal

6.1 Kavitation

Im Weiteren wird der Fehler Kavitation an Kreiselpumpen diskutiert. Für den Fehler sind drei Fälle zu diskutieren: im ersten Fall wird Kavitation bei variierender Last an zwei Pumpen der gleichen Bauart und Größe betrachtet; im zweiten und dritten Fall werden die Testobjekte separat ausgewertet. Es ist darauf hinzuweisen, dass die Klassen mit 1,5 % Förderhöhenabfall

aus der Auswertung genommen wurden, da sonst keine geeigneten Merkmalsvektoren gefunden werden können. Grund dafür ist die zu geringe Abstufung, in deren Folge sich schneidende Cluster entstehen und die Fehlerraten nicht kleiner als 5 % werden.

Für den Fall *Zielgröße: Kavitation und Störgröße: Durchfluss und Testobjekt* ist die reduzierte Auswahl der Merkmalsvektoren in Tab. 6.2 aufgeführt. Von sieben potenziellen Kandidaten, die vom Selektionsalgorithmus ausgewählt wurden, soll einer diskutiert werden.

Tabelle 6.2: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Störgröße = Durchfluss und Testobjekt.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)		
		kNN	Durchfluss	Kavitation
Auswahl 1				
Spektrum (I_1 , Seg. 11)	Pos. 1. Spitze	/	0,074	-0,030
RZ-Spektrum (r , Seg. 9)	Pos. 1. Spitze	/	0,004	0,001
Merkmalsvektor		1,333	/	/

* Prüfung bestanden.

Das resultierende Muster für *Auswahl 1* wurde mit einer Fehlerrate von 1,333 % ausgewählt und ist in Abb. 6.1 zu sehen. Es ist keine der eingepprägten Primärklassen und zudem auch keine klare Abgrenzung der Kavitationsstufen erkennbar. Das Ergebnis ist somit ein Beispiel für ein zufälliges Ergebnis, das nur mit dem kNN Klassifizierer erreicht werden kann. Die Einschätzung wird durch die Prüfung mit unterschiedlichen Klassifizierern bestätigt, siehe dazu das Balkendiagramm in Abb. 6.1. Die Klassifizierer NN und SVM erreichen mit dem Merkmalsvektor nur Fehlerraten von 24 % bzw. 43 %. Das zunächst gut erscheinende Ergebnis mit den Entscheidungsbäumen stellt sich nach Berücksichtigung der benötigten Regeln ebenfalls als unzureichend dar. Für die Fehlerrate von 1 % werden 100 bis 110 Regeln benötigt, was ein Vielfaches der eingepprägten neun Primärklassen entspricht und daher für eine Überanpassung spricht. Für mehrere Testobjekte können mit dem beschriebenen Experiment und der Auswertung keine geeigneten Merkmalsvektoren für die Klassifizierung gefunden werden. Die Beantwortung der Leitfragen ist für diesen Fall und mit den vorliegenden Daten nicht möglich. Im Folgenden werden die Ursachen dazu verdeutlicht.

Aufgrund dessen, dass eine kombinierte Auswertung der Testobjekte nicht möglich ist, sollen die beiden Testobjekte separat ausgewertet werden, um Hinweise zur Optimierung des Experiments und der Auswertung zu finden. Im Folgenden wird der Fall *Zielgröße Kavitation, Parameter TO8 und Störgröße Durchfluss* beleuchtet. Die reduzierte Auswahl von Merkmalsvektoren, die diskutiert werden sollen, ist in Tab. 6.3 zu sehen. Die Auswahl wurde wegen redundanter Merkmalsvektoren von ursprünglich sechs auf drei reduziert.

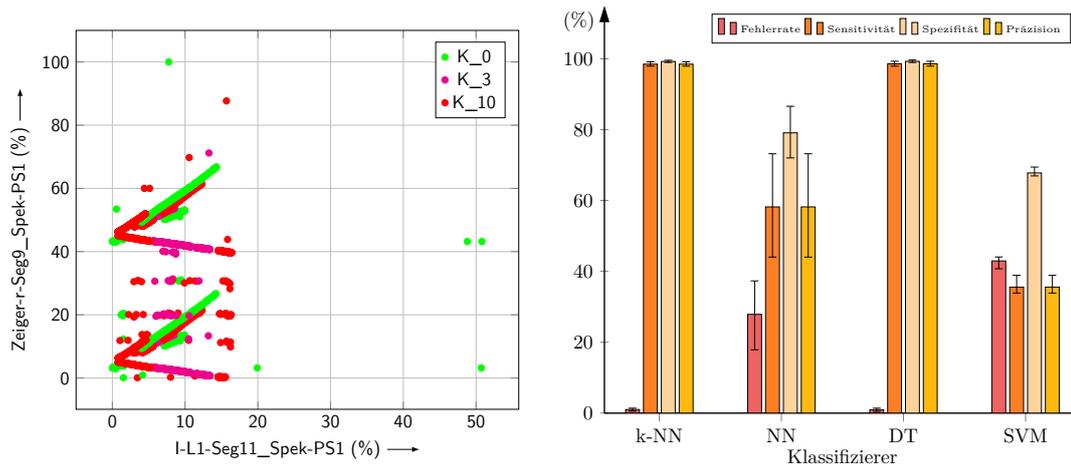


Abbildung 6.1: Untersuchung des Falls: Zielgröße = K, Störgrößen = Q, TO; Auswahl 1. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Das erste Muster, das zur Diskussion steht, wird durch *Auswahl 1* generiert und ist in Abb. 6.2 zu sehen. Erkennbar sind die drei Stufen der Kavitation, die jedoch nicht vollständig zusammenhängen und nicht entsprechend dem Kavitationsgrad angeordnet sind. Die Primärklassen sind nicht erkennbar. Zudem sind beide Merkmale der Auswahl maximal zu 24,3% mit dem Durchfluss und maximal zu 14,4% mit der Kavitation korreliert. Fließt schließlich die Bewertung mit unterschiedlichen Klassifizierungsansätzen ein, bei denen die NN eine Fehlerrate von 8% und die SVM 43% erreicht, muss die Auswahl verworfen werden. Das Muster ist ein weiteres Negativbeispiel bei der Auswahl geeigneter Merkmalsvektoren.

Ein weiterer potenzieller Merkmalsvektor ist *Auswahl 4*, mit dem resultierenden Muster aus den Daten, dargestellt in Abb. 6.3. Die Auswahl wurde mit einer Fehlerrate von 2,222% getroffen. Das Muster zeigt bei dieser Auswahl deutlich sechs der neun Primärklassen, die in aufsteigender Folge in Richtung der zunehmenden Störgröße liegen. Zudem ist eine Folge proportional zur Zielgröße angedeutet. Gestört wird eine ideale Anordnung nur durch die Primärklassen der höchsten Kavitationsstufe von 10% Förderhöhenabfall, deren Lage zufällig scheint. Dennoch können auch für diesen Fehlergrad Cluster erkannt werden, wie in der Abbildung angedeutet. Die Beobachtungen weisen darauf hin, dass der Merkmalsvektor prinzipiell für die technische Diagnostik geeignet ist und die Abweichungen auf ein nicht ideales Experiment zurückzuführen sind. Die Auswertung der Prozessdaten während des Experiments zeigt, dass die Zustände großen Schwankungen unterlegen waren. Als Ursache werden undichte Verbindungen insbesondere an der Messtechnik vermutet, wodurch Luft aufgrund des abgesenkten Drucks im Medium in den Kreislauf gelangte und somit den eingestellten Zustand verschoben hat.

Tabelle 6.3: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Parameter = TO8; Störgröße = Durchfluss.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
			Durchfluss	Kavitation
Auswahl 1				
Raumzeiger (r)	FF-SRM	/	0,042	-0,144
Spektrum (I ₂ , Seg. 9)	Pos. 1. Spitze	/	0,243	0,084
Merkmalsvektor		2,593	/	/
Auswahl 4*				
Signal (I ₂)	QWM	/	0,832	-0,468
Spektrum (I ₁ , Seg. 11)	Pos. 1. Spitze	/	0,178	0,586
Merkmalsvektor		2,222	/	/
Auswahl 5				
Zeiger (r)	QWM	/	0,874	-0,389
Spektrum (I ₃ , Seg. 14)	Pos. 1. Spitze	/	-0,082	-0,308
Merkmalsvektor		2,796	/	/

* Prüfung bestanden.

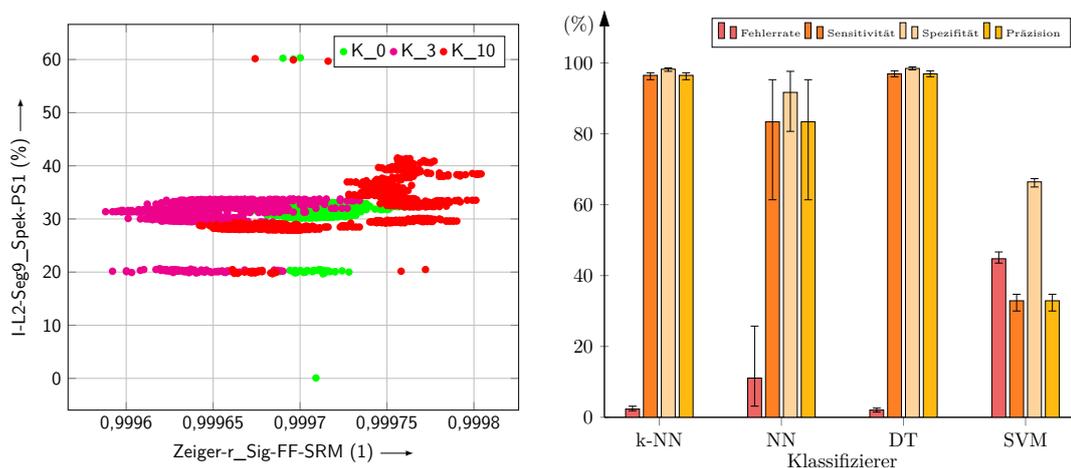


Abbildung 6.2: Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 1. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Interessant ist, dass die Merkmale trotz nicht idealer Daten Korrelationskoeffizienten von 83,2% mit dem Durchfluss und von 58,6% mit der Kavitation erreichen. Zudem zeigt die Auswertung mit unterschiedlichen Klassifizierungsverfahren, dass Fehlerraten zwischen 3% und 12% möglich sind. Aufgrund der Auswertung des Musters wird erwartet, dass der Merkmalsvektor in der Lage ist, Kavitation auch bei Laständerungen zu erkennen. Durch Optimierung des Experiments, etwa durch Absenkung des größten Kavitationsgrades von

10 % auf 6 %, ist zu erwarten, dass die Eignung über alle Kriterien nachgewiesen werden kann.

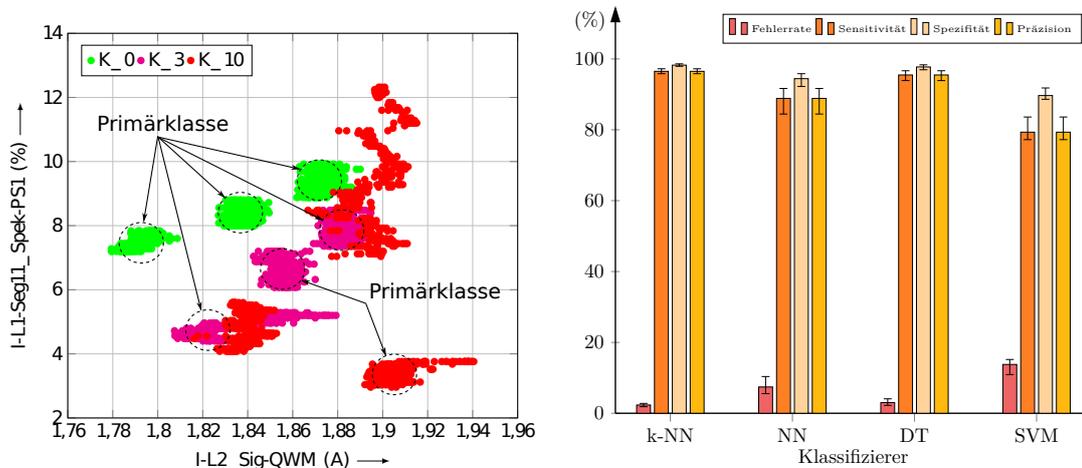


Abbildung 6.3: Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 4. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Das Muster aus *Auswahl 5* wurde mit einer Fehlerrate von 2,796 % ausgewählt und ist in Abb. 6.5 dargestellt. Ähnlich zur vorhergehenden Auswahl können in dem Muster acht der neun Primärklassen lokalisiert werden, wie mit den Markierungen gezeigt. Die Primärklassen sind zudem proportional zu Ziel- und Störgröße aufgereiht. Problematisch ist wie bereits zuvor die starke Streuung der Klassen mit der stärksten Kavitation. Zudem ist die Reihung für diese Klasse nicht gegeben. Die Beobachtungen decken sich jedoch mit denen zur Auswahl 4 und führen zur gleichen Begründung. Die Korrelationskoeffizienten aus Tab. 6.3 zeigen mit einem Maximalwert von 87,4 % zum Durchfluss vergleichbare Werte zur Auswahl 4. Jedoch sind die Merkmale mit maximal 38,9 % 20 Prozentpunkte schwächer mit der Zielgröße korreliert. Die alternativen Klassifizierer erreichen ebenfalls vergleichbare Ergebnisse, jedoch verschlechtert sich das Ergebnis für die NN. Auch wenn die Auswahl bei den Kriterien Korrelation und Fehlerrate mit unterschiedlichen Klassifizierern nicht optimal abschneidet, so wird durch die Bewertung des Musters das Potenzial deutlich. Es wird erwartet, dass die Eignung der Auswahl mit einem optimierten Experiment bestätigt werden kann.

Die Auswertung des Falls hat gezeigt, dass Auswahl 1 keine Kausalität trotz akzeptablem Klassifizierungsergebnis aufweist. Gleichzeitig wurden mit Auswahl 4 und 5 zwei Merkmalsvektoren gefunden, bei denen ein Teil der eingprägten Zustände korrekt angeordnet waren. Damit wird der Unterschied zwischen KDED und Data-Mining weiter verdeutlicht. Zudem ist erkennbar, dass die Expansion der Ziel- und Störgröße in orthogonal angeordneten Richtungen stattfindet, was die Aussage zulässt, dass die Diagnostik auch bei auftretender

Störgröße möglich ist. Die Auflösung, mit der Kavitation erkannt werden kann, liegt dabei im Bereich von 1,5 % bis 3 %, da die 1,5 % Klasse ausgeschlossen werden musste und 3 % Abstufung mit den genannten Fehlerraten möglich war.

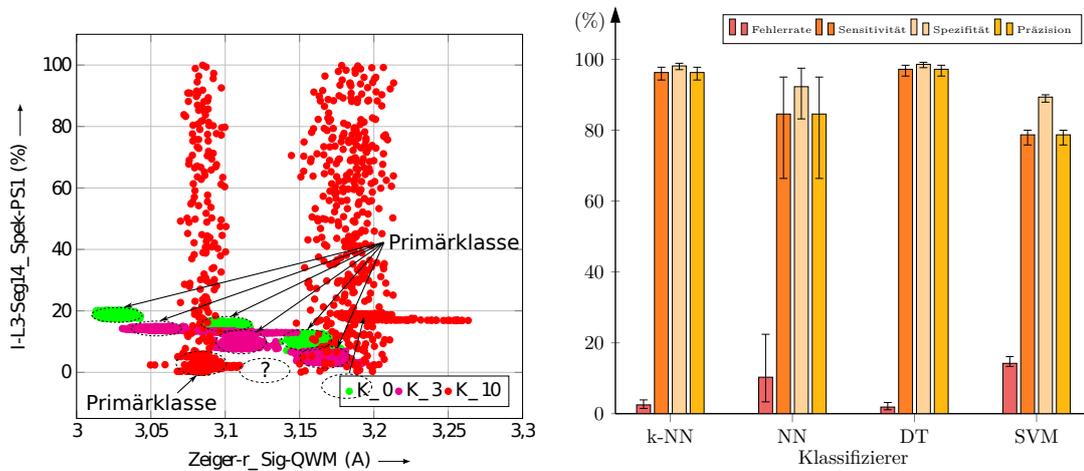


Abbildung 6.4: Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 5. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Der nächste Fall ist *Zielgröße Kavitation, Parameter TO9 und Störgröße Durchfluss*, bei dem lediglich ein weiteres Testobjekt untersucht wurde. Die zur Diskussion stehenden Merkmalsvektoren sind in Tab. 6.4 aufgeführt. Es handelt sich um zwei von zehn Vorschlägen.

Tabelle 6.4: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Parameter = TO9; Störgröße = Durchfluss.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)		Korrelation (1)	
		kNN		Durchfluss	Kavitation
Auswahl 3					
Signal (I_2)	qMW	/		0,939	-0,016
Spektrum (I_2 , Seg. 16)	Pos. 1. Spitze	/		-0,010	0,133
Merkmalsvektor		0,278		/	/
Auswahl 7*					
Signal (I_3)	qMW	/		0,919	-0,148
Raumzeiger (r, Seg. 16)	Pos. 1. Spitze	/		0,045	-0,106
Merkmalsvektor		2,370		/	/

* Prüfung bestanden.

Der erste Merkmalsvektor ist *Auswahl 3*, dessen Muster in Abb. 6.5 dargestellt ist. Der Merkmalsvektor wurde mit einer Fehlerrate von 0,278 % ausgewählt und korreliert mit 93,9 %

mit dem Durchfluss und mit 13,3% mit der Kavitation. Entscheidend ist bei dieser Auswahl ebenfalls das resultierende Muster, in dem alle neun Primärklassen identifiziert werden können. Zudem deutet sich eine Aufreihung der Cluster an, sowohl entlang der Ziel- als auch der Störgröße. Problematisch ist, dass drei Cluster von der Reihung abweichen. Die vermutete Lage und der Versatz sind in das Diagramm eingetragen. Wie bereits zuvor liegt die Ursache für diese Beobachtung in der Ausführung des Experiments. Die zuvor gemachten Aussagen treffen auch hier zu. Als neue Beobachtung wird gemacht, dass auch ein Cluster aus der Gesundklasse von der Aufreihung abweicht. Wegen der stärkeren Streuung im Vergleich zu den anderen Clustern ist davon auszugehen, dass der Tank nicht belüftet wurde und somit Druckschwankungen Einfluss auf den Zustand genommen hatten. Wegen der Bewertung des Musters ist davon auszugehen, dass auch bei diesem Testobjekt der Nachweis für einen geeigneten Merkmalsvektor gelingen kann.

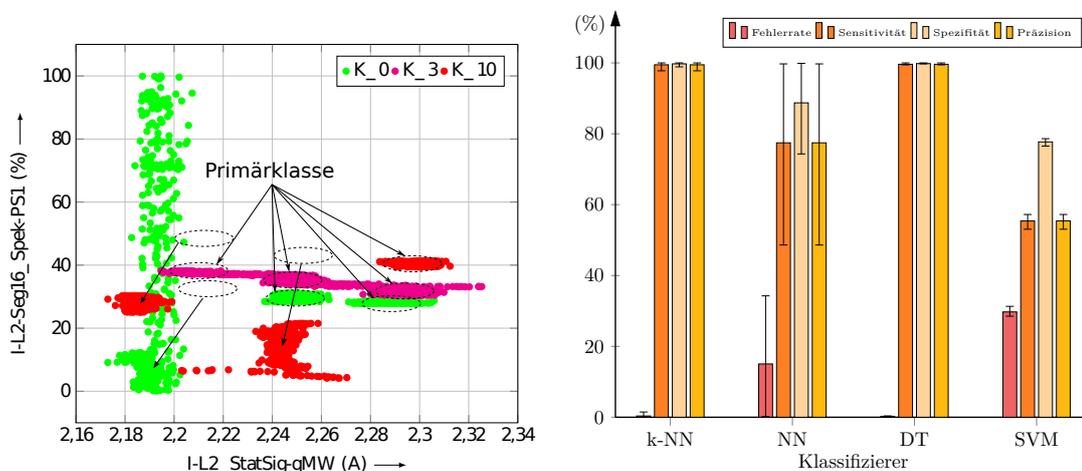


Abbildung 6.5: Untersuchung des Falls: Zielgröße = K, Parameter = TO9, Störgrößen = Q; Auswahl 3. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Ein weiterer potenzieller Merkmalsvektor ist *Auswahl 7*, die in Abb. 6.6 abgebildet ist. Vom Algorithmus wurden die Merkmale mit einer Fehlerrate von 2,37% ausgewählt. Der Merkmalsvektor zeigt für die Daten das gleiche Muster, wie zuvor Auswahl 3, mit dem Unterschied, dass es eine Wiederholung innerhalb des betrachteten Segments gibt. Wird diese Beobachtung in einem neuen Datensatz auf Basis eines angepassten Experiments weiterhin gemacht, muss für die technische Diagnostik die Breite des betrachteten Segments angepasst oder auf die Klassifizierer NN und SVM verzeichnet werden. Aufgrund des Musters wird der Merkmalsvektor als geeignet eingestuft.

In diesem Fall wurden nur Merkmalsvektoren zur Begutachtung durchgelassen, welche die Kriterien des KDED erfüllen. Trotz nicht idealer Daten sind die eingprägten Zustände

erkennbar. Auswahl 3 und 7 zeigen eine Ausdehnung der Kavitation und des Durchflusses in orthogonalen Richtungen, daher ist eine Klassifizierung auch mit Störeinfluss möglich. Die Dynamik wird durch die gefundenen Merkmalsvektoren ausreichend gut abgebildet, jedoch ist eine Wiederholung mit optimiertem Experiment sinnvoll, eine Abschwächung der Aussage wegen der Ausreißer zu verhindern. Wie zuvor liegt die Auflösung zwischen 1,5% und 3%.

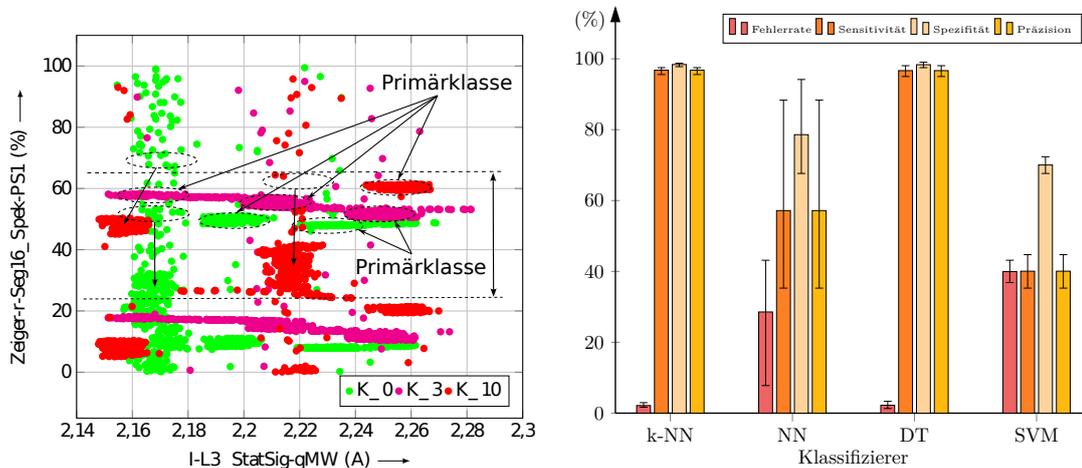


Abbildung 6.6: Untersuchung des Falls: Zielgröße = K, Parameter = TO9, Störgrößen = Q; Auswahl 7. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Die Auswertung der Daten zum Fehler Kavitation hat zunächst ergeben, dass die Auswahl der Merkmale für jedes Testobjekt separat vorgenommen werden muss. Durch die Einzelbetrachtung der Datensätze zu TO 8 und TO 9 konnten Fehler bei der Ausführung des Experiments festgestellt werden. Mit dem angewendeten Data-Mining konnten trotz der ungünstigen Datensätze dennoch Merkmalsvektoren identifiziert werden, mit denen nach einem optimierten Experiment die Eignung nachgewiesen werden kann. Wegen der ähnlichen Merkmalsauswahl für TO 8 und TO 9 wird davon ausgegangen, dass auch Merkmalsvektoren bestätigt werden können, die unabhängig vom Testobjekt sind.

6.2 Gebrochener Rotorstab

Der Fehler, der in diesem Abschnitt behandelt werden soll, ist der gebrochene Rotorstab. Für die Auswertung liegt ein Fall vor, nämlich *Zielgröße: gebrochener Stab und Störgröße: Last*. Dieser enthält zwei Stufen der Zielgröße gesund (GRS_0) und einen vollständigen Stabbruch (GRS_1). Diskutiert werden 16 von 85 gefundenen Merkmalsvektoren. Die bewertete Auswahl der Merkmalsvektoren ist in Tab. 6.5 aufgeführt. Für die Diskussion werden Ergebnisse mit gleichen Eigenschaften zudem zusammengefasst.

Tabelle 6.5: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = gebrochener Rotorstab; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
			Last	GRS
		kNN		
	Auswahl 4*			
Signal (I_2)	FF-SRM	0	-0,231	-0,886
	Auswahl 5*			
Signal (I_3)	Wb	0	-0,009	-0,991
	Auswahl 9*			
Raumzeiger (LF)	Med	0	0,099	-0,927
	Auswahl 11*			
RZ Spektrum (r, Seg. 4)	SRA	0	0,230	-0,914
	Auswahl 19*			
Raumzeiger (r)	StadAW	0,067	0,187	-0,962
	Auswahl 24*			
Raumzeiger (r)	TI	0,133	-0,254	-0,864
	Auswahl 33			
Raumzeiger (WF)	Sch	0,217	-0,140	-0,197
	Auswahl 71			
Raumzeiger (φ)	FF	/	0,016	0,890
MCSA (I_3)	BB2 (k1+)	/	-0,167	0,857
Merkmalsvektor		0,2	/	/
	Auswahl 73			
RZ Spektrum (WF, Seg. 8)	NormSumQuad	/	0,351	0,325
MCSA (I_3)	ECC2 (k1m)	/	-0,167	0,857
Merkmalsvektor		0,2	/	/
	Auswahl 74			
Spektrum (I_2 , Seg. 3)	SRA	/	0,327	-0,876
RZ Spektrum (LF, Seg. 3)	Wb	/	-0,157	-0,872
Merkmalsvektor		0,2	/	/
	Auswahl 75*			
Raumzeiger (LF)	FF-SRM	/	0,310	0,759
Spektrum (I_2 , Seg. 4)	SRA	/	0,287	-0,875
Merkmalsvektor		0,05	/	/

Auswahl 76*				
Spektrum (I_2 , Seg. 4)	SW1	/	0,287	-0,875
Spektrum ($U_{1,2}$, Seg. 3)	SRA	/	0,213	0,815
Merkmalsvektor		0,05	/	/
Auswahl 77*				
Spektrum (I_2 , Seg. 3)	SW1	/	0,327	-0,876
Spektrum ($U_{1,2}$, Seg. 3)	SW1	/	0,213	0,815
Merkmalsvektor		0	/	/
Auswahl 78*				
Spektrum (I_1 , Seg. 1)	2. Spitze	/	0,011	0,075
Raumzeiger (r , Seg. 2)	2. Spitze	/	-0,203	-0,867
Merkmalsvektor		0	/	/
Auswahl 80*				
Signal (I_3)	FF-SRM	/	-0,449	-0,736
Spektrum (I_1 , Seg. 4)	SRA	/	0,285	-0,868
Merkmalsvektor		0,133	/	/
Auswahl 82*				
Raumzeiger (r)	Wb	/	0,245	0,829
RZ Spektrum (r , Seg. 1)	SW3	/	-0,558	0,806
Merkmalsvektor		0,1	/	/

* Prüfung bestanden.

Auffällig an der Auswahl ist, dass für das Problem mit zwei Einflussgrößen eine Vielzahl eindimensionaler Merkmalsvektoren gefunden wurden. Die Muster von *Auswahl 4* (Abb. 6.7), *Auswahl 5* (Abb. 6.8), *Auswahl 9* (Abb. 6.9), *Auswahl 11* (Abb. 6.10) und *Auswahl 19* (Abb. 6.11) zeigen diesen Zusammenhang. Alle Merkmalsvektoren führen zu zwei Clustern, die aufgrund der Lastvariation breit verteilt sind. Zwischen den beiden Klassen ist eine Lücke beobachtbar, die bei der Wölbung und dem Formfaktor (SRM) am größten ist. Bei den übrigen Merkmalsvektoren findet ebenfalls eine optimale Trennung statt, jedoch stoßen die Cluster bereits aufeinander. Die gefundenen Muster sind dennoch nicht ideal, da nicht alle Primärklassen erkennbar sind. Für die technische Diagnostik sind die Merkmalsvektoren dennoch geeignet, wie aus der Bewertung mit verschiedenen Klassifizierungsansätzen hervorgeht; siehe dazu die Balkendiagramme in den Abbildungen. Die Aussage gilt, solange die Grenzen des beobachteten Bereichs eingehalten werden. Im Experiment wurde eine Teillast mit einem unteren Wert von 72 % der Nennlast beobachtet. Die Fehlerraten liegen für die Auswahl der Versuchsparameter und allen Klassifizierern zwischen null und zwei Prozent.

