

Einsatz von adaptiven Methoden zur Restlebenszeitschätzung in der chemischen Industrie als Grundlage für präskriptive Instandhaltung

von der Fakultät für Ingenieurwissenschaften,
Abteilung Elektrotechnik und Informationstechnik
der Universität Duisburg-Essen

zur Erlangung des akademischen Grades

Doktor der Ingenieurwissenschaften

genehmigte Dissertation

von

Kristian Kasten

aus

Warburg

Gutachter: Prof. Dr.-Ing. Steven X. Ding

Gutachterin: Prof. Dr.-Ing. Ping Zhang

Tag der mündlichen Prüfung: 25. August 2023

Danksagung

Die vorliegende Arbeit entstand im Rahmen meiner Tätigkeit in der BASF SE als Leiter des Key Technology Capability Projekts namens Modelbased Turnaround and Operation Support (MoTOS). Das Projekt war die Grundlage und Inspiration für diese Arbeit.

Meinem Doktorvater Professor Steven X. Ding möchte ich herzlich für die kontinuierliche Betreuung danken. Neben vielen gemeinsamen Diskussionen danke ich ihm besonders für den stetigen Nachschub von neuen Perspektiven und die gegebene Freiheit, die mich beflügelt hat. Ebenso möchte ich mich herzlich bei Professorin Ping Zhang für die Bereitschaft zur Übernahme des Zweitgutachtens bedanken.

Herrn Professor Joachim Birk von der BASF SE danke ich insbesondere, dass er zu Beginn meiner Promotion an mich geglaubt und mir einige Türen geöffnet hat. Meinem Fachgruppenleiter Alexander Walzenbach danke ich für die vielseitige Unterstützung. Ich bin sehr froh, dass er eine Konstante innerhalb der gesamten Promotionszeit für mich dargestellt hat und mir stets wertvolles Feedback gegeben hat.

Meiner Arbeitskollegin Kathrin Koffler danke ich für die fachlichen Diskussionen zu unterschiedlichen Themen, die mich zum Nachdenken angeregt und näher zum Ziel gebracht haben. Auch meinem Arbeitskollegen Marco Jäger danke ich für seine fachliche Expertise in der Diskussionen zur Realisierung der Überwachungskonzepte. Besonders danke ich Caroline Zhu vom Lehrstuhl von Herrn Professor Ding. Sie war stets eine wichtige Referenz für wissenschaftliches Arbeiten und eine hervorragende Begleiterin auf meinem Weg.

Neben Caroline Zhu danke ich Doktor Mathias van Beek für die Korrektur meiner Arbeit und die Diskussionen, die mich herausgefordert und meine Dissertation qualitativ verbessert haben. Weiterhin danke ich meiner Schwester Doktor Stephanie Knippschild für die Korrektur der Arbeit und die gemeinsamen Diskussionen. Ebenso danke ich Iris Kaes und Patrick Barras für das Lektorat.

Im Speziellen danke ich meinen Eltern Renate und Heiner Kasten. Sie haben den Grundstein für meine Wissbegierde gelegt und mich auf meinem Weg gefördert, mitgefiebert und mit echtem Interesse daran teilgenommen.

Meinem Sohn Jakob danke ich für seine Geduld, wenn ich wenig Zeit hatte und für die vielen alltäglichen Aufheiterungen, die mir Kraft gegeben haben meinen Weg weiterzuverfolgen. Abschließend danke ich meiner geliebten Frau Teresa Kasten. Sie hat mir in den letzten Jahren den Rücken freigehalten, während der langen und ermüdenden Täler der Promotion motivierend zur Seite gestanden und immer an mich geglaubt. Ich danke dir für Alles von Herzen.

*There is nothing noble in being superior to your fellow man,
true nobility is being superior to your former self.
- Ernest Hemingway -*

Kurzfassung

Die Instandhaltung einer chemischen Anlage macht einen wesentlichen Anteil der Kosten während der Betriebsphase aus. Besonders vor dem Hintergrund gestiegener Energie- und Eduktpreise, kann die Instandhaltung maßgeblich den wirtschaftlichen Erfolg beeinflussen. Maßnahmen aus dem Bereich der präskriptiven Instandhaltung und der dazu notwendigen Schätzung der Restlebenszeit optimieren die Abläufe und tragen zur Effizienz bei. Bedingt durch eine minimale Sensorausstattung sowie einer geringen Datenbasis ist die Überwachung und Ableitung von Handlungsempfehlungen eine Herausforderung.

Ziel dieser Arbeit ist die Entwicklung von adaptiven Lösungen, die der geringen Daten- und Informationsbasis in der chemischen Industrie gerecht werden. Exemplarisch werden die entwickelten Überwachungskonzepte anhand von drei repräsentativen Anwendungsfällen bewertet.

Grundlegend werden unterschiedliche Methoden evaluiert und auf Basis der industriellen Randbedingungen wird eine Vorauswahl getroffen, um zwei Überwachungskonzepte zu entwickeln. Das *Einzeltrendmodul* ist fokussiert auf einen hohen Automatisierungsgrad und limitiert durch die Anwendung auf ein Signal. Ergänzend wird das *Partikelfiltermodul* für komplexere Überwachungsaufgaben eingesetzt, das multiple Eingänge abbildet und die Handlungsempfehlung durch Szenarien ermöglicht.

Beide Überwachungskonzepte werden anhand von synthetischen Daten grundlegend entwickelt und bewertet. Im Zentrum der Bewertung des Einzeltrendmoduls steht die Onlinemodellierung der Messdaten und die sich daraus ableitende Restlebenszeit. Gegensätzlich dazu erfolgt die Modellbildung des Partikelfiltermoduls offline. Wesentlicher Teil der Bewertung ist die geeignete Einstellung und Verbesserungen der grundlegenden Methode.

Im Rahmen einer Onlinesimulation werden beide Überwachungskonzepte auf Basis von realen Betriebsdaten getestet. Sowohl das Einzeltrendmodul, als auch das Partikelfiltermodul zeigen wirksam die Verbesserung durch die Implementierung der Überwachungskonzepte. Insgesamt bilden beide Überwachungskonzepte die Grundlage für bessere Handlungsempfehlungen sowie eine gesteigerte Wettbewerbsfähigkeit.

Abstract

A major part of operation costs during the lifetime of a chemical plant are caused by maintenance. Restricted by increasing energy- and educt prices maintenance is becoming more important for a successful business. Increasing efficiency is enabled by deploying solutions from the field of prescriptive maintenance and therefore needed estimation of remaining useful life. Based on a minimal installation of sensors and a small amount of data, monitoring and decision making are challenging.

The purpose of this work is to develop adaptive solutions, which are suitable for a small amount of data and information within chemical industry. The developed monitoring concepts are evaluated based on three characteristic use cases.

Focusing on an industrial application, different solutions are discussed and a preselection of methods is made, which fulfill industrial requirements. Consequently, two different monitoring concepts are developed. The *Einzeltrendmodul* is focused on a high automation and limited by the estimation of one signal. In contrast, the *Partikelfiltermodul* is applied in more complex use cases containing multiple inputs and enables scenario-based decision making.

Both monitoring concepts are evaluated on synthetic data. The assessment of the *Einzeltrendmodul* focuses on the online modelling and the resulting remaining useful life estimation. The modelling of the *Partikelfiltermodul* is taking place in an offline process, whereas a major part of the evaluation is focused on the tuning as well as the improvement of basic methods.

Based on real operation data both monitoring concepts are assessed. Both *Einzeltrendmodul* and *Partikelfiltermodul* clearly indicate the improvement by deploying the concepts. Both concepts are the base for improved decision making as well as increase competitiveness.

Inhaltsverzeichnis

Abkürzungsverzeichnis	XI
Symbolverzeichnis	XVII
1. Einleitung	1
1.1. Industrielle Randbedingungen	2
1.2. Angewandte Nomenklatur	3
1.3. Ziel und Aufbau der Arbeit	4
2. Stand der Technik	7
2.1. Datenvorbereitung zur Restlebenszeitschätzung	8
2.1.1. Grundlegende Aufbereitung der Rohdaten	8
2.1.2. Bildung von Features	9
2.1.3. Selektion relevanter Features	10
2.2. Methodenübersicht Restlebenszeitschätzung	11
2.2.1. Stochastische Restlebenszeitschätzung	12
2.2.2. Maschinelles Lernen basierte Restlebenszeitschätzung	16
2.2.3. Modellbasierte Restlebenszeitschätzung	20
2.2.4. Übergeordnete Aspekte der Restlebenszeitschätzung	23
2.3. Zwischenfazit der Methoden zur Restlebenszeitschätzung	26
3. Ziele und Anwendungsfälle	29
3.1. Überwachung der Equipments in der BASF SE	29
3.1.1. Industrielle Verwaltung von Daten	31
3.1.2. Datenorganisation in der Anlagenstruktur	31
3.1.3. Plattform zur Onlineüberwachung	32
3.1.4. Ergebnisausgabe und Handlungsanweisung	32
3.2. Industrielle Anwendungsfälle	33
3.2.1. Ölfiler	34
3.2.2. Hochdruckmembranpumpe	35
3.2.3. Robertverdampfer	37
3.3. Konkretisiertes Ziel der Arbeit	39
4. Angewandte Methoden	41
4.1. Deskriptive Statistik	41
4.1.1. Grundlegende Kennzahlen	41
4.1.2. Analyse der Monotonie	43
4.2. Allgemeine Datenvorverarbeitung	45
4.2.1. Glättung und Filterung	45
4.2.2. Detektion von Ausreißern	46
4.2.3. Wechsellpunkt Detektion	47
4.2.4. Datensequenzen	49

4.3.	Grundlegende Modellbildung	49
4.3.1.	Lineare Regression	49
4.3.2.	Multivariate Analyse	50
4.3.3.	Metriken zur Bewertung der Modellgüte	52
4.4.	Partikelfilter im Detail	53
4.4.1.	Einsatzgebiete des Partikelfilters	53
4.4.2.	Abgrenzung zum Kalmanfilter	54
4.4.3.	Grundlegende Funktionsweise	56
4.4.4.	Herausforderung Partikel Degeneration	58
4.4.5.	Herausforderung Partikel Verarmung	61
5.	Überwachungskonzepte	63
5.1.	Entwicklung des Einzeltrendmoduls	63
5.1.1.	Schätzung des Wechsellpunktes	64
5.1.2.	Abbildung des Betriebszustands	66
5.1.3.	Schätzung der Restlebenszeit	67
5.1.4.	Datengenerator des Einzeltrendmoduls	68
5.1.5.	Ergebnisvisualisierung des Einzeltrendmoduls	69
5.2.	Entwicklung des Partikelfiltermoduls	72
5.2.1.	Aktualisierung des Zustands	74
5.2.2.	Zustandsschätzung und Restlebenszeitberechnung	76
5.2.3.	Datengenerator des Partikelfiltermoduls	79
5.2.4.	Ergebnisvisualisierung des Partikelfiltermoduls	80
6.	Modellbildung	83
6.1.	Modellportfolio des Einzeltrendmoduls	83
6.2.	Modellbildung des Partikelfiltermoduls	85
6.2.1.	Analogien zu Degradationsmechanismen	85
6.2.2.	Initiale Vorverarbeitung der Daten	88
6.2.3.	Bildung von degradationsspezifischen Features	90
6.2.4.	Auswahl der Degradationszyklen	92
6.2.5.	Selektion relevanter Features	93
6.2.6.	Entwicklung eines globalen Zustandsraummodells	95
6.2.7.	Parametrieren zyklenspezifischer Zustandsraummodelle	97
6.2.8.	Validierung des Modells	100
6.3.	Zusammenfassung Modellbildung	102
7.	Synthetische Evaluation	103
7.1.	Beurteilung des Einzeltrendmoduls	103
7.1.1.	Generierung synthetischer Daten - Einzeltrendmodul	103
7.1.2.	Ergebnisse des Sägezahn-Datensatzes	106
7.1.3.	Ergebnisse des Kurven-Datensatzes	120
7.1.4.	Diskussion des Einzeltrendmoduls auf synthetischen Daten	132
7.2.	Beurteilung des Partikelfiltermoduls	133
7.2.1.	Generierung synthetischer Daten - Partikelfiltermodul	133
7.2.2.	Initialisierung des Partikelfiltermoduls	135
7.2.3.	Variation der Partikel	140
7.2.4.	Vergleich von Resampling Methoden	142
7.2.5.	Anwendung der Partikeloptimierung	144

7.2.6. Einfluss von Störungen	148
7.2.7. Diskussion des Partikelfiltermoduls auf synthetischen Daten . . .	151
8. Onlinesimulation	153
8.1. Ergebnisse des Einzeltrendmoduls	153
8.1.1. Ergebnisse des Membranpumpen Anwendungsfalls	153
8.1.2. Ergebnisse des Ölfilter Anwendungsfalls	167
8.1.3. Diskussion des Einzeltrendmoduls auf realen Daten	173
8.2. Ergebnisse des Partikelfiltermoduls	175
8.2.1. Datenübersicht und Einstellungen	175
8.2.2. Onlinesimulation eines langsamen Robertverdampfer Zyklus . . .	177
8.2.3. Onlinesimulation eines schnellen Robertverdampfer Zyklus . . .	183
8.2.4. Diskussion des Partikelfiltermoduls auf realen Daten	188
9. Zusammenfassung und Ausblick	191
9.1. Zusammenfassung	191
9.2. Ausblick	193
A. Eigene Veröffentlichungen	195
B. Informationen zur BASF SE	197
B.1. Geschichte und Produktportfolio der BASF SE	197
B.2. BASF SE in Zahlen und Entwicklungsfelder	198
C. Grundlagen & Modellierung	199
C.1. Notwendige Python Pakete	199
C.2. Literaturübersicht Restlebenszeit Schätzung	200
C.3. Startwerte des Einzeltrendmodul-Optimierers	201
C.4. Modellierung des Robertverdampfers	202
D. Anhang zur synthetischen Evaluation des Einzeltrendmoduls	205
E. Anhang zur synthetischen Evaluation des Partikelfiltermoduls	217
F. Anhang zur Onlinesimulation des Einzeltrendmoduls	223
G. Anhang zur Onlinesimulation des Partikelfiltermoduls	231
Tabellenverzeichnis	235
Algorithmenverzeichnis	237
Abbildungsverzeichnis	249
Literaturverzeichnis	251

Abkürzungsverzeichnis

Abkürzung	Beschreibung	Seite
AF	Asset Framework	31–33
AG	Ausgangsgleichung	54–57, 75, 76, 79, 95, 133, 137, 176, 206, 240, XIX
AMS	Asset Monitoring Solutions and Services	29
ANN	Artificial Neural Network	8
APF	Auxiliary Particle Filter	56
AR	Auto Regressive	12, 14, 22, 23, 25
ARIMA	Auto Regressive Integrated Moving Average	12
ARMA	Auto Regressive Moving Average	12, 26
BASF SE	Badische Anilin und Sodafabrik	1, 5, 29, 31–33, 91, 197, 198
BM	Brownian Motion	14, 19
BS	Boot Strapping	54, 107
C-MAPSS	Commercial Modular Aero-Propulsion System Simulation	16, 18, 19, 22, 23, 25, 27
CALCE	Center for Advanced Life Cycle Engineering	19, 22
CCA	Canonical Correlation Analysis	10, 14, 50, 51, 88
CM	Condition Monitoring	7, 20
CNN	Convolutional Neural Network	10, 18
CP	Change Point	9, 45, 47–49, 63–70, 105, 108–111, 113– 118, 120–122, 124–132, 155– 157, 159, 163, 165, 169, 170, 172, 174, 192, 242, XIX, XX, XXII
DB	Dashboard	31, 33
DBN	Deep Believe Network	9, 19, 25

Abkürzung	Beschreibung	Seite
DCS	Distributed Control System	31, 33
DP	Deployment Platform	31
DT	Decision Tree	10, 16, 18, 27
EKF	Extended Kalman Filter	55
ELM	Extreme Learning Machine	18, 19, 23
ERP	Enterprise Resource Planning	31, 33
ESS	Effective Sample Size	59, 61, 75, 80, 135, 140, 176, 177
ETM	Einzeltrendmodul	5, 6, 63, 64, 67–69, 83–85, 102–108, 111, 113–117, 120–123, 125–129, 131, 132, 153, 154, 156, 159–161, 163, 167, 168, 170, 172–174, 191–193, 201
FD	Fault Detection	10, 25, 29, 40, 51, 74, 123, 132
FDI	Fault Diagnosis	23, 25, 29, 51
FIP	Fingerprint	49
FP	Fault Prognosis	23, 25
GBRT	Gradient Boosted Regression Tree	16
GM	Grey Model	15
GP	Gamma Process	12, 14, 15, 23, 26
HDMP	Hochdruckmembranpumpe	33, 35, 36, 153, 191
HI	Health Indicator	7, 9, 10, 15, 18, 23
HM	Hazard Model	12, 26
HMM	Hidden Markov Model	14, 15, 54
HS	Health Stage	7
KF	Kalman Filter	20, 22, 27, 53–55
KMC	k Means Clustering	45
KNN	k Nearest Neighbor	19
LASSO	Least Absolute Shrinkage and Selection Operator	16, 50, 94, 95
LM	Landmark	49

Abkürzung	Beschreibung	Seite
LOF	Local Outlier Factor	47
LRM	Logistic Regression Model	12
LSTM	Long Short Term Memory	19
MA	Moving Average	12
MAE	Mean Absolute Error	52
MAPE	Mean Absolute Percentage Error	52
MBSHMM	Multi Branch Semi Hidden Markov Model	15
MES	Manufacturing Execution System	31
MK	Mann Kendall	44, 45, XXI
ML	Machine Learning	10, 11, 16, 18, 19, 23, 27, 40, 88, 191
MM	Markov Model	14
MoTOS	Modelbased Turnaround and Operation Support	I
MP	Markov Process	12, 14, 15, 26
MVA	Multivariate Analysis	50–52
NASA	National Aeronautics and Space Administration	14, 16, 18, 19, 22, 23, 25, 27
NN	Neural Network	16, 18, 19, 23, 25, 27, 193
OD	Outlier Detection	45–47
OLS	Ordinary Least Squares	18, 25, 40, 50, 51, 67, 95
OT	Operational Technology	30, 33
PCA	Principle Component Analysis	10, 50–52
PD	Particle Degeneration	58, 59, 61, 192
PDF	Probability Density Function	57
PF	Particle Filter	6, 12, 20, 22, 23, 27, 40, 41, 53–59, 62, 72, 76, 80, 133, 135, 137, 140, 141, 145, 148, 151, 191
PFM	Partikelfiltermodul	5, 6, 63, 72–74, 78–80, 95, 98, 100, 102, 103, 133–135, 137– 139, 144–149, 151–153, 175– 178, 181–184, 187–189, 191– 193

Abkürzung	Beschreibung	Seite
PHM	Prognostics and Health Management	12, 15, 18, 25, 53, 191
PI	Particle Impoverishment	61, 62, 133, 139, 140, 143, 183, 192
PIMS	Process Information Management System	31, 32, 89
PLS	Projection Latent Structures	10, 49–51
PR	Parameterraum	58, 76, 98–100, 102, 135–137, 139, 141, 142, 144, 147, 151, 176, 181, 182, 189
PredM	Predictive Maintenance	2, 29, 198
PresM	Prescriptive Maintenance	2, 4, 33, 39, 174, 192
PropHM	Proportional Hazard Model	12
RBM	Restricted Boltzmann Machine	9
RCA	Root Cause Analysis	2
ReCe	Reliability Center	29, 30
RF	Random Forest	10, 16, 18, 23, 25
RMSE	Root Mean Squared Error	52
RNN	Recurrent Neural Network	25
RS	Random Seed	67, 68
RUL	Remaining Useful Life	2–12, 14–16, 18–20, 22, 23, 25, 26, 29, 33, 35, 37, 39–41, 53, 58, 63, 64, 68–70, 76, 78–80, 83–85, 100, 103, 104, 107–127, 129–134, 136, 138–141, 143–145, 147, 149, 150, 152, 154–173, 177–179, 181–189, 191–193
RV	Robertverdampfer	33, 38, 39, 83, 85, 88, 89, 92, 95, 176, 183, 188, 189, 191, 192
RVM	Relevance Vector Machine	18, 19, 25

Abkürzung	Beschreibung	Seite
SHMM	Semi Hidden Markov Model	14
SKF	Switching Kalman Filter	25
SVD	Singular Value Decomposition	51
SVM	Support Vector Machine	9, 15, 16, 18, 23, 25, 27
SVR	Support Vector Regression	18, 20
TP	Technischer Platz	33
UKF	Unscented Kalman Filter	22
WDT	Wasser Dampf Tabelle	91, 176
WP	Wiener Process	12, 14, 15, 26, 83
ZG	Zustandsgleichung	54, 56, 57, 61, 74–79, 95, 133, 136, 137, 149, 176, 206, 240, XVIII
ZR	Zustandsraum	58, 75, 76, 95, 137, 142, 144, 147, 151
ZRM	Zustandsraummodell	14, 54, 56, 72, 85, 95, 100, 102
ÖF	Ölfilter	33, 35, 153, 167, 191

Symbolverzeichnis

Symbol	Beschreibung	Einheit
$a_{\text{Fläche}}$	Geometrische Fläche	m^2
a	Temperaturleitfähigkeit	m^2/s
\mathbf{A}_{KF}	Systemmatrix des Kalman Filters	—
b	Boolescher Skalar	—
$b_{\text{Abs.}}$	Boolescher Skalar einer erzwungenen Abschaltung	—
$b_{\text{Ausr.}}$	Boolescher Skalar eines Ausreißers	—
$b_{\text{Bet.}}$	Boolescher Skalar eines aktiven Betriebszustands	—
b_{Extern}	Boolescher Skalar eines externen Betriebszustands	—
b_{mon}	Boolescher Skalar einer korrekten Monotonie	—
$b_{\text{Stat.}}$	Boolescher Skalar eines Status	—
b_{Stop}	Boolescher Skalar eines Abbruchkriteriums	—
$b_{\Omega\text{Ok}}$	Boolescher Skalar eines Betriebs innerhalb der Grenzwerte	—
$b_{\text{Zuk.bek.}}$	Boolescher Skalar eines verfügbaren zukünftigen Datensatzes	—
B	Boolescher Vektor	—
$B_{\text{Ber.}}$	Boolescher Vektor von falschen Wertebereichen	—
$B_{\text{Deak.}}$	Boolescher Vektor von abzuschaltenden Partikeln p	—
$B_{\text{Ers.}}$	Boolescher Vektor zu ersetzender Partikel	—
$B_{\text{Ers.,Ber.}}$	Boolescher Vektor von zu ersetzenden Partikeln aufgrund des Wertebereichs	—
$B_{\text{Ers.,mon}}$	Boolescher Vektor von zu ersetzenden Partikeln aufgrund der Monotonie	—
\mathbf{B}_{KF}	Eingangsmatrix des Kalman Filters	—
$B_{\Omega\text{err.}}$	Boolescher Vektor von erreichten Grenzwerten	—
c	Skalarer Parameter	.
$c_{\text{Arr.}}$	Skalarer Parameter der Arrhenius Gleichung	.
c_{ETM}	Skalarer Parameter des Einzeltrendmoduls	.
$c_{\text{Foul.}}$	Skalarer Parameter des Foulings	.
c_{Gas}	Skalare universelle Gaskonstante	J/mol
$c_{\text{Skal.}}$	Skalarer Parameter der Skalierung	.
$c_{\text{Vers.}}$	Skalarer Parameter des Versatzes	.
C	Vektor von Parametern	.
C_{ETM}	Vektor von Parametern des Einzeltrendmoduls	.
\mathbf{C}_{KF}	Ausgangsmatrix des Kalman Filters	—
$corr$	Skalarer Korrelationskoeffizient zweier Vektoren	—