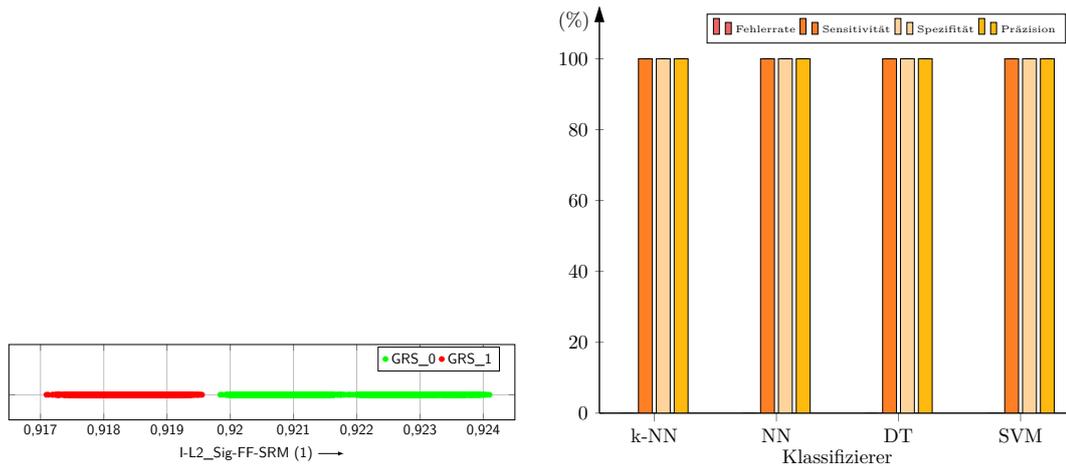


Abbildung 6.7: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 4. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

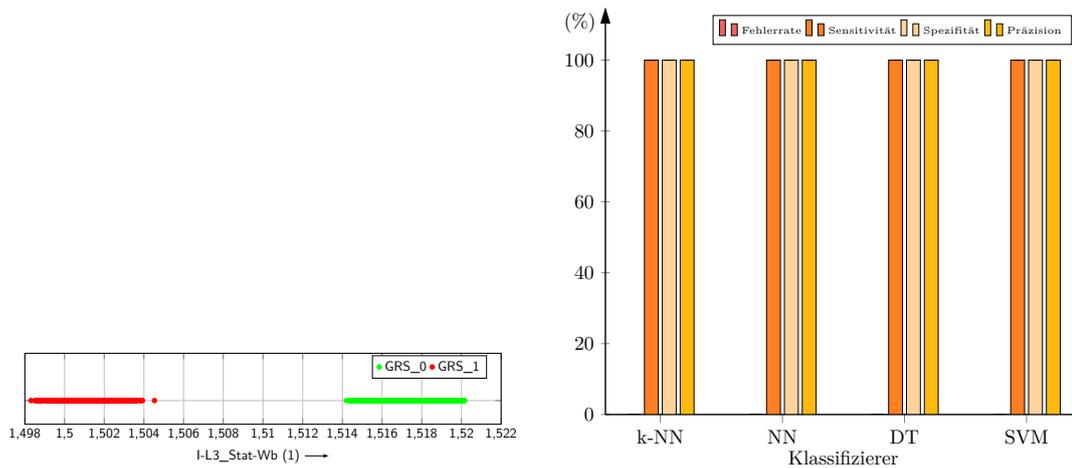


Abbildung 6.8: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 5. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Wie bei den bisherigen Merkmalsvektoren handelt es sich bei *Auswahl 24* (Abb. 6.12) und *Auswahl 33* (Abb. 6.13) ebenfalls um eindimensionale Merkmalsvektoren. Jedoch sind die Merkmale nicht für die technische Diagnostik geeignet, da die Auswahl aufgrund von Lücken zu einer geringen Fehlerrate unter 0,3% mit dem kNN Klassifizierer geführt hat. In den Mustern ist zu erkennen, dass sich die Klassen schneiden. Die Korrelationskoeffizienten zeigen dabei nur für Auswahl 33 geringe Werte für die Last und den gebrochenen Rotorstab. Auswahl 24 zeigt vergleichbare Werte wie Auswahl 4. Durch die Bewertung mit den unterschiedlichen Klassifizierungsansätzen wird deutlich, dass nur Auswahl 33 vollständig

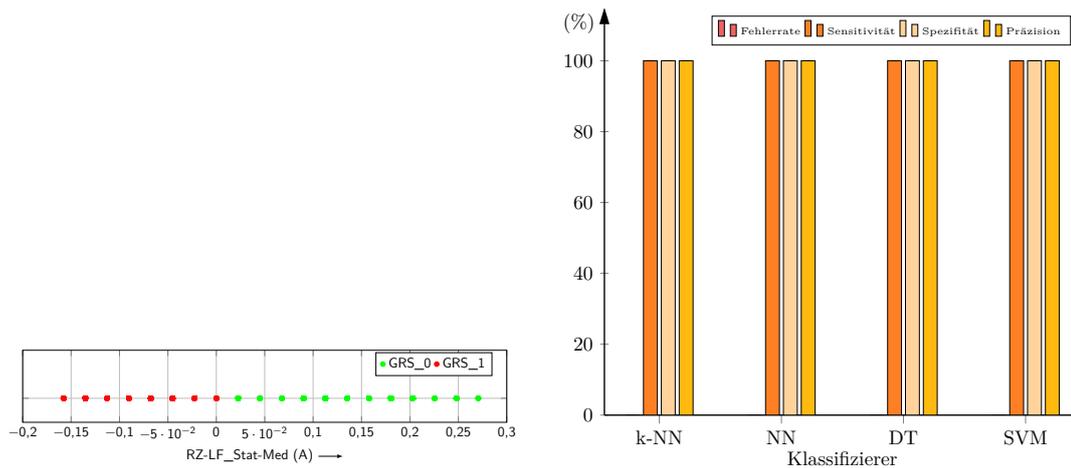


Abbildung 6.9: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 9. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

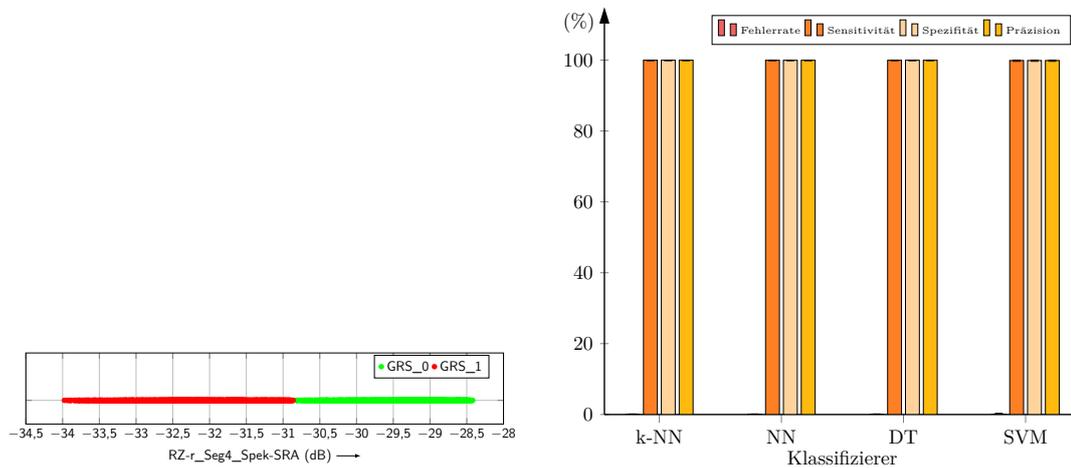


Abbildung 6.10: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 11. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

ausgeschlossen werden muss. Die Klassifizierer NN und SVM sind bei diesem Muster nicht in der Lage, Fehlerraten unter 5% zu liefern. Zudem wird mit kNN nur wegen der Lücken der Grenzwert der Fehlerrate erreicht.

Ein besonderes Muster zeigt *Auswahl 73*, dargestellt in Abb. 6.14. Das Muster wurde ebenfalls mit einer niedrigen Fehlerrate von 0,2% vom Algorithmus bestimmt. Dieses zeigt jedoch keine Übereinstimmung mit den über das Experiment eingebrachten Informationen, da die Anordnung der Primärklassen nicht korrekt ist. Stattdessen bilden sich vier Cluster, die nichts mit den Einflussgrößen zu tun haben, sondern eine Folge von Streuung oder einer feh-

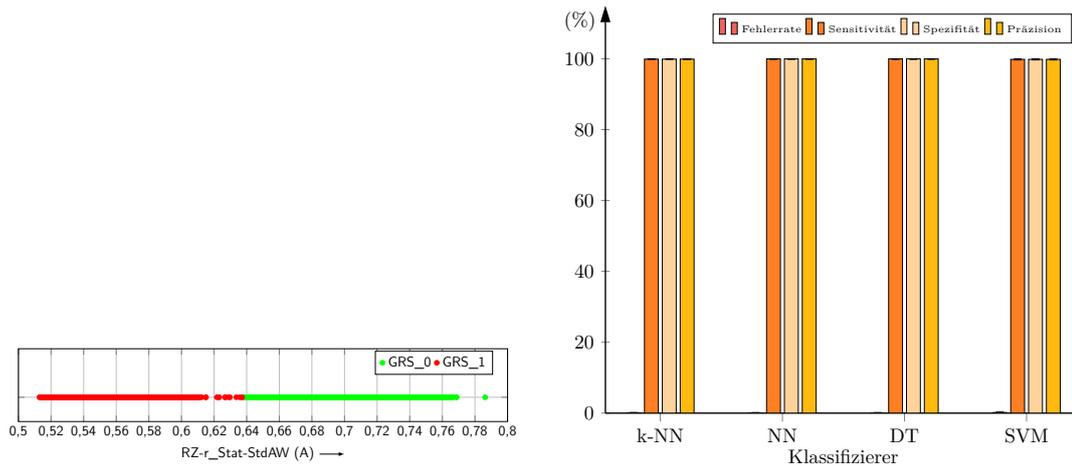


Abbildung 6.11: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 19. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

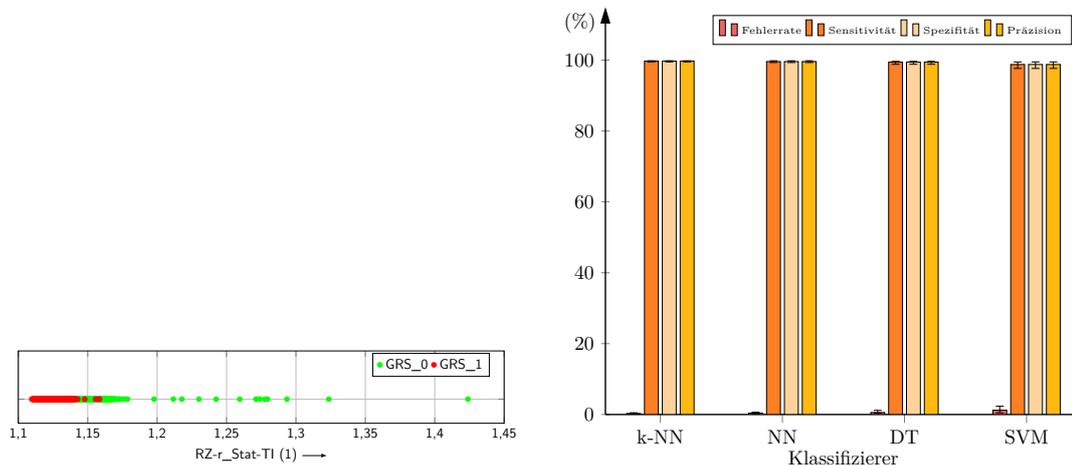


Abbildung 6.12: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 24. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

lerhaften Merkmalsextraktion sind. Das Merkmal *Spektrum der Raumzeigerwinkelfluktuation* ist jedoch nicht auf einen fehleranfälligen Auswahlmechanismus angewiesen, weshalb eine fehlerhafte Berechnung ausgeschlossen wird. Werden die Korrelationskoeffizienten in die Bewertung einbezogen, kann festgestellt werden, dass nur Merkmal 2 mit 85,7 % stark mit der Zielgröße korreliert ist. Beide Merkmale des Vektors sind dagegen mit maximal 35,1 % nur mäßig mit der Last korreliert, was durch die Beobachtung einer fehlenden Ausbildung der Primärklassen in Richtung der Last gedeckt ist. Mit dem kNN-, NN- und Entscheidungsbaum-Klassifizierer werden geringe Fehlerraten von maximal 1,1 % erzielt.

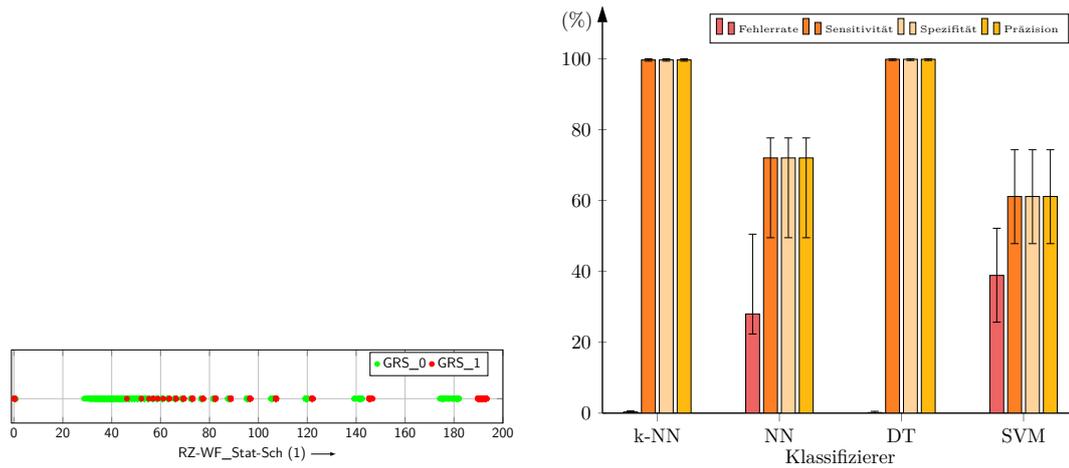


Abbildung 6.13: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 33. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

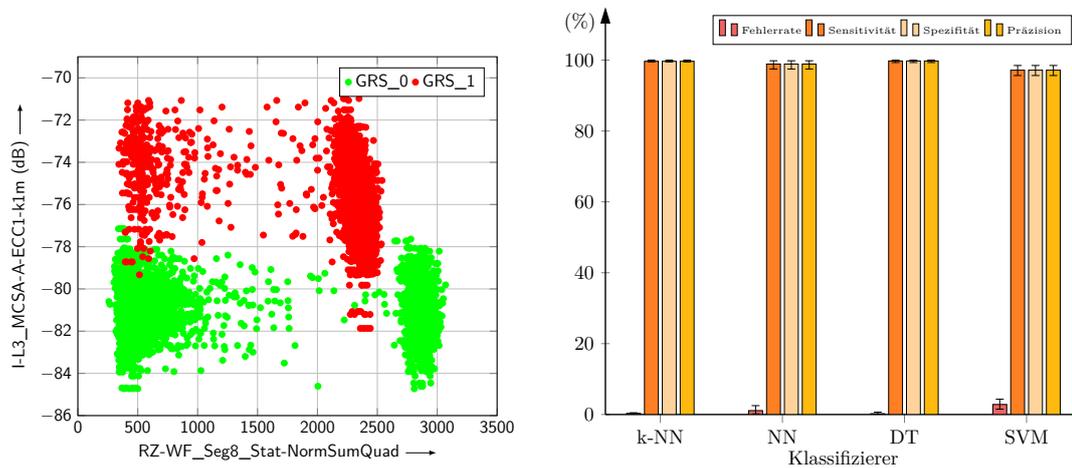


Abbildung 6.14: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 73. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Davon weichen die SVM mit 2,83 % ab. Grund dafür ist die große Anzahl von Ausreißern, die eine Trennung mit einer Hyperebene verhindert. Die Ursache für die Aufteilung der Daten einer Gruppe muss weiterhin untersucht werden.

Abbildung 6.15 zeigt für *Auswahl 78* ein weiteres unerwartetes Muster. Ausgewählt wurden die Merkmale mit einer Fehlerrate von null. Es ist bemerkenswert, dass Merkmal 1 der Auswahl nur gering mit der Last (1,1 %) und mit der Zielgröße (7,5 %) korreliert ist. Merkmal 2 zeigt jedoch eine hohe Korrelation mit der Zielgröße (86,7 %) und eine geringe Korrelation mit der Last (20,3 %). Auch wenn die Grenzen der Primärklassen verschwimmen, gibt es

eine eindeutige Aufreihung in Richtung der Last. Zur Verdeutlichung wurden die Grenzen der Primärklassen mit Strichlinien in das Diagramm eingetragen. Damit wird deutlich, dass die eigentliche Information in Merkmal 2 steckt, diese aber nur in Kombination mit Merkmal 1 nutzbar ist. Aufgrund dessen, dass die Trennung nur in einer Dimension stattfindet, ist der Merkmalsvektor nur bis zu einer bestimmten Teillast anwendbar. Im vorliegenden Fall ist eine ideale Trennung bis 72 % der Nennlast bestätigt. Der deutliche Abstand lässt vermuten, dass der Anwendungsbereich bis auf ca. 60 % der Nennlast abgesenkt werden kann und das ohne eine Steigerung der Fehlerrate. Unklar bleibt, wie sich ein angebrochener Rotorstab in das Muster einordnet. Die Eignung des Merkmalsvektors wird ebenfalls durch die Prüfung mit unterschiedlichen Klassifizierungsverfahren bestätigt. Lediglich bei den NN kommt es zu einer geringen Fehlerrate von 2 %. Zudem kann die geringe Fehlerrate von 3 % mit der SVM nicht vollständig nachvollzogen werden.

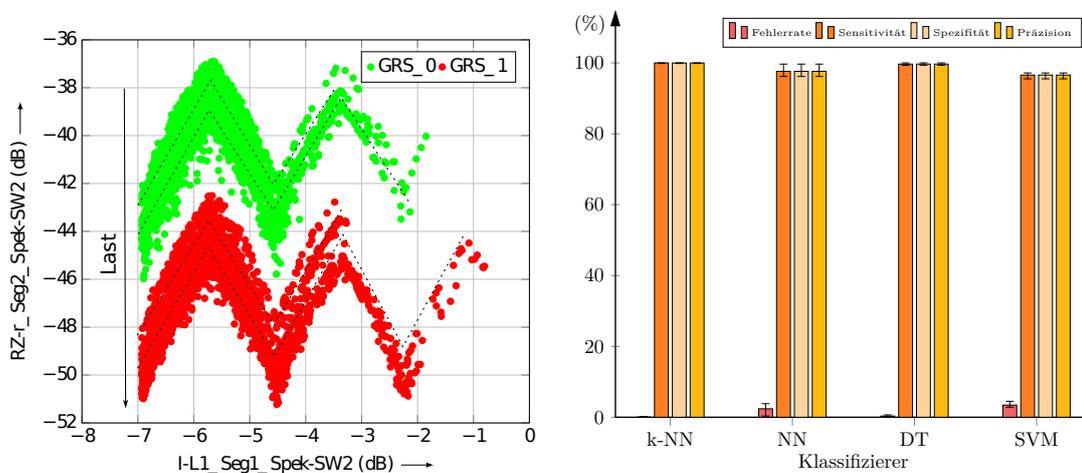


Abbildung 6.15: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 78. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Mit *Auswahl 71* und *Auswahl 74* wählt der Algorithmus jeweils einen zweidimensionalen Merkmalsvektor für den Fehler gebrochener Rotorstab. Die geringe Fehlerrate von 0,2 %, die mit jeder Auswahl erreicht wird, macht diese zu potenziellen Kandidaten für die technische Diagnostik. Jedoch zeigen die Muster in Abb. 6.16 und Abb. 6.17, dass die Merkmalsvektoren nicht optimal sind. Die beiden Cluster für den Gesund- und Fehlerfall sind deutlich getrennt, jedoch sind die Primärklassen nicht erkennbar. Somit ist eine Einschätzung des Verhaltens bei abweichenden Daten nicht möglich. Als Ursache für die verschwommenen Grenzen der Primärklassen wird die geringe Korrelation zur Last gesehen, die bei Merkmal 2 von Auswahl 71 nur bei 17 % liegt. Im Vergleich dazu sind beide Merkmale zu über 85 % mit der Zielgröße korreliert.

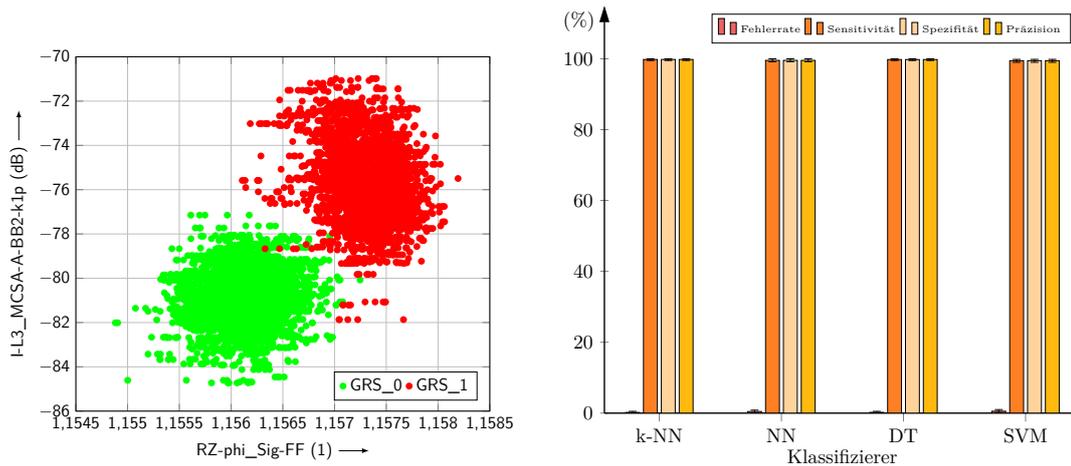


Abbildung 6.16: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 71. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

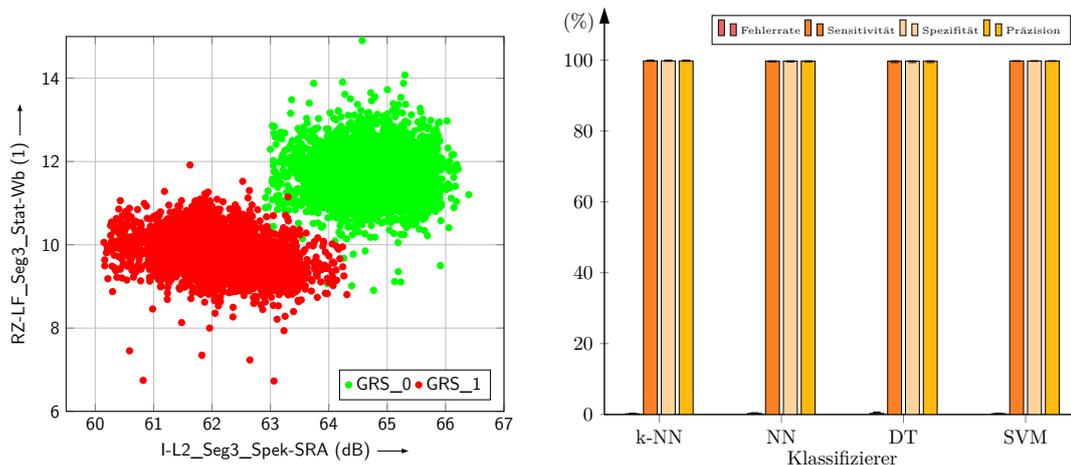


Abbildung 6.17: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 74. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Der Korrelationskoeffizient von Auswahl 74 liegt um bis zu 16 Prozentpunkte höher, ohne dass sich die Grenzen der Primärklassen abzeichnen. Dennoch ist die Merkmalsauswahl auch dazu geeignet, mit abweichenden Klassifizierern niedrige Fehlerraten zu erzielen, wie im Balkendiagramm von Abb. 6.16 und Abb. 6.17 zu sehen ist. Die Auswahl kann daher zumindest für die technische Diagnostik eingesetzt werden.

Das aus dem Merkmalsvektor *Auswahl 76* resultierende Muster ist in Abb. 6.18 zu sehen. Ein redundantes Ergebnis stellt *Auswahl 77* dar. Der Merkmalsvektor wurde vom Selektionsalgorithmus mit einer Fehlerrate von null ausgewählt. Das Muster zeigt eine geringe Andeutung

der Primärklassen für den Fehlerfall. Die Cluster Grenzen sind in der Abbildung angedeutet. Diese Reihung der Laststufen wird jedoch nicht in der Gesundklasse ausgebildet. Beide Merkmale der Auswahl zeigen den gleichen Grad an Korrelation zur Last (ca. 25 %) und zur Zielgröße (ca. 85%). Ähnliche Werte wurden bereits zuvor festgestellt, siehe Auswahl 71 und Auswahl 74. Jedoch überlappen sich die Primärklassen weniger, wenn der Rotorstab gebrochen ist. Die günstigen Eigenschaften werden ebenfalls durch den Test mit verschiedenen Klassifizierern bestätigt, siehe dazu das Balkendiagramm in Abb. 6.18. Danach ist eine optimale Trennung mit allen Klassifizierern möglich. Aufgrund der erkennbaren Lage der Primärklassen bei variierender Last ist nicht davon auszugehen, dass sich die Cluster schneiden werden. Damit ist der Merkmalsvektor für den Einsatz in der technischen Diagnostik geeignet.

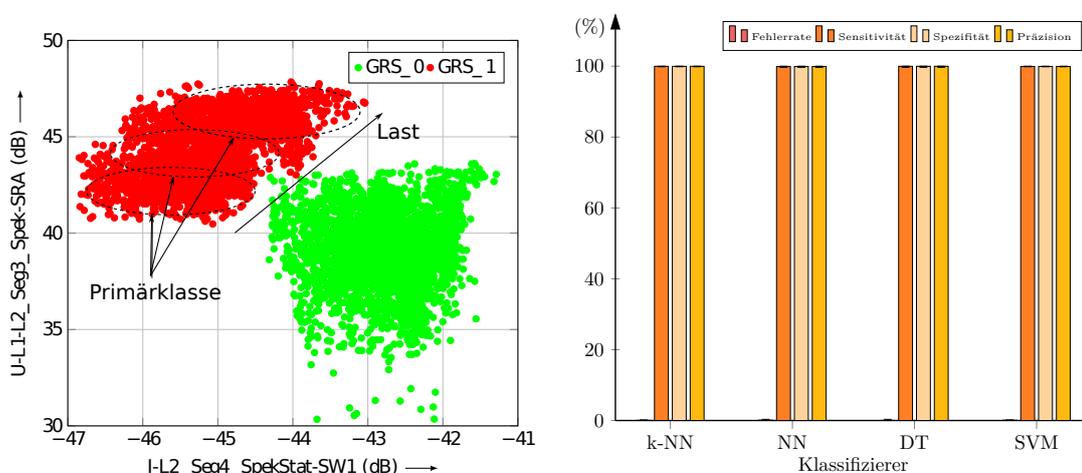


Abbildung 6.18: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 76. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Ein weiteres Beispiel für einen nutzbaren Merkmalsvektor im Sinne des KDED ist *Auswahl 75*, mit dem resultierenden Muster in Abb. 6.19. In diesem können bereits die Konturen der Primärklassen bei einem gebrochenen Rotorstab erkannt werden. Für den Zustand ohne Stabbruch ist diese Abgrenzung der Primärklassen nicht zu beobachten. Jedoch zeigt das Muster zwischen den Zuständen mit und ohne gebrochenen Rotorstab einen deutlichen Abstand, wodurch das Muster mit einer Fehlerrate von 0,05 % ausgewählt wurde. Dieses Ergebnis wird zudem mit allen Klassifizierungsansätzen erreicht, siehe dazu das Balkendiagramm in Abb. 6.19.

Vergleichbar mit der vorherigen Auswahl ist *Auswahl 80*, das Muster ist in Abb. 6.20 dargestellt. Wie auch zuvor, können in dem Muster die Konturen der Primärklassen erkannt werden.

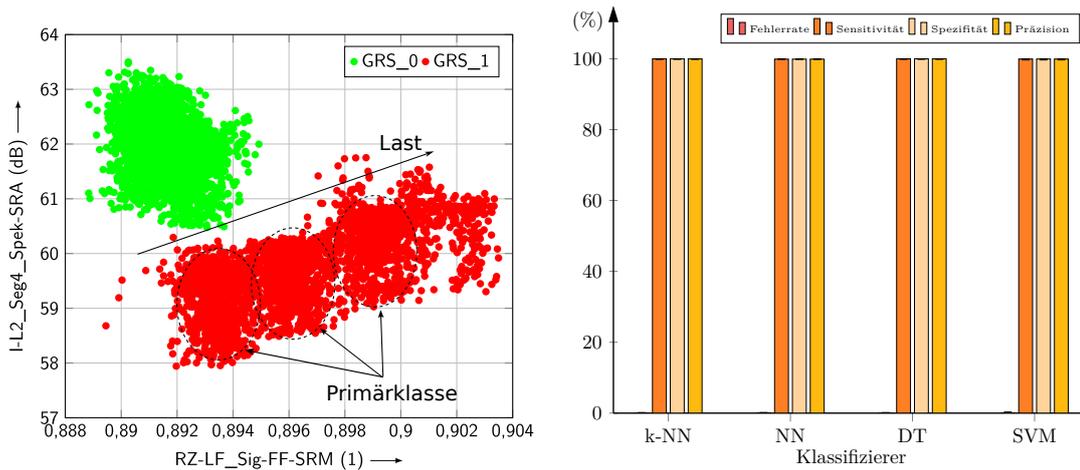


Abbildung 6.19: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 75. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

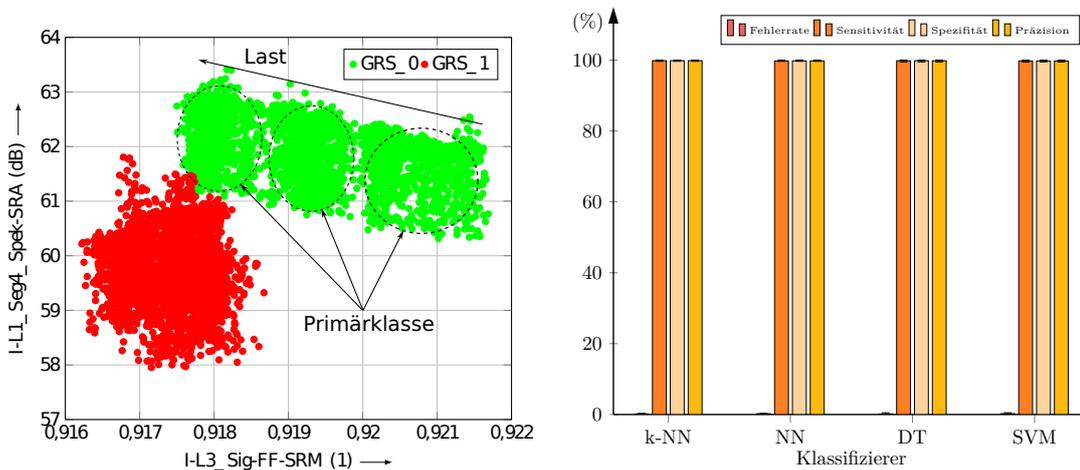


Abbildung 6.20: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 80. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Abweichend zum vorhergehenden Muster handelt es sich bei dieser Auswahl jedoch um die Primärklassen ohne Stabbruch. Da die Auswahl auch mit alternativen Klassifizierern geringe Fehlerraten erreicht, siehe Balkendiagramm in Abb. 6.20, und die Reihung der Gesundklassen mit steigender Last eindeutig ist, kann der Merkmalsvektor für die technische Diagnostik eingesetzt werden.

Der letzte Merkmalsvektor, der ausgewählt wurde und diskutiert werden soll, ist *Auswahl 82*. Das Muster, das sich in den beiden gefundenen Dimensionen abzeichnet, kann in Abb. 6.21 betrachtet werden. Vom Algorithmus wurde der Merkmalsvektor mit einer Fehlerrate von

0,1% ausgewählt. Zudem sind bei diesem Muster alle Primärklassen erkennbar. Nach Tab. 6.5 sind die Korrelationskoeffizienten zwischen den Merkmalen und der Zielgröße mit ca. 80% vergleichbar mit denen aus den vorhergehenden Beobachtungen. Merkmal 2 zeigt jedoch den größten Wert bei der Korrelation mit der Last von 55,8%. Die Abgrenzung der Primärklassen wird somit durch das Zusammenspiel der beiden Merkmale und die hohe Korrelation möglich. Die Auswertung mit unterschiedlichen Klassifizierungsansätzen bestätigt die Eignung des Merkmalsvektors. Durch die Auswertung aller Kriterien (Muster, Klassifizierer, Korrelation) wird die Eignung des Merkmalsvektors für die technische Diagnostik bestätigt. Es muss jedoch davon ausgegangen werden, dass der Teillastbereich nach unten begrenzt ist, da es durch den Verlauf der Primärklassen zu einer Schneidung kommt.

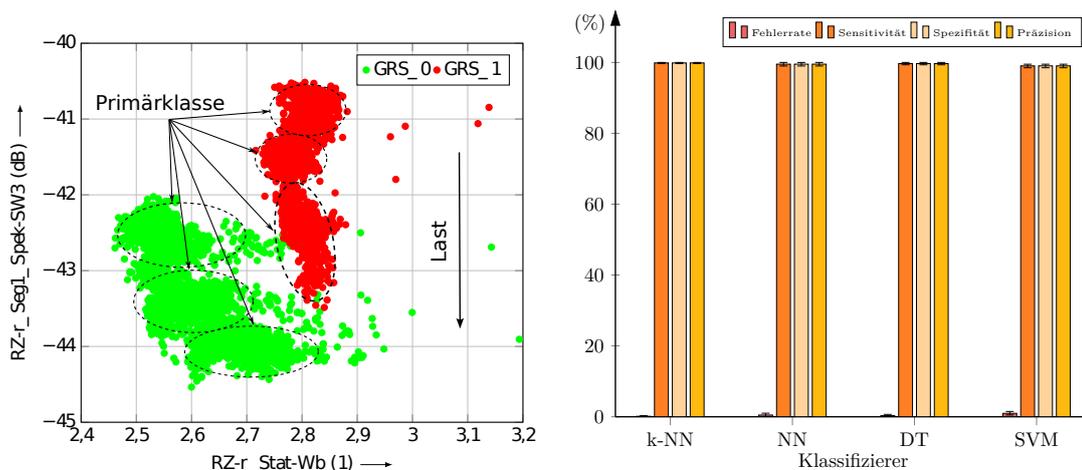


Abbildung 6.21: Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 82. Links: Verteilung der Proben (Analysedaten); rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Die Auswertung des Fehlers gebrochener Rotorstab hat gezeigt, dass eine Vielzahl von Merkmalen zur Verfügung stehen, um den Fehler auch bei Lastvariationen zu identifizieren. Grund dafür ist, dass die Expansion der Cluster mit steigender Fehler- und Störgröße für die zweidimensionalen Merkmalsvektoren in unterschiedliche Richtungen erfolgt. Es ist zu beachten, dass die Richtungen nicht orthogonal sind und dadurch der Anwendungsbereich eingeschränkt wird. Bei den eindimensionalen Merkmalen liegen dagegen Fehler- und Störgröße in einer Dimension. Jedoch ist die Auswirkung durch einen gebrochenen Rotorstab so groß, dass eine Trennung im beobachteten Bereich möglich ist. Die vorliegenden Daten zeigen, dass eine Abdeckung des Teillastbereichs bis zu 72% des Nenndrehmoments möglich ist. Auch in diesem Fall kam es zu Scheinlösungen, durch die der Unterschied zwischen Data-Mining und KDED verdeutlicht wird, siehe Auswahl 33 und 73. In diesem Fall konnten die Fehler durch die Bewertung mit der SVM verdeutlicht werden. Zur Abbildung der

Dynamik sind die bestätigten Merkmalsvektoren geeignet. Die Verwendung von eindimensionalen Merkmalsvektoren für ein mehrdimensionales Problem bringt Vor- und Nachteile mit sich. Zum einen wird der Verarbeitungsaufwand reduziert, wodurch sich Ressourcen einsparen lassen. Zudem bleibt die Komplexität niedrig, womit eine Abschätzung der Auswirkungen neuer Einflussfaktoren vereinfacht wird. Als Nachteil ist die damit verbundene Begrenzung des Anwendungsbereichs der Merkmalsvektoren für die technische Diagnostik zu nennen. Offen bleibt, wie sich ein angebrochener Rotorstab in die gefundenen Muster einordnet.

6.3 Fehlausrichtung

Abschließend werden sechs Fälle für den Fehler *Fehlausrichtung* diskutiert. Zunächst werden Parallel- und Winkelversatz ohne Einschränkung der Versuchsparameter behandelt, das heißt, als Störgröße fließen die Last und die Baugröße (BG) in die Auswertung ein. Anschließend werden vier weitere Fälle betrachtet, bei denen jeweils für Parallel- und Winkelversatz der 7,5 kW-Motor und der 1,1 kW-Motor separat ausgewertet werden. Für keinen der Fälle werden Parallel- und Winkelversatz gleichzeitig als dominante Störgröße angenommen. Da eine geringe Variation während des Experiments jedoch nicht ausgeschlossen werden kann, wird auch die komplementäre Größe bei der Auswertung berücksichtigt. Eine Bewertung der Übertragbarkeit auf neue Testobjekte wurde in [46] untersucht und wird daher hier nicht behandelt.

6.3.1 Fehlausrichtung bei Last- und Baugrößenänderungen

Der erste betrachtete Fall ist *Zielgröße: Parallelversatz und Störgrößen: Baugröße und Last*. Von den vier Merkmalsvektoren, die vom Algorithmus bestimmt wurden, sollen zwei diskutiert werden. Diese sind der reduzierten Tabelle 6.6 zu entnehmen.

Der Merkmalsvektor *Auswahl 1* ist in der Lage, die Klassen mit einer Fehlerrate von 4,635 % korrekt zu klassifizieren. Wird das Streudiagramm in Abb. 6.22 zur weiteren Untersuchung herangezogen, wird deutlich, dass dieser Merkmalsvektor nur aufgrund eines strukturellen Fehlers der Lücken, siehe Abs. 4.3, eine geringe Fehlerrate erreicht. Die Datenpunkte aller Zustände liegen auf einer Linie, wodurch bei neuen Datenpunkten nicht zwischen Laständerungen und Parallelversatz unterschieden werden kann. Das Balkendiagramm in Abb. 6.22 gibt zudem Aufschluss darüber, dass dieser Fehler nur in Kombination mit den Klassifizierern kNN und Entscheidungsbäume relevant ist. Die NN und SVM sind nicht anfällig für diese Art von Fehlern. Im ersten Fall reicht die verwendete Anzahl an Neuronen nicht aus, um die geringe Verschiebung an jeder Stelle abzubilden, und im zweiten Fall kann keine Trennebene zwischen den einzelnen Klassen gefunden werden, die diese optimal trennt.

Tabelle 6.6: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Störgröße = Last und Baugröße.

Merkmalsextraktor	Kennzahl	Fehlerrate kNN (%)	Korrelation (1)			
			Last	PV	WV	BG
Auswahl 1						
Zeiger (r)	MW	/	0,095	-0,125	0,236	0,993
Zeiger (LF)	GRW	/	0,133	-0,123	0,235	0,982
Merkmalsvektor		4,635	/	/	/	/
Auswahl 4*						
Spektrum (I_1 , Seg. 11)	Pos. 1. Spitze	/	0,086	-0,188	0,221	0,952
MCSA (I_1)	BB2 (k1+)	/	-0,302	0,213	0,362	0,607
Merkmalsvektor		4,635	/	/	/	/

* Prüfung bestanden.

Zur weiteren Optimierung des KDED wäre es daher denkbar, die Eigenschaften unterschiedlicher Klassifizierer zu kombinieren, z. B. durch eine zweite Auswertungsstufe.

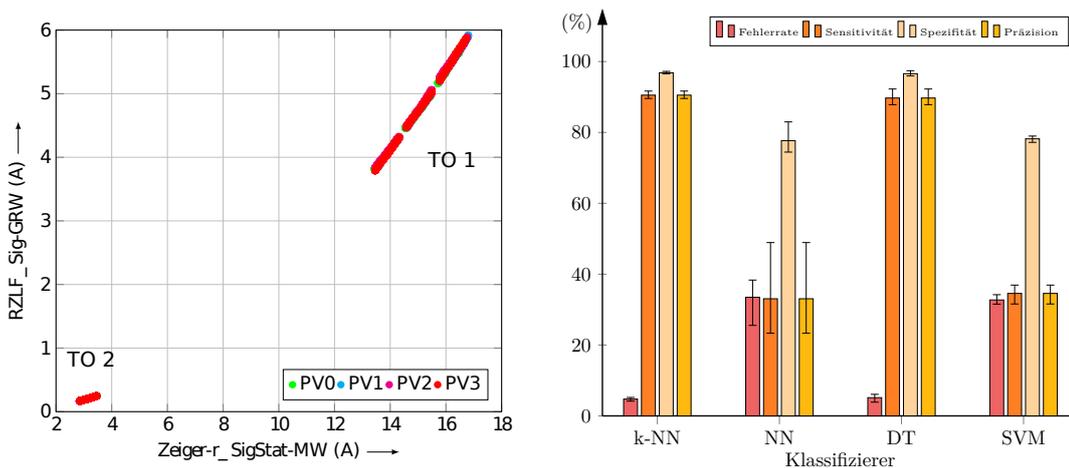


Abbildung 6.22: Untersuchung des Falls: Zielgröße = PV, Störgrößen = BG, L; Auswahl 1.
Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Auswahl 4 wird mit einer Fehlerrate von 4,635 % ausgewählt. Im Gegensatz zur vorherigen Auswahl liegen keine strukturellen Fehler vor, wie in Abb. 6.23 zu sehen ist. Wie gewünscht zeigt das Muster eine deutliche Diskriminierung der Fehlerstufen sowohl für den 7,5 kW-Motor (TO 1) als auch für den 1,1 kW-Motor (TO 2). Bei entsprechender Skalierung sind auch die Laststufen in der horizontal aufgetragenen Dimension deutlich abgetrennt. Somit ist der Merkmalsvektor für die Klassifizierung von Parallelversatz geeignet, was ebenfalls

durch die Klassifizierungsergebnisse mit den abweichenden Klassifizierern bestätigt wird. Die Korrelationskoeffizienten aus Tab. 6.6 zeigen hingegen nur eine niedrige Korrelation mit den Ziel- und Störgrößen, dennoch korreliert mindestens ein Merkmal zu 20 % mit den Größen. Heraus sticht der Korrelationskoeffizient von Merkmal 1 zur Baugröße mit 0,952. Die unterschiedliche Lokalisierung der Spitzen von TO 1 und TO 2 im Spektrum ist auch im Streudiagramm zu erkennen. Nach aktuellem Stand muss die Baugröße daher weiterhin als dominant angenommen werden. Aufgrund des großen Abstands ist in diesem Fall kein Konflikt mit variierenden Lasten zu erwarten. Wegen der Bedingung (2.1) bleibt zu prüfen, ob durch geschickte Normierung dieser Einfluss eliminiert werden kann oder ein weiteres Merkmal notwendig wird. Neben den günstigen Eigenschaften, die die ausgewählten Merkmale bieten, werden auch Probleme deutlich. Während die Datenpunkte beim 7,5 kW-Motor konzentriert um das Clusterzentrum liegen, kommt es beim 1,1 kW-Motor zu Ausreißern, die sowohl in der Anzahl als auch im Abstand zum Zentrum bedeutsam sind. Als Ursache für diesen Unterschied ist die Empfindlichkeit der Messtechnik zu nennen, die in beiden Fällen identisch war, jedoch in Kombination mit den geringeren Strömen des 1,1 kW-Motors zu Fehlern bei der Merkmalsextraktion führt. Das ist dann der Fall, wenn für die Bestimmung des Merkmals Spitzen im Spektrum lokalisiert werden müssen. Unklar ist zudem, warum sich die Primärklassen für PV 3 nicht in die erkennbare Reihe der restlichen Cluster einfügen. Auch hier wird die Messtechnik vermutet, jedoch müssen weitere Untersuchungen den Sachverhalt klären.

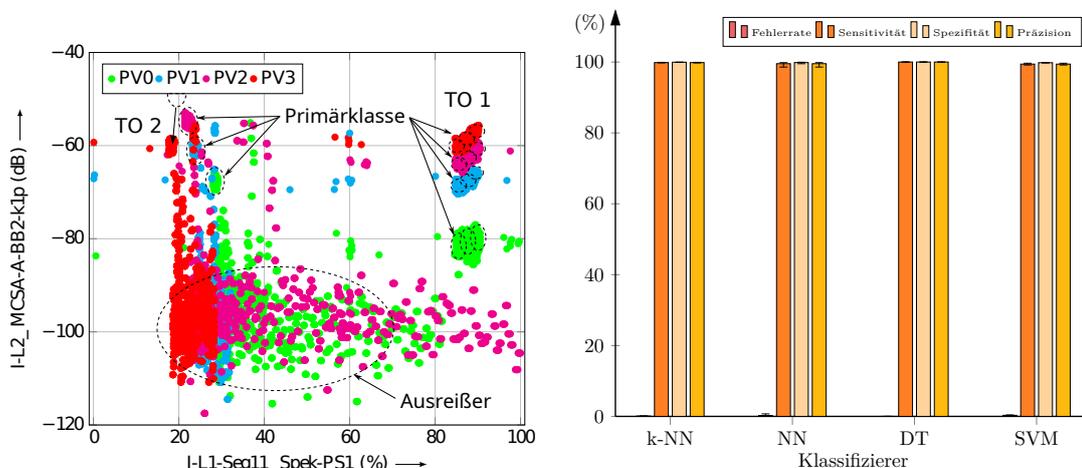


Abbildung 6.23: Untersuchung des Falls: Zielgröße = PV, Störgrößen = BG, L; Auswahl 4. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Bei Fall 2 handelt es sich um *Zielgröße: Winkelversatz* und *Störgrößen: Baugröße und Last*. Die reduzierte Auswahl der Merkmale ist in Tab. 6.7 gelistet. Für diesen Fall wurden

vom Algorithmus sechs Merkmalsvektoren vorgeschlagen, von denen keiner einer weiteren Überprüfung standhält.

Tabelle 6.7: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Winkelversatz; Störgröße = Last und Baugröße.

Merkmalsextraktor	Kennzahl	Fehlerrate kNN (%)	Korrelation (1)			
			Last	PV	WV	BG
Auswahl 1						
Zeiger (r)	qMW	/	0,094	0,187	-0,054	0,993
Zeiger (r)	QWM	/	0,095	0,187	-0,054	0,993
Merkmalsvektor		3,772	/	/	/	/

* Prüfung bestanden.

Die *Auswahl 1* soll stellvertretend für die anderen Merkmalsvektoren betrachtet werden, da die restlichen Merkmalsvektoren vergleichbare Muster zeigen. Das Muster, das vom Algorithmus vorgeschlagen wird, ist in Abb. 6.24 zu sehen. Wie bereits zuvor diskutiert, handelt es sich dabei um den Fehlerfall mit Lücken in den Clustern. Aufgrund dessen, dass der Algorithmus keine nutzbaren Muster vorschlägt, ist davon auszugehen, dass Winkelversatz sich nur gering auf die Merkmale auswirkt oder die Testobjekte abweichende Muster ausbilden, die nicht mit zwei Dimensionen darstellbar sind. Dieser Aspekt soll im Folgenden durch die Betrachtung der Daten, separiert nach Testobjekt, diskutiert werden.

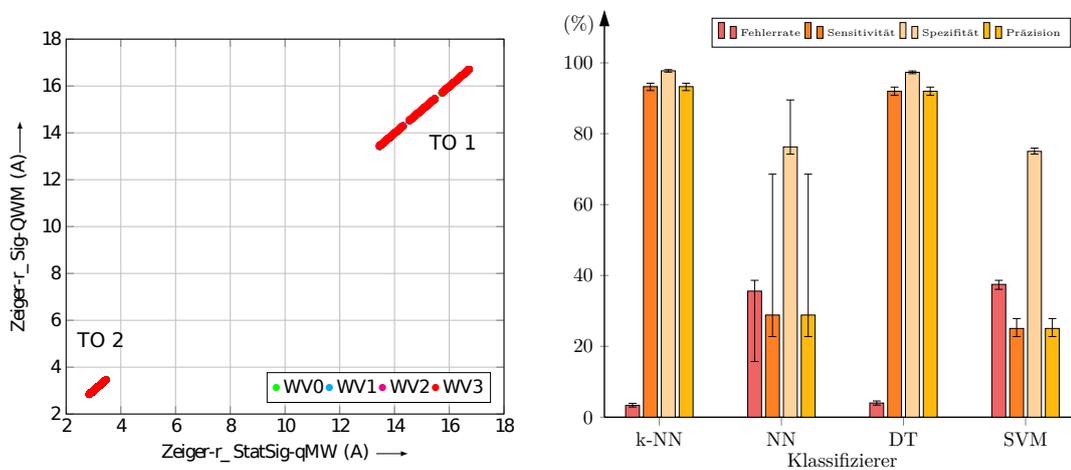


Abbildung 6.24: Untersuchung des Falls: Zielgröße = WV, Störgrößen = BG, L; Auswahl 1.
Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Mit dem KDED konnte für einen der zwei komplexeren Fälle mit zwei Störgrößen ein Merkmalsvektor Auswahl 4 identifiziert werden, der die zugrundeliegenden Einflüsse abbildet.

Außerdem konnten zwei Scheinlösungen Auswahl 1 für Parallel- und Winkelversatz erkannt und anschließend verworfen werden. Für den bestätigten Merkmalsvektor Auswahl 4 ist erkennbar, dass die Entwicklung der Fehlergröße und der Last in orthogonalen Richtungen erfolgt. Technische Diagnostik ist somit auch bei auftretender Störgröße möglich. Es ist jedoch zu beachten, dass die Trennung der Baugröße in der Dimension erfolgt, in der auch die Laständerung beobachtet wird. Das Ziel wäre hier eine sinnvolle Normierung der Daten vorzunehmen, damit das Merkmal *Position der Spitzen* gleiche Cluster bezüglich Fehler- und Lastgrad zusammenbringt. Die Auswertung zeigt zudem, dass sowohl für TO 1 und TO 2 der Parallelversatz von 0,02 mm bis 0,11 mm in 0,03 mm Schritten über den Strom erkennbar ist. Zudem kann die Last im Bereich von 72 % bis 100 % der Nennlast bei einem Abstand von 2 % erkannt werden. Wie zu sehen ist, wurde die Baugröße neben der Last und der Fehlergröße als dominanter Einfluss bestätigt. Zur besseren Einordnung müssen daher weitere Baugrößen in die Untersuchung einbezogen werden. Zur Reduzierung der Ausreißer muss die Auflösung der Messeinrichtung für TO 2 weiter verbessert werden.

6.3.2 Parallelversatz bei Laständerung – 7,5 kW-Motor

Im Vergleich zu den bisherigen Betrachtungen stellt Fall 3 mit *Zielgröße: Parallelversatz, Parameter: 7,5 kW-Motor und Störgröße: Last* eine Teilbetrachtung dar. Bei dieser Konstellation steht nicht die Frage im Fokus, ob die Diagnostik unabhängig von der Baugröße durchgeführt werden kann, sondern wie gut die technische Diagnostik für einen speziellen Fall funktioniert und welche Merkmalsvektoren dies ermöglichen. Die reduzierte Auswahl ist in Tab. 6.8 gelistet. Der Algorithmus schlägt für diesen Fall 19 Merkmalsvektoren vor, von denen sieben diskutiert werden sollen. Es ist anzumerken, dass ein Großteil der vorgeschlagenen Merkmalsvektoren als geeignet für die technische Diagnostik eingestuft wird, wegen der Ähnlichkeit der Muster, aber nicht alle Merkmalsvektoren diskutiert werden. Für die Praxis sind dann die Merkmale interessant, die am einfachsten zu berechnen sind.

Das Erste zu diskutierende Ergebnis ist *Auswahl 1*, das in Abb. 6.25 dargestellt ist. Das gefundene Muster zeigt deutlich die 12 eingestellten Zustände, dabei wird in jeder Dimension entweder die Zielgröße oder die Störgröße wiedergegeben. Der lineare Zusammenhang wird auch durch die Korrelationskoeffizienten deutlich, die in Tab. 6.8 angegeben sind. Das erste Merkmal korreliert dabei mit der Last und das zweite mit der Zielgröße zu mehr als 95 % in beiden Fällen. Der Einfluss der restlichen Größen ist in allen Fällen kleiner als 10 %, mit Ausnahme der Korrelation von 2. Merkmal mit dem Winkelversatz, der 61,9 % beträgt. Aufgrund dieser Beobachtung bleibt zu prüfen, inwieweit Parallel- und Winkelversatz unabhängig voneinander sind. Die Eignung des Musters wird auch durch die Validierung mit unterschiedlichen Klassifizierern deutlich. Das Balkendiagramm in Abb. 6.25 bestätigt, dass eine Klassifizierung mit einem Fehler unter 1 % mit unterschiedlichen Verfahren erreicht wird.

Tabelle 6.8: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate kNN (%)	Korrelation (1)		
			Last	PV	WV
Auswahl 1*					
Signal (I_1)	Effektivwert	/	0,962	-0,010	0,001
MCSA (I_1)	BB2 (k_{1+})	/	-0,087	0,962	0,619
Merkmalsvektor		0	/	/	/
Auswahl 2*					
Signal (I_1)	WSQ	/	0,962	-0,010	0,001
MCSA (I_1)	ECC1 (k_{1-})	/	-0,087	0,962	0,619
Merkmalsvektor		0	/	/	/
Auswahl 10					
Raumzeiger (r)	FF	/	-0,254	-0,396	-0,432
MCSA (I_3)	ECC1 (k_{1+})	/	-0,139	0,960	0,576
Merkmalsvektor		0,317	/	/	/
Auswahl 11					
Raumzeiger (r)	FF-SRM	/	0,256	0,396	0,431
MCSA (I_3)	ECC2 (k_{1+})	/	-0,139	0,960	0,576
Merkmalsvektor		0,317	/	/	/
Auswahl 13*					
MCSA (I_2)	n	/	-0,939	-0,070	-0,064
MCSA (I_2)	BB2 (k_{3+})	/	-0,144	0,959	0,576
Merkmalsvektor		0,492	/	/	/
Auswahl 14*					
Raumzeiger (LF)	GRW	/	0,961	0,014	0,024
MCSA (I_2)	ECC1 (k_{1+})	/	-0,143	0,959	0,576
Merkmalsvektor		0,571	/	/	/
Auswahl 19					
MCSA (I_1)	ECC1 (k_{2+})	/	-0,175	0,890	0,418
RZ Spektrum (r)	SRA (Seg. 2)	/	-0,136	-0,429	-0,436
Merkmalsvektor		2,683	/	/	/

* Prüfung bestanden.

Mit *Auswahl 2* wird das identische Muster aufgezeigt, wie bereits zuvor in Abb. 6.26. Damit wird bestätigt, dass die MCSA Merkmale BB1 und ECC1 mit der FehlAusrichtung korrelieren, wie bereits in Abs. 5.4 diskutiert. Dieser Sachverhalt ist zu berücksichtigen, wenn komplexere Fälle behandelt werden, bei denen unterschiedliche Fehler auftreten. Kann das gleichzeitige Auftreten mehrerer Fehler ausgeschlossen werden, sind die Merkmale äquivalent einsetzbar.

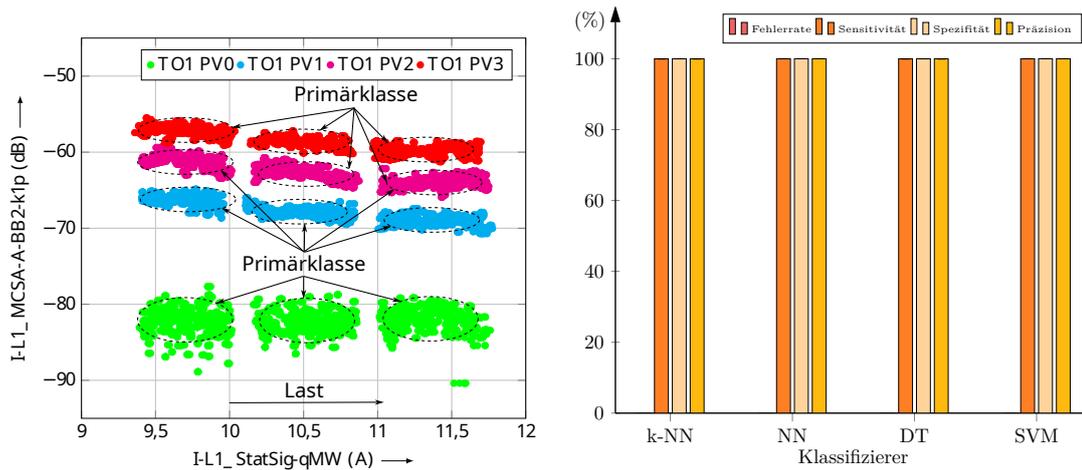


Abbildung 6.25: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 1. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

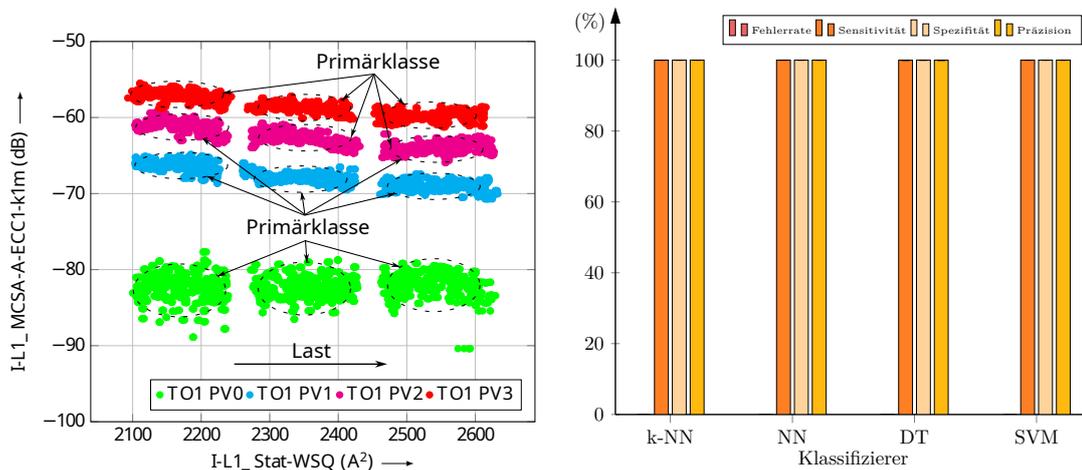


Abbildung 6.26: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 2. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Ein abweichendes Muster zeigt *Auswahl 10* in Abb. 6.27. Das Muster wurde mit einer geringen Fehlerrate von 0,317% ausgewählt. Die im Experiment eingestellten Zustände bilden bei diesen Merkmalen keine abgegrenzten Primärklassen. Die Lage und Orientierung der Klassen sind in der Abbildung zusätzlich gekennzeichnet. Dabei fällt auf, dass die Reihungen für die Laststufen sowohl horizontal als auch vertikal verlaufen. Die Korrelationskoeffizienten liegen daher bei maximal 26%, was im Vergleich zu den anderen Mustern ein geringer Wert ist. Aus diesem Grund können die Merkmale nicht zur Beschreibung der zugrundeliegenden Dynamik verwendet werden. Dennoch sind die Cluster hinsichtlich der Zielgröße mit scharfen

Rändern voneinander getrennt und die Anordnung ist entsprechend der steigenden Zielgröße. Für die reine Anwendung in der technischen Diagnostik kann der Merkmalsvektor daher eingesetzt werden, was auch durch die Validierung mit unterschiedlichen Klassifizierern bestätigt wird. Das Balkendiagramm in Abb. 6.27 zeigt Fehlerraten von unter 1 %, mit Ausnahme für die SVM. Zudem muss beachtet werden, dass für das Ergebnis der Entscheidungsbäume 21 Regeln benötigt wurden.

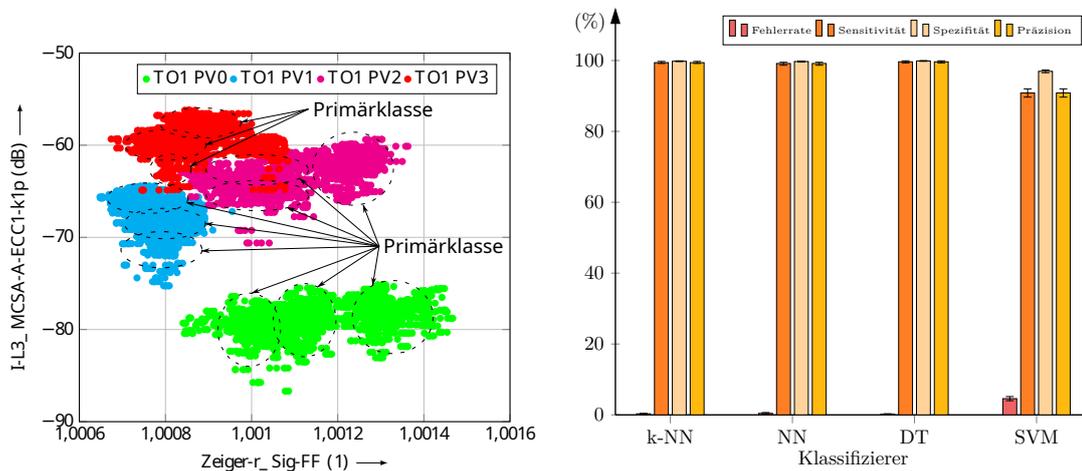


Abbildung 6.27: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 10. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Das Muster der *Auswahl 11* ist in Abb. 6.28 dargestellt. Es zeigt eine Spiegelung des zuvor beschriebenen Musters und damit gilt die gleiche Einordnung. Sowohl für die Korrelationskoeffizienten als auch für die Klassifizierer werden vergleichbare Ergebnisse erzielt.