Symbol	Beschreibung	Einheit
$corr_{XY}$	Skalarer Korrelationskoeffizient zweier Vektoren X und Y	—
$Corr$	Matrix der Korrelation	—
cov	Skalare Kovarianz zweier Vektoren	—
cov_{XY}	Skalare Kovarianz zweier Vektoren X und Y	—
d	Skalares Distanzmaß	.
$d_{Char.}$	Skalare charakteristische Länge der Reynoldszahl $z_{Dim.Re}$	m
$d_{Maha.}$	Skalare Mahalanobis Distanz	.
d_{Rohr}	Skalarer Durchmesser eines Rohres mit rundem Querschnitt	m
$d_{Spa.}$	Skalares Streumaß eines beliebigen Vektors	.
$d_{Spa.,Res}$	Skalares Streumaß eines Residuenvektors	.
D_{KF}	Durchgangsmatrix des Kalman Filters	—
$deltat$	Differenz zwischen Dampftemperatur thi und der Sumpftemperatur tc_i (Feature)	K
$e_{Akt.}$	Skalare Aktivierungsenergie	J/mol
E	Vektor von Erwartungswerten	.
$E_{\bar{X}}$	Vektor von Erwartungswerten der normierten Matrix \bar{X}	.
$E_{\bar{Y}}$	Vektor von Erwartungswerten der normierten Matrix \bar{Y}	.
$Ende$	Index zur Beschreibung des letzten Vektoreintrags	—
$expdeltat$	Exponentiale Temperaturdifferenz $deltat$ (Feature)	—
f	Allgemeine Funktion f	.
f_{WDT}	Funktion der Wasser Dampf Tabelle	.
$f_{Deg.}$	Funktion der Degradation abhängig von der Zeit t	.
$f_{Deg.Exp.}$	Funktion der exponentiellen Degradation abhängig von der Zeit t	.
$f_{Deg.Lin.}$	Funktion der linearen Degradation abhängig von der Zeit t	.
$f_{Deg.Pol.}$	Funktion der polynomischen Degradation abhängig von der Zeit t	.
f_{Filter}	Funktion eines Filters	—
f_{ETM}	Spezifische Funktionen des Einzeltrendmoduls	—
f_k	Funktion der Kosten	.
f_{ZG}	Zustandsgleichung eines Zustandsraummodells	.
F	Vektor von Funktionen f	.
F_{ETM}	Vektor von Funktionen f des Einzeltrendmoduls	—
f_{ci}	Eingangsmassenstrom in die Kolonne K1 (Feature)	kg/s
f_{hi}	Dampfmassestrom des Robertverdampfers (Feature)	kg/s
g	Skalare Erdbeschleunigung als Konstante mit 9.81	m/s^2

Symbol	Beschreibung	Einheit
h	Skalare Fensterbreite	.
h_{AG}	Ausgangsgleichung eines Zustandsraummodells	—
h_{CP}	Skalare Fensterbreite zur Detektion von Wechsellpunkten	—
$h_{Filt.}$	Skalare Fensterbreite zur Filterung	—
$h_{Filt.,S}$	Skalare Fensterbreite zur Filterung eines Signals S	—
$h_{Filt.,\sigma}$	Skalare Fensterbreite zur Filterung einer rollierenden Standardabweichung σ	—
$h_{Geo.}$	Skalare geodätische Höhe	m
$h_{Opt.}$	Skalarer Schätzhorizont der Partikeloptimierung	—
$h_{Präd.}$	Skalarer Schätzhorizont der Prädiktion	—
$h_{Präd.,max}$	Skalarer maximaler Schätzhorizont der Prädiktion	—
$h_{Smoo.}$	Skalarer Vergleichshorizont des Smoothings	—
H	Vektor von definierten Fensterbreiten h	—
H_{CP}	Vektor von Fensterbreiten h zur Wechsellpunktdetektion	—
i	Skalare spezifische Position eines Wechsellpunkts	—
$i_{Proz.}$	Skalare spezifische Position eines Wechsellpunkts in Prozent der Vektorlänge	%
I	Vektor von spezifischen Wechsellpunktspalten i	—
idx	Skalarer Index	—
idx_p	Skalarer spezifischer Index eines Partikels p	—
$idx_p, \min W$	Skalarer spezifischer Index des Partikels p mit dem minimalen Gewicht w	—
Idx	Vektor von Indices idx	—
Idx_{CP}	Vektor von Wechsellpunktindices idx	—
$Input$	Vektor von Eingängen „input“ eines synthetischen Datensatzes	.
$intercept$	Konstanter Modelleinfluss (Feature)	.
j	Skalare Zählvariable	—
$kat_{Betr.}$	Kategorieller Betriebszustand einer verfahrenstechnischen Anlage (Feature)	—
ℓ	Skalare Likelihood	—
l	Skalare Zählvariable	—
ℓ_p	Skalare Likelihood eines Partikels p	—
l_{Rohr}	Skalare Länge eines Rohres	m
\mathcal{L}	Vektor von Likelihoods ℓ	—
M	Vektor einer Messreihe	.
$M_{Feat.}$	Vektor verschiedener Feature	.
\mathbf{M}	Matrix beliebig vieler Messreihen über die Zeit	.
$\mathbf{M}_{Synth.}$	Matrix von beliebig vielen synthetischen Messreihen über die Zeit	.

Symbol	Beschreibung	Einheit
MAE	Mean Absolute Error (Metrik)	.
MAE_h	Gemittelter Mean Absolute Error über die Fensterbreite h und die Anzahl der Dimensionen (Metrik)	.
$MAPE$	Mean Absolute Percentage Error (Metrik)	%
\max	Maximum	.
\max_X	Skalares Maximum eines Vektors X	.
$Measure$	Vektor von Ausgängen „measure“ eines synthetischen Datensatzes	.
\min	Minimum	.
\min_X	Skalares Minimum eines Vektors X	.
mo	Spezifisches Modell	—
mo_{Beste}	Bestes Modell eines Vektors von Modellen Mo	—
$mo_{CP,Beste}$	Bestes Modell eines definierten Wechsellpunkts	—
mo_{CP}	Modell eines definierten Wechsellpunkts	—
Mo	Vektor von Modellen mo	—
Mo_{CP}	Vektor von Modellen mo eines definierten Wechsellpunkts	—
mds	Skalärer Betriebsmodus	—
mds_h	Skalärer Betriebsmodus des Einzeltrendmoduls mit festgelegtem Schätzhorizont $h_{Präd.}$	—
mds_ω	Skalärer Betriebsmodus des Einzeltrendmoduls mit festgelegtem Grenzwert ω	—
mon	Skalare Kennzahl der Monotonie	—
$mon_{Diff.}$	Skalare Kennzahl der Monotonie auf Basis finiter Differenzen	—
mon_{MK}	Skalare Kennzahl der Monotonie auf Basis des Mann Kendall Tests	—
$mon_{Num.}$	Skalare numerische Kennzahl der Monotonie	—
mon_{Rang}	Skalare Kennzahl der Monotonie auf Basis des Rangkorrelationskoeffizienten nach Spearman	—
Mon	Vektor von Monotonie Kennzahlen mon	—
$Mon_{Measure}$	Vektor von Monotonie Kennzahlen mon des Ausgangsvektors $Measure$	—
n	Skalare Anzahl	—
$n_{Betr.}$	Skalare Anzahl der Messungen im aktuellen Betrieb	—
n_C	Skalare Anzahl der Einträge des Parametervektor C	—
n_{CP}	Skalare Anzahl von Wechsellpunkten	—
$n_{Diff.}$	Spezifische Ordnung eines Differenzierungsvorgangs	—
$n_{h,CP}$	Skalare Anzahl von Fenstern zur Wechsellpunktsbestimmung	—
$n_{Max.Diff.}$	Skalare Anzahl der maximalen Differenzierungsvorgänge	—
$n_{Mess.}$	Skalare Anzahl von Messwerten	—
$n_{Mess.,Synth.}$	Skalare Anzahl von Messwerten eines synthetischen Signals	—

Symbol	Beschreibung	Einheit
$n_{\text{Mess.,Train.}}$	Skalare Anzahl von Messwerten, die für das Training verwendet werden	—
n_{MK}	Skalare Anzahl der paarweisen Vergleiche des Mann Kendall Tests	—
$n_{\mathcal{P}}$	Skalare Anzahl der Einträge in Partikelvektor \mathcal{P}	—
n_{Φ}	Skalare Anzahl der Einträge des Zustandsvektors Φ	—
$n_{\mathcal{P}\text{Sing.}}$	Skalare Anzahl der singulären Partikel p	—
n_{RUL}	Skalare Anzahl der Restlebenszeit in Messungen	—
n_S	Skalare Anzahl der Messwerte in einem Signal S	—
$n_{\text{Sequ.}}$	Skalare Anzahl von Sequenzen einer Messreihe	—
n_{Sprung}	Skalare Anzahl der Sprünge	—
$n_{S,\text{Synth.}}$	Skalare Anzahl der Messwerte in einem synthetischen Signal S	—
n_t	Skalare Anzahl der Zeitstempel einer Messreihe	—
n_{Θ}	Skalare Anzahl der Einträge des Parametervektors Θ	—
$n_{\text{Var.}}$	Skalare Anzahl der Variablen	—
$n_{\text{Var.,Aus.}}$	Skalare Anzahl der Ausgangsvariablen	—
$n_{\text{Var.,Ein.}}$	Skalare Anzahl der Eingangsvariablen	—
n_X	Skalare Anzahl der Einträge des Vektors X	—
n_Y	Skalare Anzahl der Einträge des Vektors Y	—
N	Vektor von Anzahlen n	—
N_{RUL}	Vektor von Restlebenszeiten	—
\mathbb{N}	Menge der natürlichen Zahlen	—
\mathcal{N}	Gaussverteilung mit Mittelwert μ und Standardabweichung σ	·
\mathcal{O}	Größenordnung des Rechenaufwands einer Berechnung	—
p	Spezifischer Partikel	—
p	Skalare Wahrscheinlichkeit	—
$p_{\text{Abs.}}$	Gemessener Absolutdruck eines verfahrenstechnischen Prozesses (Feature)	bar
p_p	Skalare Wahrscheinlichkeit eines Partikels p	—
\mathcal{P}	Vektor von Partikeln	—
$\mathcal{P}_{\text{Opt.}}$	Vektor eines optimierten Partikel	—
\mathbf{L}_{SVD}	Matrix der linken Singulärvektoren	—
phi	Dampfdruck des Robertverdampfers (Feature)	bar
$pkol$	Kopfdruck der Kolonne K1 (Feature)	bar
q	Skalares Gütemaß	·
q_{CP}	Skalares Gütemaß eines definierten Wechsellpunkts	·
$q_{\text{CP,Beste}}$	Bestes skalares Gütemaß eines definierten Wechsellpunkts	·
q_{ESS}	Skalares Gütemaß der effektiven Stichprobengröße	—
Q	Vektor von Gütemaßen q	·
Q_{CP}	Vektor von Gütemaßen q eines definierten Wechsellpunkts	·

Symbol	Beschreibung	Einheit
Q_{ESS}	Vektor von Gütemaßen q der effektiven Stichprobengröße	—
\mathbf{R}_{SVD}	Matrix der rechten Singulärvektoren	—
qh	Wärmestrom des im Robertverdampfer kondensierten Dampfes (Feature)	W
R^2	R^2 (Metrik)	—
r	Wärmedurchgangswiderstand (Feature)	K/W
R	Zustand des Wärmedurchgangswiderstands r des Robertverdampfers (Feature)	K/W
$R^2_{\text{Adj.}}$	Angepasste Variante der R^2 (Metrik)	—
r_{Ende}	Skalarer Wärmedurchgangswiderstand am Ende einer Messreihe	K/W
$r_{\text{Foul.}}$	Skalarer Wärmedurchgangswiderstand einer Fouling-Schicht	K/W
$r_{\text{Ges.}}$	Skalarer Gesamtwärmedurchgangswiderstand	K/W
$\Delta r_{\text{Kum.}}$	Kumulierte Summe der finiten Differenzen des Wärmedurchgangswiderstands Δr (Feature)	K/W
r_{Start}	Skalarer Wärmedurchgangswiderstand am Anfang einer Messreihe	K/W
R^2_{Test}	R^2 der Testdaten (Metrik)	—
R^2_{Train}	R^2 der Trainingsdaten (Metrik)	—
r_{Wand}	Skalarer Wärmedurchgangswiderstand einer Wand	K/W
\mathcal{R}	Vektor von Rängen eines Vektors	—
\mathcal{R}_X	Vektor von Rängen eines Vektors X	—
\mathcal{R}_Y	Vektor von Rängen eines Vektors Y	—
\mathbb{R}	Menge der reellen Zahlen	—
$ratiot$	Verhältnis zwischen Dampftemperatur thi und der Sumpftemperatur tci (Feature)	—
res	Skalares Residuum eines Messwerts und dessen Schätzung	\cdot
res_{CP}	Skalares Residuum der Wechsellpunktposition i und dessen Schätzung	—
$res_{\Delta r_{\text{Kum.}}}$	Skalares Residuum einer kumulierten Summe von finiten Differenzen eines Wärmewiderstands r und dessen Schätzung	K/W
res_r	Skalares Residuum eines Wärmewiderstands r und dessen Schätzung	K/W
res_{RUL}	Skalares Residuum einer Restlebenszeit t_{RUL} und deren Schätzung	s
Res	Vektor von Residuen res	\cdot
Res_{CP}	Vektor von Residuen res von Wechsellpunkten i	—
$Res_{\text{Filter},S}$	Vektor von Residuen res eines gefilterten Signals \tilde{S}	\cdot
Res_{RUL}	Vektor von Residuen res von Restlebenszeiten t_{RUL}	s
Res_S	Vektor von Residuen res eines Signals S	\cdot
$Res_{S,\text{Zuk.}}$	Vektor von Residuen res eines zukünftigen Signals $S_{\text{Zuk.}}$	\cdot

Symbol	Beschreibung	Einheit
$RMSE$	Root Mean Squared Error (Metrik)	.
S	Vektor eines zeitlich zusammenhängenden Signals	.
$S_{Bas.}$	Vektor eines zeitlich zusammenhängenden Signals als Basis zur weiteren Verarbeitung	.
S_{CP}	Vektor eines zeitlich zusammenhängenden Signals zwischen Wechsellpunktposition und Signalende	.
$S_{CP,Test}$	Vektor des Testanteils eines zeitlich zusammenhängenden Signals S zwischen Wechsellpunktposition und Signalende	.
$S_{CP,Train}$	Vektor des Trainganteils eines zeitlich zusammenhängenden Signals S zwischen Wechsellpunktposition und Signalende	.
$S_{Synth.}$	Vektor eines zeitlich zusammenhängenden synthetischen Signals	.
$S_{Zuk.}$	Vektor eines zeitlich zusammenhängenden Signals, das die Zukunft beschreibt	.
$Score_{RUL}$	Skalare Kennwert der Restlebenszeitschätzung (Metrik)	—
sgn	Signumfunktion	—
$Start$	Index zur Beschreibung des ersten Vektoreintrags	.
$State$	Vektor von Zuständen „state“ eines synthetischen Datensatzes	.
$sumt$	Summe der Dampftemperatur thi und der Sumpftemperatur tci (Feature)	K
t	Zeit	s
T	Zustand der Dampftemperatur thi des Robertverdampfers (Feature)	K
$t_{Char.}$	Skalare charakteristische Temperatur der Wärmeübertragung	K
t_{Ende}	Skalärer Zeitpunkt des Endes einer Messreihe	s
$t_{Konf.}$	Skalare Zeitspanne des Konfidenzintervalls	s
$t_{Konf. max}$	Skalare maximale Zeit des Konfidenzintervalls	s
$t_{Konf. min}$	Skalare minimale Zeit des Konfidenzintervalls	s
t_{RUL}	Restlebenszeit in Zeit	s
t_{Start}	Skalärer Zeitpunkt des Starts einer Messreihe	s
\mathcal{T}	Vektor von Zeiten t	s
$T_{Tol.}$	Vektor von Toleranzwerten $\tau_{Tol.}$.
\mathcal{T}_{RUL}	Vektor von Restlebenszeiten in Zeit	s
$\tau_{Tol.}$	Skalärer Toleranzwert	.
tci	Sumpftemperatur der Kolonne K1 (Feature)	K
thi	Dampftemperatur des Robertverdampfers (Feature)	K
u	Skalare Fließgeschwindigkeit eines Fluids	m/s
v	Allgemeines Element einer Liste	—

Symbol	Beschreibung	Einheit
$v_{\text{Szen.}}$	Spezifisches Szenario des Partikelfiltermoduls	—
V	Allgemeiner Vektor	—
$V_{\text{Erg.}}$	Vektor von Ergebnissen des Partikelfiltermoduls	·
$V_{\text{Szen.}}$	Vektor von Szenarien als Grundlage des Partikelfiltermoduls	—
var	Skalare Varianz eines Vektors	·
var_X	Skalare Varianz eines Vektors X	·
w	Skalarer Wert eines Gewichts	·
w_κ	Skalares spezifisches Gewicht des Rauschens κ	—
w_ρ	Skalares spezifisches Gewicht eines Partikels ρ	—
$w_{\rho, \text{Opt.}}$	Skalares spezifisches Gewicht eines optimierten Partikels $\mathcal{P}_{\text{Opt.}}$	—
W	Vektor von Gewichten	·
W_h	Vektor von Gewichten über h Messungen gemittelt	—
$W_{\text{Kum.}}$	Vektor von kumuliert summierten Gewichten	—
x	Skalar Eintrag eines Vektors X	·
X	Vektor einer Messreihe	·
$X_{\text{Iter.}}$	Vektor einer Messreihe in einer Iteration	·
\mathbf{X}	Matrix von mehreren Messreihen X als Spaltenvektoren	·
$\mathbf{X}_{\text{Synth.}}$	Matrix von mehreren synthetischen Messreihen X als Spaltenvektoren	·
$\mathbf{X}_{\text{Ver.}}$	Matrix von mehreren vergangenen Messreihen X als Spaltenvektoren	·
$\mathbf{X}_{\text{Zuk.}}$	Matrix von mehreren zukünftigen Messreihen X als Spaltenvektoren	·
$\underline{\mathbf{X}}$	Tensor von mehreren Matrizen \mathbf{X}	·
y	Skalar Eintrag eines Vektors Y	·
Y	Vektor einer Messreihe	·
\mathbf{Y}	Matrix von mehreren Messreihen Y als Spaltenvektoren	·
\mathcal{Z}	Matrix einer Zwischenberechnung	·
$z_{\text{Dim.}}$	Skalare dimensionslose Kennzahl	—
$z_{\text{Dim.Pr}}$	Skalare dimensionslose Prandtl-Zahl	—
$z_{\text{Dim.Re}}$	Skalare dimensionslose Reynolds-Zahl	—
$\alpha_{\text{Konv.}}$	Skalarer konvektiver Wärmeübergangskoeffizient	W/m^2K
α_{LASSO}	Skalarer Hyperparameter der LASSO Regression	—
Δ	Skalare Differenz	·
Δn	Skalare Differenz der Anzahl n	—
$\Delta n_{\text{Vers.}}$	Differenz der Indeces zwischen zwei Messreihen	—
Δt	Skalare Differenz der Zeit t	s
ϵ	Skalare Störgröße	·
ϵ_{LASSO}	Skalare Störgröße einer LASSO Regression	·
$\epsilon_{\text{lin.Reg.}}$	Skalare Störgröße einer linearen Regression	·

Symbol	Beschreibung	Einheit
η	Skalare dynamische Viskosität	kg/ms
Γ	Vektor von Eingängen	.
$\Gamma_{Iter.}$	Vektor von Eingängen in einer Iteration	.
$\mathbf{\Gamma}$	Matrix von Eingängen	.
$\mathbf{\Gamma}_{Synth.}$	Matrix von mehreren synthetischen Eingangsvektoren Γ als Zeilenvektoren	.
$\mathbf{\Gamma}_{Ver.}$	Matrix von mehreren vergangenen Eingangsvektoren Γ als Zeilenvektoren	.
κ	Skalarer Rauschterm	.
K	Vektor von Rauschtermen κ	.
K_{Input}	Vektor von Rauschtermen κ eines Eingangsvektors <i>Input</i>	.
$K_{Measure}$	Vektor von Rauschtermen κ eines Ausgangsvektors <i>Measure</i>	.
K_{Φ}	Vektor des Prozessrauscheinfluss von Rauschtermen κ	.
K_{Ψ}	Vektor des Messrauscheinfluss von Rauschtermen κ	.
λ_{Rohr}	Skalare dimensionslose Kennzahl der Strömung in Rohren	—
Λ	Allgemeinen Verteilung	.
μ	Skalarer Mittelwert eines Vektors	.
$\mu_{\mathcal{R}X}$	Skalarer Mittelwert eines Rangvektors \mathcal{R}_X	.
$\mu_{\mathcal{R}Y}$	Skalarer Mittelwert eines Rangvektors \mathcal{R}_Y	.
μ_S	Skalarer Mittelwert eines Signals S	.
μ_X	Skalarer Mittelwert eines Vektors X	.
μ_Y	Skalarer Mittelwert eines Vektors Y	.
$\mu_{\mathbf{X}}$	Vektor spaltenweiser Mittelwerte einer Matrix \mathbf{X}	.
ν	Skalare kinematische Viskosität	m^2/s
ω	Skalarer Grenzwert	.
$\omega_{Aus.}$	Skalarer Grenzwert eines Ausreißer	.
$\omega_{Ein.}$	Skalarer Grenzwert eines aktiven Modells	.
ω_{ESS}	Skalarer Grenzwert der effektiven Stichprobengröße	—
ω_S	Skalarer Grenzwert eines Signals S	.
Ω	Vektor von Grenzwerten ω	.
$\Omega_{Measure}$	Vektor von Grenzwerten ω eines synthetischen Ausgangsvektors <i>Measure</i>	.
Ω_{Φ}	Vektor von Grenzwerten ω eines Zustandsvektors Φ	.
Ω_S	Vektor von Grenzwerten ω eines Signals S	.
$\Omega_{\mathbf{X}}$	Vektor von Grenzwerten ω einer Matrix \mathbf{X}	.
$\mathbf{\Omega}$	Matrix von Grenzwertvektoren Ω	.
$\mathbf{\Omega}_{\Phi}$	Matrix von oberen- $\Phi_{O.Grenz.}$ und unteren Zustands-grenzvektoren $\Phi_{U.Grenz.}$.
$\mathbf{\Omega}_{\Theta}$	Matrix von oberen- $\Theta_{O.Grenz.}$ und unteren Parameter-grenzvektoren $\Theta_{U.Grenz.}$.
Φ	Vektor von Zuständen	.
$\Phi_{Akt.}$	Vektor von aktuellen Zuständen	.
$\Phi_{O.Grenz.}$	Vektor von Zuständen einer obere Grenze des Zustands-raums	.

Symbol	Beschreibung	Einheit
$\Phi_{\text{Opt.}}$	Vektor von optimierten Zuständen	.
Φ_p	Vektor von Zuständen eines Partikels p	.
$\Phi_{\text{U.Grenz.}}$	Vektor von Zuständen einer untere Grenze des Zustandsraums	.
Φ	Matrix von Zuständen	.
$\Phi_{\text{Ges.}}$	Matrix von gespeicherten Zuständen	.
$\Phi_{\text{Iter.}}$	Matrix von Zuständen in einer Iteration	.
$\Phi_{\text{Synth.}}$	Matrix von synthetischen Zuständen	.
$\Phi_{\text{Zuk.}}$	Matrix von zukünftigen Zuständen	.
$\underline{\Phi}$	Tensor von Zuständen	.
$\underline{\Phi}_{\text{Ver.}}$	Tensor von vergangenen Zuständen	.
$\underline{\Phi}_{\text{Zuk.}}$	Tensor von zukünftigen Zuständen	.
Π	Mathematische Menge	—
Π_A	Mathematische Menge A	—
Π_B	Mathematische Menge B	—
Ψ	Vektor von Ausgängen	.
Ψ	Matrix von Ausgängen	.
$\Psi_{\text{Synth.}}$	Matrix von synthetischen Ausgängen	.
$\Psi_{\text{Ver.}}$	Matrix von mehreren vergangenen Ausgangsvektoren Ψ als Zeilenvektoren	.
ρ	Skalare Dichte	kg/m^3
σ	Skalare Standardabweichung eines Vektors	.
$\sigma_{\mathcal{R}Y}$	Skalare Standardabweichung eines Rangvektors \mathcal{R}_Y	.
σ_S	Skalare Standardabweichung eines Signals S	.
σ_X	Skalare Standardabweichung eines Vektors X	.
σ_Y	Standardabweichung eines Vektors Y	.
$\Sigma_{\text{Roll.}}$	Vektor von rollierenden Standardabweichungen σ	.
Σ	Matrix der Kovarianz	—
Σ_M	Matrix der Kovarianz einer Matrix M	—
$\Sigma_{\bar{X}}$	Matrix der Kovarianz einer normierten Matrix \bar{X}	—
$\Sigma_{\bar{X}\bar{Y}}$	Matrix der Kovarianz einer normierten Matrizen \bar{X} und \bar{Y}	—
$\Sigma_{\bar{Y}}$	Matrix der Kovarianz einer normierten Matrix \bar{Y}	—
$\Sigma_{\bar{Y}\bar{X}}$	Matrix der Kovarianz einer normierten Matrizen \bar{Y} und \bar{X}	—
$\tau_{\text{Scher.}}$	Skalare Scherspannung	kg/ms^2
$\tau_{\text{Ver.}}$	Skalarer zeitlicher Versatz zwischen zwei Messreihen	s
Θ	Vektor von Parametern	.
$\Theta_{\text{Glob.Mod.}}$	Vektor von Parametern eines globalen Modells	.
$\Theta_{\text{Init.Mod.}}$	Vektor von Parametern eines initialen Modells	.
$\Theta_{\text{O.Grenz.}}$	Vektor von Parametern einer oberen Grenze des Parameterraums	.
$\Theta_{\text{Opt.}}$	Vektor von optimierten Parametern	.
Θ_p	Vektor von Parametern eines Partikels p	.
$\Theta_{\text{Synth.}}$	Vektor von synthetischen Parametern	.
$\Theta_{\text{U.Grenz.}}$	Vektor von Parametern einer untere Grenze des Parameterraums	.