Auswahl 13 in Abb. 6.29 zeigt ein ähnliches Muster wie zuvor *Auswahl 1* und *Auswahl 2*, jedoch erreicht das Merkmal nur eine Fehlerrate von 0,492%. Wie zuvor sind alle Primärklassen deutlich zu erkennen. Im Unterschied zu den bisherigen Mustern kommt es bei den Übergängen zwischen den Laststufen zu einer verstärkten Streuung. Mit der Folge, dass Proben in das Umfeld der anderen Cluster rutschen. Ursache hierfür ist die höhere Ordnung ($k=3$) für die das Merkmal BB2 berechnet wurde und der damit verbundenen Abnahme des Signal-Rausch-Abstands. Dennoch bilden die gefundenen Merkmale die zugrundeliegende Dynamik ab. Der Merkmalsvektor ist für die Diagnose von Fehlerrichtung im Sinne des KDED geeignet. Interessant ist dabei, dass auch die Drehzahl wichtige Informationen bereitstellt und das Verfahren zur Drehzahlschätzung ausreichend präzise Werte liefert. Die grundsätzliche Eignung des Merkmalsvektors wird durch weitere Klassifizierer bestätigt, siehe Abb. 6.29 rechts. Neben kNN führt der Merkmalsvektor auch bei den weiteren

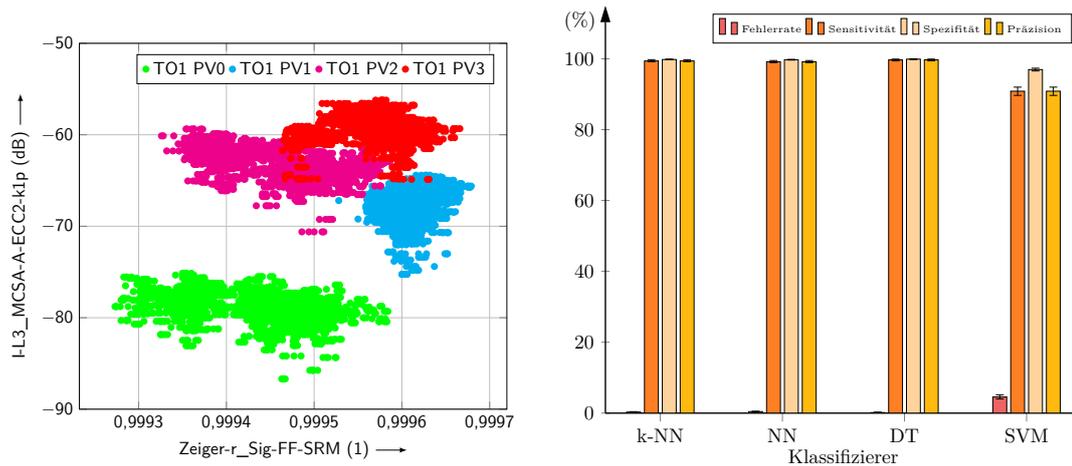


Abbildung 6.28: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 11. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Klassifizierern zu einer Fehlerrate zwischen 0 und 1 %.

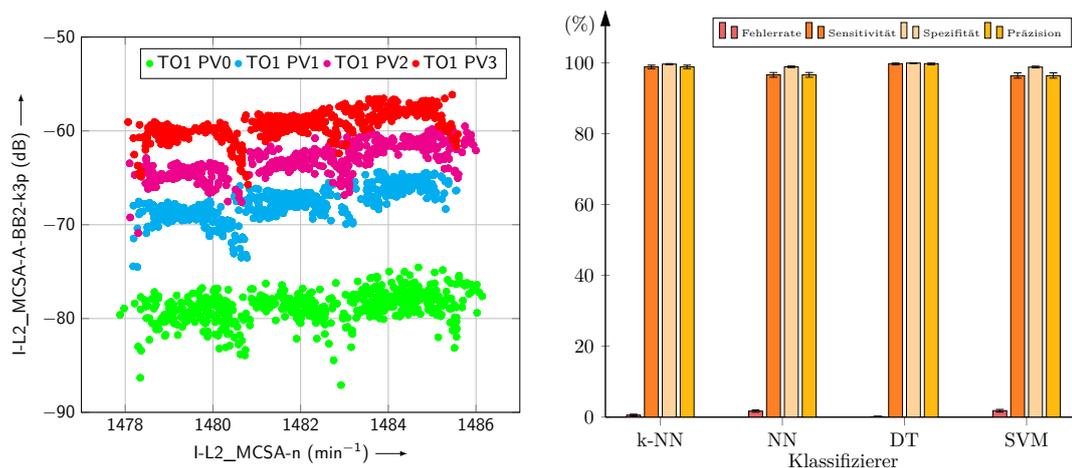


Abbildung 6.29: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 13. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Mit *Auswahl 14* steht ein weiterer Merkmalsvektor zur Verfügung, der die gleichen Eigenschaften wie *Auswahl 2* besitzt. Das Muster ist in Abb. 6.30 abgebildet. Auch in diesem Fall sind alle Primärklassen deutlich erkennbar und in Richtung der Last mit einer deutlichen Lücke angeordnet. Bei der Merkmalsuche wurde der Merkmalsvektor mit einer Fehlerrate von 0,571 % bestimmt. Im Vergleich zu *Auswahl 2* kann jedoch eine stärkere Streuung des Merkmals ECC1 festgestellt werden. Aufgrund dieser Beobachtung können die drei Leiter-

ströme nicht als gleichwertig angesehen werden. Ob die Beobachtung eines Leiters für die Diagnostik ausreicht, muss im Einzelfall entschieden werden.

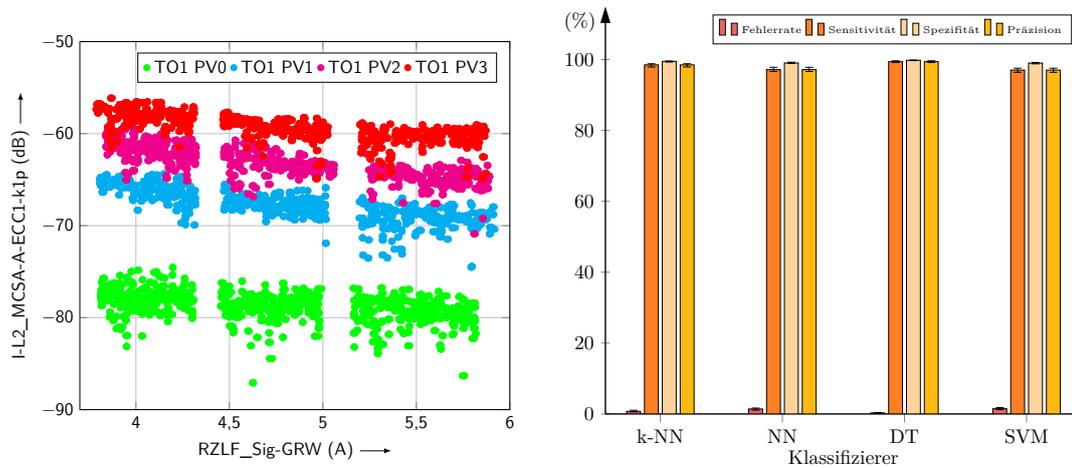


Abbildung 6.30: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 14. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Abschließend wird für den Fall *Auswahl 19* diskutiert. Das Muster, das der Merkmalsvektor hervorbringt, ist in Abb. 6.31 dargestellt. Mit einer Fehlerrate von 2,683 %, fällt diese deutlich höher aus als bei den bisher betrachteten Merkmalsvektoren. Das gefundene Muster kann nicht als ideal bezeichnet werden, da nicht alle Primärklassen erkennbar sind, jedoch bilden sich Cluster für jede Stufe der Fehlauseinrichtung. Im Gegensatz zu *Auswahl 10* und *Auswahl 11* kann jedoch keine Aufreihung proportional zur Fehlauseinrichtung festgestellt werden. Die Validierung mit unterschiedlichen Klassifizierern führt zu Klassifizierungsfehlern kleiner 3 %, siehe Balkendiagramm in Abb. 6.31. Trotz der guten Klassifizierungsrate wird der Merkmalsvektor nicht für die technische Diagnostik von Fehlauseinrichtung empfohlen.

Da das Muster die Einflüsse nicht abbildet, muss bei neuen Daten mit einem Versagen des Merkmalsvektors gerechnet werden.

Die Auswertung von Fall 3 hat gezeigt, dass mit der Strategie des KDED Merkmalsvektoren gefunden werden können, die eine robuste Diagnose von Parallelversatz erlauben. Die Qualität der Ergebnisse zeigt sich darin, dass die Merkmalsvektoren auch mit unterschiedlichen Klassifizierern zu Fehlerraten zwischen 0 und 3 % führen. Weiterhin wurden unbrauchbare Merkmalsvektoren diskutiert, die aufgrund struktureller Fehler zunächst von der Merkmalsselektion ausgewählt wurden. Ein Teil der aussortierten Muster ist zwar für eine Klassifizierung geeignet, die zugrundeliegenden Einflüsse sind jedoch nicht erkennbar, wie im KDED gefordert. Geeignet für die technische Diagnostik sind somit *Auswahl 1*, *2*, *10*, *11*, *13* und *14*. Mit Ausnahme von *Auswahl 10* und *11* ist die Unterscheidung der Fehlerzustände

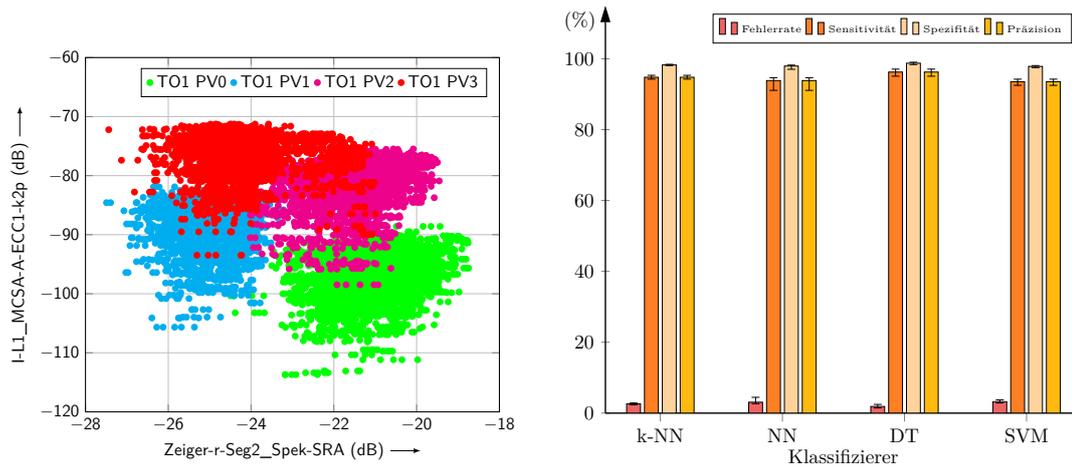


Abbildung 6.31: Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 19. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

auch bei gleichzeitig auftretender Laständerung möglich. Die geringen Fehlerraten sind dabei im Betrachtungsbereich von 72 % bis 100 % des Nenn Drehmoments mit einer Schrittweite von kleiner 2 % möglich. Für Parallelversatz hat sich der Bereich von 0,02 mm bis 0,11 mm bei einem Schritt von 0,03 mm als ausführbar ergeben.

6.3.3 Parallelversatz bei Laständerung – 1,1 kW-Motor

Im folgenden Abschnitt soll der Fall *Zielgröße: Parallelversatz, Parameter: 1,1 kW-Motor und Störgröße: Last* untersucht werden. Die reduzierte Auswahl an Merkmalsvektoren ist in Tab. 6.9 dargestellt. Von den sieben Merkmalsvektoren, die vom Algorithmus vorgeschlagen werden, sollen drei diskutiert werden.

Ein interessantes Muster für den Fall 4 wird durch *Auswahl 2* sichtbar, siehe dazu Abb. 6.32. In dem Muster sind alle Primärklassen deutlich erkennbar und zeigen auch den Freiraum zwischen den eingestellten Zuständen. Zudem sind die Cluster in der ersten Dimension nach der Last und in der zweiten Dimension nach dem Grad des Parallelversatzes aufgereiht. Dieser Zusammenhang wird auch durch die Korrelationskoeffizienten in Tab. 6.9 bestätigt, wonach das erste Merkmal zu 96,1 % mit der Last und das zweite Merkmal zu 26 % mit der Zielgröße korreliert ist. Sonst sind die Korrelationskoeffizienten gleich null, bis auf den für das Merkmal 2 mit der Last zu 57,7 %. Dieser Wert wird maßgeblich durch die starke Krümmung bestimmt, die in den Daten bei Fehlergrad 0 und Fehlergrad 2 zu sehen ist. Die Ursache für die starke Einwirkung der Last auf Merkmal 2 in nur zwei der vier Klassen ist bislang nicht geklärt. Derzeit wird geprüft, ob die Vorspannung des Motors fehlerhaft war. Erste Recherchen, die im Anschluss an die Beobachtung getätigt wurden, geben Hinweise

darauf, dass die Steifigkeit der Welle Einfluss auf das Experiment hat, wie in [23] untersucht. Die Ursache für die Krümmung in den beiden Klassen wird darüber entscheiden, ob der Merkmalsvektor für die technische Diagnostik geeignet ist oder nicht. Kommt die Krümmung durch eine Vorspannung zustande, die den Normalbereich der Anwendung übersteigt, kann das Merkmal für die technische Diagnostik eingesetzt werden. Liegen die Werte für die Vorspannungen jedoch im Anwendungsbereich, kann der Merkmalsvektor nicht für die technische Diagnostik eingesetzt werden, da der Einfluss bisher nicht identifiziert wurde.

Tabelle 6.9: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate kNN (%)	Korrelation (1)		
			Last	PV	WV
Auswahl 2					
Raumzeiger (r)	GRW	/	0,961	0,000	-0,000
Spektrum (l_3)	Pos. 1. Spitze (Seg. 10)	/	0,577	-0,260	0,000
Merkmalsvektor		0,229	/	/	/
Auswahl 3					
Raumzeiger (r)	QWM	/	0,961	0,001	0,000
Spektrum (l_2)	Pos. 1. Spitze (Seg. 9)	/	0,441	-0,381	0,000
Merkmalsvektor		0,775	/	/	/
Auswahl 5					
Raumzeiger (r)	NormSumQuad	/	0,960	-0,001	-0,000
Spektrum (l_1)	Pos. 1. Spitze (Seg. 10)	/	-0,179	0,435	0,000
Merkmalsvektor		1,963	/	/	/

* Prüfung bestanden.

Die Schwächen in der Struktur des Musters wurden auch durch die Bewertung mit unterschiedlichen Klassifizierern deutlich. Mit den NN und der SVM werden lediglich Fehlerraten zwischen 4,99% und 8,87% erreicht. Zudem ist anzumerken, dass die Entscheidungsbäume die Fehlerrate nur mit 65 bis 73 Regeln erreichen. Hier wird die ungeeignete Struktur durch zusätzliche Regeln kompensiert. Abschließend kann zum Muster beobachtet werden, dass die Segmentgrenzen von Klasse PV 3 aufgrund eines Extraktionsfehlers überschritten werden. Diese Beobachtung wirkt sich auf mehreren Ebenen aus. Für die Anwendung ist eine Überschreitung der Bereichsgrenzen problematisch, da außerhalb des Betrachtungsbereichs zufällige Werte angenommen werden. Kritisch ist auch, wenn Muster aufgrund einer erhöhten Fehlerrate vom Algorithmus ausgeschlossen werden. Wie bereits vorgeschlagen, können dynamische Bereichsgrenzen oder die Vergrößerung der Fenster das Problem reduzieren. Für die technische Diagnostik ist die Beobachtung unproblematisch, da das Muster inklusive der Grenzen bereits identifiziert wurde und somit die Bereichsgrenzen angepasst werden

können.

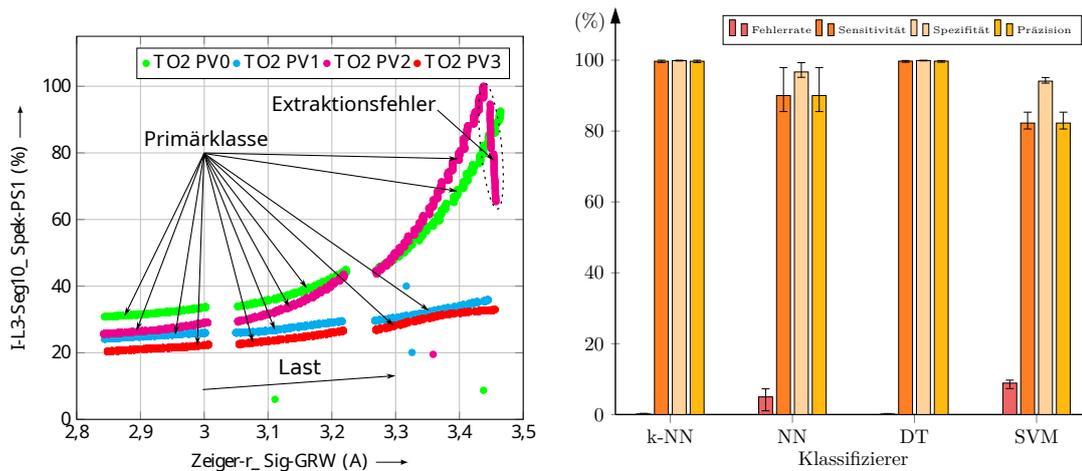


Abbildung 6.32: Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 2. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Mit *Auswahl 3* handelt es sich um ein vergleichbares Muster wie zuvor bei *Auswahl 2*, siehe dazu Abb. 6.33. Auch hier sind alle Primärklassen deutlich erkennbar und auch die zuvor beschriebene Krümmung ist zu sehen. Ursache für die Ähnlichkeit ist, dass Merkmal 2 ebenfalls die Position der Spitze in einem Segment zeigt. Der Unterschied bei den Merkmalen ist die Phase und das Segment. Zu erwarten war, dass die Spitzen in Leiter 3 auch in Leiter 2 auftreten, jedoch wurden unterschiedliche Bänder des Spektrums ausgewählt. Zudem liegt der Großteil der Cluster in der Mitte des Segments, wodurch in diesem Fall Klasse PV 3 und PV 1 vom Abschnitt am Bereichsende betroffen sind. Das hat zur Folge, dass sich die Fehlerraten bei den Klassifizierern insbesondere bei NN und SVM verschlechtern, siehe Balkendiagramm Abb. 6.33.

Auch *Auswahl 5* ist vergleichbar mit den bisherigen Beobachtungen. Jedoch fällt auf den ersten Blick die gegenläufige Anordnung der Cluster auf, siehe dazu Abb. 6.34. Das erste Merkmal ist wie zuvor bei *Auswahl 2* und *Auswahl 3* stark (96 %) mit der Last korreliert. Interessant ist, dass auch bei der dritten Auswahl die Position der Spitze in Segment 10 ausgewählt wurde und somit die Spitzen eng zusammen liegen. Aufgrund dessen, dass die Vorzeichen der Korrelationskoeffizienten beim ersten Merkmal gleich sind, muss die invertierte Entwicklungsrichtung durch das zweite Merkmal bestimmt werden. Das ist interessant, da in diesem Fall die Spitze im Spektrum mit der Last in die entgegengesetzte Richtung wandert. Diese Beobachtung muss bei der Festlegung der Segmente berücksichtigt werden, um den vollständigen Verlauf beobachten zu können. Wie bereits zuvor verursacht die Verletzung der Segmentgrenzen eine starke Zunahme der Fehlerrate bei den Klassifizierern, siehe

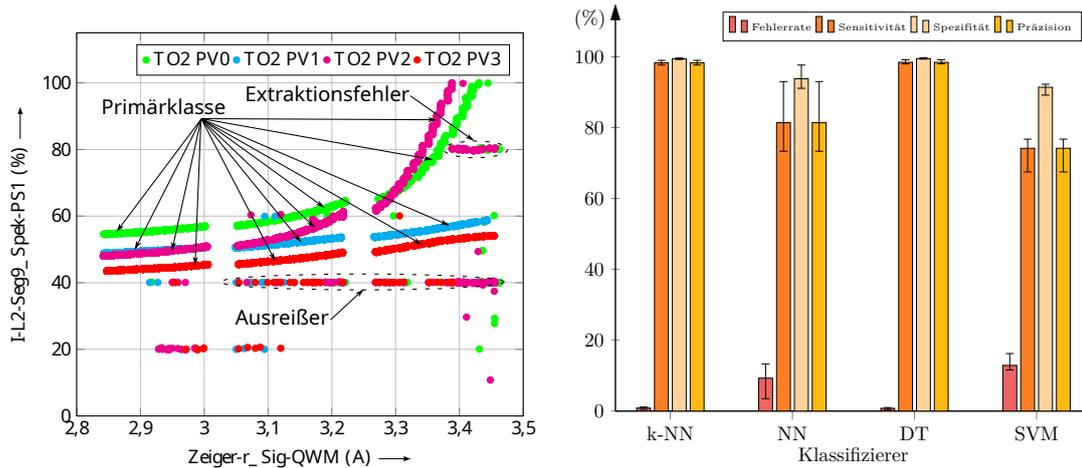


Abbildung 6.33: Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 3. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Balkendiagramm Abb. 6.34.

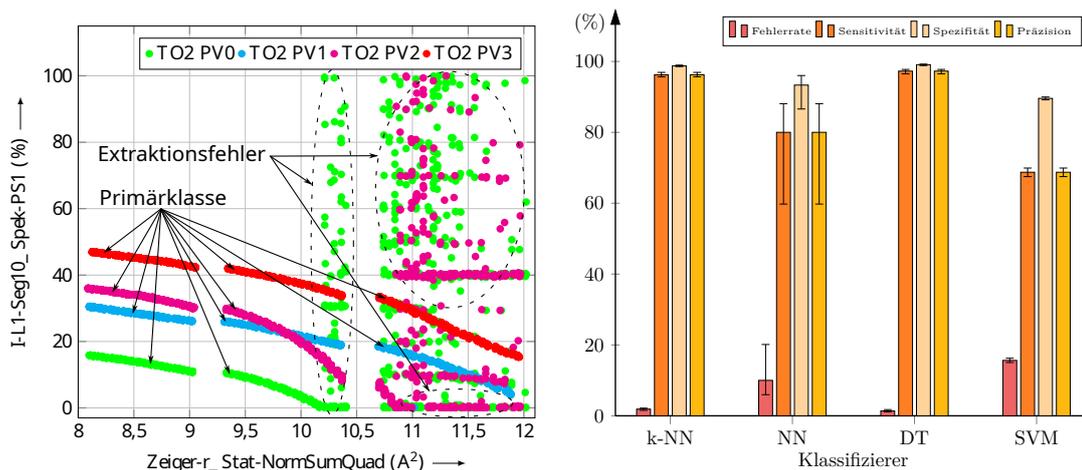


Abbildung 6.34: Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 5. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Zur Erkennung und Bewertung von Fehlansrichtung wurden für TO 2 abweichend zu TO 1 hauptsächlich der Verlauf der Spitzen in Segment 9 und Segment 10 ausgewählt. Die resultierenden Muster zeigen eine deutliche Abtrennung zwischen den Primärklassen. Zudem wird der Verlauf der Einflussgrößen vollständig abgebildet. Im Vergleich zu den Ergebnissen von TO 1 ist jedoch ein nicht linearer Verlauf erkennbar, der auf eine unbekannte Einflussgröße hindeutet. Dieser Aspekt muss weiterhin untersucht werden, bevor die Merkmalsvektoren

für die technische Diagnostik eingesetzt werden können. Insbesondere deswegen, weil die Schneidungen zu Fehlern bei neuen Daten führen werden. Die Bewertung der Merkmalsvektoren konnte in diesem Fall nur visuell vorgenommen werden, da die vermutete unbekannte Einflussgröße, die Aussagekraft der angewendeten Kriterien reduziert.

Es ist hervorzuheben, dass diese Erkenntnis nur durch den Dreiklang aus Experiment, Data-Mining und Bewertung möglich war. Auch wenn die gefundenen Muster unter Vorbehalt zu bewerten sind, ist eine Tendenz zur Ausbreitung der Fehler- und Störgröße in orthogonalen Richtungen erkennbar. Die Vermutung liegt daher nahe, dass auch in diesem Fall technische Diagnostik unter dem Einfluss der Störgröße möglich ist. Des Weiteren wurde bei dieser Auswertung beobachtet, dass die Fortsetzung der Cluster durch die Segmentbegrenzung unterbrochen wird. Die im Experiment definierten Grenzwerte können somit nicht bestätigt werden. Das Konzept zur Extraktion dieser Merkmale muss daher überarbeitet werden, um Fehler sowohl bei der Analyse als auch bei der Anwendung zu vermeiden.

6.3.4 Winkelversatz bei Laständerung – 7,5 kW-Motor

Nachfolgend soll der Fall *Zielgröße: Winkelversatz, Parameter: 7,5 kW-Motor und Störgröße: Last* betrachtet werden. Von den drei Vorschlägen, die durch den Algorithmus getroffen wurden, sollen zwei diskutiert werden. Die reduzierte Auswahl an Merkmalsvektoren ist in Tab. 6.10 dargestellt.

Tabelle 6.10: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Winkelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			Last	PV	WV
Auswahl 1					
Signal (I_2)	Mittelwert	/	0,154	-0,274	-0,482
Signal (I_3)	Wb	/	0,005	-0,970	-0,763
Merkmalsvektor		3,696	/	/	/
Auswahl 2					
Signal (I_3)	N6M	/	-0,166	-0,940	-0,737
Signal ($U_{1,2}$)	FF	/	0,397	0,846	0,842
Merkmalsvektor		1,738	/	/	/

* Prüfung bestanden.

Das erste Muster des Falls wird durch *Auswahl 1* sichtbar, siehe Abb. 6.35. Der Merkmalsvektor wurde vom Algorithmus mit einer Fehlerrate von 3,696 % bestimmt. Vergleichbare Ergebnisse liefern auch die Klassifizierer NN und Entscheidungsbäume. Nur SVM weicht davon mit 25 % deutlich ab, wie im Balkendiagramm in Abb. 6.35 zu sehen. Nach Bewertung des Musters ist festzustellen, dass sich der Merkmalsvektor nicht für die technische

Diagnostik eignet, da erstens die Primärklassen nicht erkennbar sind und zweitens keine Aufreihung proportional zur Zielgröße vorliegt. Da sich dennoch Cluster bilden, die von den meisten Klassifizierern ausgewertet werden können, handelt es sich um ein Beispiel, das am Ende durch Begutachtung aussortiert werden muss.

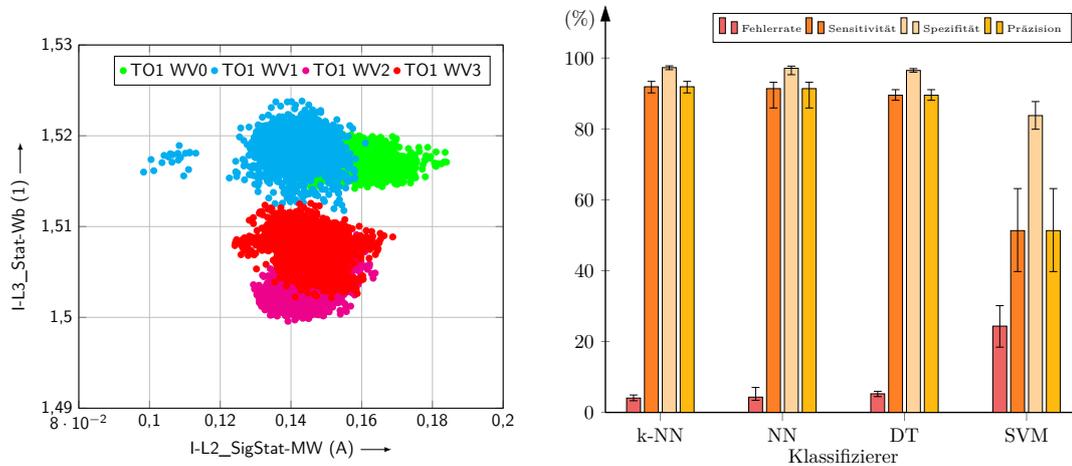


Abbildung 6.35: Untersuchung des Falls: Zielgröße = WV, Parameter = TO1, Störgrößen = L; Auswahl 1. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Ein weiterer Vorschlag des Algorithmus ist *Auswahl 2*, die in Abb. 6.36 zu sehen ist. Der Merkmalsvektor wurde mit einer Fehlerrate von 2,433 % gewählt. Die Primärklassen liegen nebeneinander und schneiden sich nur im Randbereich. Die Markierungen in der Abbildung deuten das Zentrum an. Bemerkenswert ist, dass sich eine Aufreihung der Primärklassen in Richtung der Last und der Zielgröße nur in Teilen beobachten lässt. Die Ursache dazu ist weiterhin nicht vollständig verstanden, weswegen der Merkmalsvektor nach den Kriterien des KDED nicht für die Anwendung empfohlen werden kann. Zukünftige Untersuchungen können klären, wodurch die Unterbrechung der Aufteilung zustande kommt. Auf Basis dieses Wissens können dann weitere Optimierungen vorgenommen oder der Merkmalsvektor verworfen werden. Auch bei dieser Auswahl zeigt die Untersuchung mit den Klassifizierern, dass niedrige Fehlerraten ohne vollständiges Verständnis der Einflüsse und Wirkungen erzielt werden können.

Im Gegensatz zum Parallelversatz, konnten für Winkelversatz keine anwendbaren Merkmalsvektoren identifiziert werden. Aufgrund der Unterschiede zwischen den zwei Fällen ist nach aktuellem Kenntnisstand davon auszugehen, dass reiner Winkelversatz keinen Einfluss auf den Strom hat. Die Auswertung von TO 2 steht dem nicht entgegen, da die Korrelationskoeffizienten für Parallelversatz (41,2 %, 40,5 % und 47,4 %) ähnlich stark sind wie für Winkelversatz (42,5 %, 39,8 % und 57,3 %). Als Ursache wird vermutet, dass bei

Winkelversatz die Welle nicht verbogen wird und damit der Luftspalt sich nicht verformt. Die erhöhte Reibung im Zahnkranz reicht für eine robuste Diagnose nicht aus. Der Fall verdeutlicht, dass mit Data-Mining Merkmalsvektoren gefunden werden können, die niedrige Fehlerraten bei bestimmten Klassifizierern aufweisen. Aussagen zu den grundlegenden Mechanismen werden auch hier erst im Interpretationsschritt möglich. Wie in Auswahl 1 und Auswahl 2 zu sehen ist, reihen sich die Primärklassen weder mit steigender Fehlergröße noch mit steigender Last auf. Eine Aussage zur Diagnose unter Einfluss einer Störgröße und den Grenzen ist somit ebenfalls nicht möglich.

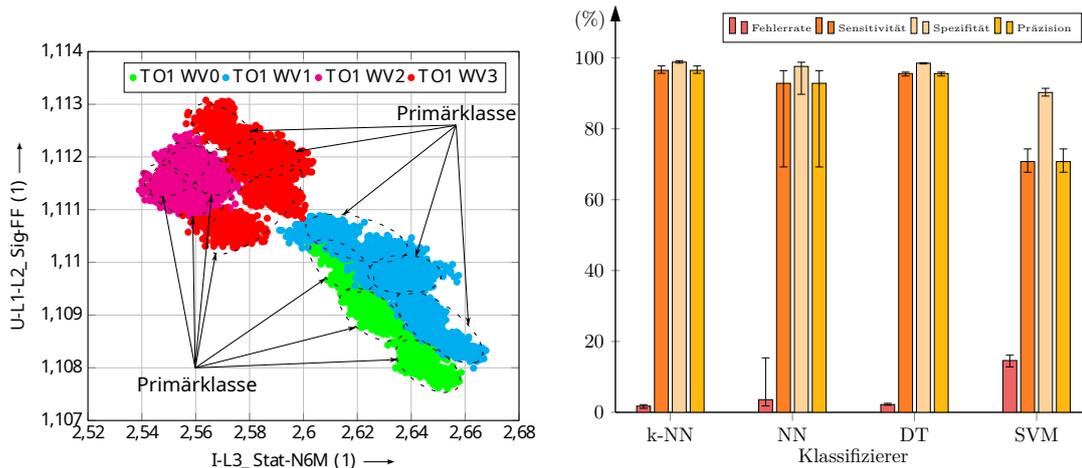


Abbildung 6.36: Untersuchung des Falls: Zielgröße = WV, Parameter = TO1, Störgrößen = L; Auswahl 2. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

6.3.5 Winkelversatz bei Laständerung – 1,1 kW-Motor

Die Untersuchung der Fehlausrichtung wird mit Fall *Zielgröße: Winkelversatz, Parameter: 1,1 kW-Motor und Störgröße: Last* abgeschlossen. Die bewertete Auswahl der Merkmale für diesen Fall ist in Tab. 6.11 dargestellt. Diskutiert werden demnach drei von sieben vorgeschlagenen Merkmalsvektoren.

Der erste Merkmalsvektor, der diskutiert werden soll, ist *Auswahl 1*. Das Muster, das der Merkmalsvektor aufzeigt, ist in Abb. 6.37 dargestellt. In der Darstellung sind alle Primärklassen deutlich erkennbar und in Richtung der Last aufsteigend angeordnet. Dies wird durch den Korrelationskoeffizienten des ersten Merkmals in Tab. 6.11 bestätigt. Das zweite Merkmal ist neben der Zielgröße ebenfalls zu 56 % mit der Last korreliert. Dies führt dazu, dass sich die Cluster mit steigender Last schneiden.

Tabelle 6.11: Reduzierte Auswahl der Merkmalsvektoren für den Fall:
Zielgröße = Winkelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			Last	PV	WV
Auswahl 1					
Raumzeiger (r)	qWM	/	0,961	0,008	-0,018
Spektrum (I ₁ , Seg. 11)	Pos. 1. Spitze	/	0,560	0,412	-0,425
Merkmalsvektor		0,304	/	/	/
Auswahl 2					
Raumzeiger (r)	NormSumQuad	/	0,960	0,009	-0,018
Spektrum (I ₃ , Seg. 10)	Pos. 1. Spitze	/	0,640	0,405	-0,398
Merkmalsvektor		0,658	/	/	/
Auswahl 5					
Raumzeiger (r)	MW	/	0,961	0,009	-0,018
Spektrum (I ₁ , Seg. 10)	Pos. 1. Spitze	/	-0,182	-0,474	0,573
Merkmalsvektor		2,433	/	/	/

* Prüfung bestanden.

Wie bereits zuvor kann der Merkmalsvektor erst nach Klärung der Ursachen für die technische Diagnostik empfohlen werden, da zunächst keine grundsätzliche Unterscheidbarkeit vorliegt. Wie aus dem Balkendiagramm in Abb. 6.37 ersichtlich ist, führt diese Anordnung nur mit kNN zu einer geringen Fehlerrate. Die Verfahren NN und SVM führen zu einer unbrauchbaren Fehlerrate. Zu beachten ist, dass auch die Entscheidungsbäume ein unbrauchbares Ergebnis liefern, da zur Erzielung der Fehlerrate 99 bis 104 Regeln benötigt werden. Die Anzahl an Regeln ist deutlich höher, als zur Trennung von 12 Primärklassen im Idealfall notwendig sind. Weiterhin ist zu erkennen, dass das Muster starke Ähnlichkeit mit denen aus der Untersuchung Parallelversatz zeigt. Zudem zeigt der Vergleich der Korrelationskoeffizienten für Parallel- und Winkelversatz ähnliche Größenordnungen. Beides deutet darauf hin, dass die Grenzwerte für den unerwünschten Anteil an Parallelversatz zu hoch angenommen sind. Weitere Untersuchungen müssen klären, ob die Muster durch Parallel- oder Winkelversatz verursacht wurden.

Der zweite Merkmalsvektor, der für diesen Fall diskutiert werden soll, ist *Auswahl 2*. Das resultierende Muster dazu ist in Abb. 6.38 dargestellt. Das Muster ist vergleichbar zu Auswahl 1, somit können die getroffenen Aussagen übertragen werden. Der Vergleich der beiden Muster zeigt darüber hinaus, dass wie bereits beim Parallelversatz Bereiche des Spektrums ausgewählt wurden, die nahe beieinander liegen (Segment 10 und 11), die Auswahl aber unterschiedliche Leiter betrifft (L₁ und L₃).

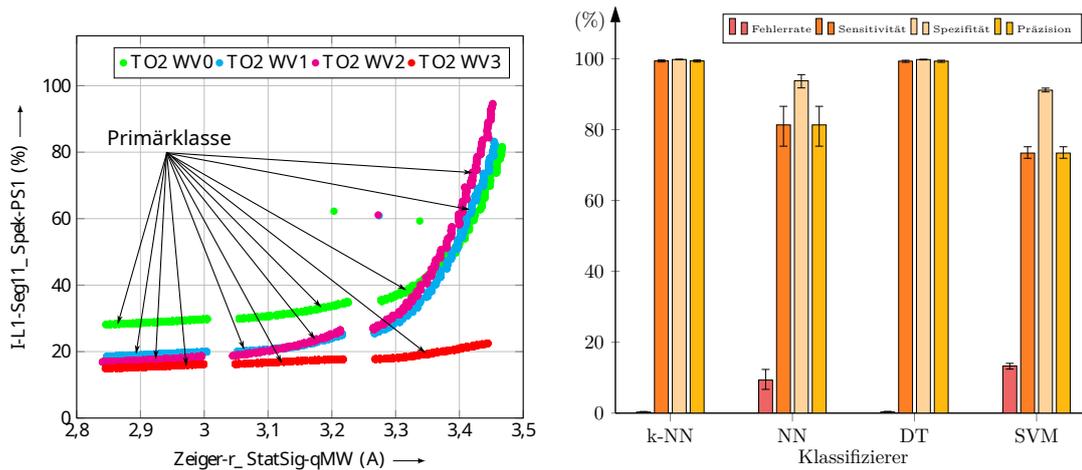


Abbildung 6.37: Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 1. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Der dritte Merkmalsvektor ist *Auswahl 5*, dessen resultierendes Muster in Abb. 6.39 dargestellt ist. Der Merkmalsvektor wurde mit einer Fehlerrate von 2,433 % ausgewählt. Das Muster zeigt die Primärklassen, die sowohl in Richtung der Last als auch in Richtung des Winkelversatzes in aufsteigender Folge angeordnet sind. Jedoch können in dem Muster auch Probleme festgestellt werden: so schneiden sich die Cluster mit steigender Last und die größte Spitze im Segment 10 tritt aus dem Beobachtungsbereich. Die Fehlerrate kann daher in einem begrenzten Umfang verbessert werden, indem das Segment angepasst wird. Wenn die Ursachen nicht ergründet sind, ist die Schneidung der Cluster jedoch ein Problem, das die Auswahl unbrauchbar macht. Die Klassifizierer NN, Entscheidungsbäume und SVM bestätigen, dass das gefundene Muster nur mit kNN zu geringen Fehlerraten führt. Daher ist eine allgemeine Eignung des Merkmalsvektors für die technische Diagnostik nicht gegeben. Eine weitere interessante Beobachtung ist, dass sich diese Auswahl wie Auswahl 5 im Fall *Zielgröße: Parallelversatz, Parameter: 1,1 kW-Motor und Störgröße: Last* verhält, weshalb von einem dominierenden Einfluss von Parallel- oder Winkelversatz ausgegangen werden muss.

Für den untersuchten Fall wurden Muster identifiziert, die wie gewünscht die Primärklassen darstellen und bei denen die Reihung der Cluster der aufsteigenden Größe folgt. Die Merkmalsvektoren können jedoch bisher nicht für die technische Diagnostik empfohlen werden, da sich die Cluster mit steigender Last zu schneiden beginnen. Diese Beobachtung wurde bereits zuvor beim 1,1 kW-Motor im Fall *Parallelversatz* gemacht. Zudem wurden Merkmale mit vergleichbaren Eigenschaften ausgewählt. Diese Beobachtung legt nahe, dass der Entwurf zum Experiment überarbeitet werden muss.

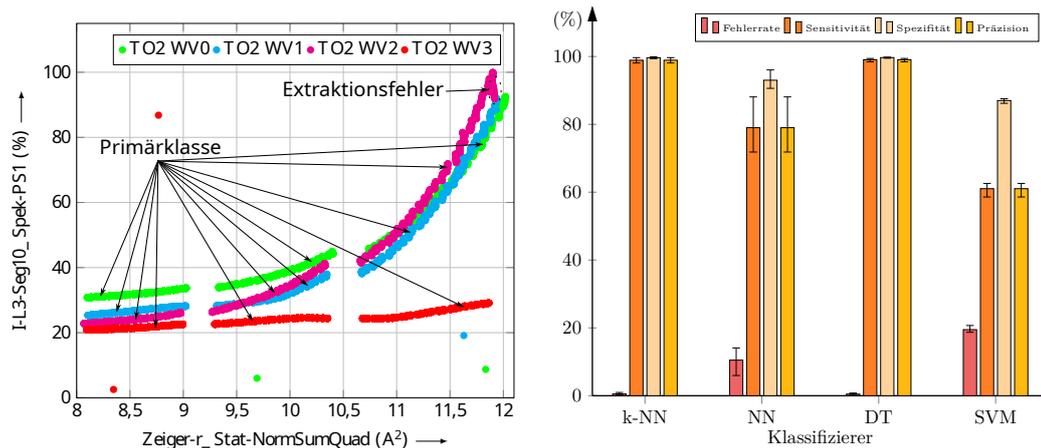


Abbildung 6.38: Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 2. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

Grund dafür ist der zu hoch angesetzte Grenzwert für die Störgröße Parallel- oder Winkelversatz, je nach Untersuchung. Unter Berücksichtigung der Ergebnisse mit dem 7,5 kW-Motor ist anzunehmen, dass der ungewollte Anteil an Parallelversatz die Muster verursacht. Unter Vorbehalt ist anzumerken, dass bei allen Merkmalsvektoren ein Teilbereich eine orthogonale Ausbreitungsrichtung von Fehler- und Störgröße deutlich erkennen lässt. Es wird daher vermutet, dass auch in diesem Fall technische Diagnostik unter Einfluss der Störgröße Last möglich ist. Eine Aussage zu den Grenzwerten ist in diesem Fall jedoch nicht möglich, da zunächst geklärt werden muss, wodurch die Schneidung verursacht wird.

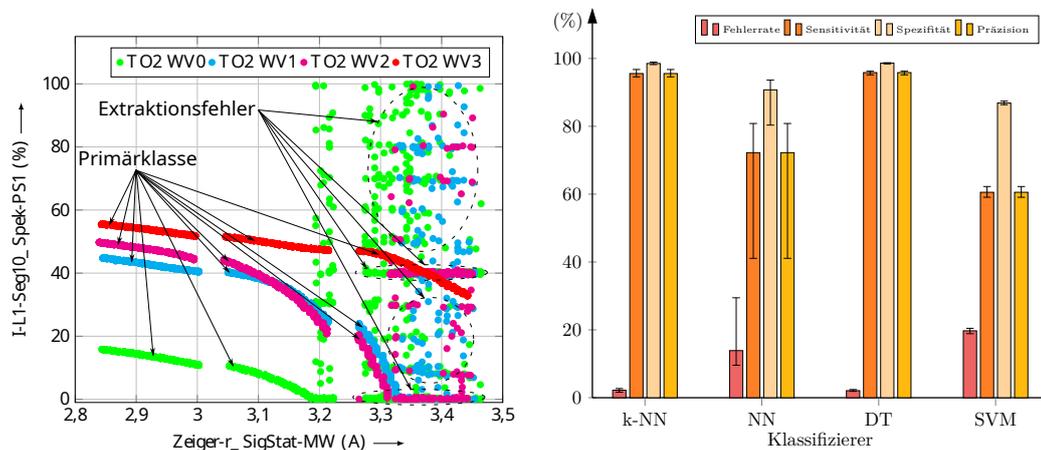


Abbildung 6.39: Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 5. Links: Verteilung der Proben; rechts: Validierungsfehler mit unterschiedlichen Klassifizierern.

7 Schlussbetrachtung und Ausblick

In der vorliegenden Arbeit wurde das KDED als neues Konzept für die Identifikation von Merkmalen zur Anwendung in der technischen Diagnostik beschrieben und angewendet. Dieses entstand durch die Verbindung klassischer Experimente mit leistungsfähigen Algorithmen des Data-Minings und einer Strategie zur Bewertung maschinell erstellter Vorschlagslisten. Mithilfe einer Kaskade von Bewertungskriterien, zu denen ein Ausdruck zur Beschreibung der Einfachheit eines Merkmalsvektors, die Korrelation, der Validierungsfehler unterschiedlicher Klassifizierungsverfahren und die Anordnung von Clustern im identifizierten Raum zählen, ist es möglich, die Vielzahl von Vorschlägen effizient zu verarbeiten.

Für die Auswertung ausgewählter Fehler wie Fehlausrichtung, gebrochener Rotorstab und Kavitation wurde das Konzept auf jeder Ebene implementiert und umfangreiche Daten gesammelt. Entscheidend für die erfolgreiche Anwendung des Konzepts ist die Durchführung der Experimente. Hier hat sich gezeigt, dass zur Beherrschung der Prozesse hohe Anforderungen an die Prozesssteuerung gestellt werden und der Umfang der Experimente nur durch Automatisierung zu bewältigen ist. Für das Data-Mining hat sich das Wrapper-Verfahren in Kombination mit den kNN bewährt. Zum einen wurde die Qualität der damit gefundenen Merkmalsvektoren auch durch andere Klassifizierer bestätigt und zum anderen wurden Muster nicht maskiert, die aufgrund von Fehlern in der Versuchsdurchführung nicht ideal waren. Einziger Nachteil bei der Anwendung von kNN ist die Empfindlichkeit bei lückenden Clustern. Muster mit diesem strukturellen Fehler werden nicht verworfen und müssen manuell oder durch den Einsatz eines weiteren Klassifizierers automatisch entfernt werden. Mit dem KDED war es letztlich möglich, leistungsfähige Merkmale zu entdecken, für die nur der Leiterstrom des überwachten ASM notwendig ist. Die Auswertung hat gezeigt, dass selbst Fehler an der Verbindungsstelle und an der angeschlossenen Arbeitsmaschine über die elektrischen Signale erkannt werden können.

Die Auswertung des Fehlers Parallelversatz hat nützliche Merkmalspaarungen hervorgebracht, von denen auszugehen ist, dass diese auch bei abweichenden Systemen eingesetzt werden können. Diese Erkenntnis wird maßgeblich von der Bewertung des resultierenden Musters getragen, das für mehrere Merkmalsvektoren alle Primärklassen aufgereiht nach dem Grad der Einflussgrößen zeigt. Für den 7,5 kW-Motor wurden für Winkelversatz allerdings keine Merkmalsvektoren gefunden, die alle Kriterien erfüllen. Im Falle des 1,1 kW-Motors wurden Muster gefunden, die sich bezüglich der Merkmalsauswahl und den Mustern für

Parallel- und Winkelversatz ähnlich sind. Die Erkennung von Winkelversatz ist nach dieser Bewertung nicht möglich. Der Einfluss auf die Merkmale ist bei beiden Fehlern erkennbar, jedoch ist unklar, ob die Ursache der Parallelversatz oder der Winkelversatz ist. Weitere Untersuchungen, bei denen Parallelversatz als Zielgröße, Winkelversatz als Störgröße und umgekehrt definiert werden, sind zur weiteren Klärung notwendig.

Eine Vielzahl von Lösungen wurde für die Erkennung des gebrochenen Rotorstabs gefunden. Wichtigstes Ergebnis ist dabei, dass der Fehler bis zu einem Teillastbetrieb von ca. 60 % mit einem Merkmal sicher erkannt werden kann. Das liegt daran, dass die identifizierten Merkmale durch einen Rotorstabbruch im Vergleich zur Laständerung eine starke Wertänderung erfahren. Ferner wurden auch zweidimensionale Merkmalsvektoren gefunden, bei denen nicht von einer Einschränkung im Teillastbereich auszugehen ist. Hierzu wurde ebenfalls die Lage der Primärklassen ausgewertet. Es ist jedoch weiterhin unklar, wie sich ein angebrochener Rotorstab in die gefundenen Muster einordnet und sich dieser Zwischenzustand negativ auf eine zuverlässige Auswertung auswirkt.

Bei der Auswertung der Daten zum Fehler Kavitation mussten zunächst Fehler in der Versuchsdurchführung festgestellt werden. Aufgrund des großen Grads an Kavitation von 10 % Förderhöhenabfall konnte der Prozess nicht über das ganze Experiment stabil gehalten werden. Infolge dieses Fehlers sind die Primärklassen in den gefundenen Mustern deplatziert, dennoch sind deutliche Tendenzen zur Anordnung der Cluster für die restlichen Kavitationsstufen erkennbar. Durch die Verwendung des kNN Klassifizierers war es dennoch möglich, Muster zu finden, die zur Klärung des Problems beigetragen hatten und das Potenzial der gefundenen Merkmalsvektoren aufzeigen. Nach Auswertung der vorliegenden Daten lässt sich sagen, dass Kavitation zuverlässig über den Strom diagnostiziert werden kann. Zudem kann für die untersuchte Pumpe die Auflösung sicher mit 3 % Förderhöhenabfall angegeben werden. Eine Auflösung von 2 % wurde nicht bestätigt, erscheint aber umsetzbar. Darunter ist von einer Zunahme der Fehlerrate auszugehen.

Alle Fehlerfälle wurden unter Einfluss mindestens einer Störgröße wie der Last oder des Durchflusses durchgeführt. Die Ergebnisse zeigen dabei, dass selbst in diesen Fällen technische Diagnostik mit den entdeckten Merkmalsvektoren möglich ist.

Trotz der zufriedenstellenden Ergebnisse bei der Anwendung des vorgestellten KDED wurde während der Auswertung an verschiedenen Stellen Optimierungspotential deutlich. Als günstig zu bewerten ist, dass alle Beobachtungen in das Konzept einfließen können, ohne grundlegende Änderungen vornehmen zu müssen.

Der erste Punkt zur Optimierung ist die Prüfung der untersuchten Fehler auf weitere dominante Störgrößen. Im nächsten Schritt können als dominanter Einfluss auch zusätzliche Fehler definiert werden, wodurch die Unterscheidbarkeit adressiert wird. Im Fall von Fehlerrichtung können Parallel- und Winkelversatz als abhängig voneinander betrachtet werden. Für bestimmte Fehler ist zudem die Temperatur als dominanter Einfluss denkbar.

Durch die Betrachtung weiterer Einflussgrößen wird die Interpretation der Muster eine Herausforderung. Denkbar wäre, dass komplexere Probleme in mehrere zweidimensionale Muster zerlegt werden, um eine Vorstellung von der Datenstruktur zu gewinnen.

So wertvoll die Muster für die Bewertung eines Fehlers sind, besteht weiterhin das Problem mit der Übertragbarkeit zum einen auf gleiche Systeme, aber auch auf ähnliche Systeme. Zur Lösung dieses Problems muss an einer geeigneten Normierung der Merkmale gearbeitet werden.

8 Anhang

8.1 Vollständige Ergebnisse des Data-Mining

Tabelle 8.1: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Störgröße = Durchfluss und Testobjekt.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
		kNN	Durchfluss	Kavitation
Auswahl 1*				
Spektrum (I_1 , Seg. 11)	Pos. 1. Spitze	/	0,074	-0,030
RZ-Spektrum (r , Seg. 9)	Pos. 1. Spitze	/	0,004	0,001
Merkmalsvektor		1,333	/	/
Auswahl 2				
Spektrum (I_1 , Seg. 10)	Pos. 1. Spitze	/	0,032	-0,325
Spektrum (I_2 , Seg. 16)	Pos. 1. Spitze	/	0,015	-0,141
Merkmalsvektor		2,815	/	/
Auswahl 3				
Spektrum (I_1 , Seg. 10)	Pos. 2. Spitze	/	0,010	-0,032
RZ-Spektrum (r , Seg. 9)	Pos. 2. Spitze	/	0,019	0,036
Merkmalsvektor		2,648	/	/
Auswahl 4				
Raumzeiger (r)	FF-SRM	/	-0,230	-0,234
Spektrum (I_2 , Seg. 16)	Pos. 2. Spitze	/	0,024	-0,143
Merkmalsvektor		3,546	/	/
Auswahl 5				
Spektrum (I_1 , Seg. 10)	Pos. 2. Spitze	/	-0,098	-0,161
Spektrum (I_2 , Seg. 9)	Pos. 1. Spitze	/	-0,040	0,175
Merkmalsvektor		1,509	/	/

Auswahl 6				
RZ-Spektrum (r, Seg. 10)	Pos. 1. Spitze	/	-0,007	0,045
RZ-Spektrum (r, Seg. 16)	Pos. 1. Spitze	/	-0,024	-0,124
Merkmalsvektor		4,454	/	/
Auswahl 7				
Spektrum (I ₃ , Seg. 9)	Pos. 1. Spitze	/	0,185	0,134
RZ-Spektrum (r, Seg. 11)	Pos. 1. Spitze	/	0,055	0,174
Merkmalsvektor		3,898	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.2: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Parameter = TO8; Störgröße = Durchfluss.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
			Durchfluss	Kavitation
Auswahl 1*				
Raumzeiger (r)	FF-SRM	/	0,042	-0,144
Spektrum (I ₂ , Seg. 9)	Pos. 1. Spitze	/	0,243	0,084
Merkmalsvektor		2,593	/	/
Auswahl 2				
Raumzeiger (r)	FF	/	-0,042	0,145
Spektrum (I ₁ , Seg. 10)	Pos. 1. Spitze	/	-0,178	-0,585
Merkmalsvektor		2,741	/	/
Auswahl 3				
Raumzeiger (LF)	N5M	/	0,035	0,038
Spektrum (I ₂ , Seg. 16)	Pos. 1. Spitze	/	0,075	-0,343
Merkmalsvektor		1,148	/	/
Auswahl 4*				
Signal (I ₂)	QWM	/	0,832	-0,468
Spektrum (I ₁ , Seg. 11)	Pos. 1. Spitze	/	0,178	0,586
Merkmalsvektor		2,222	/	/
Auswahl 5*				
Zeiger (r)	QWM	/	0,874	-0,389
Spektrum (I ₃ , Seg. 14)	Pos. 1. Spitze	/	-0,082	-0,308
Merkmalsvektor		2,796	/	/

Auswahl 6				
Zeiger (r)	StdAW	/	0,192	0,060
Spektrum (I ₂ , Seg. 16)	Pos. 2. Spitze	/	0,086	-0,328
Merkmalsvektor		3,648	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.3: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Kavitation; Parameter = TO9; Störgröße = Durchfluss.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
			Durchfluss	Kavitation
Auswahl 1				
Spektrum (I ₁ , Seg. 11)	Pos. 1. Spitze	/	0,039	-0,255
Spektrum (I ₂ , Seg. 9)	Pos. 1. Spitze	/	-0,276	0,205
Merkmalsvektor		0,407	/	/
Auswahl 2				
Signal (U _{1,2})	Var	/	-0,297	-0,607
Zeiger (r, Seg. 9)	Pos. 1. Spitze	/	-0,009	-0,016
Merkmalsvektor		0,667	/	/
Auswahl 3*				
Signal (I ₂)	qMW	/	0,939	-0,016
Spektrum (I ₂ , Seg. 16)	Pos. 1. Spitze	/	-0,010	0,133
Merkmalsvektor		0,278	/	/
Auswahl 4				
Spektrum (I ₁ , Seg. 10)	Pos. 1. Spitze	/	0,305	-0,250
Spektrum (I ₂ , Seg. 16)	Pos. 2. Spitze	/	-0,006	0,124
Merkmalsvektor		0,278	/	/
Auswahl 5				
Spektrum (U _{1,2} , Seg. 3)	Pos. 1. Spitze	/	0,185	-0,462
Raumzeiger (r, Seg. 9)	Pos. 2. Spitze	/	-0,009	-0,010
Merkmalsvektor		1,815	/	/
Auswahl 6				
Signal (I ₂)	StdAW	/	0,939	-0,016
Spektrum (I ₃ , Seg. 9)	Pos. 1. Spitze	/	0,321	-0,110
Merkmalsvektor		0,722	/	/

Auswahl 7*				
Signal (I_3)	qMW	/	0,919	-0,148
Raumzeiger (r, Seg. 16)	Pos. 1. Spitze	/	0,045	-0,106
Merkmalsvektor		2,370	/	/
Auswahl 8				
Signal ($U_{1,2}$)	qMW	/	0,307	0,613
Spektrum (I_1 , Seg. 10)	Pos. 2. Spitze	/	-0,017	-0,118
Merkmalsvektor		1,5	/	/
Auswahl 9				
Signal ($U_{1,2}$)	NormSumQuad	/	0,306	0,612
Signal ($U_{1,2}$)	Wb	/	-0,302	-0,612
Merkmalsvektor		2,444	/	/
Auswahl 10				
Signal ($U_{1,2}$)	QS	/	0,306	0,612
Spektrum ($U_{1,2}$, Seg. 1)	4. Spitze	/	-0,303	-0,613
Merkmalsvektor		3,648	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.4: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = gebrochener Rotorstab; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)	
			kNN	Last GRS
Auswahl 1				
Signal (I_1)	MW	0	-0,002	0,978
Auswahl 2				
Signal (I_1)	FF	0	0,390	0,872
Auswahl 3				
Signal (I_1)	FF-SRM	0	-0,296	-0,900
Auswahl 4*				
Signal (I_2)	FF-SRM	0	-0,231	-0,886
Auswahl 5*				
Signal (I_3)	Wb	0	-0,009	-0,991
Auswahl 6				
Signal (I_3)	N6M	0	-0,141	-0,978

	Auswahl 7			
Signal ($U_{1,2}$)	FF	0	0,341	0,919
	Auswahl 8			
Signal ($U_{1,2}$)	FF-SRM	0	-0,271	-0,939
	Auswahl 9*			
Raumzeiger (LF)	Med	0	0,099	-0,927
	Auswahl 10			
Raumzeiger (LF)	Wb	0	-0,261	-0,954
	Auswahl 11*			
RZ Spektrum (r, Seg. 4)	SRA	0	0,230	-0,914
	Auswahl 12			
RZ Spektrum (r, Seg. 4)	SW1	0	0,230	-0,914
	Auswahl 13			
Raumzeiger (LF)	N6M	0,017	-0,279	-0,926
	Auswahl 14			
Raumzeiger (LF)	FF	0,017	-0,229	-0,925
	Auswahl 15			
Raumzeiger (WF)	QWM	0,017	-0,151	-0,874
	Auswahl 16			
Spektrum ($U_{1,2}$, Seg. 4)	SRA	0,033	0,039	0,925
	Auswahl 17			
Spektrum ($U_{1,2}$, Seg. 4)	SW1	0,033	0,039	0,925
	Auswahl 18			
Signal ($U_{1,2}$)	N6M	0,05	0,254	-0,953
	Auswahl 19*			
Raumzeiger (r)	StadAW	0,067	0,187	-0,962
	Auswahl 20			
Raumzeiger (r)	Var	0,067	0,181	-0,962
	Auswahl 21			
Raumzeiger (r, Seg. 2)	SRA	0,067	-0,187	-0,958
	Auswahl 22			
Raumzeiger (r, Seg. 2)	SW1	0,067	-0,187	-0,958
	Auswahl 23			
Raumzeiger (LF)	N5M	0,117	-0,056	-0,955
	Auswahl 24*			
Raumzeiger (r)	TI	0,133	-0,254	-0,864

Auswahl 25				
Raumzeiger (r)	FF	0,2	-0,296	-0,921
Auswahl 26				
Raumzeiger (r)	FF-SRM	0,2	0,298	0,921
Auswahl 27				
Raumzeiger (WF)	qWM	0,217	-0,390	-0,537
Auswahl 28				
Raumzeiger (WF)	NormSumQuad	0,217	-0,408	-0,469
Auswahl 29				
Raumzeiger (WF)	QS	0,217	-0,408	-0,469
Auswahl 30				
Raumzeiger (WF)	WSQ	0,217	-0,390	-0,537
Auswahl 31				
Raumzeiger (WF)	StdAW	0,217	-0,390	-0,537
Auswahl 32				
Raumzeiger (WF)	Var	0,217	-0,408	-0,469
Auswahl 33*				
Raumzeiger (WF)	Sch	0,217	-0,140	-0,197
Auswahl 34				
Signal (I_3)	TI	2,233	0,045	-0,910
Auswahl 35				
Signal (I_2)	FF	3,167	0,398	0,836
Auswahl 36				
Raumzeiger (WF)	N5M	0,333	-0,082	0,055
Auswahl 37				
Raumzeiger (phi)	MW	0,35	-0,196	0,907
Auswahl 38				
Signal ($U_{1,2}$)	MW	0,45	0,284	0,919
Auswahl 39				
Raumzeiger (r)	Spw	0,533	0,235	-0,818
Auswahl 40				
Raumzeiger (r)	N6M	0,617	0,002	-0,926
Auswahl 41				
Raumzeiger (WF)	GRW	0,633	-0,340	-0,721
Auswahl 42				
RZ Spektrum (LF, Seg. 2)	Wb	0,75	-0,102	-0,926