Symbol	Beschreibung	Einheit
Θ	Matrix von Parametern	.
$\Theta_{\text{Ges.}}$	Matrix von gespeicherten Parametern	.
$\underline{\Theta}$	Tensor von Parametern	.
ξ	Skalarer Median	.
ξ_{Test}	Skalarer Median von Testdaten	.
$\xi_{\text{Train.}}$	Skalarer Median von Trainingsdaten	.
Ξ	Matrix der Singulärwerte	—
ζ	Skalares Perzentil	.
ζ_{Druck}	Skalare dimensionslose Kennzahl des Druckverlustes	—

1. Einleitung

Der Betrieb einer chemischen Produktionsanlage ist komplex und durch vielseitige Randbedingungen beschränkt. Wesentliche Einflussfaktoren sind die Verfügbarkeit bzw. der Preis von Ressourcen, Einschränkungen durch politische Bedingungen und die Effizienz des Betriebs sowie den daraus folgenden Kosten. Die Tragweite der Einflussfaktoren wird exemplarisch anhand des Standortes Deutschland veranschaulicht.

Neben den notwendigen Edukten ist die Energie eine wesentliche Ressource. Als energieintensive Industrie benötigt die chemische Industrie vor allem Strom und Wärme, die beispielsweise aus Erdgas erzeugt werden. Im Jahr 2021 entfallen etwa 27% des deutschen Primärenergieverbrauchs auf Erdgas. Bezogen auf die Erdgasimporte ohne Flüssiggas im Jahr 2020 werden mit 55% mehr als die Hälfte aus Russland importiert [1]. Bedingt durch den Einbruch der Lieferungen von russischem Erdgas im Jahr 2022, wird die Abhängigkeit von Energie und im Speziellen Erdgas deutlich. Der Energiepreis sowie die Verfügbarkeit der Energie stellen somit eine Beschränkung der energieintensiven Industrie dar.

Auch politische Beschränkungen erschweren eine wirtschaftliche Produktion. Ein Beispiel dafür ist die Reduzierung des CO_2 -Ausstoßes, der im Rahmen des Pariser Klimaabkommens [2] festgelegt und auf Basis des „Klimaschutzplans 2050“ [3] für Deutschland konkretisiert wird. Beispielsweise plant die Badische Anilin und Sodafabrik (BASF SE) bis zum Jahr 2030 eine Reduzierung des CO_2 -Ausstoßes um 25% verglichen mit dem Jahr 2018 und strebt für das Jahr 2050 eine Netto-Null Emission an [4].

Innerhalb der Betriebskosten ist die Instandhaltung ein wesentlicher Kostenfaktor einer chemischen Produktionsanlage während der Betriebszeit. Die für den Weiterbetrieb notwendigen Instandhaltungsarbeiten können im Rahmen von unterschiedlichen Strategien umgesetzt werden. Dazu zählen die korrigierende, zeitbasierte, risikobasierte, zustandsbasierte und möglichkeitsbasierte Wartung [5]. Die Auswahl der passenden Strategie hängt von unterschiedlichen Einflussfaktoren wie Ausfallhäufigkeit, möglichen Auswirkungen des Versagens auf die Produktion und Umgebung sowie der notwendigen Verfügbarkeit ab.

Der Betrieb einer chemischen Produktionsanlage bewegt sich folglich in einem starken Spannungsfeld aus externen Anforderungen und den daraus folgenden Kosten, das nur wenig Freiräume zur Optimierung ermöglicht. In diesem Zusammenhang ist es bei Grenzfällen die Instandhaltung, die zwischen einem profitablen und einem unwirtschaftlichen Geschäft unterscheidet. Durch den Hebel über die gesamte Betriebszeit einer chemischen Produktionsanlage kann die Optimierung der Instandhaltung zu einer höheren Verfügbarkeit und somit zu nachhaltigen Wettbewerbsvorteilen führen.

In diesem Zusammenhang ist es wichtig eine chemische Produktionsanlage als Verknüpfung einzelner technischer Equipments zu verstehen - fällt eine Komponente aus, könnten eine gesamte Produktionsanlage oder Teile eines größeren Verbunds von chemischen Produktionsanlagen ausfallen. Daher ist es wichtig die Instandhaltung an die konkreten Bedürfnisse anzupassen.

Die höchste Ausbaustufe der Instandhaltung ist die *präskriptive Instandhaltung* (engl. Prescriptive Maintenance (PresM)). Nach Liu u. a. [6] ist PresM die Methodenkombination der prädiktiven Instandhaltung (engl. Predictive Maintenance (PredM)) und der Ursachenanalyse (engl. Root Cause Analysis (RCA)), um eine definierte zeitliche Entwicklung mit einer konkreten Handlungsempfehlung zu verknüpfen. Im Hinblick auf eine bessere Verfügbarkeit sowie eine optimierte Instandhaltung steht die Frage nach der verbleibenden Betriebszeit im Mittelpunkt. Diese Zeit wird als Restlebenszeit (engl. Remaining Useful Life (RUL)) bezeichnet und definiert die Differenz zwischen dem aktuellen Zeitpunkt und dem Zeitpunkt, an dem ein Equipment nicht mehr wie benötigt eingesetzt werden kann [7], [8].

Die modellbasierte Schätzung der RUL ist durch die oben genannten Faktoren sowie eine Vielzahl weiterer Herausforderungen eingeschränkt. Eine wesentliche Limitierung ist die Verfügbarkeit von Daten in einer geeigneten Qualität. Bedingt durch implementierte Basisregelungen wird die Variation des Betriebs in engen Grenzen geführt. Das ist insbesondere in Bezug auf eine Identifizierung des Systems eine Herausforderung, da mitunter die notwendige Anregung fehlt. Auf der anderen Seite gibt es ebenso manuelle Eingriffe in die Betriebsweise, die nicht notwendigerweise durch das in der Regelung umfasste Verhalten abgebildet werden. Die größte Herausforderung ist jedoch, dass die zeitliche Entwicklung der Degradation *a priori* nur in wenigen Fällen bekannt ist. Der Betrieb einer chemischen Produktionsanlage wird folglich wirtschaftlich und regulatorisch stark beschränkt. Ein verbleibendes Entwicklungsfeld ist die Optimierung der Instandhaltung, die jedoch aufgrund der Datenverfügbarkeit technisch limitiert ist.

1.1. Industrielle Randbedingungen

Chemische Produktionsanlagen sind häufig Einzelanfertigungen, weshalb die Übertragbarkeit und Generalisierung von Überwachungsansätzen erschwert wird. Heruntergebrochen auf das konkrete Equipment besteht für Hersteller vermeintlich die Möglichkeit Erkenntnisse aus einer Flotte von gleichartigen Equipments zu ziehen. Die Betriebsdaten sind jedoch Eigentum des Betreibers und werden nur im Rahmen definierter Kooperationen geteilt. Zudem sind es nicht nur die Eigenschaften des Equipments, sondern auch das Verhalten und die Wechselwirkungen mit dem verfahrenstechnischen Prozess, die den Zustand eines Equipments charakterisieren. Für die meisten technischen Anwendungen in der chemischen Industrie gibt es daher keine generalisierten Überwachungskonzepte von den Herstellern der Equipments, die anwendungsspezifische Methoden in einen industriellen Überwachungsprozess einbetten.

Folglich ist die Entwicklung und der Betrieb von Überwachungskonzepten von zentralem Interesse für den Betreiber und ein sich entwickelndes Geschäftsfeld für die Hersteller. Nachfolgend werden die Herausforderungen der chemischen Industrie in Bezug auf Überwachungskonzepte anhand des Prozesses von den Daten bis zur Umsetzung der Instandhaltung aufgezeigt.

Insbesondere der Umstand, dass viele verfahrenstechnische Prozesse zwar Ähnlichkeiten zueinander aufweisen, jedoch nicht gleich sind, reduziert die Datenverfügbarkeit. Weiterhin ist auch die Erhebung von Daten begrenzt, da Eingriffe in den laufenden Betrieb, beispielsweise zur Systemidentifikation, nur in Sonderfällen möglich sind. Neben der Variation der Daten ist auch die Beobachtbarkeit des Systems durch eine geringe Anzahl

an Sensoren eingeschränkt. Insgesamt führt dies zu einer qualitativen und quantitativen Limitierung der Daten.

Innerhalb der Wissenschaft existiert eine Vielzahl an Methoden und deren Kombinationen zur RUL Schätzung. Für den Einsatz innerhalb der chemischen Industrie ist die Auswahl der Methoden durch die Datenverfügbarkeit begrenzt. Somit ist eine Prüfung der Eignung, in Bezug auf den Einsatz in der chemischen Industrie, von zentraler Bedeutung für die Funktionalität des zu entwickelnden Überwachungskonzeptes.

Die Ableitung von konkreten Handlungsempfehlungen ist heterogen und sowohl vom Anforderungsprofil des Betreibers als auch dem spezifischen Anwendungsfall abhängig. Für einige Anwendungsfälle sind keine historischen Fehlerdaten als mögliche Grundlage für eine Überwachung vorhanden. Besonders in diesen Fällen ist eine möglichst frühzeitige Aussage des Überwachungskonzeptes als Handlungsgrundlage notwendig. Demgegenüber existiert für andere Anwendungsfälle eine Fehlerhistorie, die weder umfangreich noch vollständig sein muss. Die Nutzung der vorhandenen Erkenntnisse ist die Grundlage, um Handlungsoptionen auszugeben.

Auf Basis einer Handlungsempfehlung können konkrete Instandhaltungsmaßnahmen abgeleitet werden. Im Prozess zur Umsetzung der Instandhaltungsmaßnahmen sind unterschiedliche Disziplinen und Verantwortliche eingebunden. Für die Entscheidung über die Durchführung einer Instandhaltungsmaßnahme muss die entscheidende Person von dem Überwachungskonzept und der Validität der Aussage überzeugt sein. Daraus folgt, dass die Akzeptanz der eingesetzten Methoden von Seiten der Anwender und Entscheider eine zentraler Bedeutung für die Ausführung ist.

Mögliche Anwendung zur Überwachung müssen in eine bestehenden IT-Landschaft und deren Schnittstellen integriert werden. Trotz der Individualität einzelner Equipments und deren Überwachung, liegt das Hauptaugenmerk von industriellen Anwendungen auf der Skalierung von Überwachungskonzepten.

1.2. Angewandte Nomenklatur

Die in dieser Arbeit verwendete Nomenklatur entspricht grundlegend der allgemein üblichen Definition, wobei Abweichungen im Folgenden spezifiziert werden. Falls nicht anders ausgewiesen, sind alle verwendeten Daten Elemente des reellen Zahlenbereichs \mathbb{R} . Durch Angaben in geschweiften Klammern kann der Zahlenbereich eingeschränkt werden. Mit $\mathbb{R}\{0, 1\}$ wird beispielsweise der Zahlenbereich auf die reellen Zahlen zwischen 0 und 1 reduziert. Alle Zahlen werden in englischer Schreibweise aufgeführt, demnach wird für das Dezimaltrennzeichen ein Punkt „.“ und für das Tausendertrennzeichen ein Komma „.“ verwendet. Sind die Einheiten bekannt, werden diese angezeigt. Im Falle, dass die Messgröße eine Einheit besitzt, diese aber nicht bekannt ist, erfolgt die Kennzeichnung mit einem Punkt „.“ und falls keine Einheit vorhanden ist, wird ein Strich „-“ anstelle der Einheit eingefügt.

Der Fokus dieser Arbeit liegt auf der Verarbeitung von äquidistant abgetasteten Zeitreihen und wird an nachfolgendem Beispiel verdeutlicht. Der einzelne Messwert ist ein Skalar $x \in \mathbb{R}^{1 \times 1}$, der mit kleinen Buchstaben gekennzeichnet wird. Das Zusammenfassen von mehreren Messwerten über n_t Zeitschritte erfolgt in einem Spaltenvektor, der mit großem Anfangsbuchstaben beschrieben wird, wie beispielsweise $X \in \mathbb{R}^{n_t \times 1}$. Ausgedehnt auf die Zusammenführung mehrerer Messreihen, erfolgt die Bildung einer

Matrix $\mathbf{X} \in \mathbb{R}^{n_t \times n_{\text{Var.}}}$ mit $n_{\text{Var.}}$ Messgrößen, die mit großem Anfangsbuchstaben und fett dargestellt werden. Durch das Überlagern einer weiteren beliebigen Dimension entsteht ein Tensor $\underline{\mathbf{X}}$, der mit einem großem Anfangsbuchstaben, fett und unterstrichen dargestellt wird. Eine Ausnahme dieser Konvention stellen die Features zur Modellbildung dar, die für einen konkreten Zeitpunkt als Skalar definiert, jedoch auch als Vektor über die Zeit verstanden werden.

Die Auswahl eines Teilbereichs eines Tensors wird mit Klammern gekennzeichnet und wird analog für Matrizen und Vektoren angewendet. Zur besseren Übersichtlichkeit kann die Kennzeichnung auch im Index erfolgen, wie beispielsweise $\underline{\mathbf{X}}(:, :, t) = \underline{\mathbf{X}}(t) = \mathbf{X}_t$. Die zählende Indizes beziehen sich somit auf die Einordnung innerhalb der übergeordneten Datenstruktur. Alle spezifizierenden Indizes werden im Symbolverzeichnis aufgeführt. Neben der Anzeige zur Nutzung der vollständigen Dimension, werden die Doppelpunkte „:“ auch zur Kennzeichnung eines Bereichs eingesetzt, wie beispielsweise $X(3 : 5) = [x_3 \ x_4 \ x_5]$.

Darüber hinaus wird die Manipulation der Daten gekennzeichnet. Keine Kennzeichnung bedeutet, dass es berechnete oder gemessene Werte sind, die nicht verändert werden. Die Schätzung wird durch ein Dach \hat{X} über der Messgröße angezeigt. Demgegenüber wird die Filterung anhand einer Tilde \tilde{X} und die Standardisierung durch einen hochgestellten Querstrich \bar{X} gekennzeichnet. Die Ausführung der Filterung und Standardisierung erfolgt, falls nicht anders ausgewiesen, messwertspezifisch, d.h. bei einer Matrix \mathbf{X} spaltenweise. Analog gilt dies auch für die Auswertung von statistischen Größen, wie beispielsweise dem Mittelwert, der mit $\mu_{\mathbf{X}}$ die messwertspezifischen Mittelwerte als Vektor einer Matrix \mathbf{X} ausgibt, wobei μ_X ein Skalar des Vektors X ist. Für die Rechenoperationen gelten die üblichen Operatoren, wie beispielsweise die Kennzeichnung mit $*$ für die Faltung von zwei Funktionen. Der duale Einsatz einer Funktion durch Vertauschen der Ein- und Ausgangsgrößen wird mit \circ ausgedrückt.

Zur Veranschaulichung von Programmiercode erfolgt die Darstellung als Pseudocode. Variablen werden kursiv geschrieben und Funktionen nicht-kursiv. Die Übergabe an die Funktionen erfolgt in runden Klammern nach dem Funktionsnamen. In Anlehnung an die Implementierung sowie die gängigen Programmierkonventionen werden die Benennungen in englischer Sprache vorgenommen. Dies gilt analog auch für die Fachtermini der angewendeten Methoden, die im Allgemeinen in der englischen Sprache bekannt sind und die Basis für die Abkürzungen bilden.

1.3. Ziel und Aufbau der Arbeit

Um von PresM profitieren zu können, ist es das übergeordnete Ziel dieser Arbeit geeignete Überwachungskonzepte zur Schätzung der RUL zu entwickeln. Der Einsatz in der chemischen Industrie und den damit verbundenen Randbedingungen beeinflusst die Entwicklung der Überwachungskonzepte maßgeblich und begründet die Notwendigkeit von adaptiven Eigenschaften.

Für die Entwicklung ist eine breitgefächerte Evaluierung aktueller Methoden zur RUL Schätzung essentiell. Die Auswahl geeigneter Methoden und deren Weiterentwicklung ist in diesem Zusammenhang eng an das Ziel der Implementierung der Überwachungskonzepte in komplexe chemische Produktionsprozesse gekoppelt. Die Basis für die Evaluierung bilden exemplarische Anwendungsfälle, die stellvertretend für eine Vielzahl von heterogenen Anwendungsfällen in der chemischen Industrie stehen. Abschließend

soll die Wirksamkeit und der Nutzen der Konzepte für einfache und skalierbare sowie komplexe und einzigartige Anwendungsfälle differenziert vorgestellt werden.

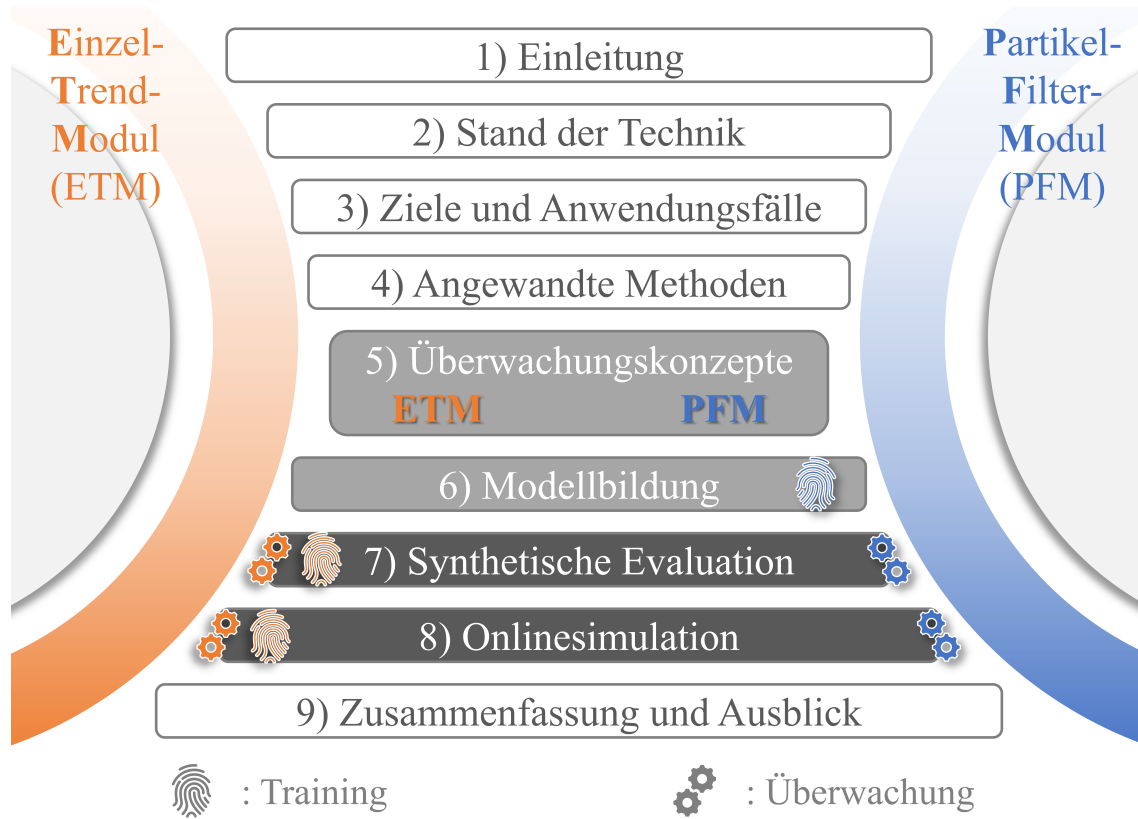


Abbildung 1.1.: Grafische Darstellung des vereinfachten Ablaufschemas dieser Arbeit mit Untergliederung in das Einzeltrendmodul und das Partikelfiltermodul sowie der Aufteilung in Offlinetraining und Onlineüberwachung.

Nachfolgend wird der Aufbau dieser Arbeit schematisch anhand von Abbildung 1.1 visualisiert.

In Kapitel 2 findet eine globale Einordnung des Stands der Technik statt. Dazu werden spezifische vorbereitende Maßnahmen für die Modellbildung zur RUL Schätzung skizziert. Anschließend werden die verschiedenen Methodengruppen zur RUL Schätzung vorgestellt, wodurch eine Einbettung in einen größeren Kontext erfolgt.

Das Vorgehen zur Überwachung der Equipments innerhalb der BASF SE wird in Kapitel 3 eingeleitet. Im Anschluss werden drei exemplarische Anwendungsfälle vorgestellt, die aufgrund ihrer heterogenen Eigenschaften den möglichen Lösungsraum aufspannen und zugleich eine technische Relevanz besitzen. Abgeleitet aus dem Stand der Technik sowie den spezifischen Randbedingungen innerhalb der BASF SE werden die Ziele dieser Arbeit konkretisiert.

In Kapitel 4 werden die konkreten Methoden für die Lösung der Anwendungsfälle vorgestellt. Dabei werden sowohl grundlegende Methoden zur Datenaufbereitung sowie spezifische Methoden zur Schätzung der RUL beschrieben.

Abgeleitet aus der Zielsetzung dieser Arbeit sowie dem Stand der Technik werden zwei Überwachungskonzepte in Kapitel 5 entwickelt, die nachfolgend parallel evaluiert werden. Das Einzeltrendmodul (ETM) bildet die einfacheren und skalierbaren Anwendungsfälle ab. Demgegenüber ist das Partikelfiltermodul (PFM) die Lösung für komplexere An-

wendungsfälle und umfangreichere Anforderungen an die RUL Schätzung. Die Abläufe innerhalb beider Überwachungskonzepte werden skizziert und anhand von Pseudocode veranschaulicht.

In Kapitel 6 wird die Modellbildung für die vorgestellten Anwendungsfälle umgesetzt. Da das ETM während der Betriebszeit das Modell identifiziert, wird das Modellportfolio vorgestellt und die Modellbildung in Kapitel 7 und 8 evaluiert. Demgegenüber wird die vollständige Modellbildung für das PFM offline umgesetzt. Neben den Schritten der Aufarbeitung des Datensatzes sowie der Merkmals (engl.Feature) Bildung, wird die Modellvalidierung diskutiert.

Auf Basis von synthetischen Daten werden beide Überwachungskonzepte in Kapitel 7 evaluiert. Das ETM wird insbesondere auf realitätsnahe Signale angewendet, die sich im Verhalten sowie in den überlagerten Störungen unterscheiden. Die Evaluierung des PFM basiert ebenfalls auf einem synthetischen Datensatz mit dem Fokus den Einfluss der Einstellungsmöglichkeiten des verwendeten Partikelfilters (engl. Particle Filter (PF)) auf die RUL Schätzung zu untersuchen.

Anhand von realen Betriebsdaten wird in Kapitel 8 die Onlineüberwachung auf Basis unbekannter Daten simuliert und werden die Ergebnisse vorgestellt. Im Hinblick auf das Anforderungsprofil werden die aus Unterkapitel 3.2 bekannten Anwendungsfälle entweder dem ETM oder dem PFM zur Auswertung zugeordnet. In diesem Zusammenhang werden unterschiedliche Betriebsvarianten betrachtet.

Abschließend erfolgt die Zusammenfassung der gewonnenen Erkenntnisse in Kapitel 9 und darauf aufbauend die Darstellung von verschiedenen Weiterentwicklungsoptionen.

2. Stand der Technik

Die Schätzung der RUL wird sowohl in der Wirtschaft als auch in der Wissenschaft mit großem Interesse verfolgt. Unter anderem Si u. a. [7] und Kordestani u. a. [8] beschreiben die RUL als verbleibende Zeit, die ein Gegenstand vom jetzigen Zeitpunkt bis zum Versagen des Gegenstandes genutzt werden kann. Diese Definition wird durch Lei u. a. [9] ergänzt, sodass die RUL Schätzung eine der wesentlichen Aufgaben einer zustandsbasierten Instandhaltung auf Basis von historischen und aktuellen Degradationstrends ist. Tang u. a. [10] bringen in diesem Kontext noch den Aspekt der Langzeitschätzung mit ein, der für eine bestmöglich abgeleitete Handlung notwendig ist. Neben der inhaltlichen Definition gibt es auch weitere Perspektiven, die das Themengebiet der RUL Schätzung aufspannen. Dazu zählen sowohl die Strukturierung zur Erstellung einer RUL Schätzung als auch die Wahl der eigentlichen RUL Schätzmethode.

Im Hinblick auf die Strukturierung des Ablaufs der Modellierung teilen Lei u. a. [9] den Prozess in die vier Schritte Datenakquisition, Konstruktion des Gesundheitsindikators (engl. Health Indicator (HI)) und des Gesundheitszustandes (engl. Health Stage (HS)) sowie RUL Schätzung ein. Dieses Vorgehen wird beispielsweise auch durch Kordestani u. a. [8] aufgegriffen. Der Aspekt der Datenakquise und deren Transfer in ein Condition Monitoring (CM) System wird im industriellen Umfeld häufig durch standardisierte Lösungen umgesetzt und daher nicht weitergehend behandelt.

Der Prozessschritt der vorbereitenden Maßnahmen zur Umsetzung der RUL Schätzung wird exemplarisch von Lei u. a. [9] nicht explizit in den Vordergrund gestellt. Dennoch besitzt die Vorbereitung einen wesentlichen Einfluss auf die Qualität der Schätzung. Aus diesem Grund werden als initialer Schritt der Entwicklung von RUL Schätzmodellen, in Unterkapitel 2.1 RUL spezifische Methoden zur Datenvorverarbeitung vorgestellt. Die Evaluierung umfasst die Aufbereitung der Rohdaten sowie die Bildung und Auswahl von Features.

Die methodische Perspektive spannt ein weites Feld auf, das zusätzlich durch unterschiedliche Anwendungsfälle differenziert wird. Zheng [11] stellt zur methodischen Unterteilung drei wesentliche Modellarten mit Ähnlichkeits-, Degradations- und Überlebensmodellen vor. Dies ist eine grundlegende Unterteilung, die unterschiedliche Methoden grob unter dem Aspekt der verfügbaren Daten aufteilt. Im Wesentlichen fokussiert auf die Degradationsmodelle, stellen An u. a. [12] eine weitere Unterscheidung in modellbasierte und datengetriebene Methoden vor, wobei die datengetriebenen Verfahren weiter in künstliche Intelligenz sowie statistische Ansätze unterteilt werden. Ähnlich teilen Lei u. a. [9] in die Kategorien statistisch, künstliche Intelligenz, physikalisch und hybrid ein. Besonders die Klasse der hybriden Methoden ermöglicht die Abbildung durch eine Kombination unterschiedlicher Basismethoden. Dieses Vorgehen wird auch von Chen u. a. [13] genutzt, jedoch nur global in die Kategorien modellbasiert, datengetrieben und hybrid unterteilt.

Die Strategien zur Klassifizierung der RUL Schätzmethoden sind vielfältig. Im Rahmen

dieser Arbeit werden diese Methoden in Unterkapitel 2.2 anhand der Kategorien *maschinelles Lernen basierte*-, *modellbasierte*-, und *stochastische* RUL gebündelt. Erweiternd werden übergeordnete Aspekte der RUL Schätzung zur Einbettung in einen größeren Kontext aufgezeigt.

Im Anschluss an den Stand der Technik erfolgt in Unterkapitel 2.3 eine Zwischenzusammenfassung sowie die Diskussion der wesentlichen Charakteristika unterschiedlicher Methodengruppen.

2.1. Datenvorbereitung zur Restlebenszeitschätzung

Der Aspekt der Datenvorverarbeitung ist ein wesentlicher Schritt im Gesamtprozess der RUL Schätzung. Auf Basis der Rohdaten werden die Informationen zunächst aufbereitet. Dieser Prozess wird in Unterkapitel 2.1.1 von verschiedenen Perspektiven betrachtet. Darauf aufbauend wird in Unterkapitel 2.1.2 die Komposition unterschiedlicher Signale zu sogenannten Features diskutiert. Ausgehend von einer Vielzahl von Features werden in Unterkapitel 2.1.3 verschiedene Methoden zu deren Selektion vorgestellt.

2.1.1. Grundlegende Aufbereitung der Rohdaten

Innerhalb der Datenaufbereitung ist die Extraktion von Informationen ein wesentlicher Schritt, der die Grundlage für die weitere Verarbeitung darstellt. In Abhängigkeit von der Struktur sowie den Schadstellen der Daten werden unterschiedliche Methoden eingesetzt.

Die Daten können beispielsweise Fehlstellen aufweisen, die behandelt werden müssen. Ein trivialer Ansatz besteht in der Löschung des gesamten Datenpunkts über alle Dimensionen hinweg. Insbesondere wenn mehrere Dimensionen von Fehlstellen betroffen sind und diese nicht auf die gleichen Zeitpunkte entfallen, werden mitunter viele Datenpunkte entfernt. Trotz der einfachen Umsetzung ist diese Methode nur in manchen Anwendungsfällen sinnvoll. Besonders vor dem Hintergrund einer Rekonstruktion eines sich aufbauenden Zustandes kann auf die Daten nicht verzichtet werden. Daher besteht ebenfalls die Möglichkeit die Fehlstellen linear zu interpolieren. Speziell bei kurzen zu ersetzenden Zeiträumen und bei einem zu dem Zeitpunkt unbekanntem Systemverhalten kann dieses Vorgehen genutzt werden. Falls jedoch ausreichend Daten zur Verfügung stehen, können auch komplexere Methoden zur Wiederherstellung eingesetzt werden. Beispielsweise stellen Bu u. a. [14] einen Ansatz auf Basis eines künstlichen neuronalen Netzes (engl. Artificial Neural Network (ANN)) vor, um nicht gemessene Daten in der Vergangenheit zu erzeugen.

Ein weiterer Aspekt der Informationsextraktion ist die Filterung. Gleichsam zur Behandlung der Fehlstellen sind die Methoden aus diesem Bereich sehr vielfältig. Ein grundlegendes Verfahren ist die Filterung auf Grundlage eines gleitenden Fensters. Chen u. a. [15] filtern die Signale auf Basis eines gleitenden Mittelwerts. Durch die Sensitivität des Mittelwerts in Bezug auf große Ausreißer kann alternativ auch ein gleitender Medianfilter eingesetzt werden. Beide Varianten sind robuste Techniken und eignen sich, insbesondere wenn wenig Wissen über das zu filternde Signal als solches vorliegt. Besonders für die Aufbereitung von Schwingungsdaten werden Filter eingesetzt. Beispielsweise bereiten Wu u. a. [16] die Schwingungsdaten mit einem Minimalentropy

Entfaltungsfiler (engl. Minimum Entropy Deconvolution Filter) für die weitere Verarbeitung vor. Um den Signal- und Rauschanteil zu separieren, setzen Akpudo u. a. [17] empirische Bandzerlegung (engl. Empirical Mode Decomposition) ein, das Ähnlichkeiten zur Fourieranalyse aufweist. Basierend auf konkretem Wissen über die Charakteristik des Signals können auch andere Filtertechniken eingesetzt werden. Chen u. a. [13] nutzen dazu zum Beispiel eine polynomische Abbildung zur Extraktion der Information.

Mit der Diskussion von Ausreißern bzw. Fehlstellen und Filterung werden nur zwei häufige Aspekte adressiert. Die Vorverarbeitung der Daten hängt wesentlich von der Beschaffenheit sowie der Kenntnis über die Daten ab. Somit basiert die grundlegende Vorbereitung der Daten auf einer Vielzahl möglicher Methoden, von denen wenige für den Anwendungsfall geeignete Methoden ausgewählt werden.

2.1.2. Bildung von Features

Auf Grundlage eines bereinigten Datensatzes können sogenannte Features erzeugt werden. Allgemein können verschiedene Klassen von Features gebildet werden.

Die grundlegende Gruppe der Features sind statistische Größen. Kim u. a. [18] erzeugen statistische Größen wie Mittelwert, Standardabweichung, Schiefe als Grundlage für eine nachfolgende Klassifizierung in einer Stützvektormaschine (engl. Support Vector Machine (SVM)). Gleichsam werten Li u. a. [19] die Kurtosis als Feature der Schwingungsdatenverteilung aus.

Die Bildung der statistischen Größen kann neben dem aktuellen Zeitschritt auch vergangene Zeitschritte umfassen, wie Chen u. a. [15] zeigen. Die Nutzung von vorangegangenen Zeitpunkten kann besonders bei dynamischen Systemen wertvolle Informationen liefern. Li u. a. [20] beziehen die zeitliche Entwicklung in die Featurebildung mit ein, indem Differenzen zwischen dem jetzigen und einem vorherigen Zeitschritt gebildet werden. Auch Verfahren wie die Volterra-Reihe werden von Liu u. a. [21] zur Bildung von Features eingesetzt, die in gewisser Weise nicht nur den aktuellen Zustand, sondern ebenso das Gedächtnis an vergangene Zeitschritte abbilden. Neben dem Einbeziehen von vergangenen Zeitschritten ist auch das Beschränken des Zeitintervalls zur Featurebildung wesentlich. Ossai u. a. [22] detektieren, basierend auf statistischen Größen, Wechselpunkte (engl. CP) und zerlegen das Signal in Teilabschnitte für die weitere Verarbeitung.

Die zuvor skizzierten grundlegenden Methoden der Featurebildung werden durch spezielle Verfahren ergänzt. Zheng [11] bildet Features mit Hilfe der Hilbert-Huang-Transformation. Allgemein steht die klare Struktur einer Transformation der Featurebildung durch trainierte Modelle gegenüber. Beispielsweise entwickeln Louen u. a. [23] einen HI basierend auf dem Distanzmaß einer trainierten SVM, als Grundlage für die RUL Schätzung. Zhao u. a. [24] setzen ein mehrschichtiges neuronales Netz (engl. Deep Believe Network (DBN)) basierend auf mehreren beschränkten Boltzmann Maschinen (engl. Restricted Boltzmann Machine (RBM)) ein, um aus dem zeitlichen Verlauf des Kapazitätssignals mehrere Features zu generieren. Phurattanaprapin u. a. [25] setzen zur Featurebildung mehrschichtige Entschlüsselung (engl. multilayer encoding) ein. Bei den komplexeren Methoden ist die Feature- und Modellbildung in manchen Fällen bereits methodisch kombiniert.

Abschließend zeigen Wang u. a. [26], dass der Featurebildungsprozess auch auf zuvor gebildeten Features aufgebaut werden kann, indem durch Verschmelzung der Merkmale

(engl. Feature Fusion) einzelne Messwerte und Features zu einem HI kombiniert werden. Grundlegend lassen sich verschiedene Methodengruppen für bestimmte Anwendungsfelder identifizieren, wie beispielsweise die Fourieranalyse für Schwingungsdaten. Dennoch ist die Featurebildung ein Schritt, der stark an den Anwendungsfall gekoppelt ist und somit individuell ausgeführt wird.

2.1.3. Selektion relevanter Features

Auf Grundlage von einem Datensatz mit verschiedenen Messwerten und aggregierten Features ist besonders vor dem Hintergrund, dass einige Features keine physikalische Basis besitzen und unter Umständen keinen Beitrag zur Modellbildung leisten, eine Auswahl notwendig.

Die statische Bewertung der Abhängigkeit ist eine grundlegende Methode zur Auswahl möglicher Features. Wang u. a. [27] nutzen dazu den Pearsonschen Korrelationskoeffizienten, um den Zusammenhang zwischen dem Verschleiß und einzelnen Einflussgrößen zu bestimmen. Der Korrelationskoeffizient nach Pearson berücksichtigt allerdings nur lineare Zusammenhänge. Eine bessere Abbildung nichtlinearer Zusammenhänge kann der Korrelationskoeffizient nach Spearman liefern. Dieser wird von Lei u. a. [28] zur Bewertung der Features für eine erste Sichtung eingesetzt und im Anschluss durch eine Kollinearitätsprüfung erweitert, um redundante Features zu vermeiden. Diese Varianten berücksichtigen allerdings nur eine 1:1 Beziehung und können komplexere Zusammenhänge nur schwer identifizieren.

Ein weiteres bekanntes Verfahren ist die Hauptkomponentenanalyse (engl. Principle Component Analysis (PCA)). Neben den erweiterten Methoden zur Fehlerdetektion (engl. Fault Detection (FD)) von Ding u. a. [29], wird die PCA häufig zur Dimensionsreduktion eingesetzt. Dies hilft insbesondere in der Modellierungsphase zum besseren Verständnis. Wie Sun u. a. [30] beschreiben, kann die PCA auch zur Featureselektion genutzt werden. Analog selektieren Benkedjough u. a. [31] die Features mittels einer Erwartungswertmaximierung (engl. Expectation Maximization) PCA als Vorbereitung zur Berechnung eines HI mit isometrischer Featurezuordnung (engl. Isometric Feature Mapping). Der Einsatz der PCA und verwandter Methoden wie Projektion latenter Strukturen (engl. Projection Latent Structures (PLS)) und kanonische Korrelationsanalyse (engl. Canonical Correlation Analysis (CCA)) nutzt die mehrdimensionale Abbildung im Gegensatz zum Korrelationskoeffizienten aus und kann auch kollineare Features handhaben [32], [33].

Neben den statistischen Methoden werden auch Machine Learning (ML) Techniken eingesetzt. Dazu gehört beispielsweise der Entscheidungsbaum (engl. Decision Tree (DT)). Die Kombination verschiedener DT zu einer Entscheidungsstruktur wird Zufallswald (engl. Random Forest (RF)) genannt. Li u. a. [34] setzen eine Featureselektion durch Trainieren eines initialen RF Modells um. Dieser basiert auf verschiedenen DT, die Korrelation zwischen der RUL und den Features abbilden und mittels einer Bewertung werden die einzelnen Einflussfaktoren gewichtet und ausgewählt. Auch Li u. a. [35] verwenden den RF zur Featureselektion.

Auch komplexere Ansätze werden zur Featureselektion angewendet. Li u. a. [19] nutzen dazu einen mehrschichtigen Feature Extraktion (engl. Multi Layer Feature Extraction) Ansatz, als Anteil eines gefalteten neuronalen Netzes (engl. Convolutional Neural Network (CNN)). Analog zur Featurebildung ist besonders bei den komplexeren Methoden eine Kombination von Featurebildung, Featureselektion und Modellierung gegeben.

Mit der Auswahl der Features werden die wesentlichen Eigenschaften, des darauf aufbauenden Modells, definiert. Eine umfangreiche Vorverarbeitung mit Fokus auf den ersten Bereich der Modellbildung ist daher besonders vor dem Hintergrund von gemessenen Daten sinnvoll.

2.2. Methodenübersicht Restlebenszeitschätzung

Nachfolgend werden die Methoden zur RUL Schätzung in vier verschiedene Methodengruppen eingeteilt. In Unterkapitel 2.2.1 werden die stochastischen Methoden, in Unterkapitel 2.2.2 die Methoden aus dem Bereich ML und in Unterkapitel 2.2.3 die modellbasierten Methoden vorgestellt. Abgeschlossen wird die Diskussion durch die Vorstellung von übergeordneten Aspekten zur Einbettung der RUL Schätzung in Unterkapitel 2.2.4. Eine Übersicht der Methodengruppen inklusive der Anzahl der evaluierten Veröffentlichungen wird anhand von Abbildung 2.1 vorgestellt. Die vollständige Auflistung aller evaluierten Veröffentlichungen sowie deren Anwendungsklassen wird in Abbildung C.1 dargestellt.

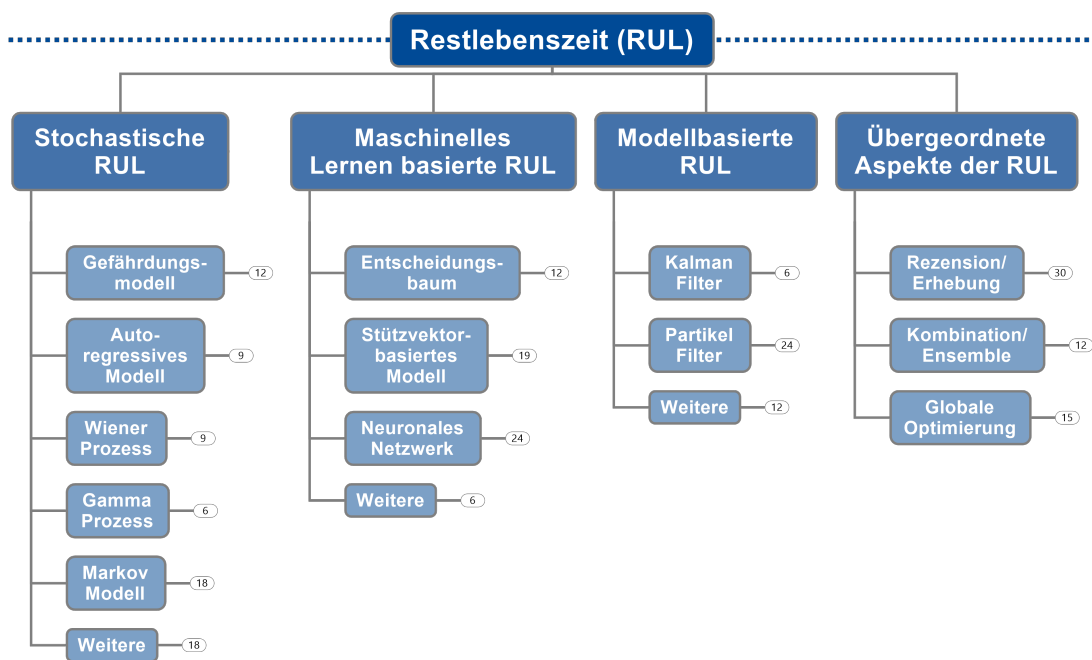


Abbildung 2.1.: Grafische Darstellung der Klassifikation verschiedener Methoden zur Restlebenszeitschätzung untergliedert in Methodengruppen.

2.2.1. Stochastische Restlebenszeitschätzung

Die stochastische Methodengruppe basiert auf einem Teilgebiet der Mathematik und umfasst die Gebiete Wahrscheinlichkeitsberechnung und Statistik. Im Folgenden wird auf Gefährdungs- (engl. Hazard Model (HM)) und autoregressive Modelle (engl. Auto Regressive (AR)) eingegangen. Darüber hinaus werden auch bekannte Methoden zur RUL Schätzung, wie der Wiener Prozess (engl. Wiener Process (WP)), der Gamma Prozess (engl. Gamma Process (GP)) und der Markov Prozess (engl. Markov Process (MP)) vorgestellt. Abschließend wird die Methodengruppe durch Vorstellung weiterer Methoden vervollständigt. Eine Übersicht der RUL Schätzmethode sowie der zu Grunde liegenden Veröffentlichungen wird anhand von Abbildung 2.2 gegeben.

Gefährdungsmodell

Das HM ist eine grundlegende Methode, die auf Cox [36] zurückgeht und das Risiko bzw. die Gefahr eines Gegenstandes beschreibt. Die RUL kann auf Grundlage des Risikos abgeleitet werden, das eine Funktion der Zeit und weiteren Eingangssignalen ist.

Barker u. a. [37] nutzen das HM, um unterschiedliche Einflüsse in einem Gesamtrisiko zu verbinden. Anhand eines Elektrizitätsversorgungssystems wird das Vorgehen vorgestellt, wobei die Berechnung des Risikos im Zentrum steht. Ähnlich entwickeln auch Liao u. a. [38] ein proportionales Gefährdungsmodell (engl. Proportional Hazard Model (PropHM)) zur Kombination von händisch gebildeten Features auf Schwingungsmessdaten eines Wälzkörperlagers. Basierend auf einem logistischen Regressionsmodell (engl. Logistic Regression Model (LRM)) wird das Risiko in eine RUL umgewandelt. Eghbali u. a. [39] erweitern den grundlegenden Ansatz von Cox [36], wobei die Fehlerrate nicht nur zeit-, sondern auch zustandsabhängig ist. Ein weiteres Beispiel liefern Ansell u. a. [40], die das HM zur Risikoschätzung von unterschiedlichen Anwendungsfällen, wie beispielsweise unterschiedlichen Rohrleitungsschäden, einsetzen.

Allgemein ist die Risikobewertung des HM eine Basis für die Schätzung der RUL.

Autoregressives Modell

Historische Daten enthalten wesentliche Informationen zur Beschreibung des Systems. Diesen Aspekt greifen AR Modelle auf, indem vergangene Messdaten zur Schätzung des aktuellen Wertes verwendet werden. Die Schätzung basiert auf der Summe der gewichteten vergangenen Messwerte. AR Modelle bilden die Basis für Erweiterungen, wie beispielsweise das Auto Regressive Moving Average (ARMA) Modell, das einen gleitenden Mittelwert (engl. Moving Average (MA)) miteinbezieht, oder das integrierte ARMA Modell (engl. Auto Regressive Integrated Moving Average (ARIMA)), das dynamische Systeme abbilden kann.

Wu u. a. [16] stellen ein ARIMA Modell vor, das zur Schätzung der Degradation von Wälzkörperlagern eingesetzt wird. Dazu wird das Modell auf ein aussagekräftiges und charakteristisches Schwingungssignal angewendet. Wang u. a. [26] entwickeln anhand eines Getriebelagerschadens einer Windkraftanlage einen Partikelfilter (engl. PF) sowie ein ARMA Modell zur Schätzung der RUL des Lagers. Wang u. a. [41] betten das Konzept zur Schätzung, auf Grundlage von Turbofan-Daten aus der Prognostics and Health Management (PHM) Datachallenge 2008, ein. Konkret wird die Ähnlichkeit der Ergebnisse unterschiedlicher Modelle mit der Realität auf Basis der euklidischen Distanz verglichen und zu einem Gesamtergebnis zusammengeführt.