	Auswahl 43			
RZ Spektrum (LF, Seg. 2)	N6M	0,8	-0,097	-0,921
	Auswahl 44			
Spektrum (I ₃ , Seg. 2)	SRA	0,967	-0,033	-0,873
	Auswahl 45			
Spektrum (I ₃ , Seg. 2)	SW1	0,967	-0,033	-0,873
	Auswahl 46			
RZ Spektrum (r, Seg. 2)	Wb	0,967	-0,052	-0,906
	Auswahl 47			
MCSA (I ₁)	BB2 (k1+)	1,05	-0,124	0,899
	Auswahl 48			
MCSA (I ₁)	ECC1 (k1-)	1,05	-0,124	0,899
	Auswahl 49			
MCSA (I ₁)	ECC2 (k1-)	1,05	-0,124	0,899
	Auswahl 50			
RZ Spektrum (r, Seg. 4)	SW5	1,083	0,114	0,915
	Auswahl 51			
Spektrum (I ₂ , Seg. 2)	SRA	1,167	-0,018	-0,869
	Auswahl 52			
Spektrum (I ₂ , Seg. 2)	SW1	1,167	-0,018	-0,869
	Auswahl 53			
MCSA (I ₂)	BB2 (k1+)	1,2	-0,164	0,882
	Auswahl 54			
MCSA (I ₂)	ECC1 (k1-)	1,2	-0,164	0,882
	Auswahl 55			
MCSA (I ₂)	ECC2 (k1-)	1,2	-0,164	0,882
	Auswahl 56			
Spektrum (I ₁ , Seg. 2)	SRA	1,217	-0,028	-0,860
	Auswahl 57			
Spektrum (I ₁ , Seg. 2)	SW1	1,217	-0,028	-0,860
	Auswahl 58			
Raumzeiger (LF)	SCH	1,55	0,010	-0,896
	Auswahl 59			
RZ Spektrum (LF, Seg. 4)	N6M	1,8	-0,049	-0,885
	Auswahl 60			
RZ Spektrum (LF, Seg. 2)	N5M	1,817	-0,086	-0,899

Auswahl 61				
RZ Spektrum (LF, Seg. 4)	Wb	1,817	-0,047	-0,894
Auswahl 62				
Raumzeiger (r)	N5M	1,917	-0,027	-0,887
Auswahl 63				
Spektrum (I_1 , Seg. 3)	SRA	2,05	0,282	-0,900
Auswahl 64				
Spektrum (I_1 , Seg. 3)	SW1	2,05	0,282	-0,900
Auswahl 65				
RZ Spektrum (LF, Seg. 4)	SW2	2,567	0,147	-0,894
Auswahl 66				
RZ Spektrum (LF, Seg. 6)	SRA	2,567	-0,104	-0,896
Auswahl 67				
RZ Spektrum (LF, Seg. 6)	SW1	2,567	-0,104	-0,896
Auswahl 68				
Signal (I_2)	N6M	2,783	-0,217	-0,865
Auswahl 69				
Spektrum ($U_{1,2}$, Seg. 4)	SW2	2,817	0,022	0,863
Auswahl 70				
Signal (I_1)	N6M	2,9	-0,331	-0,854
Auswahl 71*				
Raumzeiger (φ)	FF	/	0,016	0,890
MCSA (I_3)	BB2 (k1+)	/	-0,167	0,857
Merkmalsvektor		0,2	/	/
Auswahl 72				
Spektrum ($U_{1,2}$, Seg. 3)	Pos. 1. Spitze	/	0,131	0,892
MCSA (I_3)	ECC1 (k1m)	/	-0,167	0,857
Merkmalsvektor		0,2	/	/
Auswahl 73*				
RZ Spektrum (WF, Seg. 8)	NormSumQuad	/	0,351	0,325
MCSA (I_3)	ECC2 (k1m)	/	-0,167	0,857
Merkmalsvektor		0,2	/	/
Auswahl 74*				
Spektrum (I_2 , Seg. 3)	SRA	/	0,327	-0,876
RZ Spektrum (LF, Seg. 3)	Wb	/	-0,157	-0,872
Merkmalsvektor		0,2	/	/

Auswahl 75*				
Raumzeiger (LF)	FF-SRM	/	0,310	0,759
Spektrum (l_2 , Seg. 4)	SRA	/	0,287	-0,875
Merkmalsvektor		0,05	/	/
Auswahl 76*				
Spektrum (l_2 , Seg. 4)	SW1	/	0,287	-0,875
Spektrum ($U_{1,2}$, Seg. 3)	SRA	/	0,213	0,815
Merkmalsvektor		0,05	/	/
Auswahl 77*				
Spektrum (l_2 , Seg. 3)	SW1	/	0,327	-0,876
Spektrum ($U_{1,2}$, Seg. 3)	SW1	/	0,213	0,815
Merkmalsvektor		0	/	/
Auswahl 78*				
Spektrum (l_1 , Seg. 1)	2. Spitze	/	0,011	0,075
Raumzeiger (r, Seg. 2)	2. Spitze	/	-0,203	-0,867
Merkmalsvektor		0	/	/
Auswahl 79				
Spektrum (l_3 , Seg. 3)	SRA	/	0,341	-0,870
RZ Spektrum (LF, Seg. 3)	N6M	/	-0,179	-0,861
Merkmalsvektor		0,2	/	/
Auswahl 80*				
Signal (l_3)	FF-SRM	/	-0,449	-0,736
Spektrum (l_1 , Seg. 4)	SRA	/	0,285	-0,868
Merkmalsvektor		0,133	/	/
Auswahl 81				
Spektrum (l_1 , Seg. 4)	SW1	/	0,285	-0,868
RZ Spektrum (WF, Seg. 10)	NormSumQuad	/	0,358	0,315
Merkmalsvektor		0,15	/	/
Auswahl 82*				
Raumzeiger (r)	Wb	/	0,245	0,829
RZ Spektrum (r, Seg. 1)	SW3	/	-0,558	0,806
Merkmalsvektor		0,1	/	/
Auswahl 83				
Spektrum (l_2 , Seg. 2)	N6M	/	-0,031	-0,845
Spektrum ($U_{1,2}$, Seg. 3)	SW4	/	0,176	0,770
Merkmalsvektor		0,45	/	/

Auswahl 84				
Spektrum (I_1 , Seg. 2)	N6M	/	-0,023	-0,844
Spektrum ($U_{1,2}$, Seg. 3)	SW2	/	0,159	0,835
Merkmalsvektor		0,317	/	/
Auswahl 85				
Spektrum (I_3 , Seg. 2)	N6M	/	-0,129	-0,845
Spektrum ($U_{1,2}$, Seg. 3)	SW3	/	0,109	0,817
Merkmalsvektor		0,5	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.5: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Störgröße = Last und Baugröße.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)			
			kNN	Last	PV	WV
Auswahl 1*						
Zeiger (r)	MW	/	0,095	-0,125	0,236	0,993
Zeiger (LF)	GRW	/	0,133	-0,123	0,235	0,982
Merkmalsvektor		4,635	/	/	/	
Auswahl 2						
Zeiger (r)	GRW	/	0,095	-0,125	0,236	0,993
Zeiger (LF)	qWM	/	0,132	-0,124	0,234	0,982
Merkmalsvektor		4,753	/	/	/	
Auswahl 3						
Zeiger (r)	QWM	/	0,095	-0,125	0,236	0,993
Zeiger (LF)	WSQ	/	0,132	-0,124	0,234	0,982
Merkmalsvektor		4,646	/	/	/	
Auswahl 4*						
Spektrum (I_1 , Seg. 11)	Pos. 1. Spitze	/	0,086	-0,188	0,221	0,952
MCSA (I_1)	BB2 (k1+)	/	-0,302	0,213	0,362	0,607
Merkmalsvektor		4,635	/	/	/	

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.6: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Winkelversatz; Störgröße = Last und Baugröße.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)			
			kNN	Last	PV	WV
Auswahl 1*						
Zeiger (r)	qMW	/	0,094	0,187	-0,054	0,993
Zeiger (r)	QWM	/	0,095	0,187	-0,054	0,993
Merkmalsvektor		3,772	/	/	/	/
Auswahl 2						
Zeiger (r)	NormSumQuad	/	0,135	0,185	-0,053	0,982
Zeiger (LF)	GRW	/	0,133	0,183	-0,054	0,982
Merkmalsvektor		3,772	/	/	/	/
Auswahl 3						
Zeiger (r)	QS	/	0,135	0,185	-0,053	0,982
Zeiger (LF)	qWM	/	0,131	0,181	-0,056	0,983
Merkmalsvektor		3,865	/	/	/	/
Auswahl 4						
Zeiger (r)	WSQ	/	0,094	0,187	-0,054	0,993
Zeiger (LF)	WSQ	/	0,131	0,181	-0,056	0,983
Merkmalsvektor		3,915	/	/	/	/
Auswahl 5						
Zeiger (r)	MW	/	0,095	0,187	-0,054	0,993
Zeiger (LF)	StadAW	/	0,131	0,181	-0,056	0,983
Merkmalsvektor		3,763	/	/	/	/
Auswahl 6						
Zeiger (r)	GRW	/	0,095	0,187	-0,054	0,993
Zeiger (LF)	QWM	/	0,135	0,184	-0,052	0,982
Merkmalsvektor		4,085	/	/	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.7: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			kNN	Last	PV
Auswahl 1*					
Signal (I_1)	Effektivwert	/	0,962	-0,010	0,001
MCSA (I_1)	BB2 (k_1+)	/	-0,087	0,962	0,619
Merkmalsvektor		0	/	/	/
Auswahl 2*					
Signal (I_1)	WSQ	/	0,962	-0,010	0,001
MCSA (I_1)	ECC1 (k_1-)	/	-0,087	0,962	0,619
Merkmalsvektor		0	/	/	/
Auswahl 3					
Signal (I_1)	StadAW	/	0,962	-0,010	0,001
MCSA (I_1)	ECC2 (k_1-)	/	-0,087	0,962	0,619
Merkmalsvektor		0	/	/	/
Auswahl 4					
Signal (I_3)	Effektivwert	/	0,959	0,035	0,015
MCSA (I_2)	BB2 (k_1+)	/	-0,094	0,965	0,610
Merkmalsvektor		0	/	/	/
Auswahl 5					
Signal (I_3)	NormSumQuad	/	0,958	0,036	0,016
MCSA (I_2)	ECC1 (k_1-)	/	-0,094	0,965	0,610
Merkmalsvektor		0	/	/	/
Auswahl 6					
Signal (I_3)	QS	/	0,958	0,036	0,016
MCSA (I_2)	ECC2 (k_1-)	/	-0,094	0,965	0,610
Merkmalsvektor		0	/	/	/
Auswahl 7					
Signal (I_1)	NormSumQuad	/	0,961	-0,010	0,001
MCSA (I_3)	BB2 (k_1+)	/	-0,098	0,968	0,591
Merkmalsvektor		0	/	/	/

		Auswahl 8			
Signal (l_1)	QS	/	0,961	-0,010	0,001
MCSA (l_3)	ECC1 (k_1-)	/	-0,098	0,968	0,591
Merkmalsvektor		0	/	/	/
		Auswahl 9			
Signal (l_1)	Varianz	/	0,961	-0,010	0,001
MCSA (l_3)	ECC2 (k_1-)	/	-0,098	0,968	0,591
Merkmalsvektor		0	/	/	/
		Auswahl 10*			
Raumzeiger (r)	FF	/	-0,254	-0,396	-0,432
MCSA (l_3)	ECC1 (k_1+)	/	-0,139	0,960	0,576
Merkmalsvektor		0,317	/	/	/
		Auswahl 11*			
Raumzeiger (r)	FF-SRM	/	0,256	0,396	0,431
MCSA (l_3)	ECC2 (k_1+)	/	-0,139	0,960	0,576
Merkmalsvektor		0,317	/	/	/
		Auswahl 12			
MCSA (l_3)	n	/	-0,939	-0,070	-0,065
MCSA (l_3)	BB2 (k_3+)	/	-0,139	0,960	0,576
Merkmalsvektor		0,525	/	/	/
		Auswahl 13*			
MCSA (l_2)	n	/	-0,939	-0,070	-0,064
MCSA (l_2)	BB2 (k_3+)	/	-0,144	0,959	0,576
Merkmalsvektor		0,492	/	/	/
		Auswahl 14*			
Raumzeiger (LF)	GRW	/	0,961	0,014	0,024
MCSA (l_2)	ECC1 (k_1+)	/	-0,143	0,959	0,576
Merkmalsvektor		0,571	/	/	/
		Auswahl 15			
Raumzeiger (LF)	QWM	/	0,961	0,018	0,028
MCSA (l_2)	ECC2 (k_1+)	/	-0,143	0,959	0,576
Merkmalsvektor		0,579	/	/	/
		Auswahl 16			
MCSA (l_1)	n	/	-0,938	-0,070	-0,064
MCSA (l_1)	ECC1 (k_1+)	/	-0,144	0,960	0,568
Merkmalsvektor		0,446	/	/	/

Auswahl 17					
MCSA (I ₁)	ECC2 (k ₁ +) /	-0,144	0,960	0,568	
MCSA (I ₃)	s /	0,947	0,003	0,019	
Merkmalsvektor	0,467	/	/	/	
Auswahl 18					
Signal (I ₃)	QWM (k ₁ +) /	0,958	0,033	0,010	
MCSA (I ₁)	BB2 (k ₃ +) /	-0,145	0,960	0,568	
Merkmalsvektor	0,483	/	/	/	
Auswahl 19*					
MCSA (I ₁)	ECC1 (k ₂ +) /	-0,175	0,890	0,418	
RZ Spektrum (r)	SRA (Seg. 2) /	-0,136	-0,429	-0,436	
Merkmalsvektor	2,683	/	/	/	

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.8: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Parallelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			kNN	Last	PV
Auswahl 1					
Raumzeiger (r)	Mittelwert	/	0,961	0,000	-0,000
Spektrum (I ₁)	Pos. 1. Spitze (Seg. 11)	/	0,521	-0,299	-0,000
Merkmalsvektor		0,092	/	/	/
Auswahl 2*					
Raumzeiger (r)	GRW	/	0,961	0,000	-0,000
Spektrum (I ₃)	Pos. 1. Spitze (Seg. 10)	/	0,577	-0,260	0,000
Merkmalsvektor		0,229	/	/	/
Auswahl 3*					
Raumzeiger (r)	QWM	/	0,961	0,001	0,000
Spektrum (I ₂)	Pos. 1. Spitze (Seg. 9)	/	0,441	-0,381	0,000
Merkmalsvektor		0,775	/	/	/
Auswahl 4					
Raumzeiger (r)	qMW	/	0,961	-0,000	-0,000
Spektrum (I ₃)	Pos. 2. Spitze (Seg. 10)	/	0,509	-0,244	-0,000
Merkmalsvektor		1,908	/	/	/

Auswahl 5*					
Raumzeiger (r)	NormSumQuad	/	0,960	-0,001	-0,000
Spektrum (I_1)	Pos. 1. Spitze (Seg. 10)	/	-0,179	0,435	0,000
Merkmalvektor		1,963	/	/	/
Auswahl 6					
Raumzeiger (r)	QS	/	0,960	-0,001	0,000
Spektrum (I_1)	Pos. 2. Spitze (Seg. 11)	/	0,259	-0,179	-0,000
Merkmalvektor		2,813	/	/	/
Auswahl 7					
Raumzeiger (r)	WSQ	/	0,961	-0,000	0,000
Spektrum (I_2)	Pos. 1. Spitze (Seg. 15)	/	-0,259	0,442	0,000
Merkmalvektor		3,183	/	/	/

* Merkmalvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.9: Auflistung der Merkmalvektoren für den Fall:
Zielgröße = Winkelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			kNN	NN	PV
Auswahl 1*					
Signal (I_2)	Mittelwert	/	0,154	-0,274	-0,482
Signal (I_3)	Wb	/	0,005	-0,970	-0,763
Merkmalvektor		3,696	/	/	/
Auswahl 2*					
Signal (I_3)	N6M	/	-0,166	-0,940	-0,737
Signal ($U_{1,2}$)	FF	/	0,397	0,846	0,842
Merkmalvektor		1,738	/	/	/
Auswahl 3					
Raumzeiger (WF)	Sch	/	0,214	0,272	0,168
Raumzeiger (LF)	Med	/	0,477	-0,754	-0,712
Merkmalvektor		7,908	/	/	/

* Merkmalvektor für weitere Untersuchungen vorgemerkt.

Tabelle 8.10: Auflistung der Merkmalsvektoren für den Fall:
Zielgröße = Winkelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.

Merkmalsextraktor	Kennzahl	Fehlerrate (%)	Korrelation (1)		
			kNN	Last	PV
Auswahl 1*					
Raumzeiger (r)	qWM	/	0,961	0,008	-0,018
Spektrum (I ₁ , Seg. 11)	Pos. 1. Spitze	/	0,560	0,412	-0,425
Merkmalsvektor		0,304	/	/	/
Auswahl 2*					
Raumzeiger (r)	NormSumQuad	/	0,960	0,009	-0,018
Spektrum (I ₃ , Seg. 10)	Pos. 1. Spitze	/	0,640	0,405	-0,398
Merkmalsvektor		0,658	/	/	/
Auswahl 3					
Raumzeiger (r)	QS	/	0,960	0,009	-0,018
Spektrum (I ₂ , Seg. 9)	Pos. 1. Spitze	/	0,475	0,384	-0,459
Merkmalsvektor		1,508	/	/	/
Auswahl 4					
Raumzeiger (r)	WSQ	/	0,961	0,008	-0,018
Spektrum (I ₃ , Seg. 10)	Pos. 2. Spitze	/	0,553	0,354	-0,346
Merkmalsvektor		2,263	/	/	/
Auswahl 5*					
Raumzeiger (r)	MW	/	0,961	0,009	-0,018
Spektrum (I ₁ , Seg. 10)	Pos. 1. Spitze	/	-0,182	-0,474	0,573
Merkmalsvektor		2,433	/	/	/
Auswahl 6					
Raumzeiger (r)	GRW	/	0,961	0,009	-0,018
Spektrum (I ₁ , Seg. 11)	Pos. 2. Spitze	/	0,319	0,288	-0,300
Merkmalsvektor		3,412	/	/	/
Auswahl 7					
Raumzeiger (r)	FF	/	-0,077	-0,450	0,059
Spektrum (I ₂ , Seg. 15)	Pos. 2. Spitze	/	-0,248	-0,463	0,554
Merkmalsvektor		5,563	/	/	/

* Merkmalsvektor für weitere Untersuchungen vorgemerkt.

8.2 Kennzahlen

$$MW = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{Mittelwert} \quad (8.1)$$

$$qMW = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2} \quad \text{quadratischer Mittelwert} \quad (8.2)$$

$$NormSumQuad = \frac{1}{N} \sum_{i=1}^N (x_i)^2 \quad \text{normierte Summe der Quadrate} \quad (8.3)$$

$$Median = x_{m+1} \quad \text{Median für } n = 2m + 1 \quad (8.4)$$

$$Median = \frac{1}{2}(x_m + x_{m+1}) \quad \text{Median für } n = 2m \quad (8.5)$$

$$SW = x_{\max} - x_{\min} \quad \text{Spannweite} \quad (8.6)$$

$$QS = \sum_{i=1}^N (|x_i|)^2 \quad \text{Quadratsumme} \quad (8.7)$$

$$WSQ = \sqrt{\sum_{i=1}^N (|x_i|)^2} \quad \text{Wurzelsumme der Quadrate} \quad (8.8)$$

$$T = \frac{\max|x_i|}{\left(\frac{1}{N} \sum_{i=0}^N |x_i|^{\frac{1}{2}}\right)^2} \quad \text{Toleranzindex} \quad (8.9)$$

$$StdAW = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad \text{Standardabweichung} \quad (8.10)$$

$$Var = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad \text{Varianz} \quad (8.11)$$

$$S = \frac{\sum [(x_i - \bar{x})^3]}{(X_{SRM})^3} \quad \text{Schiefe} \quad (8.12)$$

$$Wb = \frac{\sum [(x_i - \bar{x})^4]}{(X_{SRM})^4} \quad \text{Wölbung} \quad (8.13)$$

$$N5M = \frac{\sum [(x_i - \bar{x})^5]}{(X_{SRM})^5} \quad \text{normalisiertes 5. Moment} \quad (8.14)$$

$$N6M = \frac{\sum [(x_i - \bar{x})^6]}{(X_{SRM})^6} \quad \text{normalisiertes 6. Moment} \quad (8.15)$$

$$QWM = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2 \quad \text{Quadratwurzel Mittelwert} \quad (8.16)$$

$$GRW = \frac{1}{N} \sum_{i=1}^N |x_i| \quad \text{Gleichrichtwert} \quad (8.17)$$

$$FF = \frac{x_{\text{Eff}}}{|x|} \quad \text{Formfaktor} \quad (8.18)$$

$$FF - SRM = \frac{U_{SRM}}{U_{GIR}} \quad \text{SRM - Formfaktor} \quad (8.19)$$

$$I = \frac{|X_{\text{max}}|}{|\bar{X}|} \quad \text{Impulsfaktor} \quad (8.20)$$

$$SF = \frac{|X_{\text{max}}|}{X_{\text{Eff}}} \quad \text{Scheitelfaktor} \quad (8.21)$$

$$BF = \frac{|X_{\text{max}}|}{X_{SRM}} \quad \text{Breitengradfaktor} \quad (8.22)$$

$$SRV = \left(\frac{|X|_{\text{max}}}{X_{\text{eff}}} \right)^2 \quad \text{Spitzenwert zu mittlerer Leistung} \quad (8.23)$$

$$SRA = |X|_{\text{max}} - X_{\text{eff}} \quad \text{Signal - Rausch - Abstand} \quad (8.24)$$

$$PSn = \left(\frac{X_{\text{max}}}{N} \right) \cdot 100 \quad \text{Position des n - ten Spitzenwerts} \quad (8.25)$$

$$SPn = \max_n(x) \quad \text{n - ter Spitzenwert} \quad (8.26)$$

$$PSH = \left[\frac{kR}{p} (1-s) \pm \nu \right] \cdot f_0 \quad \text{Nutschlitzharmonische} \quad (8.27)$$

$$ECC1 = \left[1 \pm \frac{k}{p} \cdot (1-s) \right] \cdot f_0 \quad \text{Harmonische der Exzentrizität} \quad (8.28)$$

1. Gruppe

$$ECC2 = \left[\left(R \pm n_d(1-s) \frac{k}{p} \pm \nu \right) \right] \cdot f_0 \quad (8.29)$$

Harmonische der Exzentrizität
2. Gruppe

$$BB1 = [1 \pm 2 \cdot k \cdot s] \cdot f_0 \quad (8.30)$$

Harmonische des gebrochenen
Rotorstabs 1. Gruppe

$$BB2 = \left[\frac{k}{p}(1-s) \pm s \right] \cdot f_0 \quad (8.31)$$

Harmonische des gebrochenen
Rotorstabs 2. Gruppe

Literatur

- [1] B. Leidinger, *Wertorientierte Instandhaltung, Kosten senken, Verfügbarkeit erhalten* (SpringerLink), 2. Aufl. 2017. Wiesbaden: Springer Gabler, 2017, 14668 S., ISBN: 9783658178550.
- [2] M. Strunz, *Instandhaltung, Grundlagen - Strategien - Werkstätten*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, 1713 S., ISBN: 9783642273902.
- [3] M. Schenk, Hrsg., *Instandhaltung technischer Systeme, Methoden und Werkzeuge zur Gewährleistung eines sicheren und wirtschaftlichen Anlagenbetriebs*. Berlin ; Springer-Verlag, 2010, 383 S., Includes index., ISBN: 9783642039492.
- [4] M. Salah, S. B. Salem, W. Touti, K. Bacha und A. Chaari, „Stator current signature analysis to monitor shaft misalignment in induction motor speed-controlled,“ in *2017 International Conference on Control, Automation and Diagnosis (ICCAD)*, IEEE, Jan. 2017. DOI: 10.1109/cadiag.2017.8075685. Adresse: <https://ieeexplore.ieee.org/document/8075685>.
- [5] J. D. Martinez-Morales, E. R. Palacios-Hernandez und D. U. Campos-Delgado, „Multiple-fault diagnosis in induction motors through support vector machine classification at variable operating conditions,“ *Electrical Engineering*, Jg. 100, Nr. 1, S. 59–73, Nov. 2016. DOI: 10.1007/s00202-016-0487-x. Adresse: <https://link.springer.com/article/10.1007/s00202-016-0487-x>.
- [6] S. T. Kandukuri, H. V. Khang und K. G. Robbsersmyr, „Multi-Component Fault Detection in Wind Turbine Pitch Systems Using Extended Park’s Vector and Deep Autoencoder Feature Learning,“ in *2018 21st International Conference on Electrical Machines and Systems (ICEMS)*, IEEE, Okt. 2018. DOI: 10.23919/icems.2018.8549293. Adresse: <https://ieeexplore.ieee.org/document/8549293>.
- [7] M. Heydarzadeh, S. H. Kia, M. Nourani, H. Henao und G.-A. Capolino, „Gear fault diagnosis using discrete wavelet transform and deep neural networks,“ in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, IEEE, Okt. 2016. DOI: 10.1109/iecon.2016.7793549. Adresse: <https://ieeexplore.ieee.org/document/7793549>.

- [8] E. Martinez-Montes, L. Jimenez-Chillaron, J. Gilabert-Marzal, J. Antonino-Daviu und A. Quijano-Lopez, „Evaluation of the Detectability of Bearing Faults at Different Load Levels Through the Analysis of Stator Currents,“ in *2018 XIII International Conference on Electrical Machines (ICEM)*, IEEE, Sep. 2018. DOI: 10.1109/icelmach.2018.8507224. Adresse: <https://ieeexplore.ieee.org/document/8507224>.
- [9] R. R. Obaid und T. G. Habetler, „Effect of load on detecting mechanical faults in small induction motors,“ in *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003.*, IEEE, Okt. 2003. DOI: 10.1109/demped.2003.1234591. Adresse: <https://ieeexplore.ieee.org/document/1234591>.
- [10] V. Becker, T. Schwamm, S. Urschel und J. A. Antonino-Daviu, „Detection of Rotor and Impeller Faults in Wet-rotor Pumps,“ in *2020 International Conference on Electrical Machines (ICEM)*, IEEE, Aug. 2020. DOI: 10.1109/icem49940.2020.9270767. Adresse: <https://ieeexplore.ieee.org/document/9270767>.
- [11] R. F. Walliser und C. F. Landy, „The role of interbar currents in squirrel cage motors having broken rotor bars,“ *Transactions of the South African Institute of Electrical Engineers (Volume: 83, Issue: 2)*, Juli 1992. Adresse: <https://ieeexplore.ieee.org/document/9486210/authors#authors>.
- [12] G. B. Kliman, R. A. Koegl, J. Stein, R. D. Endicott und M. W. Madden, „Noninvasive detection of broken rotor bars in operating induction motors,“ *IEEE Transactions on Energy Conversion*, Jg. 3, Nr. 4, S. 873–879, 1988. DOI: 10.1109/60.9364. Adresse: <https://ieeexplore.ieee.org/document/9364>.
- [13] C. Kral, A. Haumer und C. Grabner, „Modeling and Simulation of Broken Rotor Bars in Squirrel Cage Induction Machines,“ in *World Congress on Engineering, WCE 2009*, S. I. Ao, Hrsg., Ser. Lecture notes in engineering and computer science, Bd. Vol. 1, Hong Kong: IAENG, 2009, ISBN: 9789881701251. Adresse: https://www.iaeng.org/publication/WCE2009/WCE2009_pp435-440.pdf.
- [14] T. Aroui, Y. Koubaa und A. Toumi, „Modeling and Diagnostics of Inductions Machines under Rotor Failures,“ *Automatic Control and System Engineering ACSE*, Jg. 7, S. 9–18, Nov. 2007. Adresse: file:///home/sebastian/Downloads/Modeling_and_diagnostics_of_inductions_machines_un.pdf.
- [15] G. H. Müller und C. F. Landy, „Detection of broken rotor bars part I - New theory,“ *Transactions of the South African Institute of Electrical Engineers, Volume: 94, Issue: 1*, März 2003. Adresse: <https://ieeexplore.ieee.org/document/9487941/authors#authors>.

- [16] J. R. Cameron, W. T. Thomson und A. B. Dow, „Vibration and current monitoring for detecting airgap eccentricity in large induction motors,“ *IEE Proceedings B Electric Power Applications*, Jg. 133, Nr. 3, S. 155, 1986. DOI: 10.1049/ip-b.1986.0022. Adresse: <https://digital-library.theiet.org/content/journals/10.1049/ip-b.1986.0022>.
- [17] C. Kral, A. Haumer und C. Grabner, „Broken Rotor Bars in Squirrel Cage Induction Machines – Modeling and Simulation,“ in *Lecture Notes in Electrical Engineering*, Springer Netherlands, 2010, S. 81–91. DOI: 10.1007/978-90-481-8776-8_8. Adresse: https://www.researchgate.net/publication/225241509_Broken_Rotor_Bars_in_Squirrel_Cage_Induction_Machines_-_Modeling_and_Simulation.
- [18] S. H. Kia, M. H. Marzebali, H. Henao, G.-A. Capolino und J. Faiz, „Simulation and experimental analyses of planetary gear tooth defect using electrical and mechanical signatures of wound rotor induction generators,“ in *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, IEEE, Aug. 2017. DOI: 10.1109/demped.2017.8062367. Adresse: <https://ieeexplore.ieee.org/document/8062367>.
- [19] P. Popaleny und J. Antonino-Daviu, „Electric Motors Condition Monitoring Using Currents and Vibrations Analyses,“ in *2018 XIII International Conference on Electrical Machines (ICEM)*, IEEE, Sep. 2018. DOI: 10.1109/icelmach.2018.8506709. Adresse: <https://ieeexplore.ieee.org/document/8506709>.
- [20] S. Perovic, „Diagnosis of pump faults and flow regimes,“ Diss., University of Sussex, 2000. Adresse: <https://ethos.bl.uk/OrderDetails.do?uin=uk.bl.ethos.288827>.
- [21] L. Wu, T. G. Habetler und R. G. Harley, „A Review of Separating Mechanical Load Effects from Rotor Faults Detection in Induction Motors,“ in *2007 IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, IEEE, Sep. 2007. DOI: 10.1109/demped.2007.4393098. Adresse: <https://ieeexplore.ieee.org/document/4393098>.
- [22] M. M. Tahir, A. Hussain, S. Badshah, A. Q. Khan und N. Iqbal, „Classification of unbalance and misalignment faults in rotor using multi-axis time domain features,“ in *2016 International Conference on Emerging Technologies (ICET)*, IEEE, Okt. 2016. DOI: 10.1109/icet.2016.7813273. Adresse: <https://ieeexplore.ieee.org/document/7813273>.