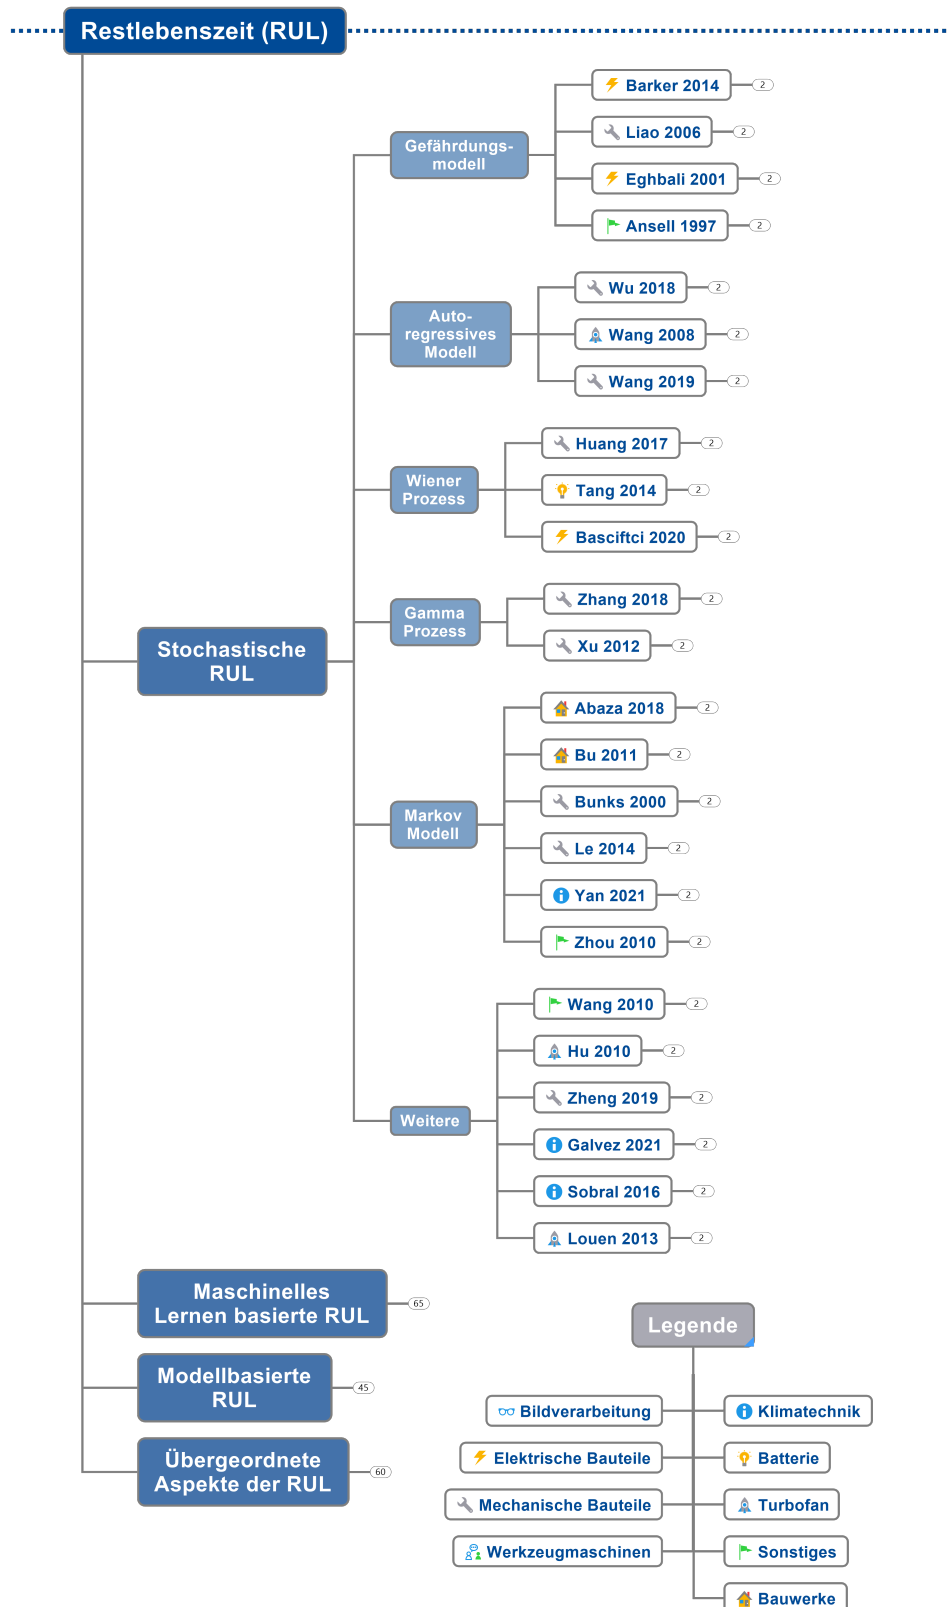


Abbildung 2.2.: Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die stochastische Methodengruppe.

Modelle auf Grundlage der AR Methode zeichnen sich durch die starke Beziehung zu vergangenen Daten und wiederkehrenden Mustern aus. Die einfache Form resultiert in einem verhältnismäßig geringen Rechenaufwand der RUL Schätzung.

Wiener Prozess

Der WP ist eine Sonderform des Levy Prozesses und geht auf Norbert Wiener zurück. Der stochastische Prozess enthält im eindimensionalen Fall einen Driftterm, der mit einer Brownschen Bewegung (engl. Brownian Motion (BM)) überlagert ist.

Basciftci u. a. [42] berechnen die RUL von Generatoren auf Basis des WP, wobei die Last als Einflussfaktor berücksichtigt wird. Das übergeordnete Ziel ist die bestmögliche Instandhaltungsmaßnahme unter der Einschränkung der Generatorbelastung. Huang u. a. [43] schätzen die Degradation von Wälzkörperlagern mit einem adaptiven WP Modell. Die Besonderheit ist, dass die zugrunde gelegte Verteilung für die BM eine schiefe Normalverteilung ist. Tang u. a. [44] nutzen den WP zur Schätzung der RUL von Batterien auf Basis eines Datensatzes der nationalen Aeronautik- und Raumfahrtbehörde (engl. National Aeronautics and Space Administration (NASA)).

Die Variation der Anwendungsfälle unterstreicht die Relevanz des WP zur Schätzung der RUL. Die Einfachheit des Modells ist vorteilhaft für die Implementierung und zugleich ist die Linearität eine Einschränkung für die Abbildung.

Gamma Prozess

Gleichsam wie der WP ist auch der GP eine Sonderform des Levy Prozesses. Im Gegensatz zum WP gibt es keinen Driftterm, wodurch die Veränderung lediglich durch positive Sprünge hervorgerufen wird, die auf einer Gammaverteilung basieren.

Zhang [45] schätzt die RUL eines Riemenantriebs mit einem GP anhand der Schätzung eines Residuumsignals. Dieses wird im Rahmen der Vorverarbeitung durch eine CCA generiert. Xu u. a. [46] bilden die Simulation eines Risswachstums durch einen stochastischen GP ab und integrieren diesen in ein Zustandsraummodell (ZRM). Hierbei werden die Vorzüge des adaptiven Charakters sowie die vielfältige Anwendbarkeit deutlich.

Die unterschiedlichen Anwendungen verdeutlichen den universellen Charakter des GP insbesondere in Kombination mit anderen Methoden. Die Vorgabe einer strengen Monotonie ist jedoch eine Einschränkung hinsichtlich der Modellierung.

Markov Modell

Das Markov Modell (engl. Markov Model (MM)) basiert auf einem MP, der die Transition zwischen diskreten Zuständen mit definierten Wahrscheinlichkeiten belegt. Die Abbildung verdeckter Zustände wird durch ein verdecktes Markov Modell (engl. Hidden Markov Model (HMM)) realisiert.

Yan u. a. [47] entwickeln anhand des Datensatzes ASHRAE-1312 eines Hubschraubers ein halbverdecktes Markov Modell (engl. Semi Hidden Markov Model (SHMM)), um die RUL zu schätzen. Die gemessenen Daten sind fehlerfrei und werden anhand eines Modells mit simulierten Fehlerdaten erweitert. Bu u. a. [14] stellen ein Modell zur Schätzung der Degradation von Brücken auf Basis eines MP vor. Die Transitionsmatrix, die die Übergangswahrscheinlichkeiten zwischen den Zuständen beschreibt, ist dünn besetzt. Somit ist nur ein Verbleib in dem aktuellen Zustand oder eine Verschlechterung in den nächstmöglichen Zustand vorgesehen. Analog bilden Bunks u. a. [48]

die RUL Schätzung eines Hubschraubergetriebes mit einem HMM ab. Die Zustände umfassen neben zwei Fehlerstufen auch einen fehlerfreien Zustand sowie verschiedene Drehmomentbetriebspunkte. Demnach kann das Drehmoment in diskreten Stufen variiert werden, die Fehlerstufen können jedoch nur gleichbleiben oder sich verschlechtern. Le u. a. [49] nutzen zur Schätzung des Risswachstums der RUL ein teilverdecktes Mehrzweig Markov Modell (engl. Multi Branch Semi Hidden Markov Model (MBSHMM)). Die Daten eines Wälzkörperlagers werden anhand eines Paris Erdogan Modells generiert. Das Modell bildet verschiedene Fehler innerhalb einer Schätzung ab und knüpft an die realen Herausforderungen an, in denen mehrere Fehler sich zeitgleich überlagern können. Abaza [50] nutzt einen MP zur Schätzung der Straßenbelagsdeckschichtdicke unter bestimmten Belastungsszenarien. Abschließend entwickeln Zhou u. a. [51] anhand von Simulationsdaten eines kontinuierlichen Rührreaktors einen MP zur Schätzung des Betriebszustandes. Die Transitionsmatrix wird durch sogenannte Plausibilitätsregeln (engl. Belief Rules) mit den Umgebungseinflüssen verknüpft, das eine Abbildung von äußeren Einflüssen und Expertenwissen ermöglicht.

Der MP bietet in Form des HMM die Möglichkeit nicht vollständig beobachtbare Prozesse abzubilden. Die Modellierung eines kontinuierlichen Prozesses durch diskrete Zustände kann für einige technische Anwendungen eine Einschränkung darstellen.

Weitere Stochastische Methoden

Im Folgenden werden einzelne Konzepte vorgestellt, die aus dem Bereich der Stochastik stammen, jedoch wenig gemeinsame Eigenschaften zur Berechnung der RUL besitzen. Ein grundlegendes Konzept stellen Sobral u. a. [52] zur Schätzung der mittleren Zeit bis zum Eintreten des Fehlers am Beispiel einer Heiz- und Klimaanlage vor. Im konkreten Fall wird eine statistische Schätzung auf Basis der Weibullverteilung aufgebaut und mit einem exponentiellen Degradationsmodell kombiniert. Ebenfalls basierend auf einer Weibullverteilung entwickeln Louen u. a. [23] eine RUL Schätzung mit dem Fokus auf der Erstellung des HI mittels einer SVM und zeigen die Leistungsfähigkeit anhand eines Turbofan Benchmarks. Neben dem WP und GP gibt es auch noch weitere stochastische Prozesse. Einen stochastischen Prozess stellen Gálvez u. a. [53] anhand von simulierten Fehlerdaten eines hybriden Modells für den Luftfilter einer Zugklimaanlage vor. Die Modellbildung der Degradation ist vollständig datenbasiert und bezieht keine weiteren Features mit ein. Auch Zheng [11] entwickelt ein lineares stochastisches Modell zur Schätzung von Wälzkörperlagern auf Basis der PHM Data Challenge 2012. Neben der Schätzung besteht der Fokus in der Entwicklung des HI auf Basis der Hilbert-Huang Transformation. Wang u. a. [54] stellen einen weiterführenden Ansatz auf Basis von sogenannten grauen Modellen (engl. Grey Model (GM)) vor, das dem Bereich der Informationstheorie entstammt. Kennzeichnend für die GM Methode ist, dass die Einflüsse teilweise bekannt und teilweise unbekannt sind [55]. Hu u. a. [56] beschreiben die Schätzung der RUL von Turboladern anhand der offensichtlichen Begründung (engl. Evidential Reasoning), die einzelne Feature gewichtet und miteinander verknüpft. Das Ergebnis ist die Ausgabe eines diskreten, zuvor definierten Zustandes, der beispielsweise zur Unterstützung der Instandhaltung genutzt werden kann.

Stochastische Methoden ermöglichen die Abbildung zufälliger Einflüssen auf die RUL Schätzung. Die geringe Komplexität der Modelle ermöglicht eine ressourcenschonende Onlineimplementierung. Dennoch sind die Abbildungen der Modelle zumeist einfach und beschreiben nur bedingt komplexe Zusammenhänge.

2.2.2. Maschinelles Lernen basierte Restlebenszeitschätzung

Für die Schätzung der RUL werden Verfahren aus dem Bereich ML eingesetzt, die auf eine spezifische Aufgabe trainiert werden. Im Anschluss können die Eigenschaften des trainierten Modells auf gleichartige unbekannte Daten angewendet werden. Das Spektrum der Algorithmen reicht von der intuitiven Anwendung durch DT, über komplexere Verfahren wie SVM bis zu Algorithmen wie neuronale Netze (engl. Neural Network (NN)) aus dem Bereich des sogenannten tiefen Lernens (engl. deep learning). Nachfolgend werden die Verfahren anhand von Anwendungsbeispielen skizziert. Die evaluierten Veröffentlichungen werden in Abbildung 2.3 dargestellt und die Zuordnung zu den jeweiligen Methoden aus der Methodengruppe des maschinellen Lernens visualisiert.

Entscheidungsbaum

Für Klassifizierungs- oder Regressionsaufgaben können DT eingesetzt werden. Analog zu einer Regression wird durch eine Kombination der Eingangsvariablen die Ausgangsvariable approximiert. Die einfachste Form der Unterteilung ist die Bisektion, die anhand einer Eingangsvariable den Wertebereich durch einen sogenannten Entscheidungsknoten in zwei Abschnitte unterteilt. Durch Wiederholen dieses Vorgehens mit anderen Eingangsvariablen kann der Entscheidungsbaum Ebene für Ebene aufgebaut werden und endet mit einem Endknoten, der die Klassifizierung beschreibt. Die Teilung kann auf Basis von unterschiedlichen Metriken bewertet werden. Eine beispielhafte Metrik ist die Transinformation (engl. Mutual Information), die eine Verringerung der Entropie mit einer zusätzlichen Aufteilung in Verbindung bringt. Im Rahmen des Trainingsprozesses wird die Anzahl sowie die Entscheidungsgrenze der Knoten optimiert.

Gerdes u. a. [57] berechnen die RUL einer Flugzeugraumklimatisierungsanlage auf Basis von gemessenen Betriebsdaten eines Flugzeuges. Methodisch wird ein DT eingesetzt, der sowohl numerische und boolesche Features verarbeitet. Li u. a. [20] schätzen Defekte von Festplatten anhand eines gradientenverstärkten Regressionsbaums (engl. Gradient Boosted Regression Tree (GBRT)). Das Ziel ist die Reduktion von Datenverlusten und der optimale Austausch in Serveranwendungen. Ossai u. a. [22] stellen eine Schätzung der RUL von Batterien auf Basis des NASA Datensatzes vor. Dazu wird eine extrem randomisierte Baumregression (engl. Extremely Randomized Tree Regression) eingesetzt, die auf einer vorangegangenen Signalzerlegung einer rollierenden Standardabweichung basiert. Chen u. a. [13] fügen mehrere DT zu einem RF zusammen und ermöglichen damit bessere Ergebnisse sowie eine robustere Abbildung der RUL Schätzung. Chen u. a. [13] selektieren die Features mit Hilfe einer kleinsten absoluten Schrumpfungs- und Auswahloperator (engl. Least Absolute Shrinkage and Selection Operator (LASSO)) Featureselektion und verdeutlichen die Funktionalität anhand eines Datensatzes zur Simulation eines kommerziellen modularen Luftantriebssystems (engl. Commercial Modular Aero-Propulsion System Simulation (C-MAPSS)) der NASA.

Komplexe Prozesse können durch DT abgebildet werden und sind für den Endnutzer anteilig nachvollziehbar. Die Extrapolation der Abbildung ist jedoch nur bedingt möglich. Die Kombination von mehreren DT zu einem RF steigert die Robustheit und Leistung, wirkt jedoch der Nachvollziehbarkeit entgegen.

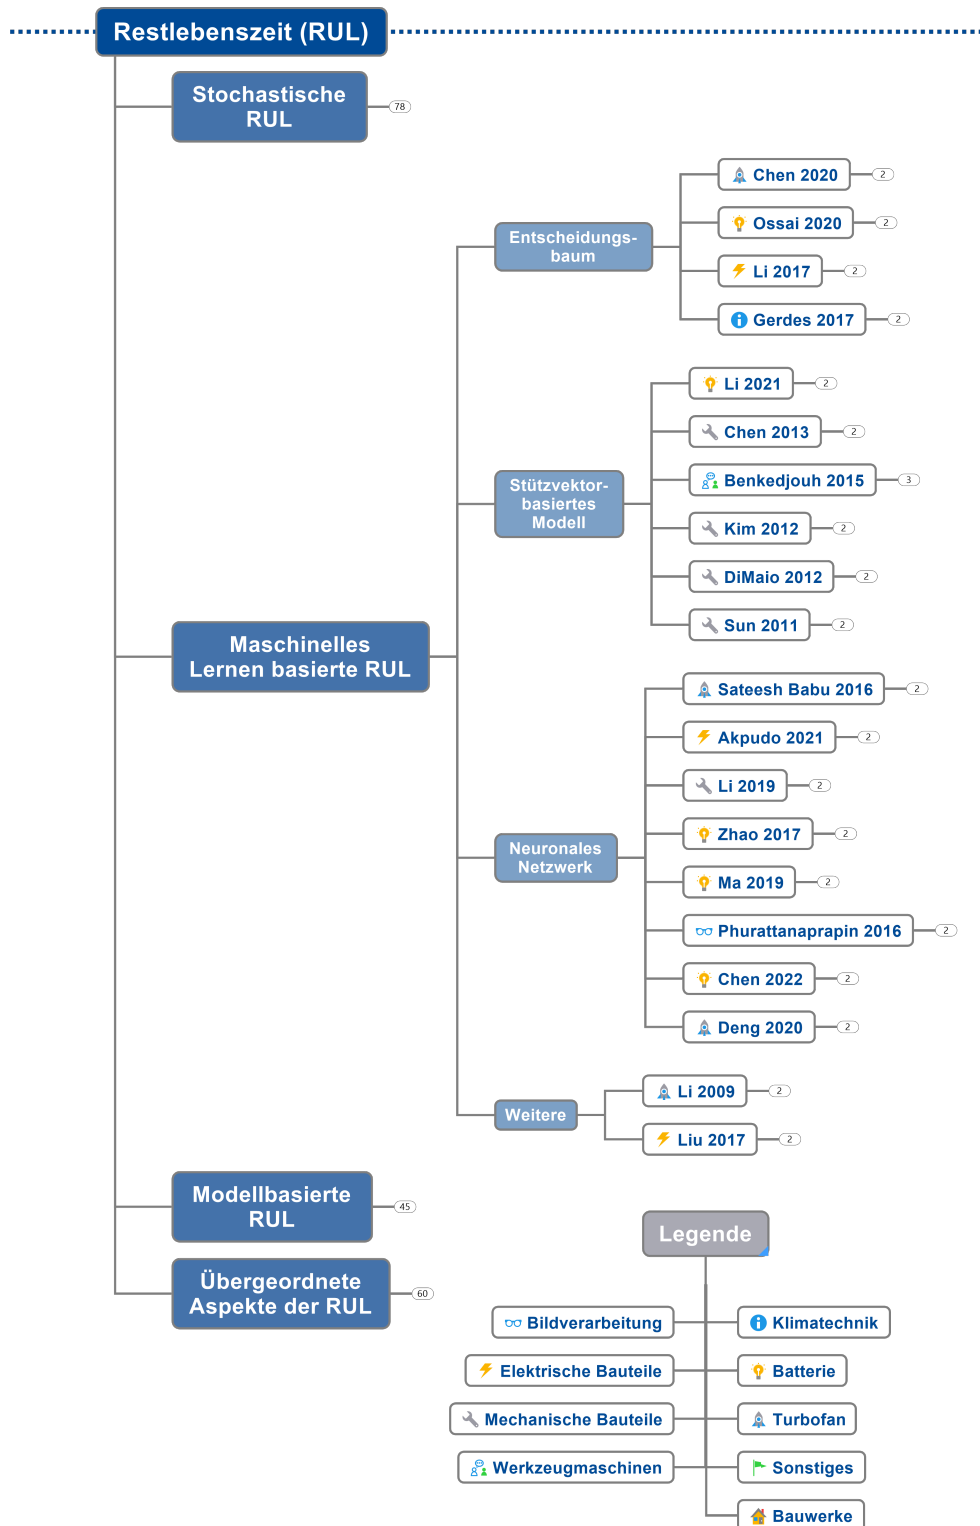


Abbildung 2.3.: Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die Methodengruppe des maschinellen Lernens.

Stützvektorbasiertes Modell

Die stützvektorbasierten Methoden umfassen unter anderem die SVM sowie die Stützvektorregression (engl. Support Vector Regression (SVR)). Ähnlich wie DT kann die Methodik zur Klassifikation mit SVM oder zur Regression mit SVR genutzt werden. Im Gegensatz zur kleinsten Quadrate (engl. Ordinary Least Squares (OLS)) Regression wird durch die SVR nicht der quadrierte Fehler sondern die L2-Norm des Koeffizientenvektors minimiert. Das Minimierungsproblem besitzt einen Hyperparameter, mit dem die Lockerheit (engl. Slack) und daraus folgend auch die Abweichung zum Rand der Trennebene eingestellt wird. Die Einschränkung der Linearität, kann mit einem passenden Kern (engl. Kernel) kompensiert und nichtlineares Verhalten abgebildet werden.

Chen u. a. [15] testen in einem Prüfstand Wälzkörperlager und messen Unterschiede in den Degradationsverläufen. Zur Berechnung der RUL wird eine SVM genutzt, die auf die Degradationsdaten trainiert wird. Benkedjough u. a. [31] untersuchen den Verschleiß von Schneidwerkzeugen von Werkzeugmaschinen. Die gemessenen Prüfstanddaten werden zu einem HI zusammengefasst und auf Basis einer SVR in eine RUL umgerechnet. Sun u. a. [30] zeigen auf Basis einer SVM anhand von Wälzkörper Experimentdaten der Universität Cincinnati, die Notwendigkeit zur Nutzung eines geeigneten Kernels für die Abbildung nichtlinearer Zusammenhänge auf. Li u. a. [34] schätzen mit einer SVR die RUL von Batterien eines NASA Datensatzes. Die Featureselektion wird auf Basis eines RF vorgenommen. Anhand einer Flüssiggaspumpe untersuchen Kim u. a. [18] gemessene Lagerschäden und wenden eine SVM zur Unterscheidung unterschiedlicher Schadensstadien an, die im Anschluss in eine RUL umgerechnet werden. Ebenfalls auf Basis von Wälzkörperlagern schätzen Di Maio u. a. [58] die RUL mit einer Relevanzvektormaschine (engl. Relevance Vector Machine (RVM)), die eine optimierte Variante der SVM mit geringerer Stützvektoranzahl ist und sowohl zur Klassifizierung als auch zur kontinuierlichen Abbildung eingesetzt werden kann.

Die stützvektorbasierten Methoden zeigen Stärken in der Abbildung von nichtlinearen Zusammenhängen. Innerhalb der Kategorie der ML Algorithmen sind die Methoden noch in Ansätzen für den Endanwender nachvollziehbar, wobei der Einsatz von unterschiedlichen Kernen die Verhaltensweise stark verändert.

Neuronales Netzwerk

Ein einfaches NN besteht aus mindestens einer Ein- und Ausgabeschicht. Dazwischen können mehrere verdeckte Schichten liegen. Jede Schicht enthält eine bestimmte Anzahl von sogenannten Neuronen, die zunächst mit allen Neuronen der vorangegangenen sowie der nachgelagerten Schicht verbunden sind. Jede Verbindung der Neuronen besitzt eine Gewichtung, die im Rahmen des Trainingsprozesses optimiert und somit die Eigenschaften des Netzes geändert werden. Neben der Anzahl der Schichten und Neuronen bestimmt die konkrete Architektur des Netzes maßgeblich die Eigenschaften des Modells. Sateesh Babu u. a. [59] entwickeln auf Basis des NASA C-MAPSS Datensatzes und einem CNN eine Schätzung der RUL. Durch mehrere Schichten ist die Anpassungsfähigkeit an den spezifischen Anwendungsfall gegeben. Ebenfalls auf Basis eines CNN berechnen Li u. a. [19] die RUL von Wälzkörperlagern der PHM Data Challenge 2012 und Daten des PRONOVIA Prüfstands. Eine weitere Entwicklung von NN sind extrem lernende Maschinen (engl. Extreme Learning Machine (ELM)), die grundlegend eine einfache Struktur besitzen, jedoch kombiniert sehr leistungsfähig sind. Phurattanapapin

u. a. [25] setzen eine ELM anhand der Datensätze Semeion, MNIST und NORB zur Bildererkennung ein, das ein unbeaufsichtigtes Training zur Featurebildung mit einem beaufsichtigten Training der ELM kombiniert. Ma u. a. [60] entwickeln eine Erweiterung der ELM durch Anordnung in mehreren Schichten zur Schätzung der RUL von Batterien. Es wird deutlich, dass die komplexen technischen Zusammenhänge durch einfache ELM nicht abgebildet werden können, allerdings mit steigenden Einstellungsmöglichkeiten das Risiko von Überanpassung (engl. Overfitting) besteht. Deng u. a. [61] stellen eine weitere Spezialform des NN in Form eines Long Short Term Memory (LSTM) vor. Dies wird zur Schätzung der RUL von Turbofans auf Basis der NASA C-MAPSS Daten eingesetzt. Chen u. a. [62] nutzen ein LSTM in Kombination mit einer BM zur adaptiven Anpassung an historische Degradationsverläufe. Das Verfahren wird anhand von Batteriedaten des Zentrums für fortgeschrittene Lebenszyklusforschung (engl. Center for Advanced Life Cycle Engineering (CALCE)) und Simulationsdaten evaluiert. Ebenfalls auf Basis des CALCE Batterie Datensatzes trainieren Zhao u. a. [24] ein DBN und eine RVM zur Schätzung der RUL von Batterien. Akpudo u. a. [17] entwickeln auf Basis von gestapelten Repräsentationskomprimierern (engl. Stacked Auto Encoder) und geschlossenen wiederkehrenden Einheiten (engl. Gated Recurrent Unit) ein Konzept aus Fehlerdetektion und RUL Schätzung. Auf Basis von Daten einer Vibrationspumpe wird die Detektion und Prognose evaluiert, wobei die Features auf einem Grundsignal aufgebaut sind.

Die Methodenklasse der NN ermöglicht die Abbildung von komplexen Zusammenhängen und enthält durch die Struktur indirekt eine Featurebildung sowie eine Featuresелеktion. Wie Zhao u. a. [24] andeuten, ist die Herausforderung die geeignete Wahl der Parameter, die das Verhalten der Abbildung maßgeblich definieren. Ebenso verdeutlichen die verwendeten Datensätze der zuvor genannten Veröffentlichungen, dass ein großes Datenvolumen für das Training der Methoden benötigt wird.

Weitere Methoden des Maschinellen Lernens

Neben den zuvor genannten Verfahren werden auch andere Methoden aus dem Bereich ML eingesetzt. Beispielsweise bilden Liu u. a. [21] auf Basis einer Volterra Zerlegung sowie der bekannten Temperatur und Belastung von Transistoren die Schätzung der RUL durch einen k-nächste-Nachbarn (engl. k Nearest Neighbor (KNN)) Ansatz ab. Li u. a. [63] sagen die RUL einer Gasturbine von Chevron durch eine intuitive lineare und quadratische Abbildung vorher. Die Modelle sind robust, lassen jedoch keine Eingangssignale zu und der Wechsel zwischen den Modellen findet erst während der Betriebszeit statt, sodass die Schätzung anfangs überschätzt wird.

Beide Modelle können als einfache Varianten aus dem Bereich ML angesehen werden. Aufgrund der grundlegenden Struktur dieser Methoden sind die Modelle nachvollziehbar und ermöglichen die Entscheidungsunterstützung in praktischen Anwendungsfällen.

Die Gruppe der ML Methoden deckt ein großes Feld ab, das von intuitiven Anwendungen bis zu komplexen Strukturen reicht. In Abhängigkeit zum Anwendungsfall sind diese komplexen Modelle zum Teil notwendig, bringen jedoch eine erhöhte Achtsamkeit für die Einstellung der Parameter und Hyperparameter mit sich. Besonders das große Volumen an Trainingsdaten ist eine Herausforderung für viele praktische Anwendungsfälle und eine mögliche Erklärung für die häufige Anwendung dieser Methoden auf bekannte Benchmarks mit großem Datenumfang.

2.2.3. Modellbasierte Restlebenszeitschätzung

Die Methoden aus dem Bereich modellbasierte RUL Schätzung gründen sich auf bekannte Zusammenhänge in Form von Gleichungssystemen. Ein bekanntes Beispiel für einen physikalischen Zusammenhang ist ein Feder-Dämpfer-System. Die Einbettung dieser Gleichungssysteme in ein geeignetes Konzept zur Berechnung der RUL wird im Folgenden anhand des Kalmanfilters (engl. Kalman Filter (KF)) und PF vorgestellt und mit weiteren Methoden ergänzt. Die zugrunde gelegten Veröffentlichungen werden in Abbildung 2.4 für die modellbasierte Methodengruppe dargestellt.

Kalmanfilter

Im Zentrum des KF steht die Schätzung des Zustands. Anhand von aktuellen Beobachtungen kann die Schätzung des Zustands mit jeder neuen Beobachtung verbessert werden. Diese Verbesserung wirkt sich auch positiv auf die Schätzung der RUL aus. Der KF ist für die Schätzung von linearen Systemen konzipiert unter der Annahme, dass sowohl Prozess- als auch Messrauschen normalverteilt und weiß sind.

Beispielhaft identifizieren Batzel u. a. [64] im Rahmen einer Fehleranalyse Windungskurzschlüsse und fehlerhafte Gleichrichterdiode. Abgeleitet aus der Fehleranalyse wird ein synthetischer Fehler generiert und ein KF zur Schätzung der RUL eingesetzt. Einen erweiterten Ansatz entwickeln Lim u. a. [65] anhand der Daten eines CM Systems der Firma SKF, das an einem AH64D Hubschrauber installiert ist. Das Schätzmodell basiert auf mehreren KF und wechselt automatisch in Abhängigkeit des diskreten Degradationszustands von gut zu mäßigem oder beschleunigtem Verschleiß. In diesem Zusammenhang wird darauf verwiesen, dass in zukünftigen Studien nichtlineare Filter zur besseren Abbildung genutzt werden sollen.

Die Implementierung des KF ist auf Basis der mathematischen Matrixrechenoperationen sowohl mit geringer Rechenleistung möglich als auch skalierbar. Limitierende Faktoren sind ein normalverteiltes Mess- und Prozessrauschen sowie die Linearität des Gleichungssystems. Diese Annahmen können in praxisnahen Anwendungsfällen nicht immer eingehalten werden.

Partikelfilter

Auf der Grundlage eines KF lässt sich das Konzept eines PF entwickeln. Analog zum KF besitzt der PF ein Gleichungssystem zur Beschreibung des Zustands bzw. dessen Transition. Im Gegensatz dazu benötigt der PF aber weder ein lineares Gleichungssystem noch ein normalverteiltes Prozess- oder Messrauschen. Dies ermöglicht einen Einsatz in weiteren Anwendungsfällen.

Sun u. a. [66] stellen einen grundlegenden PF zur RUL Schätzung von Batterien vor. Das Modell gründet sich auf historischen Daten und einer polynomischen Abbildung dritten Grades. Zhu u. a. [67] entwickeln ein Modell zur Schätzung des Schmieröls von Windkraftanlagen anhand von Prüfstanddaten. Ebenfalls anhand eines mechanischen Anwendungsfalles entwickeln Lei u. a. [28] ein Konzept auf Grundlage eines PF zur Schätzung der RUL. Die Basis dafür sind Wälzkörperlagerdaten des PRONOVIA Prüfstands und die wesentliche Aktivität bezieht sich auf die Vorbereitung der Daten. Ebenfalls anhand von Prüfstanddaten stellt Wang u. a. [27] einen PF zur Schätzung des Schneidwerkzeugverschleißes von Werkzeugmaschinen vor. Im Fokus steht ein grundlegendes physikalisches Modell, das mit Hilfe einer SVR optimiert wird. Tang u. a. [10] stellen

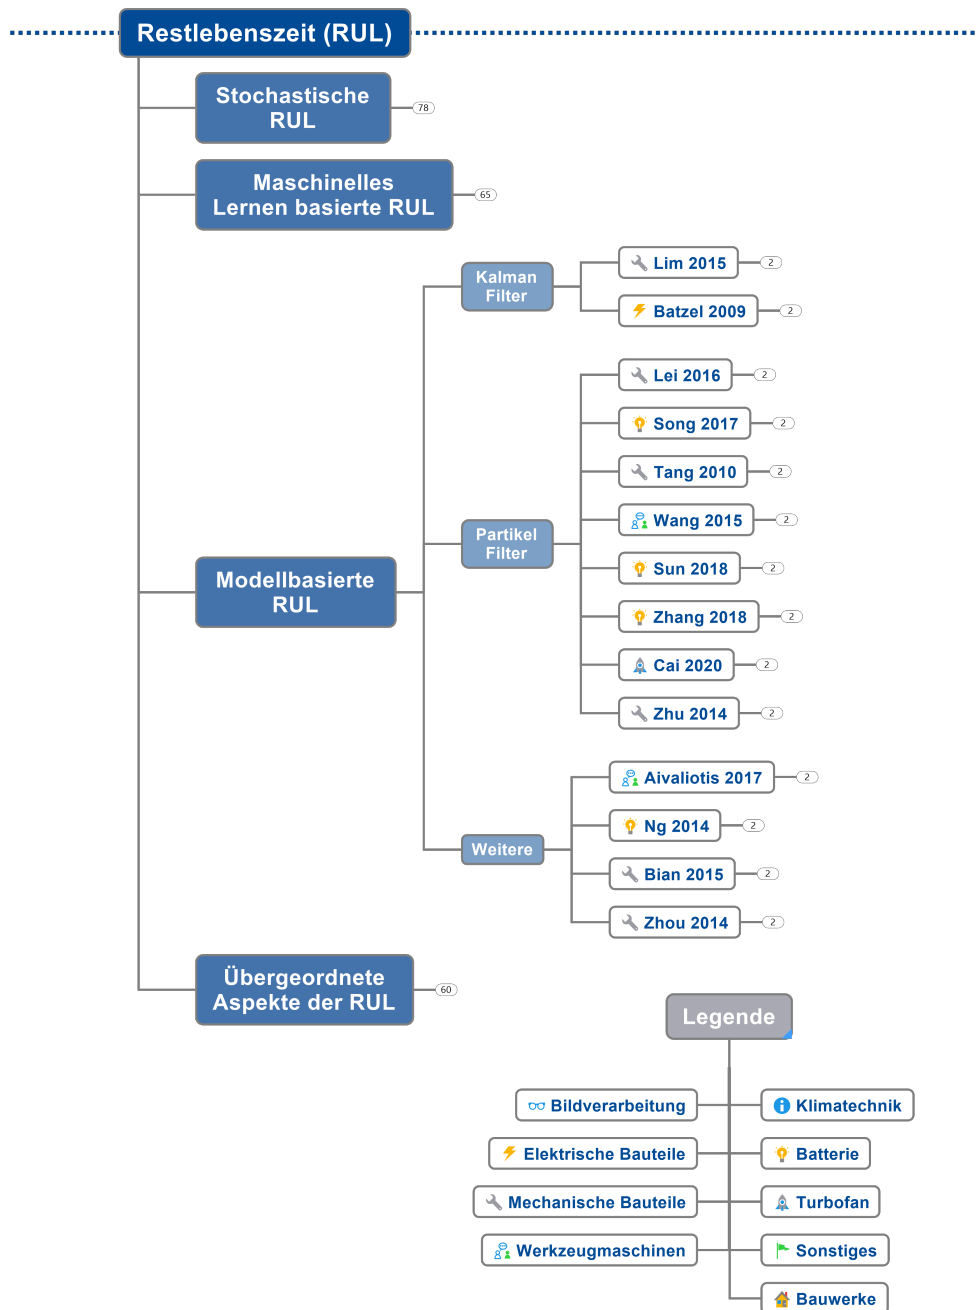


Abbildung 2.4.: Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die modellbasierte Methodengruppe.

verschiedene Filtertechniken vor zur Schätzung des Risswachstums einer Getriebeplatte eines UH60 Hubschraubers. Dabei wird unterstrichen, dass der Exakt Filter eine sehr gute Wahl ist, falls die Gleichung analytisch lösbar ist und alternativ ein PF mit wenig Einschränkungen eingesetzt werden kann. Auf der Grundlage eines unbeschränkten Kalmanfilters (engl. Unscented Kalman Filter (UKF)) setzen Zhang u. a. [68] einen PF zur Schätzung der RUL von Batterien des NASA Ames Datensatzes ein. Besonders die Wahl eines Optimierungsalgorithmus trägt zur Verbesserung der Verteilung der Partikel und somit zur Gesamtleistung des PF bei. Auf Basis von CALCE Batterie Daten und Raumfahrt Batteriedaten entwickeln Song u. a. [69] einen hybriden Ansatz aus der Kombination eines nichtlinearen AR Modells sowie einem PF. Die Anwendung des nichtlinearen NASA Batterie Modells verdeutlicht in diesem Zusammenhang auch die Notwendigkeit von Expertenwissen für den Modellierungsprozess. Cai u. a. [70] erweitern den PF durch einen Ähnlichkeitsabgleich mit historischen Degradationszyklen, um bestmögliche Startwerte zu definieren. Die Evaluierung basiert auf dem NASA Datensatz C-MAPSS und zeigt die indirekte Integration von vergangenem Wissen. Methoden auf Basis des PF haben einen weiten Einsatzbereich, der durch unterschiedliche Anwendungsfälle sowie realitätsnahe Prüfstandsversuchen abgesteckt wird. Die Kombination mit anderen Methoden verdeutlicht die Flexibilität des PF, wobei die hohe Rechenleistung ein Gegengewicht setzt, das besonders Echtzeitanwendungen einschränkt.

Weitere modellbasierte Methoden

Neben den zuvor genannten Verfahren in der Methodengruppe der modellbasierten RUL Schätzung gibt es unterschiedliche Ansätze, die nicht direkt den Filtern zugeordnet werden. Ng u. a. [71] setzen eine Naive Bayes basierte Methode ein, um die RUL von Batterien des NASA Ames Datensatzes zu schätzen. Die Bayessche Aktualisierung (engl. Update) ist ein Aspekt des PF und daher eine gemeinsame Funktionskomponente. Im Vergleich zu den klassischen modellbasierten RUL Schätzmodellen unterscheidet sich der Ansatz von Ng u. a. [71], aufgrund deren indirekten Schätzung der RUL. Bian u. a. [72] entwickeln anhand von Labordaten eines Wälzkörperprüfstands ein Konzept auf Basis der Bayessche Aktualisierung, das Umgebungseinflüsse durch stochastische Prozesse einbindet. Auch Zhou u. a. [73] untersuchen eine methodische Kombination aus Zeitverzerrung (engl. Time Warping) und Bayesscher Aktualisierung, um die gemeinsamen Eigenschaften von unterschiedlichen Degradationsprozessen zusammenzuführen. Dies ist insbesondere von Interesse, wenn nicht alle physikalischen Eigenschaften des Prozesses bekannt sind. Abschließend stellen Aivaliotis u. a. [74] ein physikalisches Modell zur Schätzung des Zustands von Werkzeugmaschinen vor.

Methoden, wie die Bayessche Aktualisierung oder Ähnliche, dienen zur geeigneten Einbettung der Modelle in ein Gesamtkonzept. Im Hinblick auf das Modell als solches gibt es keine wesentlichen Unterschiede. Da die Bayessche Aktualisierung ein Teil des PF bzw. des KF ist, gibt es eine inhaltliche Überschneidung.

Modellbasierte Methoden sind in Bezug auf die Verarbeitung und Abbildungsqualität anderen Verfahren überlegen. Die Herausforderung liegt in den Modellen als solchen, denn neben klassischen Bewegungsgleichungen sind die Zusammenhänge technischer Anwendungsfälle komplexer und oftmals nicht bekannt. Aivaliotis u. a. [74] formulieren im Ausblick, dass die Modelle zukünftig präzisiert werden sollen, um die Fehler zu minimieren. Diese Reflektion beschreibt, dass die Bildung des Modells sowie dessen Parametrierung die eigentliche Herausforderung modellbasierter Methoden darstellen.

2.2.4. Übergeordnete Aspekte der Restlebenszeitschätzung

Die zuvor vorgestellten Veröffentlichungen geben einen Überblick über spezifische Verfahren und Techniken. Für einen initialen Überblick sowie einen direkten Vergleich verschiedener Methoden gibt es spezifische Veröffentlichungen, die nachfolgend vorgestellt werden. Weiterhin werden im Speziellen Methodenkombinationen und Ensemble sowie die RUL als Teil einer globalen Optimierung vorgestellt. Anhand von Abbildung 2.5 wird eine Übersicht der spezifischen Veröffentlichungen mit Fokus auf die übergeordneten Aspekte der RUL Schätzung vorgestellt.

Rezensionen und Erhebungen

Okoh u. a. [75] führen grundlegend in die Thematik der RUL Schätzung ein, wobei der Schwerpunkt auf der Differenzierung zwischen unterschiedlichen mechanischen Schädigungsmechanismen, wie Verschleiß, Korrosion, Bruch und Verformung liegt. Die Schädigungsmechanismen können als Ursache des Degradationsprozesses angesehen werden. Ausgehend von einer Schädigung bauen Park u. a. [76] die logische Kette von der Fehlerdetektion (engl. Fault Detection (FD)), über die Fehlerdiagnose (engl. Fault Diagnosis (FDI)) hin zur Fehlerprädiktion (engl. Fault Prognosis (FP)) auf. Im Rahmen der Veröffentlichungen werden unterschiedliche Technologien, wie PF, AR Modelle sowie ELM thematisiert. Kordestani u. a. [8] zeigen im Gegensatz dazu die vier Phasen der Modellbildung auf, die in *Datenbezug*, *Gesundheitszustandsindikator*, *Gesundheitszustandsdivision* und *Restlebenszeitschätzung* unterteilt werden. Funktional erfolgt die Einteilung in modellbasierte, datengetriebene und wissensbasierte Methoden sowie die Thematisierung von hybriden Kombinationen.

Mathew u. a. [77] vergleichen verschiedene Methoden mit dem Schwerpunkt auf ML Methoden. Anhand des NASA C-MAPSS Datensatzes werden grundlegende Methoden gegenübergestellt. Demnach sind zur Schätzung besonders RF geeignet, wobei auch einfache lineare Modelle unter den besten Bewertungen vertreten sind. An u. a. [12] stellen ebenfalls einen Vergleich der RUL Schätzmethode vor. Grundlegend werden die Methoden PF, NN, GP sowie Bayessche Methoden vorgestellt und abschließend anhand von Simulationsdaten des Paris Risswachstumsmodells verglichen. In diesem Zusammenhang wird die Anpassungsfähigkeit der datengetriebenen Methoden unter der Voraussetzung ausreichend großer Daten unterstrichen. Lei u. a. [9] geben einen umfassenden Überblick über die Einbettung der Schätzung in das Gesamtüberwachungskonzept. Die umfangreiche Evaluierung wird durch grundlegende Berechnungen und Metriken zur Evaluierung der Schätzung ergänzt. Die aufgeführten Anwendungsbeispiele basieren auf bekannten Benchmarkdatensätzen und beziehen sich im Wesentlichen auf Turbofans, Wälzkörperlager und Mühlen.

Neben den umfassenden Recherchen sind auch Veröffentlichungen zu bestimmten Methoden verfügbar. Noortwijk [78] gibt einen Überblick über die Anwendung des GP zur RUL Schätzung. Dabei wird deutlich, dass der GP vorwiegend im Bereich von Einzelsignalschätzung bzw. auf Basis eines HI und weniger für gesamte Systeme eingesetzt wird. Huang u. a. [79] fokussieren sich auf SVM und deren Einsatzfelder. Anhand der genannten Beispiele wird deutlich, dass die SVM vor allem in Kombination mit anderen Methoden eingesetzt wird und dass der Einsatz bisher auf einige wenige Anwendungsfälle, wie Batterien oder ähnlich großen Datensätzen ausgerichtet ist. Der Aspekt der Anwendbarkeit wird auch von weiteren Autoren diskutiert. Vogl u. a. [80]

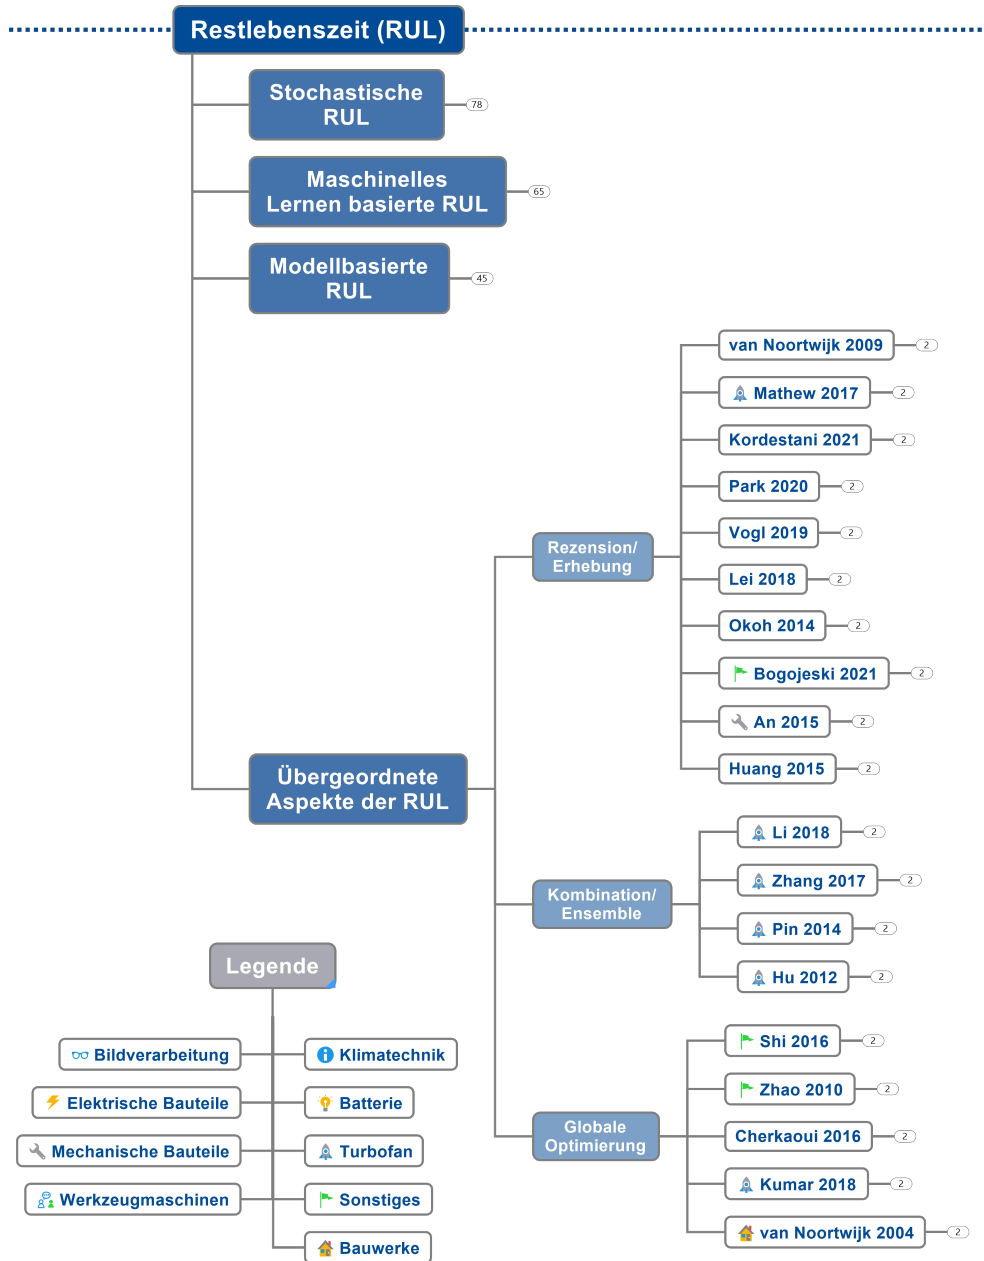


Abbildung 2.5.: Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf übergeordnete Aspekte der Restlebenszeitschätzung.

differenzieren zunächst in FD, FDI und FP und skizzieren die Herausforderungen in der Industrie. Diese werden konkret als Entwicklungsfelder im Bereich Nutzerfreundlichkeit, Standards und Datenintegration identifiziert und benannt. Auch Bogojeski u. a. [81] stellen einen Benchmark verschiedener Methoden anhand von Simulations- und realen Katalysatordegradationsdaten eines industriellen Prozesses vor. Konkret werden bei weniger als 100 Zyklen tendenziell einfachere Modelle empfohlen. Dabei bilden die einfachen Modelle die Prozessabhängigkeiten gut, jedoch die degradationsbedingte Veränderung nicht ausreichend ab.

Die unterschiedlichen Perspektiven zeichnen ein umfassendes Bild von der methodischen Landschaft zur RUL Schätzung und thematisieren auch die Vor- und Nachteile der einzelnen Methoden.