- [23] J. M. Bossio, G. R. Bossio und C. H. D. Angelo, „Angular misalignment in induction motors with flexible coupling,“ in *2009 35th Annual Conference of IEEE Industrial Electronics*, IEEE, Nov. 2009. DOI: 10.1109/iecon.2009.5414696. Adresse: <https://ieeexplore.ieee.org/document/5414696>.
- [24] D. Kostic-Perovic, M. Arkan und P. Unsworth, „Induction motor fault detection by space vector angular fluctuation,“ in *Conference Record of the 2000 IEEE Industry Applications Conference. Thirty-Fifth IAS Annual Meeting and World Conference on Industrial Applications of Electrical Energy (Cat. No.00CH37129)*, IEEE, 2000. DOI: 10.1109/ias.2000.881140. Adresse: <https://ieeexplore.ieee.org/document/881140>.
- [25] L. Eren und M. J. Devaney, „Effect of current resampling in Motor Current Signature Analysis,“ in *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, IEEE, Mai 2013. DOI: 10.1109/i2mtc.2013.6555437. Adresse: <https://ieeexplore.ieee.org/document/6555437>.
- [26] J. A. Antonino-Daviu, A. Quijano-Lopez, M. Rubbiolo und V. Climente-Alarcon, „Advanced Analysis of Motor Currents for the Diagnosis of the Rotor Condition in Electric Motors Operating in Mining Facilities,“ *IEEE Transactions on Industry Applications*, Jg. 54, Nr. 4, S. 3934–3942, Juli 2018. DOI: 10.1109/tia.2018.2818671. Adresse: <https://ieeexplore.ieee.org/document/8322315>.
- [27] J. Antonino-Daviu und P. Popaleny, „Detection of Induction Motor Coupling Unbalanced and Misalignment via Advanced Transient Current Signature Analysis,“ in *2018 XIII International Conference on Electrical Machines (ICEM)*, IEEE, Sep. 2018. DOI: 10.1109/icelmach.2018.8506949.
- [28] T. Goktas, M. Arkan und V. Gurusamy, „A Comparative Study of Current, Vibration and Stray Magnetic Flux Based Detection for Parallel Misalignment Fault in Induction Motors,“ in *2021 IEEE 13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, IEEE, Aug. 2021. DOI: 10.1109/sdemped51010.2021.9605507. Adresse: <https://ieeexplore.ieee.org/document/9605507>.
- [29] C. Kumar, G. Krishnan und S. Sarangi, „Experimental investigation on misalignment fault detection in induction motors using current and vibration signature analysis,“ in *2015 International Conference on Futuristic Trends on Computational Analysis and Knowledge Management (ABLAZE)*, IEEE, Feb. 2015. DOI: 10.1109/ablaze.2015.7154971.

- [30] A. G. Nath, S. S. Udmale und S. K. Singh, „Role of artificial intelligence in rotor fault diagnosis: a comprehensive review,“ *Artificial Intelligence Review*, Jg. 54, Nr. 4, S. 2609–2668, Sep. 2020. DOI: 10.1007/s10462-020-09910-w. Adresse: <https://link.springer.com/article/10.1007/s10462-020-09910-w>.
- [31] J. S. Rapur und R. Tiwari, „Automation of multi-fault diagnosing of centrifugal pumps using multi-class support vector machine with vibration and motor current signals in frequency domain,“ *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, Jg. 40, Nr. 6, Mai 2018. DOI: 10.1007/s40430-018-1202-9.
- [32] S. Haroun, A. N. Seghir, S. Touati und S. Hamdani, „Misalignment fault detection and diagnosis using AR model of torque signal,“ in *2015 IEEE 10th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, IEEE, Sep. 2015. DOI: 10.1109/demped.2015.7303709. Adresse: <https://ieeexplore.ieee.org/document/7303709>.
- [33] C. Janiesch, P. Zschech und K. Heinrich, „Machine learning and deep learning,“ en, *Electronic Markets*, Jg. 31, Nr. 3, S. 685–695, Sep. 2021, ISSN: 1422-8890. DOI: 10.1007/s12525-021-00475-2. Adresse: <https://doi.org/10.1007/s12525-021-00475-2> (besucht am 03.02.2025).
- [34] P. Kumar und A. S. Hati, „Convolutional neural network with batch normalisation for fault detection in squirrel cage induction motor,“ *IET Electric Power Applications*, Jg. 15, Nr. 1, S. 39–50, Dez. 2020. DOI: 10.1049/elp2.12005. Adresse: <https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/elp2.12005>.
- [35] S.-Y. Shao, W.-J. Sun, R.-Q. Yan, P. Wang und R. X. Gao, „A Deep Learning Approach for Fault Diagnosis of Induction Motors in Manufacturing,“ *Chinese Journal of Mechanical Engineering*, Jg. 30, Nr. 6, S. 1347–1356, Okt. 2017. DOI: 10.1007/s10033-017-0189-y. Adresse: <https://link.springer.com/article/10.1007/s10033-017-0189-y?>.
- [36] U. E. Akpudo und J.-W. Hur, „Towards bearing failure prognostics: a practical comparison between data-driven methods for industrial applications,“ *Journal of Mechanical Science and Technology*, Jg. 34, Nr. 10, S. 4161–4172, Okt. 2020. DOI: 10.1007/s12206-020-0908-7. Adresse: https://link.springer.com/article/10.1007/s12206-020-0908-7?error=cookies_not_supported&code=00c1ba8a-24e7-46bd-911f-9504c83c6b11.
- [37] C. N. Okwuosa, U. E. Akpudo und J.-W. Hur, „A Cost-Efficient MCSA-Based Fault Diagnostic Framework for SCIM at Low-Load Conditions,“ *Algorithms*, Jg. 15, Nr. 6, S. 212, Juni 2022. DOI: 10.3390/a15060212. Adresse: <https://www.mdpi.com/1999-4893/15/6/212>.

- [38] F. Calabrese, A. Regattieri, M. Bortolini, F. G. Galizia und L. Visentini, „Feature-Based Multi-Class Classification and Novelty Detection for Fault Diagnosis of Industrial Machinery,“ *Applied Sciences*, Jg. 11, Nr. 20, S. 9580, Okt. 2021. DOI: 10.3390/app11209580. Adresse: <https://www.mdpi.com/2076-3417/11/20/9580>.
- [39] M. J. Hasan, M. Sohaib und J.-M. Kim, „A Multitask-Aided Transfer Learning-Based Diagnostic Framework for Bearings under Inconsistent Working Conditions,“ *Sensors*, Jg. 20, Nr. 24, S. 7205, Dez. 2020. DOI: 10.3390/s20247205. Adresse: <https://www.mdpi.com/1424-8220/20/24/7205>.
- [40] A. K. Sinha, A. S. Hati, M. Benbouzid und P. Chakrabarti, „ANN-Based Pattern Recognition for Induction Motor Broken Rotor Bar Monitoring under Supply Frequency Regulation,“ *Machines*, Jg. 9, Nr. 5, S. 87, Apr. 2021. DOI: 10.3390/machines9050087. Adresse: <https://www.mdpi.com/2075-1702/9/5/87>.
- [41] U. Fayyad, G. Piatetsky-Shapiro und P. Smyth, „Knowledge Discovery and Data Mining: Towards a Unifying Framework,“ in *Second International Conference on Knowledge Discovery and Data Mining*, 1996. Adresse: <https://aaai.org/papers/014-knowledge-discovery-and-data-mining-towards-a-unifying-framework/>.
- [42] D. Sacha, A. Stoffel, F. Stoffel, B. C. Kwon, G. Ellis und D. A. Keim, „Knowledge Generation Model for Visual Analytics,“ *IEEE Transactions on Visualization and Computer Graphics*, Jg. 20, Nr. 12, S. 1604–1613, Dez. 2014. DOI: 10.1109/tvcg.2014.2346481. Adresse: <https://ieeexplore.ieee.org/document/6875967>.
- [43] Q. Luo, „Advancing Knowledge Discovery and Data Mining,“ in *First International Workshop on Knowledge Discovery and Data Mining (WKDD 2008)*, IEEE, Jan. 2008. DOI: 10.1109/wkdd.2008.153. Adresse: <https://ieeexplore.ieee.org/document/4470338>.
- [44] Q. Chen, C. Chen und X. Chen, „An Intelligent Knowledge Discovery System with a Novel Knowledge Acquisition Methodology,“ in *Fourth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD 2007)*, IEEE, 2007. DOI: 10.1109/fskd.2007.168. Adresse: <https://ieeexplore.ieee.org/document/4406405>.
- [45] S. Bold und S. Urschel, „Feature Identification for Diagnosing Misalignment under the Influence of Parameter Variation,“ in *2022 International Conference on Electrical Machines (ICEM)*, IEEE, Sep. 2022. DOI: 10.1109/icem51905.2022.9910920. Adresse: <https://ieeexplore.ieee.org/document/9910920>.
- [46] S. Bold und S. Urschel, „A Knowledge Discovery Process Extended to Experimental Data for the Identification of Motor Misalignment Patterns,“ *Machines*, Jg. 11, Nr. 8, S. 827, Aug. 2023. DOI: 10.3390/machines11080827.

- [47] C. Fuchs, S. Klein, J. Schauer, A. Schütze und T. Schneider, „Eine Methode zur erklärbaren Merkmalsextraktion aus dem Zeit- und Frequenzbereich für Condition Monitoring,“ in *22. GMA/ITG – Fachtagung Sensoren und Messsysteme 2024*, AMA Service GmbH, Von-Münchhausen-Str. 49, 31515 Wunstorf, 2024. DOI: 10.5162/sensoren2024/p36. Adresse: <https://www.ama-science.org/proceedings/details/5009>.
- [48] G. Piatetsky-shapiro und C. J. Matheus, „The Interestingness of Deviations,“ in *Workshop on Knowledge Discovery in Databases*, 1994.
- [49] R. McDonald und B. Kovalerchuk, „Lossless Visual Knowledge Discovery in High Dimensional Data with Elliptic Paired Coordinates,“ in *2020 24th International Conference Information Visualisation (IV)*, IEEE, Sep. 2020. DOI: 10.1109/iv51561.2020.00053. Adresse: <https://ieeexplore.ieee.org/document/9373206>.
- [50] P. Dymora, M. Mazurek und S. Bomba, „A Comparative Analysis of Selected Predictive Algorithms in Control of Machine Processes,“ *Energies*, Jg. 15, Nr. 5, S. 1895, März 2022. DOI: 10.3390/en15051895. Adresse: <https://www.mdpi.com/1996-1073/15/5/1895>.
- [51] N. A. Mahoto, A. Shaikh, M. S. A. Reshan, M. A. Memon und A. Sulaiman, „Knowledge Discovery from Healthcare Electronic Records for Sustainable Environment,“ *Sustainability*, Jg. 13, Nr. 16, S. 8900, Aug. 2021. DOI: 10.3390/su13168900. Adresse: <https://www.mdpi.com/2071-1050/13/16/8900>.
- [52] S. Visalakshi und V. Radha, „A literature review of feature selection techniques and applications: Review of feature selection in data mining,“ in *2014 IEEE International Conference on Computational Intelligence and Computing Research*, IEEE, Sep. 2015. DOI: 10.1109/iccic.2014.7238499. Adresse: <https://ieeexplore.ieee.org/document/7238499>.
- [53] U. M. Fayyad, G. Piatetsky-Shapiro und P. Smyth, „From Data Mining to Knowledge Discovery in Databases,“ *AI Magazine*, Jg. 17, Nr. 3, S. 37–54, 1996. DOI: 10.1609/aimag.v17i3.1230. Adresse: <https://ojs.aaai.org/aimagazine/index.php/aimagazine/article/view/1230>.
- [54] A. Kaur, K. Guleria und N. K. Trivedi, „Feature Selection in Machine Learning: Methods and Comparison,“ in *2021 International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, IEEE, März 2021. DOI: 10.1109/icacite51222.2021.9404623. Adresse: <https://ieeexplore.ieee.org/document/9404623>.

- [55] N. Rachburee und W. Punlumjeak, „A comparison of feature selection approach between greedy, IG-ratio, Chi-square, and mRMR in educational mining,“ in *2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE)*, IEEE, Okt. 2015. DOI: 10.1109/iciteed.2015.7408983. Adresse: <https://ieeexplore.ieee.org/document/7408983>.
- [56] G. S. Thejas, R. Garg, S. S. Iyengar, N. R. Sunitha, P. Badrinath und S. Chennupati, „Metric and Accuracy Ranked Feature Inclusion: Hybrids of Filter and Wrapper Feature Selection Approaches,“ *IEEE Access*, Jg. 9, S. 128 687–128 701, 2021. DOI: 10.1109/access.2021.3112169. Adresse: <https://ieeexplore.ieee.org/document/9536707>.
- [57] R. K. Bania, „Survey on Feature Selection for Data Reduction,“ *International Journal of Computer Applications*, Jg. 94, Nr. 18, S. 1–7, Mai 2014, ISSN: 0975-8887. DOI: 10.5120/16456-2390.
- [58] B. R. Prasad, U. K. Bendale und S. Agarwal, „Distributed information gain theoretic feature selector using spark,“ in *2016 11th International Conference on Industrial and Information Systems (ICIIS)*, IEEE, Dez. 2016. DOI: 10.1109/iciinfs.2016.8263049. Adresse: <https://ieeexplore.ieee.org/document/8263049>.
- [59] S. F. Crone und N. Kourentzes, „Feature selection for time series prediction – A combined filter and wrapper approach for neural networks,“ *Neurocomputing*, Jg. 73, Nr. 10-12, S. 1923–1936, Juni 2010. DOI: 10.1016/j.neucom.2010.01.017. Adresse: <https://www.sciencedirect.com/science/article/abs/pii/S0925231210000974?via=ihub>.
- [60] R. Wald, T. Khoshgoftaar und A. Napolitano, „Comparison of Stability for Different Families of Filter-Based and Wrapper-Based Feature Selection,“ in *2013 12th International Conference on Machine Learning and Applications*, IEEE, Dez. 2013. DOI: 10.1109/icmla.2013.162. Adresse: <https://ieeexplore.ieee.org/document/6786153>.
- [61] A. Colorni, M. Dorigo, V. Maniezzo, F. J. Varela und P. E. Bourguine, „Distributed Optimization by Ant Colonies,“ in *EUROPEAN CONFERENCE ON ARTIFICIAL LIFE*, 1992. Adresse: <http://faculty.washington.edu/paymana/swarm/colorni92-ecal.pdf>.
- [62] M. Dorigo, V. Maniezzo und A. Colorni, „Ant system: optimization by a colony of cooperating agents,“ *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, Jg. 26, Nr. 1, S. 29–41, Feb. 1996. DOI: 10.1109/3477.484436. Adresse: <https://ieeexplore.ieee.org/document/484436/keywords#keywords>.

- [63] S. Subbotin und A. Oleynik, „Modifications of Ant Colony Optimization Method for Feature Selection,“ in *2007 9th International Conference - The Experience of Designing and Applications of CAD Systems in Microelectronics*, IEEE, Feb. 2007. DOI: 10.1109/cadsm.2007.4297628. Adresse: <https://ieeexplore.ieee.org/document/4297628/keywords#keywords>.
- [64] Z. Yang und J. Ren, „An Effective Two-Stage Feature Selection Method with Parameters Optimized by Simulated Annealing Algorithm,“ in *2018 5th International Conference on Information, Cybernetics, and Computational Social Systems (IC-CSS)*, IEEE, Aug. 2018. DOI: 10.1109/iccss.2018.8572468. Adresse: <https://ieeexplore.ieee.org/document/8572468/keywords#keywords>.
- [65] W. Ertel, *Grundkurs Künstliche Intelligenz*. Springer Fachmedien Wiesbaden, 2021. DOI: 10.1007/978-3-658-32075-1.
- [66] T. A. Runkler, *Data Mining, Methoden und Algorithmen intelligenter Datenanalyse* (Springer eBook Collection). Wiesbaden: Vieweg+Teubner, 2010, 16572 S., ISBN: 9783834893536.
- [67] H. Ellouzi, M. B. Ayed und H. Ltifi, „Modeling of distributed visual knowledge discovery from data process,“ in *2017 12th International Conference on Intelligent Systems and Knowledge Engineering (ISKE)*, IEEE, Nov. 2017. DOI: 10.1109/iske.2017.8258791. Adresse: <https://ieeexplore.ieee.org/document/8258791>.
- [68] M. Bastuck, T. Baur und A. Schütze, „DAV3E – a MATLAB toolbox for multivariate sensor data evaluation,“ *Journal of Sensors and Sensor Systems*, Jg. 7, Nr. 2, S. 489–506, Sep. 2018, ISSN: 2194-878X. DOI: 10.5194/jsss-7-489-2018. Adresse: <https://jsss.copernicus.org/articles/7/489/2018/>.
- [69] I. Guyon und A. Elisseeff, „An introduction to variable and feature selection,“ *The Journal of Machine Learning Research*, Jg. 3, Nr. null, S. 1157–1182, 1. März 2023, ISSN: 1532-4435. Adresse: <https://dl.acm.org/doi/10.5555/944919.944968>.
- [70] A. Schütze, „Multisensorsignalverarbeitung,“ Vorlesungsskript Universität des Saarlandes, Naturwissenschaftlich-Technische Fakultät, Saarbrücken, 2022.
- [71] O. Buchtala, M. Klimek und B. Sick, „Evolutionary Optimization of Radial Basis Function Classifiers for Data Mining Applications,“ *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, Jg. 35, Nr. 5, S. 928–947, Okt. 2005, ISSN: 1083-4419. DOI: 10.1109/tsmcb.2005.847743. Adresse: <https://ieeexplore.ieee.org/document/1510769>.

- [72] M. Trabs, *Statistik und maschinelles Lernen, Eine mathematische Einführung in klassische und moderne Methoden*, 1. Aufl. 2021, M. Jirak, K. Krenz und M. Reiß, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2021, 1263 S., ISBN: 9783662629383. Adresse: https://link.springer.com/chapter/10.1007/978-3-662-62938-3_5.
- [73] C. E. Shannon, „A mathematical theory of communication,“ *Bell Syst. Tech. J.*, Jg. 27, S. 623–656, 1948. Adresse: <https://people.math.harvard.edu/~ctm/home/text/others/shannon/entropy/entropy.pdf>.
- [74] K. H. Quah und C. Quek, „MCES: A Novel Monte Carlo Evaluative Selection Approach for Objective Feature Selections,“ *IEEE Transactions on Neural Networks*, Jg. 18, Nr. 2, S. 431–448, März 2007. DOI: 10.1109/tnn.2006.887555. Adresse: <https://ieeexplore.ieee.org/document/4118276>.
- [75] N. J. Helwig, *Zustandsbewertung industrieller Prozesse mittels multivariater Sensordatenanalyse am Beispiel hydraulischer und elektromechanischer Antriebssysteme* (Aktuelle Berichte aus der Mikrosystemtechnik - Recent Developments in MEMS 30), 1. Aufl. Herzogenrath: Shaker, 2019, 180 S., ISBN: 9783844064940.
- [76] S. Klein, T. Schneider und A. Schütze, „Zustandsüberwachung in der Automatisierungstechnik mittels maschinellem Lernen,“ in *Tagungsband*, AMA Service GmbH, Von-Münchhausen-Str. 49, 31515 Wunstorf, 2019, S. 366–372. DOI: 10.5162/sensoren2019/4.4.1.
- [77] S. L. Hahn, *Hilbert transforms in signal processing* (The Artech House signal processing library). Boston, Mass. [u.a.]: Artech House, 1996, 442 S., ISBN: 0890068860.
- [78] P. Konar, S. Bhawal, M. Saha, J. Sil und P. Chattopadhyay, „Rough set based multi-class fault diagnosis of induction motor using Hilbert Transform,“ in *2012 International Conference on Communications, Devices and Intelligent Systems (CODIS)*, IEEE, Dez. 2012. DOI: 10.1109/codis.2012.6422207. Adresse: <https://ieeexplore.ieee.org/document/6422207>.
- [79] A. Medoued, A. Lebaroud und D. Sayad, „Application of Hilbert transform to fault detection in electric machines,“ *Advances in Difference Equations*, Jg. 2013, Nr. 1, Jan. 2013, ISSN: 1687-1847. DOI: 10.1186/1687-1847-2013-2. Adresse: <https://advancesincontinuousanddiscretemodels.springeropen.com/articles/10.1186/1687-1847-2013-2>.
- [80] J. Bergh, *Wavelets mit Anwendungen in Signal- und Bildverarbeitung* (Masterclass), M. Stern, F. Ekstedt und M. Lindberg, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, 1207 S., ISBN: 9783540490128.

- [81] M. V. Wickerhauser, *Adaptive Wavelet-Analysis, Theorie und Software* (Vieweg-Lehrbuch Mathematik), K. Jetter, Hrsg. Braunschweig: Vieweg, 1996, 440 S., Hier auch später erschienene, unveränderte Nachdrucke, ISBN: 3528066881.
- [82] C. Blatter, *Wavelets - Eine Einführung* (Advanced Lectures in Mathematics). Wiesbaden: Vieweg+Teubner Verlag, 1998, 178 S., ISBN: 9783322968876.
- [83] W. Bäni, *Wavelets, Eine Einführung für Ingenieure*. München: Oldenbourg, 2002, 264 S., ISBN: 3486254278.
- [84] H. Yang, G. Li, J. He, L. Wang und X. Nie, „Health condition evaluation method for motorized spindle on the basis of optimised VMD and GMM-HMM,“ *The International Journal of Advanced Manufacturing Technology*, Jg. 124, Nr. 11–12, S. 4465–4477, Okt. 2022, ISSN: 1433-3015. DOI: 10.1007/s00170-022-10202-6. Adresse: <https://link.springer.com/article/10.1007/s00170-022-10202-6>.
- [85] A. Bellini, F. Filippetti, C. Tassoni und G.-A. Capolino, „Advances in Diagnostic Techniques for Induction Machines,“ *IEEE Transactions on Industrial Electronics*, Jg. 55, Nr. 12, S. 4109–4126, Dez. 2008. DOI: 10.1109/tie.2008.2007527. Adresse: <https://ieeexplore.ieee.org/document/4663821>.
- [86] S. A. Alhashmi, „Detection and Diagnosis of Cavitation in Centrifugal Pumps,“ Diss., University of Manchester, 2005.
- [87] Y. Kawase, T. Yamaguchi, H. Uozumi, H. Kawano, M. Watanabe und T. Kusadome, „Characteristics Analysis of Induction Motor with Broken Rotor Bars at Steady State,“ in *2020 23rd International Conference on Electrical Machines and Systems (ICEMS)*, IEEE, Nov. 2020. DOI: 10.23919/icems50442.2020.9290789. Adresse: <https://ieeexplore.ieee.org/document/9290789>.
- [88] I. Jaksch und P. Fuchs, „Using space transformation for exact diagnostic of induction motor stator faults,“ in *2005 5th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, IEEE, Sep. 2005. DOI: 10.1109/demped.2005.4662493.
- [89] K. N. Gyftakis und A. J. M. Cardoso, „A new space vector approach to detect stator faults in induction motors,“ in *2017 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, IEEE, Apr. 2017. DOI: 10.1109/wemdc.2017.7947752. Adresse: <https://ieeexplore.ieee.org/document/7947752>.
- [90] S. H. Kia, H. Henao und G.-A. Capolino, „Gear Tooth Surface Damage Fault Detection Using Induction Machine Stator Current Space Vector Analysis,“ *IEEE Transactions on Industrial Electronics*, Jg. 62, Nr. 3, S. 1866–1878, März 2015. DOI: 10.1109/tie.2014.2360068.

- [91] N. Afrizal und R. Ferrero, „Leakage Error Compensation in Motor Current Signature Analysis for Shaft Misalignment Detection in Submersible Pumps,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 69, Nr. 11, S. 8821–8830, Nov. 2020. DOI: 10.1109/tim.2020.2998301. Adresse: <https://ieeexplore.ieee.org/document/9103087>.
- [92] Z. Gao, T. G. Habetler, R. G. Harley und R. S. Colby, „A novel online rotor temperature estimator for induction machines based on a cascading motor parameter estimation scheme,“ in *2005 5th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, IEEE, Sep. 2005. DOI: 10.1109/demped.2005.4662539. Adresse: <https://ieeexplore.ieee.org/document/4662539>.
- [93] Y. Du, T. G. Habetler und R. G. Harley, „Methods for thermal protection of medium voltage induction motors - A review,“ in *2008 International Conference on Condition Monitoring and Diagnosis*, IEEE, 2008. DOI: 10.1109/cmd.2008.4580269. Adresse: <https://ieeexplore.ieee.org/document/4580269>.
- [94] K. Zhao und X. You, „Speed estimation of induction motor using modified voltage model flux estimation,“ in *2009 IEEE 6th International Power Electronics and Motion Control Conference*, IEEE, Mai 2009. DOI: 10.1109/ipemc.2009.5157719. Adresse: <https://ieeexplore.ieee.org/document/5157719>.
- [95] S. Ozdemir, „Speed Estimation of Vector Controlled Three-Phase Induction Motor Under Four-Quadrant Operation Using Stator Currents and Voltages,“ in *2020 2nd Global Power, Energy and Communication Conference (GPECOM)*, IEEE, Okt. 2020. DOI: 10.1109/gpecom49333.2020.9248723. Adresse: <https://ieeexplore.ieee.org/document/9248723>.
- [96] L. Zhao, J. Huang, Z. Hou und H. Liu, „Induction motor speed estimation based on rotor slot effects,“ in *2014 IEEE Energy Conversion Congress and Exposition (ECCE)*, IEEE, Sep. 2014. DOI: 10.1109/ecce.2014.6953887. Adresse: <https://ieeexplore.ieee.org/document/6953887>.
- [97] J. M. Bossio, C. H. D. Angelo und G. R. Bossio, „Self-organizing map approach for classification of mechanical and rotor faults on induction motors,“ *Neural Computing and Applications*, Jg. 23, Nr. 1, S. 41–51, Nov. 2012. DOI: 10.1007/s00521-012-1255-0. Adresse: <https://link.springer.com/article/10.1007/s00521-012-1255-0>.
- [98] M. Zagirnyak, A. Kalinov, V. Ogar und V. Lotous, „Experimental assessment of the accuracy of the method for determination the power on an induction motor shaft,“ in *2017 18th International Conference on Computational Problems of Electrical*

- Engineering (CPEE)*, IEEE, Sep. 2017. DOI: 10.1109/cpee.2017.8093054. Adresse: <https://ieeexplore.ieee.org/document/8093054>.
- [99] M. Drif und A. J. M. Cardoso, „Stator Fault Diagnostics in Squirrel Cage Three-Phase Induction Motor Drives Using the Instantaneous Active and Reactive Power Signature Analyses,“ *IEEE Transactions on Industrial Informatics*, Jg. 10, Nr. 2, S. 1348–1360, Mai 2014. DOI: 10.1109/tii.2014.2307013. Adresse: <https://ieeexplore.ieee.org/document/6750029>.
- [100] Z. Liu, X. Yin, Z. Zhang, D. Chen und W. Chen, „Online Rotor Mixed Fault Diagnosis Way Based on Spectrum Analysis of Instantaneous Power in Squirrel Cage Induction Motors,“ *IEEE Transactions on Energy Conversion*, Jg. 19, Nr. 3, S. 485–490, Sep. 2004. DOI: 10.1109/tec.2004.832052. Adresse: <https://ieeexplore.ieee.org/document/1325285>.
- [101] K. N. Gyftakis, A. J. Marques Cardoso und J. A. Antonino-Daviu, „Introducing the Filtered Park’s and Filtered Extended Park’s Vector Approach to detect broken rotor bars in induction motors independently from the rotor slots number,“ *Mechanical Systems and Signal Processing*, Jg. 93, S. 30–50, Sep. 2017, ISSN: 0888-3270. DOI: 10.1016/j.ymsp.2017.01.046. Adresse: <https://www.sciencedirect.com/science/article/pii/S0888327017300481>.
- [102] S. Bernet, *Selbstgeführte Stromrichter am Gleichspannungszwischenkreis, Funktion, Modulation und Regelung*, 1st ed., M. Michel, Hrsg. Berlin, Heidelberg: Springer Berlin / Heidelberg, 2012, 1204 S., Description based on publisher supplied metadata and other sources., ISBN: 9783540688617.
- [103] K. C. Maliti, „Modeling and analysis of magnetic noise in squirrel-cage induction motors,“ eng, Diss., Institutionen für elkrafttechnik, 2000, ISBN: 91-7170-553-8. Adresse: <https://urn.kb.se/resolve?urn=urn:nbn:se:kth:diva-2980> (besucht am 25.09.2024).
- [104] D. G. Dorrell, W. T. Thomson und S. Roach, „Analysis of airgap flux, current and vibration signals as a function of the combination of static and dynamic airgap eccentricity in 3-phase induction motors,“ in *IAS '95. Conference Record of the 1995 IEEE Industry Applications Conference Thirtieth IAS Annual Meeting*, IEEE, 1995. DOI: 10.1109/ias.1995.530349. Adresse: <https://ieeexplore.ieee.org/document/530349/keywords#keywords=>.
- [105] S. Nandi, S. Ahmed und H. A. Toliyat, „Detection of rotor slot and other eccentricity related harmonics in a three phase induction motor with different rotor cages,“ *IEEE Transactions on Energy Conversion*, Jg. 16, Nr. 3, S. 253–260, 2001, ISSN: 0885-8969.