Kombinationen und Ensemble

Die vorgestellten Veröffentlichungen zeigen, dass nur eine geringe Anzahl auf einer Methode allein basiert. Erfolgreiche RUL Schätzer sind meist eine Kombination unterschiedlicher Ansätze und werden auch als Hybride Methoden bezeichnet. Dieser Aspekt wird insbesondere bei Methoden aus dem Bereich Machine Learning noch erweitert, indem mehrere unterschiedliche RUL Schätzungen gleichzeitig berechnet und zu einer Aussage zusammengefasst werden. Diese Kombinationen werden als Ensemble bezeichnet.

Eine effektive Kombination stellen Pin u. a. [82] auf Basis des NASA C-MAPSS Datensatzes vor. Das Ensemble besteht aus einem NN in Kombination mit einem umschaltenden Kalmanfilter (engl. Switching Kalman Filter (SKF)). Der SKF ermöglicht die Schätzung einer konstanten RUL am Anfang der Degradation und wechselt selbstständig in ein lineares Degradationsmodell. Dieser Ansatz kombiniert die Stärken der Einzelmethode für eine bessere Gesamtleistung. Eine umfangreiche Kombination verschiedener Methoden stellen Li u. a. [35] anhand von RF, rückgekoppelten neuronalen Netzen (engl. Recurrent Neural Network (RNN)), AR Modellen und weiteren Methoden vor. Die Einzelergebnisse werden via einem Meta Algorithmus zur Optimierung gebündelt. Dieses Vorgehen wird auch als paralleles Ensemble bezeichnet. Zhang u. a. [83] bilden ein Ensemble aus mehreren DBN, das auf den NASA C-MAPSS Turbofan Datensatz angewandt wird. Ziel ist die Erstellung eines möglichst allgemeinen Ansatzes, der unterschiedliche Anwendungsfälle abdeckt. Auch Hu u. a. [84] erstellen ein Ensemble auf Basis einer ähnlichkeitsbasierten Interpolation sowie RVM, SVM, einer exponentiellen OLS Abbildung und weiteren Methoden. Die Methoden werden anhand des Datensatzes der PHM Data Challenge 2008, eines Transformer- und Lüfterdatensatzes validiert. Die einzelnen Methoden werden auf Basis unterschiedlicher Gewichtungen, die neben dem minimalen Fehler auch die größte Unterschiedlichkeit zu den anderen Verläufen berücksichtigt, bewertet.

Die Kombination verschiedener Verfahren ist naheliegend und sinnvoll, um von den Einzelstärken in Summe zu profitieren. Einer Aggregation von komplexen Methoden anhand einer weiteren komplexen Meta Struktur sind besonders Grenzen in Bezug auf die Akzeptanz und Nachvollziehbarkeit gesetzt, wobei diese Eigenschaften besonders im industriellen Umfeld wesentlich für den Erfolg sind.

Globale Optimierung

Die Schätzung der RUL ist ein wesentlicher Bestandteil zur Verbesserung der Instandhaltungsprozesse, allerdings nicht der einzige notwendige Schritt. Nachfolgend werden daher weitere Aspekte für eine Optimierung auf Basis der RUL aufgezeigt.

Shi u. a. [85] stellen ein Konzept auf Basis eines stochastischen Filters vor, in dem die RUL der Einzelkomponenten zu einer Gesamtaussage der Anlage zusammengeführt wird. Diese Kenntnisse werden auf Grundlage der Einzelkosten zu den Gesamtkosten aggregiert und optimiert. Zhao u. a. [86] fokussieren sich auf die globale Optimierung des Instandhaltungsprozesses und des Austauschzeitpunkts. Zu diesem Zweck werden ein MP mit einem HM kombiniert und Eingangssignale in die Abbildung der RUL Schätzung integriert. Anhand einer Fluggasturbinen Simulation stellen Kumar u. a. [87] einen Algorithmus vor, dessen Schwerpunkt auf dem nachgelagerten Entscheidungsprozess liegt und die konkrete Maßnahmen für eine optimale Instandhaltung auswählt. Cherkaoui u. a. [88] schätzen auf Basis eines GP die Fehler sowie die damit einhergehenden Kosten ab. Ziel ist die langfristige Minimierung der Kosten, wobei die Autoren den großen Beitrag der Abstellungsinstandhaltungskosten herausstellen. Noortwijk [89] berechnet das Ausfallrisiko mit Hilfe eines GP. Die Berechnung der Zeit zum Erreichen eines Grenzwertes geht in die übergeordnete Berechnung der Instandhaltungskosten eines Schwingbrückenzyinders mit ein.

Die unterschiedlichen Anwendungsbereiche der RUL Schätzung als Basis zur Kostenoptimierung zeigen die Wichtigkeit des Themas. Es fällt auf, dass besonders komplexere Optimierungen häufig mit vergleichsweise einfachen Methoden, wie dem GP kombiniert werden. Weiterhin ist die Feingliedrigkeit der Betrachtung inklusive eines Aufschlüsselns der Ersatzteilkosten ins das Verhältnis zu den möglichen Ausfallkosten zu setzen.

Im Wesentlichen sind die Basisfunktionalitäten bekannt und werden häufig miteinander kombiniert. Dieses Konzept ist die Grundlage auf der die Ensemble Methoden aufbauen, die besonders in der Methodengruppe des maschinellen Lernens vorangetrieben werden. Neben der stetigen Verbesserung der Leistung der Methoden wird auch der Einsatzzweck zur nachgelagerten Optimierung verdeutlicht. Die Verknüpfung von RUL Schätzung und Instandhaltungsoptimierung ist insbesondere für komplexere Anwendungsfälle noch nicht ausgeschöpft.

2.3. Zwischenfazit der Methoden zur Restlebenszeitschätzung

In den vorangegangenen Unterkapiteln werden zahlreiche Methoden zur RUL Schätzung vorgestellt, die im Folgenden vor dem Hintergrund der industriellen Anwendung eingeordnet werden. Vor allem die in Unterkapitel 1.1 vorgestellte Problemstellung wird als Referenz genutzt.

In Unterkapitel 2.2.1 wird die Methodengruppe der stochastischen Verfahren zur RUL Schätzung vorgestellt, die unter anderem WP, GP, ARMA und MP umfasst. Die Vorteile sind die einfache Grundstruktur sowie der breite Anwendungsbereich. Besonders die Modellbildung auf Basis einer groben Struktur mit geringem Einfluss durch Eingangssignale, in Kombination mit den stochastischen Eigenschaften der Degradationsprozesse, spiegelt die industriellen Bedürfnisse wider. Im Gegensatz dazu sind industrielle Prozesse komplex, sodass die einfache Beschreibung der Prozesse nicht immer der Realität gerecht

wird.

Das Unterkapitel 2.2.2 beschäftigt sich mit Methoden aus dem Bereich ML. Dieser Bereich umfasst eine Reihe an Methoden, wie DT, SVM und weitere, die für einen Anwender nachvollziehbar sind und somit mögliche Empfehlungen auch besser umgesetzt werden können. Demgegenüber stehen komplexe Methoden, wie NN, die kaum transparent sind. Der große Vorteil dieser komplexeren Verfahren ist die Abbildung des Verhaltens auch ohne Kenntnis über die genauen Zusammenhänge. Dies ist für komplexe industrielle Anwendungen von Interesse, allerdings werden dazu verhältnismäßig viele Daten benötigt. Beispielsweise enthält der NASA C-MAPSS Datensatz mehrere hundert Degradationszyklen, die für das Training eingesetzt werden [59].

Im Rahmen von Unterkapitel 2.2.3 werden modellbasierte Ansätze diskutiert. Exemplarisch werden KF und PF aufgeführt, die eine grundlegende Funktionsweise der Gruppe beschreiben. Die Methoden bieten einen Rahmen für bekannte Zusammenhänge, die durch Formeln beschrieben werden können. Wenn die Annahmen erfüllt und die mathematische Beschreibung bekannt ist, sind diese Methoden den zuvor genannten Gruppen zu bevorzugen. Allerdings ist die Herausforderung vieler technischer Anwendungsfälle, dass die technischen Zusammenhänge nicht vollständig beschrieben werden können. Neben den einzelnen Veröffentlichungen unterstreichen die Ensemble Methoden klar die Notwendigkeit der Kombination von Methoden, um von den Stärken einzelner Methoden zu profitieren. Besonders der Aspekt der globalen Optimierung zeigt, dass nur die Einbettung der geeigneten Methode in ein Überwachungskonzept mit den passenden Schnittstellen die Umsetzung der korrekten Instandhaltungsmaßnahme ermöglicht.

3. Ziele und Anwendungsfälle

Innerhalb dieses Kapitels werden die industriellen Anwendungsfälle und die Ziele dieser Arbeit vorgestellt. Zunächst wird in Unterkapitel 3.1 in das aktuelle Vorgehen der Equipment Überwachung innerhalb der BASF SE eingeführt. In diesem Zusammenhang werden auch die industriellen Schnittstellen als ein wesentlicher Bestandteil der Implementierung von Modellen zur RUL Schätzung vorgestellt. Drei konkrete Anwendungsfälle aus der chemischen Industrie werden in Unterkapitel 3.2 vorgestellt. Diese stehen exemplarisch für weitere gleichartige Equipments oder übertragbare Anwendungen. Aus der Kombination des Stands der Technik sowie den Anwendungsfällen, werden in Unterkapitel 3.3 die konkreten Ziele dieser Arbeit abgeleitet.

3.1. Überwachung der Equipments in der BASF SE

Für die Herstellung von vielseitigen chemischen Produkten betreibt die BASF SE weltweit Produktionsanlagen. Für eine bessere Vorstellung über die Größe und Geschichte der BASF SE gibt Kapitel B eine detaillierte Einführung. Der reibungslose Betrieb dieser Anlagen wird von interdisziplinären Experten unterstützt, die innerhalb der BASF SE in sogenannten Fachgruppen organisiert sind. Eine dieser Fachgruppen ist Asset Monitoring Solutions and Services (AMS), die auf die Onlineüberwachung von Equipments spezialisiert ist. Die Aktivitäten sind in drei Kategorien eingeteilt und werden nachfolgend beschrieben [90]:

Zentrale Prozesse & Maschinen

Diese Kategorie ist insbesondere auf kritische Equipments fokussiert, zu denen große rotierende Maschinen innerhalb des verfahrenstechnischen Prozesses gehören. Dazu zählen Kompressoren, oszillierende Pumpen und langsam drehende Maschinen, wie beispielsweise Drehrohröfen.

Neben den rotierenden Maschinen umfasst diese Produktklasse Anwendungen zur Überwachung unterschiedlicher Apparate, wie Wärmeübertrager, Kolonnen und Behälter. Insbesondere die Apparate werden durch die unterschiedlichen chemischen Prozesse geprägt, was insbesondere für deren Überwachung eine Herausforderung ist.

Beide Bereiche vereint der Überwachungsservice, der für alle Equipments durch die Experten des Überwachungszentrums (engl. Reliability Center (ReCe)) erbracht wird.

Modellbasierte Lösungen

In dieser Kategorie steht die Abbildung des Betriebsverhaltens durch Modelle im Vordergrund. Die Palette der implementierten Anwendungen reicht von klassischen FD- und FDI Modellen bis zu Lösungen aus dem Bereich PredM. Dies ermöglicht neue Perspektiven zur Integritäts- und Leistungsüberwachung einer Anlage.

Flottenüberwachung

Auf die Überwachung von vielen gleichartigen Equipments ist diese Kategorie ausgerichtet und basiert auf der nachträglichen Implementierung von Sensoren und innovativen Messsystemen. Die Nachrüstung ist besonders bei Bestandsanlagen eine Herausforderung, da die Anlagen bereits betrieben und nicht alle Messkonzepte nachgerüstet werden können. Ein zentraler Bestandteil ist die Nachrüstung mit kabellosen Sensoren für kleine rotierende Maschinen, wie Motoren, Pumpen und Lüfter. Das Sensorportfolio umfasst weitere drahtlose Sensoren für die Überwachung von Ventilen, Kondensatabscheidern und weiteren Equipments.

Die zuvor vorgestellten Produkte und Services haben sowohl im Sinne der Anwendungsfälle wie auch methodisch Schnittmengen. Übergreifend für alle Lösungen gilt, dass am Anfang des Services ein Projekt initialisiert wird, mit dem Ziel der Umsetzung notwendiger Anlagenänderungen. Im Anschluss erfolgt der Überwachungsservice durch das ReCe, der von der Aufnahme in die Überwachung die gesamte aktive Betriebsphase der Anlage umfasst [90].

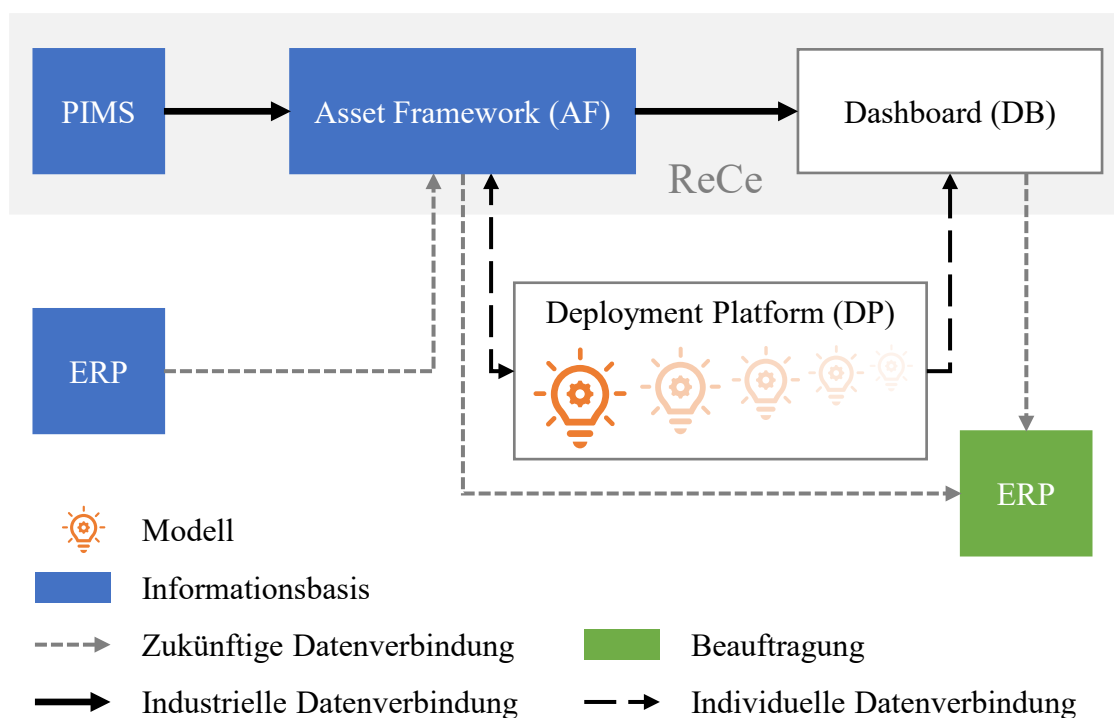


Abbildung 3.1.: Grafische Darstellung der operativen Infrastruktur innerhalb des Überwachungszentrums (ReCe) der BASF SE, bestehend aus Betriebsdateninformationssystem (PIMS), Unternehmensressourcenplanung (ERP), Anlagenstruktur (AF), Ausführungsplattform (DP) und Anzeigetafeln (DB) zur modellbasierten Onlineüberwachung der Equipments.

Für die Implementierung eines erfolgreichen Überwachungsservices, sind eine Vielzahl an unterschiedlichen Komponenten und Schnittstellen notwendig. Einen Überblick über die gesamte Wertschöpfungskette wird in Abbildung 3.1 gegeben. Alle eingesetzten Systeme sind Teil der operativen Technologie (engl. Operational Technology (OT))

Infrastruktur. Die Grundlage für einen Onlineüberwachungsservice sind die während des Betriebs gemessenen Daten. Diese werden im Betriebs-Daten-Informationssystem (engl. Process Information Management System (PIMS)) gespeichert, das in Unterkapitel 3.1.1 näher beschrieben wird. Neben der Speicherung werden die Daten auch strukturiert und mit Metainformationen erweitert. Dies erfolgt in der Anlagenstruktur (engl. Asset Framework (AF)), die in Unterkapitel 3.1.2 erläutert wird. Die Weiterverarbeitung der Messdaten durch trainierte Modelle in der Ausführungsplattform (engl. Deployment Platform (DP)) wird in Unterkapitel 3.1.3 erläutert. Abschließend können die Ergebnisse zurückgeführt werden, um Entscheidungen zu unterstützen. Diese Schnittstelle zur Unternehmensressourcenplanung (engl. Enterprise Resource Planning (ERP)) sowie der Darstellung auf Anzeigetafeln (engl. Dashboard (DB)) werden in Unterkapitel 3.1.4 beschrieben.

3.1.1. Industrielle Verwaltung von Daten

Der Betrieb von chemischen Anlagen sowie die dazu notwendigen Datenströme sind komplex. Zur besseren Strukturierung und Erhöhung der Sicherheit wird die Datenhierarchie gemäß der Automatisierungspyramide angewendet. Die Daten werden im Feld erhoben und können im Prozessleitsystem (engl. Distributed Control System (DCS)) zur Basisautomatisierung genutzt werden. Durch sogenannte DCS-Snapshots wird eine Momentaufnahme aller gemessenen Daten erzeugt, die für die Datenverarbeitung im Fertigungsmanagementsystem (engl. Manufacturing Execution System (MES)) zur Verfügung steht. Die Historisierung ausgewählter Messwerte erfolgt im PIMS. Abhängig von der Größe und der gewachsenen Struktur hat eine verfahrenstechnische Anlage ein eigenes oder teilt sich ein PIMS mit weiteren Betrieben. Innerhalb der BASF SE werden mehrere Millionen Messstellen in unterschiedlichen Systemen historisiert [91]. Um Speicherplatz zu sparen, die Leistung für Berechnungen und Visualisierungen zu verbessern und das Netzwerk weniger zu belasten, werden die Daten verlustbehaftet komprimiert [92]. Die Komprimierung basiert unter anderem auf der Änderung des Messwerts. Demnach wird ein neuer Messwert historisiert, wenn ein definierter Grenzwert der Sensormessspanne überschritten wird [93]. Neben der Änderung des Wertes, kann auch die maximale Zeitspanne bis zur letzten Historisierung des Messwerts das erneute Speichern auslösen. In Abhängigkeit dieser zwei Parameter wird das Signal komprimiert und für die weitere Verarbeitung gespeichert. Die komprimierten Daten können im Anschluss in der Rohform mit der Zuordnung der Messstelle und des Zeitstempels bzw. äquidistant interpoliert abgefragt werden.

3.1.2. Datenorganisation in der Anlagenstruktur

Neben der Speicherung der Zeitreihen, ist auch eine Verwaltung der Messstellen und die Anreicherung mit Metadaten notwendig. Dies wird in einem sogenannten AF umgesetzt [94].

Durch die Nutzung des AF werden die Daten strukturiert. In diesem Zusammenhang bekommen die kryptischen Messstellenbezeichnungen einen zusätzlichen „sprechenden“ Namen, der die Interpretationen der Ergebnisse oder Fehleranalyse unterstützt. Der sprechende Name ist an die topologischen Zusammenhänge angelehnt und beschreibt die Art des Sensors sowie dessen Funktion an dem konkreten Equipment. Wiederkehrende Strukturen werden in eine zentrale Vorlage überführt und verwaltet.

Das AF trägt dazu bei, dass die historisierten PIMS Daten in einem standardisierten Format verfügbar sind und in verständlicher Form zusammengestellt werden. Darüber hinaus unterstützt das AF auch bei der Organisation der Daten. Somit können die Informationen nicht nur anwendungsfallsspezifisch, sondern auch auf Anlagenebenen organisiert werden. Dies ermöglicht auf der einen Seite die Aggregation der Informationen sowie bedarfsgerecht den zielgerichteten Fokus auf Details. Neben diesen Eigenschaften sind weitere Funktionalitäten, wie beispielsweise ein Alarmmanagement vorhanden, die an dieser Stelle nicht im Detail beschrieben werden.

Insgesamt bilden das PIMS und das AF die Basis für eine onlinefähige und strukturierte Überwachung der Equipments innerhalb der BASF SE.

3.1.3. Plattform zur Onlineüberwachung

Für die Weiterverarbeitung der historisierten Daten aus dem AF stehen unterschiedliche Möglichkeiten zur Verfügung. Grundlegende Berechnungen können direkt innerhalb des AF umgesetzt werden und die Ergebnisse als neue Messstelle ebenfalls historisiert werden.

Im Falle von komplexeren Berechnungen erfolgt die Verarbeitung durch anwendungsspezifische Programme. Als Teilaspekt wird für die Codeentwicklung die Software gitLab genutzt. Diese ermöglicht die gemeinsame Zusammenarbeit in Softwareentwicklungsprojekten und erleichtert die Instandhaltung der Software während der Betriebszeit [95]. Hinsichtlich der Programmiersprache gibt es keine Limitierungen, wobei aufgrund der umfangreichen Bibliotheken unter anderem auf Python zurückgegriffen wird.

Neben der Softwareentwicklung ist die Ausführung des Programmcodes im Rahmen der Onlineüberwachung von zentraler Bedeutung. Dazu werden Server mit der Open-Source Orchestrierungssoftware Kubernetes betrieben, die das Ausführen von wiederkehrenden Berechnungen ermöglicht und steuert [96]. Im Konkreten ermöglicht dies die Ausführung von trainierten Modellen oder kommerzieller Software in abgeschlossenen virtuellen Maschinen, den sogenannten Containern. Ein Container ist eine standardisierte Umgebung, die auf Grundlage von übergebenen Informationen ein definiertes Programm ausführen und Ergebnisse zurückgeben kann. Beispielsweise kann ein Container das Überwachungsmodell eines Equipments enthalten, das einen digitalen Zwilling des realen Equipments widerspiegelt. Änderungen des Equipments oder dessen Betriebsverhalten, können auch die Anpassungen des Modells notwendig machen. Diese möglichen Änderungen über den gesamten Lebenszyklus eines Equipments werden an dieser Stelle nicht weiter ausgeführt. Im Zuge einer stetigen Optimierung des gesamten Überwachungsprozesses, werden weitere Möglichkeiten für eine schnellere und bessere Implementierung entwickelt.

Der Einsatz von zentral verwalteten Strukturen zur Ausführung von Berechnungen ermöglicht eine gute Skalierbarkeit sowie eine optimale Instandhaltung der Software. Die mit den Berechnungen generierten Ergebnisse können durch Schnittstellen übergeben und beispielsweise im PIMS gespeichert werden. Dies stellt die Basis für weitere Verarbeitungsschritte dar.

3.1.4. Ergebnisausgabe und Handlungsanweisung

Sowohl die gemessenen Zeitreihendaten als auch die modellbasierten Berechnungen dienen als Entscheidungsgrundlage für mögliche Anpassungen des verfahrenstechnischen

Prozesses und für die Terminierung von Instandhaltungsarbeiten. Die Wege zu einer Handlung sind vielfältig und umfassen einen manuellen sowie einen teilautomatisierten Prozess.

Beispielsweise können die Zeitreihendaten direkt im AF visualisiert werden. Bei der klassischen Darstellung über die Zeit sind die Werte für einen Experten zwar interpretierbar, aber können nur bedingt sinnvoll durch weitere Personen genutzt werden. Aus diesem Grund werden die Daten, vergleichbar zum DCS, optisch aufbereitet und basierend auf dem Kontext des AF dargestellt. Die Visualisierung in einem DB ermöglicht den intuitiven Zugang zu den Daten und eine schnellere Entscheidungsfindung. Die grafische Darstellung der Daten ist jedoch nur eine Unterstützung in der Entscheidungsfindung. Eine Wartung bzw. Instandsetzung wird in dem ERP System gemeldet. Im Falle der BASF SE in Ludwigshafen wird dazu unter anderem das Modul PM der Software SAP genutzt. Die Instandsetzungsmeldung umfasst neben einem Kurz- und Langtext auch das Zeitfenster zur gewünschten Umsetzung. Weiterhin werden auch die Zeitstempel der Änderungen mitaufgenommen, um die Abarbeitung zu dokumentieren. Neben der konkreten Beschreibung der Handlung erfolgt auch die Verknüpfung der technischen Maßnahme zum konkreten Equipment. Für die Zuordnung wird ein sogenannter Technischer Platz (TP) für jedes Equipment definiert, der eindeutig und hierarchisch strukturiert ist. Somit kann eine grobe Strukturierung des Prozesses anhand der TP erfolgen und die Anlagenstruktur anhand einer fünfsegmentigen Kodierung erfolgen. Die Meldung einer Maßnahme ist inhaltlich der maßgebende Aspekt, wobei die Beauftragung über einen aus der Meldung abgeleiteten Auftrag erfolgt. Innerhalb des ERP Prozesses wird die Meldung mit einem Auftrag verknüpft, um die notwendigen Kosten einem TP zuzuweisen und abrechnen zu können.