- DOI: 10.1109/60.937205. Adresse: <https://ieeexplore.ieee.org/document/937205>.
- [106] U. A. Orji u. a., „Fault detection and diagnostics for non-intrusive monitoring using motor harmonics,“ in *2010 Twenty-Fifth Annual IEEE Applied Power Electronics Conference and Exposition (APEC)*, IEEE, Feb. 2010. DOI: 10.1109/apec.2010.5433437. Adresse: <https://ieeexplore.ieee.org/document/5433437>.
- [107] M. Aiello, A. Cataliotti und S. Nuccio, „An Induction Motor Speed Measurement Method Based on Current Harmonic Analysis With the Chirp-Z Transform,“ *IEEE Transactions on Instrumentation and Measurement*, Jg. 54, Nr. 5, S. 1811–1819, Okt. 2005. DOI: 10.1109/tim.2005.854246. Adresse: <https://ieeexplore.ieee.org/document/1514629/keywords#keywords>.
- [108] B. Xue, M. Zhang, W. N. Browne und X. Yao, „A Survey on Evolutionary Computation Approaches to Feature Selection,“ *IEEE Transactions on Evolutionary Computation*, Jg. 20, Nr. 4, S. 606–626, Aug. 2016. DOI: 10.1109/tevc.2015.2504420. Adresse: <https://ieeexplore.ieee.org/document/7339682>.
- [109] S. Ghosh und P. Pramanik, „A Combined Framework for Dimensionality Reduction of Hyperspectral Images using Feature Selection and Feature Extraction,“ in *2019 IEEE Recent Advances in Geoscience and Remote Sensing : Technologies, Standards and Applications (TENGARSS)*, IEEE, Okt. 2019. DOI: 10.1109/tengarss48957.2019.8976039.
- [110] T. M. Cover, „The Best Two Independent Measurements Are Not the Two Best,“ *IEEE Transactions on Systems, Man, and Cybernetics*, Jg. SMC-4, Nr. 1, S. 116–117, Jan. 1974, ISSN: 2168-2909. DOI: 10.1109/tsmc.1974.5408535. Adresse: <https://ieeexplore.ieee.org/document/5408535>.
- [111] C. Meinel, *Digitale Kommunikation, Vernetzen, Multimedia, Sicherheit* (X.media.press), H. Sack, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, 1422 S., ISBN: 9783540929239.
- [112] H. Peng, F. Long und D. Chris., „Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy,“ *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Jg. 27, Nr. 8, S. 1226–1238, Aug. 2005, ISSN: 0162-8828. DOI: 10.1109/tpami.2005.159. Adresse: <https://ieeexplore.ieee.org/document/1453511>.
- [113] B. Singh, J. S. Sankhwar und O. P. Vyas, „Optimization of feature selection method for high dimensional data using fisher score and minimum spanning tree,“ in *2014 Annual IEEE India Conference (INDICON)*, IEEE, Dez. 2014. DOI: 10.1109/indicon.2014.7030450. Adresse: <https://ieeexplore.ieee.org/document/7030450>.

- [114] N. Henze, *Stochastik für Einsteiger, Eine Einführung in die faszinierende Welt des Zufalls ; mit 260 Übungsaufgaben und Lösungen* (Für Einsteiger), 9., erw. Aufl. Wiesbaden: Vieweg + Teubner, 2012, 402 S., Literaturverz. S. 389 - 390, ISBN: 9783834818454.
- [115] R. O. Duda, *Pattern classification*, 2. Aufl., D. G. Stork und P. E. Hart, Hrsg. New York: Wiley, 2001, 654 S., ISBN: 9780471056690.
- [116] K. Kira und L. A. Rendell, „The Feature Selection Problem: Traditional Methods and a New Algorithm,“ in *Proceedings of the Tenth National Conference on Artificial Intelligence*, 92 Bde., Ser. AAAI, San Jose, California: AAAI Press, 1992, S. 129–134, ISBN: 0262510634. Adresse: <https://cdn.aaai.org/AAAI/1992/AAAI92-020.pdf>.
- [117] M. Robnik-Šikonja und I. Kononenko, „Theoretical and Empirical Analysis of ReliefF and RReliefF,“ *Machine Learning*, Jg. 53, Nr. 1/2, S. 23–69, 2003, ISSN: 0885-6125. DOI: 10.1023/a:1025667309714. Adresse: https://link.springer.com/article/10.1023/A:1025667309714?sv1=affiliate&sv_campaign_id=922583&awc=26429_1703865334_5ab47df67dbd77a2777208a2e20f1641.
- [118] H.-J. Mittag, *Statistik, Eine interaktive Einführung*, 2. Aufl. Springer Spektrum Berlin, Heidelberg, Juni 2012, S. 369, ISBN: 978-3-642-30090-5. DOI: <https://doi.org/10.1007/978-3-642-30090-5>. Adresse: <https://link.springer.com/book/10.1007/978-3-642-30090-5#bibliographic-information> (besucht am 21.04.2023).
- [119] A. W. Götz Kersting, *Elementare Stochastik*. Springer-Verlag GmbH, 11. Apr. 2011, 170 S., ISBN: 9783034604147. Adresse: https://www.ebook.de/de/product/19950734/goetz_kersting_anton_wakolbinger_elementare_stochastik.html.
- [120] Q. Gu, Z. Li und J. Han, *Generalized Fisher Score for Feature Selection*, 2012. DOI: 10.48550/ARXIV.1202.3725. Adresse: <https://arxiv.org/abs/1202.3725>.
- [121] I. Kononenko, „Estimating attributes: Analysis and extensions of RELIEF,“ in *Lecture Notes in Computer Science*. Springer Berlin Heidelberg, 1994, S. 171–182, ISBN: 9783540483656. DOI: 10.1007/3-540-57868-4_57. Adresse: https://link.springer.com/chapter/10.1007/3-540-57868-4_57?sv1=affiliate&sv_campaign_id=922583&awc=26429_1703856650_3571b4ff152ceef87d1c58da95%2041cb86#citeas.

- [122] P. Somol und P. Pudil, „Oscillating search algorithms for feature selection,“ in *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*, Ser. ICPR-00, Bd. 2, IEEE Comput. Soc, 2000, S. 406–409. DOI: 10.1109/icpr.2000.906098. Adresse: <https://ieeexplore.ieee.org/document/906098>.
- [123] H. H. Liu, *Feature Selection for Knowledge Discovery and Data Mining* (The Springer International Series in Engineering and Computer Science Ser. v.454), H. Motoda, Hrsg. New York, NY: Springer, 1998, 1225 S., Description based on publisher supplied metadata and other sources., ISBN: 9781461556893.
- [124] S. Kashef und H. Nezamabadi-pour, „A new feature selection algorithm based on binary ant colony optimization,“ in *The 5th Conference on Information and Knowledge Technology*, IEEE, Mai 2013. DOI: 10.1109/ikt.2013.6620037. Adresse: <https://ieeexplore.ieee.org/document/6620037>.
- [125] B. Schölkopf, *Learning with kernels, Support vector machines, regularization, optimization, and beyond* (Adaptive computation and machine learning), A. J. Smola, Hrsg. Cambridge, Mass.: MIT Press, 2002, 1626 S., ISBN: 0262194759.
- [126] J. Xu, B. Tang, H. He und H. Man, „Semisupervised Feature Selection Based on Relevance and Redundancy Criteria,“ *IEEE Transactions on Neural Networks and Learning Systems*, Jg. 28, Nr. 9, S. 1974–1984, Sep. 2017. DOI: 10.1109/tnnls.2016.2562670.
- [127] R. Kruse, *Computational Intelligence, Eine methodische Einführung in Künstliche Neuronale Netze, Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze* (SpringerLink), 2. Aufl. 2015, C. Borgelt, C. Braune, F. Klawonn, C. Möwes und M. Steinbrecher, Hrsg. Wiesbaden: Springer Vieweg, 2015, 515239 S., ISBN: 9783658109042. Adresse: https://link.springer.com/chapter/10.1007/978-3-658-10904-2_7.
- [128] N. M. Varma und A. Choudhary, „Evaluation Of Distance Measures In Content Based Image Retrieval,“ in *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, IEEE, Juni 2019. DOI: 10.1109/iceca.2019.8821957. Adresse: <https://ieeexplore.ieee.org/document/8821957>.
- [129] M. Marinaki, Y. Marinakis, M. Doumpos, N. Matsatsinis und C. Zopounidis, „A comparison of several nearest neighbor classifier metrics using Tabu Search algorithm for the feature selection problem,“ *Optimization Letters*, Jg. 2, Nr. 3, S. 299–308, Juli 2007, ISSN: 1862-4480. DOI: 10.1007/s11590-007-0057-2. Adresse: <https://link.springer.com/article/10.1007/s11590-007-0057-2>.
- [130] A. Zell, *Simulation neuronaler Netze*. R. Oldenbourg Verlag, 1997.

- [131] T. Taulli, *Grundlagen der Künstlichen Intelligenz, Eine nichttechnische Einführung*, 1. Aufl. 2022. Berlin, Heidelberg: Springer Berlin Heidelberg, 2023, 1211 S., ISBN: 9783662662830.
- [132] B. Scholkopf u. a., „Comparing support vector machines with Gaussian kernels to radial basis function classifiers,“ *IEEE Transactions on Signal Processing*, Jg. 45, Nr. 11, S. 2758–2765, 1997, ISSN: 1053-587X. DOI: 10.1109/78.650102. Adresse: <https://ieeexplore.ieee.org/document/650102>.
- [133] B. Schölkopf, A. J. Smola und R. C. Williamson, „New Support Vector Algorithms,“ in *Neural and Computational Learning 2*, Nov. 1998. Adresse: <https://svms.org/nu/SSWB98.pdf>.
- [134] S. Alelyani, H. Liu und L. Wang, „The Effect of the Characteristics of the Dataset on the Selection Stability,“ in *2011 IEEE 23rd International Conference on Tools with Artificial Intelligence*, IEEE, Nov. 2011. DOI: 10.1109/ictai.2011.167. Adresse: <https://ieeexplore.ieee.org/document/6103458>.
- [135] A. Kalousis, J. Prados und M. Hilario, „Stability of feature selection algorithms: a study on high-dimensional spaces,“ *Knowledge and Information Systems*, Jg. 12, Nr. 1, S. 95–116, Dez. 2006. DOI: 10.1007/s10115-006-0040-8. Adresse: <https://link.springer.com/article/10.1007/s10115-006-0040-8#citeas>.
- [136] Y. Han und L. Yu, „A Variance Reduction Framework for Stable Feature Selection,“ in *2010 IEEE International Conference on Data Mining*, IEEE, Dez. 2010. DOI: 10.1109/icdm.2010.144. Adresse: <https://ieeexplore.ieee.org/document/5693974>.
- [137] M. M. Stopa, B. J. C. Filho und C. B. Martinez, „Detection of incipient cavitation phenomenon in a centrifugal pump,“ in *2012 IEEE Industry Applications Society Annual Meeting*, IEEE, Okt. 2012. DOI: 10.1109/ias.2012.6374080. Adresse: <https://ieeexplore.ieee.org/document/6374080>.
- [138] C. Yang u. a., „Starting Current Analysis in Medium Voltage Induction Motors: Detecting Rotor Faults and Reactor Starting Defects,“ *IEEE Industry Applications Magazine*, Jg. 25, Nr. 6, S. 69–79, Nov. 2019. DOI: 10.1109/mias.2019.2923105. Adresse: <https://ieeexplore.ieee.org/document/8827460>.
- [139] D. H. C. de Sá Só Martins u. a., „Diagnostic and severity analysis of combined failures composed by imbalance and misalignment in rotating machines,“ *The International Journal of Advanced Manufacturing Technology*, Jg. 114, Nr. 9-10, S. 3077–3092, Apr. 2021. DOI: 10.1007/s00170-021-06873-2. Adresse: <https://link.springer.com/article/10.1007/s00170-021-06873-2>.
- [140] G. Müller und B. Ponick, *Grundlagen elektrische Maschinen*, 9., völlig neu bearb. Auf., 1. Nachdr. Weinheim: Wiley-VCH, 2009, Bd. 1, 682 S., ISBN: 9783527405244.

- [141] H. Dubbel, *Taschenbuch für den Maschinenbau*. Berlin New York: Springer, 2007, ISBN: 9783540497141.
- [142] D.-H. Hellmann, *Kreiselpumpenlexikon*. 2013, ISBN: 9783938381588.
- [143] D.-H. Hellmann, *Kreiselpumpen-Lexikon, KSB-Kreiselpumpen-Lexikon*, 4., überarb. und erw. Aufl., D.-H. Hellmann, Hrsg. Frankenthal Pfalz: KSB, 2009, 383 S., ISBN: 9783000297113.
- [144] G. Junge, *Einführung in die Technische Strömungslehre*. Carl Hanser Verlag GmbH & Co. KG, 2011, ISBN: 9783446423008.
- [145] S. Bschorer, *Technische Strömungslehre, Lehr- und Übungsbuch* (SpringerLink), 11. Aufl. 2018. Wiesbaden: Springer Vieweg, 2018, 42818810 S., ISBN: 9783658200374.
- [146] A. Binder, *Elektrische Maschinen und Antriebe, Grundlagen, Betriebsverhalten*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, 11249 S., ISBN: 9783540718505.
- [147] L. Beneduce, G. Caruso, D. Iannuzzi, F. Maceri, E. Pagano und L. Piegari, „Analysis of a structural failure mode arising in cage rotors of induction machines,“ *Electrical Engineering*, Jg. 93, Nr. 3, S. 179–191, Apr. 2011. DOI: 10.1007/s00202-011-0204-8. Adresse: <https://link.springer.com/article/10.1007/s00202-011-0204-8>.
- [148] T. Mauffrey, J.-F. Pradurat, L. Durantay und J. Fontini, „Comparison of 5 different squirrel cage rotor designs for large high speed induction motors,“ *PCIC Europe 2013*, Mai 2013. Adresse: <https://ieeexplore.ieee.org/document/6581591>.
- [149] M. F. Cabanas u. a., „Analysis of the fatigue causes on the rotor bars of squirrel cage asynchronous motors: experimental analysis and modelling of medium voltage motors,“ in *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003.*, IEEE, Aug. 2003. DOI: 10.1109/demped.2003.1234581. Adresse: <https://ieeexplore.ieee.org/document/1234581>.
- [150] I. D. Lomax, „Electrical Machines and Drives (IEEE Conference Publication),“ *Fifth International Conference on Electrical Machines and Drives (Conf. Publ. No. 341)*, S. 330, Sep. 1991. Adresse: <https://ieeexplore.ieee.org/document/154009/authors#authors>.
- [151] I. Kerszenbaum und C. F. Landy, „The Existence of Large Inter-Bar Currents in Three Phase Squirrel Cage Motors with Rotor-Bar and/or End-Ring Faults,“ *IEEE Power Engineering Review*, Jg. PER-4, Nr. 7, S. 61–61, Juli 1984. DOI: 10.1109/mpwr.1984.5525906. Adresse: <https://ieeexplore.ieee.org/document/5525906>.

- [152] D. P. Hujare und M. G. Karnik, „Vibration responses of parallel misalignment in AI shaft rotor bearing system with rigid coupling,“ *Materials Today: Proceedings*, Jg. 5, Nr. 11, Part 3, S. 23 863–23 871, Jan. 2018, ISSN: 2214-7853. DOI: 10.1016/j.matpr.2018.10.178. Adresse: <https://www.sciencedirect.com/science/article/pii/S2214785318324738> (besucht am 19.01.2025).
- [153] A. H. Bonnett, „Cause, analysis and prevention of motor shaft failures,“ in *Conference Record of 1998 Annual Pulp and Paper Industry Technical Conference (Cat. No.98CH36219)*, IEEE, Juni 1998. DOI: 10.1109/papcon.1998.685518. Adresse: <https://ieeexplore.ieee.org/document/685518>.

Abbildungsverzeichnis

2.1	Konzeptvergleich Knowledge Discovery.	13
2.2	Vorverarbeitung des KDED Verfahrens.	14
2.3	Ablauf des Data-Minings als Teil von KD.	15
2.4	Ablauf der Interpretation als Teil von KD.	17
3.1	Prozess der Merkmalsextraktion.	19
3.2	Konstruktion des Raumzeigers aus drei Phasen.	22
3.3	Anpassung des Stichprobenumfangs für Zeit- und Frequenzbereichsmerkmale.	25
3.4	Techniken zur Segmentierung des Spektrums.	26
4.1	Konzepte zu den Validierungsverfahren.	35
4.2	Ablauf sequenziellen Merkmalsextraktion.	36
4.3	Approximation einer Klasse durch k-nächste Nachbarn.	39
4.4	Substitution von Clustern durch Codebook-Vektoren bei der Learning Vector Quantisation.	40
4.5	Vernetzung von Neuronen zur Klassifikation von Daten.	41
4.6	Beispiel eines automatisch konstruierten Entscheidungsbaums.	43
4.7	Konzepte der SVM zur Datentrennung.	45
4.8	Einfluss der Verteilung der Daten auf die Stabilität der Merkmalsselektion. Oben links: Cluster mit idealer Form und Lage; oben rechts: lückende Cluster; unten links: schmale Cluster; unten rechts: fehlplatziertes Cluster.	50
4.9	Strategie zur Suche redundanter Merkmale.	52
4.10	Konstruktion von Verbundklassen aus Elementarklassen und Ableitung der Fragestellung an den FS-Algorithmus.	54
5.1	Druckverlauf über einer Pumpe	61
5.2	Rohleitungs- und Instrumentenschaubild des Pumpenprüfstands.	64
5.3	NPSHR-Kennlinie der ausgewählten Pumpe	65
5.4	Ausführungen des Rotors bei Asynchronmotoren.	67
5.5	Modell des Rotorkäfigs mit gebrochenem Rotorstab und Zwischenströmen.	69
5.6	Verschiedene Arten von Fehlansrichtung. Oben: keine; mitte: Parallelversatz; unten: Winkelversatz.	71
5.7	Aufbau des Experiments Fehlansrichtung.	72
6.1	Untersuchung des Falls: Zielgröße = K, Störgrößen = Q, TO; Auswahl 1.	78
6.2	Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 1.	79

6.3	Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 4.	80
6.4	Untersuchung des Falls: Zielgröße = K, Parameter = TO8, Störgrößen = Q; Auswahl 5.	81
6.5	Untersuchung des Falls: Zielgröße = K, Parameter = TO9, Störgrößen = Q; Auswahl 3.	82
6.6	Untersuchung des Falls: Zielgröße = K, Parameter = TO9, Störgrößen = Q; Auswahl 7.	83
6.7	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 4.	86
6.8	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 5.	86
6.9	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 9.	87
6.10	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 11.	87
6.11	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 19.	88
6.12	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 24.	88
6.13	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 33.	89
6.14	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 73.	89
6.15	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 78.	90
6.16	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 71.	91
6.17	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 74.	91
6.18	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 76.	92
6.19	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 75.	93
6.20	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 80.	93
6.21	Untersuchung des Falls: Zielgröße = GRS, Parameter = 7,5 kW, Störgrößen = L; Auswahl 82.	94
6.22	Untersuchung des Falls: Zielgröße = PV, Störgrößen = BG, L; Auswahl 1. . . .	96
6.23	Untersuchung des Falls: Zielgröße = PV, Störgrößen = BG, L; Auswahl 4. . . .	97
6.24	Untersuchung des Falls: Zielgröße = WV, Störgrößen = BG, L; Auswahl 1. . . .	98
6.25	Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 1.	101
6.26	Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 2.	101

6.27 Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 10.	102
6.28 Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 11.	103
6.29 Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 13.	103
6.30 Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 14.	104
6.31 Untersuchung des Falls: Zielgröße = PV, Parameter = TO1, Störgrößen = L; Auswahl 19.	105
6.32 Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 2.	107
6.33 Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 3.	108
6.34 Untersuchung des Falls: Zielgröße = PV, Parameter = TO2, Störgrößen = L; Auswahl 5.	108
6.35 Untersuchung des Falls: Zielgröße = WV, Parameter = TO1, Störgrößen = L; Auswahl 1.	110
6.36 Untersuchung des Falls: Zielgröße = WV, Parameter = TO1, Störgrößen = L; Auswahl 2.	111
6.37 Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 1.	113
6.38 Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 2.	114
6.39 Untersuchung des Falls: Zielgröße = WV, Parameter = TO2, Störgrößen = L; Auswahl 5.	114

Tabellenverzeichnis

2.1	Einschätzung von Methoden zur Merkmalsidentifikation	11
3.1	Eignung der Merkmalsextraktoren für die Fehlererkennung	21
5.1	Beispiel einer Zustandstabelle zur Erfassung aller Kombinationen.	58
5.2	Zustandstabelle für das Experiment Kavitation	63
5.3	Zustandstabelle für das Experiment gebrochener Rotorstab	69
5.4	Bewertung von Kupplungsarten	71
6.1	Übersicht zum Stand der Experimente und der Daten.	76
6.2	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Störgröße = Durchfluss und Testobjekt.	77
6.3	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Parameter = TO8; Störgröße = Durchfluss.	79
6.4	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Parameter = TO9; Störgröße = Durchfluss.	81
6.5	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = gebro- chener Rotorstab; Störgröße = Last.	84
6.6	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Parallel- versatz; Störgröße = Last und Baugröße.	96
6.7	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Winkel- versatz; Störgröße = Last und Baugröße.	98
6.8	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Parallel- versatz; Parameter = 7,5 kW-Motor; Störgröße = Last.	100
6.9	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Parallel- versatz; Parameter = 1,1 kW-Motor; Störgröße = Last.	106
6.10	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Winkel- versatz; Parameter = 7,5 kW-Motor; Störgröße = Last.	109
6.11	Reduzierte Auswahl der Merkmalsvektoren für den Fall: Zielgröße = Winkel- versatz; Parameter = 1,1 kW-Motor; Störgröße = Last.	112
8.1	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Störgröße = Durchfluss und Testobjekt.	118
8.2	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Parame- ter = TO8; Störgröße = Durchfluss.	119
8.3	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Kavitation; Parame- ter = TO9; Störgröße = Durchfluss.	120

8.4	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = gebrochener Rotorstab; Störgröße = Last.	121
8.5	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Parallelversatz; Störgröße = Last und Baugröße.	127
8.6	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Winkelversatz; Störgröße = Last und Baugröße.	128
8.7	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Parallelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.	129
8.8	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Parallelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.	131
8.9	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Winkelversatz; Parameter = 7,5 kW-Motor; Störgröße = Last.	132
8.10	Auflistung der Merkmalsvektoren für den Fall: Zielgröße = Winkelversatz; Parameter = 1,1 kW-Motor; Störgröße = Last.	133

Glossar

Abnutzungsvorrat Qualitativer Vorrat einer Komponente, der durch degenerative Prozesse aufgebraucht wird. Nach Verbrauch des Vorrats unterschreitet die Komponente die notwendige Qualitätsanforderung zur Gewährleistung des Betriebs, wodurch es zu Ausfällen kommt.

Anomalieerkennung Verfahren zur Erkennung von Ausreißern und Ereignissen, die deutlich von der Mehrzahl der Beobachtungen abweichen.

Ant Colony Optimization (ACO) Optimierungsalgorithmus nach dem Vorbild einer Ameisenkolonie. Durch Modifikation kann der Algorithmus für die Merkmalsuche verwendet werden.

Autoregressives Modell Mathematische Beschreibung eines autoregressiven Prozesses. Der Prozess entsteht durch Anregung eines rekursiven Filters mit einem stationären weißen Prozess.

Back Propagation Trainingsverfahren für neuronale Netze nach dem Gradientenabstiegsverfahren mit der Delta-Regel.

Bayes-Modelle Modelle, die zur Entscheidungsfindung verwendet werden. Diese bauen auf der Bayes-Wahrscheinlichkeit auf, mit der die Unabhängigkeit von Variablen bestimmt wird. Sie bilden die Grundlage für den Bayes-Klassifizierer.

Clustering Verfahren, bei dem Proben einem Cluster zugeordnet werden. Cluster zeichnen sich dadurch aus, dass der Abstand zwischen zwei Datenpunkten kleiner ist, wenn diese demselben Cluster angehören, und größer, wenn diese aus unterschiedlichen Clustern kommen.

Convolutional Neural Network (CNN) Künstliches neuronales Netzwerk aus dem Bereich tiefes Lernen. Zur Stabilisierung der Konvergenz beim Training werden die Merkmalsneuronen nicht vollständig vernetzt.

Data Warehousing Methoden zur Datenhaltung und -bereitstellung in verteilten Datenbanksystemen.

Data-Mining Prozess zur Entdeckung versteckter Informationen oder Zusammenhänge in einem großen Datenpaket, das in mehreren heterogenen Ressourcen gespeichert sein kann.

Diagnosegröße Physikalische Größe, die indirekt zur Bestimmung eines Fehlers und dessen Schwere verwendet wird. Aus der Diagnosegröße werden Merkmale abgeleitet.

Einflussgröße Physikalische Größen, die auf das begutachtete System einwirken. Untergruppen sind die Fehlergrößen und die Störgrößen.

Entscheidungsbaum Klassifizierer aus der Gruppe des maschinellen Lernens. Beim Training wird ein Regelsatz mit verzweigten Wenn-, Wann-, Sonst-Anweisungen erstellt. Zur Bestimmung der Klassenzugehörigkeit einer Probe werden die Regeln durchlaufen und die Probe der resultierenden Klasse zugeordnet. Eine Besonderheit ist, dass der Regelsatz als Baumdiagramm dargestellt werden kann und somit eine grafische Darstellung des Wissens gegeben ist.

Fehlergröße Physikalische Größe, die aufgrund eines Fehlers im begutachteten System auftritt und ein Maß für die Schwere des Fehlers ist.

Generative Adversarial Network (GAN) Konzept, das zur Generierung von Bildern entwickelt wurde. Die Grundlage bilden zwei neuronale Netze, die gegeneinander arbeiten. Mit dem Ansatz können Bilder generiert werden, die zuvor nicht gelernt wurden.

Instandhaltung (ausfallbasiert) Instandsetzungsmaßnahmen werden erst dann durchgeführt, wenn es in einer Anlage oder an einer Komponente bereits zu einem Störereignis gekommen ist.

Instandhaltung (zeitbasiert) Instandsetzungsmaßnahmen werden nach einer festgelegten Anzahl an Betriebsstunden oder nach einer kalendarischen Terminvorgabe durchgeführt.

Instandhaltung (zustandbasiert) In festgelegten zeitlichen Intervallen werden Diagnosen durchgeführt, deren Ergebnisse über den Handlungsbedarf entscheiden. In der Folge wird der Betrieb fortgesetzt, das Intervall für die Inspektion angepasst oder Instandsetzungsmaßnahmen eingeleitet.

Interessantheit Kriterium für das Knowledge Discovery.

k-nächste Nachbarn (kNN) Klassifizierer aus der Gruppe des maschinellen Lernens. Für das Training werden bei diesem Verfahren alle Trainingsdaten abgespeichert. Für

die Klassifizierung wird der Abstand über eine Metrik zwischen der Probe und allen Trainingsdaten berechnet. Anschließend wird die Probe der Gruppe zugeordnet, zu der der Abstand am geringsten ist.

Klassifikation Klassifikation bezeichnet die statistische Analyse des Zusammenhangs zwischen einer Zielgröße und einem Vektor von Merkmalen. Im Gegensatz zur Regression ist die Zielgröße kategoriell.

Klassifizierer System, das in der Lage ist, Merkmalsvektoren in eine endliche Anzahl von Klassen einzuteilen.

Knowledge Discovery in Database (KDD) Gesamtprozess zur Gewinnung nützlicher Erkenntnisse aus Datenbanken.

Künstliche Intelligenz (KI) Disziplin, die sich mit Algorithmen befasst, welche ein Verhalten aus Trainingsinformationen und einem Optimierungskriterium lernen. Der Themenbereich wird in die Teilbereiche maschinelles Lernen und tiefes Lernen untergliedert.

Künstliche Neuronale Netze (NN) Klassifizierer, der den biologischen neuronalen Netzen des Gehirns nachempfunden ist. Während eines Trainings kann das Netzwerk an ein Problem angepasst werden, indem die Verbindungen zwischen den Neuronen gewichtet werden. Die Information, wie eine Entscheidung getroffen wird, ist daher nur implizit vorhanden. Für ein erfolgreiches Training müssen spezielle Trainingsverfahren angewendet werden. Sind mehr als zwei Neuronenschichten zu trainieren, wird von tiefem Lernen gesprochen.

Maschinelles Lernen Gruppe von Algorithmen aus dem Bereich der künstlichen Intelligenz, die ein Verhalten aus Trainingsinformationen und einem Optimierungskriterium lernen.

Merkmal Unterscheidendes Zeichen, an dem ein Zustand erkennbar wird.

Merkmalsextraktion Wandlung der ursprünglichen Daten eines Datensatzes in einen kleineren, kompakteren Datensatz. Dabei sollen so viele Informationen wie möglich erhalten bleiben. Zudem soll die Interpretierbarkeit erhöht werden.

Merkmalsselektion Prozess, bei dem aus einer Menge von Merkmalen die ausgewählt werden, die eine Abhängigkeit von der Zielgröße ausweisen. Durch die Reduzierung der Anzahl von Merkmalen wird die Modellkomplexität reduziert, wodurch Klassifikation und Regression verbessert werden können.

Merkmalsvorrat Sammlung aller Merkmale, die für ein System berechnet werden können. Bei der Erstellung des Merkmalsvorrats ist unklar, ob charakteristische Merkmale vorhanden sind, die für die Klassifikation verwendet werden können.

monokausal Nur auf eine Ursache zurückgehend oder sich auf nur eine Grundlage stützend.

nominalskaliert Eigenschaft von Merkmalen. Diese sind unterscheidbar, folgen aber keiner natürlichen Rangfolge und treten daher in Kategorien auf.

Perzeptron Frühes Konzept eines Algorithmus aus dem Bereich der künstlichen Intelligenz und des Konnektionismus, das auf einer Vernetzung von neuronähnlichen Teilsystemen beruht.

Recurrent Neural Network (RNN) Spezielles künstliches neuronales Netzwerk, bei dem alle Neuronen auf sich selbst rückgekoppelt sind. Mit der Rückkopplung ist es möglich, Erinnerung zu simulieren.

Regression Regression bezeichnet die statistische Analyse des Zusammenhangs zwischen einer Zielgröße (auch Regressand, Response-Variable oder abhängige Variable genannt) und einem Vektor von Merkmalen (oder auch Kovariablen, Regressoren, erklärenden Variablen, unabhängigen Variablen). Im Gegensatz zur Klassifikation ist die Zielgröße reellwertig.

Selbstorganisierende Karten (SOM) Klassifizierer aus der Gruppe des maschinellen Lernens. Der Klassifizierer wird durch ein besonderes neuronales Netz umgesetzt, bei dem die Neuronen Nachbarschaftsbeziehungen aufweisen.

Simulated Annealing Optimierungsalgorithmus nach dem Vorbild eines Glühprozesses. Durch Modifikation kann der Algorithmus für die Merkmalssuche verwendet werden.

Störgröße Physikalische Größe, die neben der Fehlergröße und der Diagnosegröße im begutachteten System auftreten und die Unterscheidung von Zuständen erschwert.

Support Vector Machine (SVM) Klassifizierer aus dem Bereich des maschinellen Lernens. Charakteristisch für diesen Algorithmus ist die Trennung von Daten durch eine Hyperebene, deren Lage und Ausrichtung durch wenige Datenpunkte bestimmt ist.

Tiefes Lernen Unter tiefem Lernen wird die Weiterentwicklung von künstlichen neuronalen Netzen in Richtung tiefer Netze und die Verbesserung des Lernverhaltens zusammengefasst.

Transfer Learning Verfahren zur Übertragung von erlerntem Wissen zwischen zwei technischen Systemen.

Validierung Prozess zur Bestimmung der Qualität eines Klassifizierers.