Der grundlegende Prozess zur Instandhaltung ist in den Grundfunktionen bereits vorhanden. Mit dem Ziel der weiteren Automatisierung des Instandhaltungsprozesses sowie der Verbesserung der Handlungsempfehlungen im Rahmen von PresM ist es notwendig, die Schnittstellen zwischen den einzelnen OT-Systemen zu stärken.

3.2. Industrielle Anwendungsfälle

Innerhalb der BASF SE gibt es eine Vielzahl möglicher Anwendungsfälle für die Überwachung von Equipments und die Schätzung deren RUL. Nachfolgend werden drei unterschiedliche Anwendungsfälle vorgestellt, die entweder häufig in der chemischen Industrie vorkommen oder aufgrund der technischen Herausforderung eine praktische Relevanz besitzen. Diese Anwendungsfälle werden zur Validierung der zu entwickelnden Überwachungskonzepte genutzt und gründen sich auf der Datenbasis besteht aus drei zusammenhängenden Jahren an stündlich interpolierten Messwerten für alle genannten Messstellen.

Zunächst wird in Unterkapitel 3.2.1 ein Ölfilter (ÖF) vorgestellt, wie er in ähnlicher Form bei vielen großen Maschinen eingesetzt wird. Im Anschluss wird in Unterkapitel 3.2.2 eine Hochdruckmembranpumpe (HDMP) vorgestellt, die unter anderem auch zur Dosierung eingesetzt wird und stellvertretend für die Möglichkeit einer Überwachung auf Grundlage von geringer Instrumentierung steht. Abschließend wird in Unterkapitel 3.2.3 ein Robertverdampfer (RV) vorgestellt, der exemplarisch die Verdampfer innerhalb der chemischen Industrie repräsentiert. Der Fokus dieses Anwendungsfalls ist die technische Limitierung der Nachrüstensorik und der Umgang mit den damit verbundenen Herausforderungen.

3.2.1. Ölfilter

In der chemischen Industrie werden Maschinen vor allem zur Förderung eingesetzt. Vereinzelt wandeln Maschinen auch die Strömungsenergie eines Mediums in mechanische Energie, wie beispielsweise Kraftwerksturbinen. Unabhängig von der konkreten Maschine entsteht bei der Wandlung der Energie Reibung in den mechanischen Bewegungsabläufen. Um eine hohe Effizienz zu erreichen, ist es notwendig die Reibungsverluste auf ein Minimum zu reduzieren. In einigen Anwendungsfällen wird dazu Öl zur Schmierung eingesetzt.

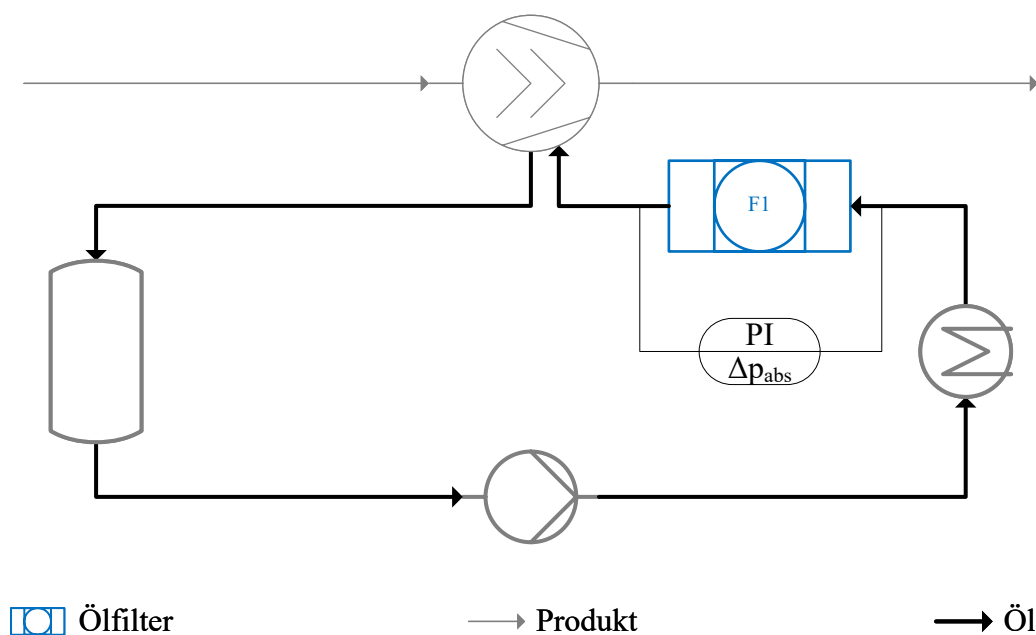


Abbildung 3.2.: Grafische Darstellung eines schematischen Ölfilterkreislaufs bestehend aus einem Ölbehälter, Ölkühler und dem Ölfilter F1 als Unterstützungseinrichtung eines exemplarischen Verdichters.

Gemäß Abbildung 3.2 ist zu erkennen, dass das eingesetzte Öl wiederverwendet und in einem sogenannten Ölkreislauf gefördert wird. Während des Betriebs können große Kräfte auftreten und die mechanischen Bauteile stark beanspruchen. Der durch die Reibung entstehende Abrieb kann zur Beschädigung der Maschine führen [97], [98]. Aus diesem Grund ist es das Ziel, den Abrieb sowie die durch die Reibungsverluste entstehende Wärme durch das Öl aus der Entstehungszone abzuführen. Weiterhin ermöglicht das Ölsystem den Abtransport von Verunreinigungen, die von außen in das Ölsystem eingetragen werden.

Filter werden eingesetzt, um mechanische Schäden durch Fremdkörper im Ölkreislauf zu vermeiden und die Schmiereigenschaften beizubehalten. Allgemein gelten für den Filter die Hauptsätze der Thermodynamik und damit die Energieerhaltung [99]. Auf dieser Grundlage kann die Bernoulli-Gleichung abgeleitet werden, die anhand von Gleichung 3.1

die Strömung beschreibt [100].

$$\frac{u^2}{2} + \frac{p_{\text{Abs.}}}{\rho} + gh_{\text{Geo.}} = \textit{konstant} \quad (3.1)$$

In Gleichung 3.1 gehen die Geschwindigkeit u , das Verhältnis aus Druck $p_{\text{Abs.}}$ und Dichte ρ sowie das Produkt aus Erdbeschleunigung g und geodätischer Höhe $h_{\text{Geo.}}$ ein. Die Bernoulli Gleichung besagt, dass die Energie entlang einer Stromlinie konstant ist. Daraus folgt für den ÖF, unter der Voraussetzung, dass $h_{\text{Geo.}} \approx 0$ und $\rho \approx \textit{konstant}$, dass $\Delta p_{\text{Abs.}}$ zwischen Aus- und Eintritt des ÖF von u abhängt. Dieser ideale Zusammenhang wird durch die empirische Funktion zur Berechnung des Druckverlusts eines Rohres in Gleichung 3.2 ergänzt. Die Formel des Rohrdruckverlusts wird Darcy-Weisbach zugeordnet, wobei auch weitere Wissenschaftler einen Beitrag zur empirischen Gleichung geleistet haben [101].

$$\Delta p_{\text{Abs.}} = \frac{\rho u^2}{2} \left(\lambda_{\text{Rohr}} \frac{l_{\text{Rohr}}}{d_{\text{Rohr}}} + \sum \zeta_{\text{Druck}} \right) \quad (3.2)$$

In Gleichung 3.2 gehen die Rohrreibungszahl λ_{Rohr} und Druckverlustbeiwerte ζ_{Druck} sowie die Geometrie des Rohres mit Länge l_{Rohr} und Durchmesser d_{Rohr} ein. Ein Zusetzen des Filters kann in diesem Zusammenhang als Reduzierung von d_{Rohr} verstanden werden. Demnach ist $\Delta p_{\text{Abs.}}$ ein Indikator für eine Geschwindigkeitsänderung oder die Änderung des Filterverhaltens. Da die Pumpe im Ölsystem in einem konstanten Betriebspunkt betrieben wird, korreliert der Ölfilterdifferenzdruck $\Delta p_{\text{Abs.}}$ direkt mit dem Filterbelag. Somit kann eine Veränderung der Filterleistung durch $\Delta p_{\text{Abs.}}$ detektiert werden.

Die Reinigung oder der Wechsel des ÖF ist mit Kosten und unter Umständen Ausfallzeiten verbunden. Eine zu späte Instandhaltung des Filters birgt das Risiko einer unzureichenden Schmierung der mechanischen Bauteile und folglich einer massiven Beschädigung der Maschine. Im Gegensatz dazu entstehen durch eine zu frühe Instandhaltung unnötige Kosten. Aus diesem Grund ist es das Ziel für diesen Anwendungsfall die RUL bis zur nächsten Instandhaltung des ÖF auf Grundlage eines maximal zulässigen $\Delta p_{\text{Abs.}}$ zu schätzen. Durch diese Kenntnis ist die spontane Umsetzung der Maßnahme nicht nötig, sondern kann geplant durchgeführt werden. Somit können notwendige Einsatzstoffe und Ersatzteile zuvor beschafft und sowohl die Stillstandszeit als auch die Instandhaltungskosten auf ein Minimum reduziert werden.

3.2.2. Hochdruckmembranpumpe

In der chemischen und petrochemischen Industrie werden HDMP für eine Vielzahl von Anwendungen eingesetzt. Zu den Vorteilen des Pumpentyps zählen unter anderem das präzise Dosieren von Flüssigkeiten sowie die Förderung unter hohem Druck [102]. Die Funktionsweise ähnelt der einer Fahrradluftpumpe und wird nachfolgend auf Basis von LEWA [103] beschrieben:

Die HDMP besteht im Wesentlichen aus dem Triebwerk und dem Pumpenkopf. Das Triebwerk setzt die Rotation eines Antriebsmotors in eine Translation um. Durch eine Mechanik kann der Hub der Translation eingestellt werden. Diese Mechanik und die Änderung der Antriebsdrehzahl ermöglichen die Variation der Fördermenge. Die Kopplung des Triebwerks und des Kolbens bewirkt eine Oszillation, die das Öl im

Ölraum verdrängt. Aufgrund der in guter Näherung inkompressiblen Eigenschaften des Öls bewirkt das verdrängte Öl die Auslenkung einer doppelwandigen Membran. Zur Illustration der Funktionsweise, wird der Pumpenkopf mit dem Fokus auf die Membran einer HDMP im Schnitt in Abbildung 3.3 dargestellt.




Abbildung 3.3.: Grafische Darstellung eines schematischen Hochdruckmembranpumpenkopfes im Schnitt mit dem Detail einer beschädigten doppelwandigen Membran.

Die produktführende Seite ist durch die Membran von dem Ölraum getrennt. Innerhalb eines Pumpenzyklus wird das im Produktraum befindliche Fluid, durch die Expansion der Membran in den Produktraum, aus dem Pumpenkopf ausgeschoben. Das Auslassventil ist zu diesem Zeitpunkt geöffnet, sodass das Produkt das Ventil umströmt und auf die Druckseite der Pumpe gefördert wird. Während dieser Zeit ist das Einlassventil geschlossen und sperrt die Verdrängung des Produktes in Richtung Einlass ab. Analog wird bei der Rückwärtsbewegung des Kolbens die Membran in Richtung des Ölraums ausgelenkt und das Produkt angesaugt. Zu diesem Zeitpunkt ist das Einlassventil geöffnet und das Auslassventil geschlossen.

Neben dem Ein- und Auslassventil gibt es ein weiteres Ventil, das den druckführenden Teil des Ölraums mit dem weitestgehend drucklosen Reservoir verbindet. Dieses Ventil dient zur Regulierung der Ölmenge im druckführenden Teil, sodass bei zu viel Öl die Membran nicht geschädigt und bei zu wenig Öl eine reduzierte Fördermenge vermieden wird.

Während jedes Pumpenzyklus wird die Membran in beide Richtungen ausgelenkt und damit verformt. Die wiederkehrende Bewegung beansprucht die gleichen Bereiche der Membran und führt zu einem Verschleiß. Der Riss der Membran kann effektiv durch die Überwachung des Membraninnendruckes $p_{\text{Abs.}}$ überwacht werden. In vielen technischen Anwendungen wird der Membraninnendruck jedoch nur als binäres Signal überwacht.

Im Gegensatz zum spontanen Versagen der Membran ist die kontinuierliche Degradation der Membran eine häufige Herausforderung. Zu Beginn kann die Materialschwächung zu einer Beschleunigung der Diffusion in den Membranzwischenraum führen und folglich detektiert werden.

Im konkreten Fall ist eine kontinuierliche Messung des Membraninnendrucks $p_{\text{Abs.}}$ installiert. Das zu frühe Entlüften und der damit einhergehenden Reduzierung von $p_{\text{Abs.}}$ bindet unnötige Betriebsressourcen, wobei der Membranwechsel zusätzliche Ersatzteilkosten und bauartbedingt Ausfallzeiten der Maschine verursacht. Das zu späte Entlüften der Membran führt, basierend auf Betreibererfahrungen, zur vorzeitigen Degradation der Membran und Verkürzung der Gesamtbetriebszeit.

Das Ziel dieses Anwendungsfalles ist die Schätzung der zukünftigen Entwicklung des Membraninnendrucks $p_{\text{Abs.}}$. Basierend auf der Schätzung soll die RUL bis zur nächsten notwendigen Entlüftung auf Grundlage eines maximal zulässigen Membraninnendrucks berechnet werden. Dies ermöglicht eine Maximierung der Gesamtbetriebszeit sowie eine optimal in den Betriebsablauf integrierte Instandhaltungsmaßnahme.

3.2.3. Robertverdampfer

In diesem Anwendungsfall wird ein thermischer Aufbereitungsschritt untersucht, der Teil eines größeren Prozesses ist und schematisch in Abbildung 3.4 dargestellt wird.

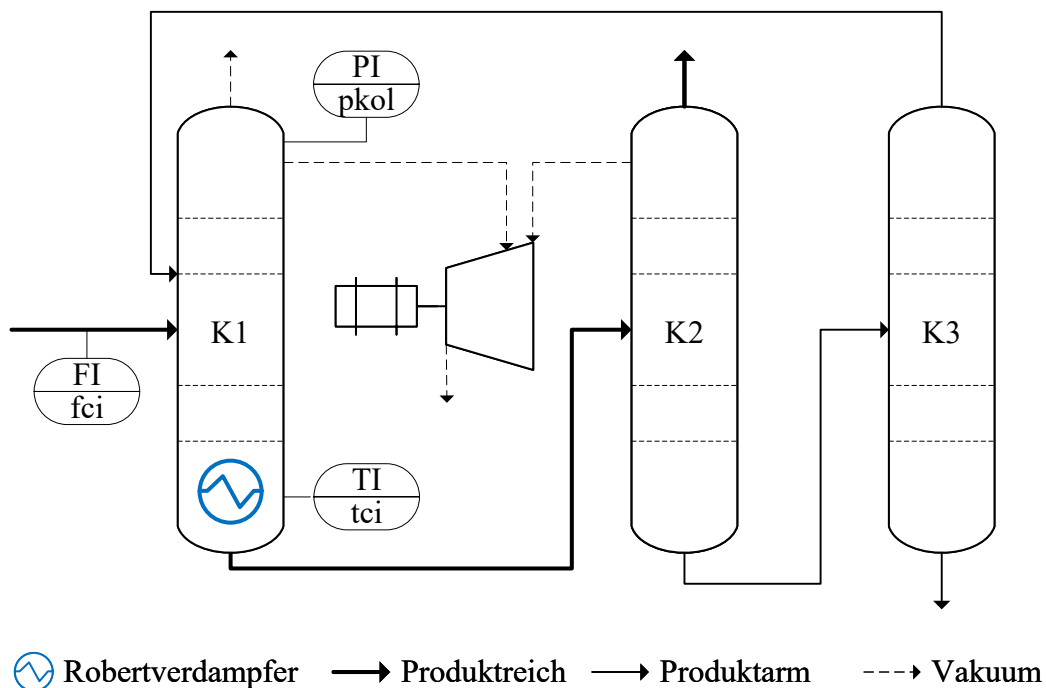


Abbildung 3.4.: Grafische Darstellung eines Prozesses bestehend aus drei Kolonnen zur Aufbereitung eines Produkts mit dem Fokus auf die Wärmeübertragung durch einen Robertverdampfer.

Der Aufarbeitungsprozess in Abbildung 3.4 beginnt mit der Einleitung des Eduktmassenstroms f_{ci} in die Kolonne K1. In K1 werden die leichtflüchtigen Bestandteile vom schwerer siedenden Wertstrom abgetrennt. Die Kolonne K2 trennt die schwerflüchtigen

Bestandteile von dem leichtflüchtigen Wertstrom ab. Zur Erhöhung der Ausbeute werden dem Sumpfmassenstrom aus K2 weitere Wertanteile in der Kolonne K3 entzogen und diese wieder in K1 eingebracht. Der Kopfdruck von K1 p_{kol} wird durch einen Verdichter abgesenkt. Der Betrieb im anteiligen Vakuum senkt die Siede- und damit auch die Sumpftemperatur t_{ci} ab und spart in Folge dessen Energie ein. Die zur Verdampfung des Produkts notwendige Energie wird durch den Dampfmassenstrom f_{hi} mit einem Dampfdruck phi zur Verfügung gestellt. Im konkreten Anwendungsfall ist der Wärmeübertrager als sogenannter RV ausgeführt.

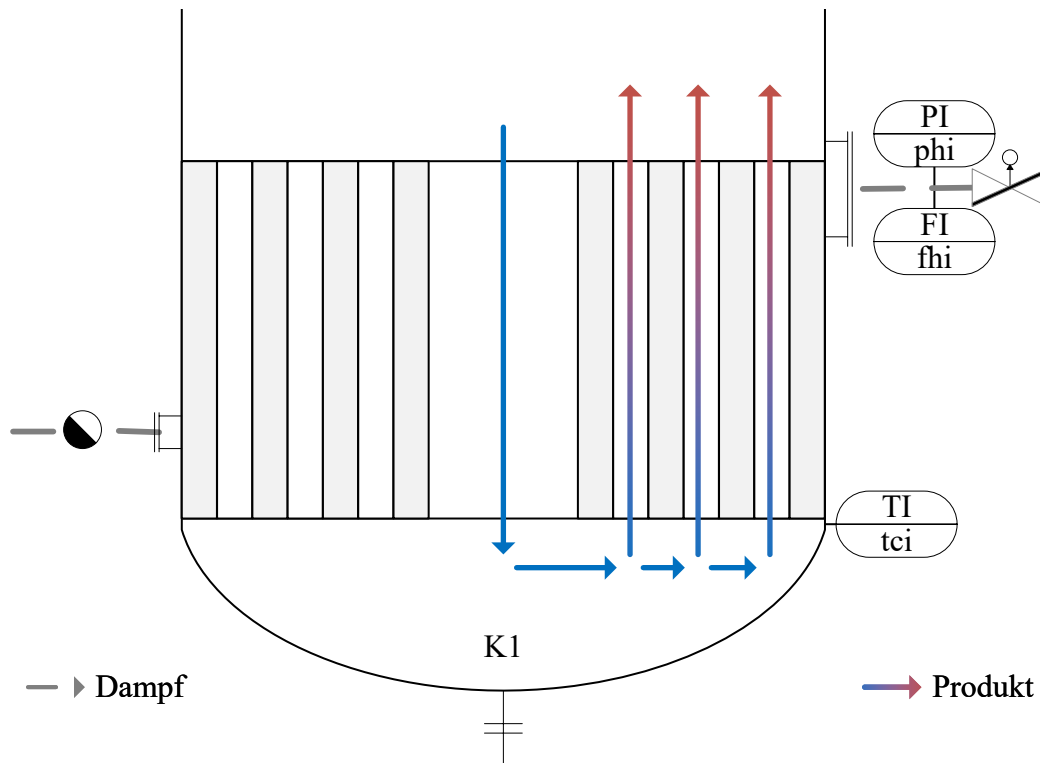


Abbildung 3.5.: Grafische Darstellung eines Robertverdampfers im Schnitt inklusive der verfügbaren Messstellen sowie der Differenzierung zwischen Produkt- und Dampfseite.

Die Bauform inklusive der zur Verfügung stehenden Sensoren wird anhand von Abbildung 3.5 skizziert. Im Gegensatz zu konventionellen Rohrbündelwärmeübertrager-Kolonnen Kombinationen, ist der Verdampfer in diesem Fall nicht außerhalb einer Kolonne installiert, sondern direkt im Sumpf der Kolonne verbaut. Durch die Ausrichtung der Längsachse der Rohre des RV entlang der Wirkung der Schwerkraft, ist der RV eine Sonderbauform des Naturumlaufverdampfers, der meist mit sehr kurzen Siederohren ausgestattet ist [104]. Abbildung 3.5 zeigt, dass der Mantelraum mit Dampf beheizt wird, der nach Abgabe der Verdampfungsenthalpie als flüssiges Kondensat über eine weitere Rohrleitung aus dem Mantelraum abgeführt wird. Die Wärme wird durch die Rohrwandung geleitet und erhitzt das Produkt auf der Rohrinne-seite. Der Rohrlänge folgend wird das Fluid von unten nach oben erhitzt und verdampft, sodass an der Oberseite die gasförmige Phase aufsteigen und die flüssige Phase sowie der Rücklauf der Kolonne über die zentrale Rohrleitung an die Unterseite des RV und in die Verdampferrohre strömen. Die Strömung in den Verdampferrohren stellt sich durch den Dichteunterschied zwischen dem zentralen Rohr sowie dem Verdampferrohr ein und

variiert in Abhängigkeit des Betriebszustands.

Durch chemische Nebenprozesse bilden sich besonders in den heißen Zonen von K1 Ablagerungen. Aufgrund des Temperaturprofils der Kolonnen können die Ablagerungen die unteren Böden der Kolonne über die Zeit zusetzen und somit die Effizienz aufgrund eines geringeren Vakuums beschränken. Primär bilden sich die Ablagerungen an den Kontaktflächen des RV. Der durch die Degeneration, dem sogenannten Fouling, erzeugte zusätzliche Wärmewiderstand verschlechtert die Wärmeübertragung. Um die gleiche Leistung in das Produkt zu übertragen, wird das treibende Temperaturgefälle erhöht und somit der Dampfdruck gesteigert. Der degradationsbedingte Einsatz von Dampf auf einem höheren Druckniveau erhöht auch die Verlustanteile der eingesetzten Energie. Besonders im Sinne von steigenden Energiepreisen und eines wirtschaftlichen Anlagenbetriebs ist eine hohe Effizienz wünschenswert. Im Hinblick auf den verfahrenstechnischen Prozess ist der Dampfdruck begrenzt und somit ab einem definierten maximalen Dampfdruck eine Reinigung notwendig.

Bauformbedingt kann auf ein Gehäuse sowie lange Siederohre verzichtet und dadurch Material eingespart werden, wobei die Wandungen des Kolonnensumpfes das zusätzliche Gewicht des Rohrbündels tragen muss. Diese baulichen Vorteile beinhalten Herausforderungen für die Überwachung, da die Strömung innerhalb der Verdampferrohre nicht messbar ist. Vor dem Hintergrund des großen Einflusses der Strömungsgeschwindigkeit auf den Wärmeübergang ist die vollständige Beschreibung somit kaum möglich und die Modellbildung komplex.

Die chemische Reinigung des RV ist aufwendig und reduziert die Verfügbarkeit der Teilanlage. Eine zu frühe Reinigung bindet Betriebspersonal und verschwendet die eingesetzten Reinigungsmittel. Durch häufigere Reinigungen wird folglich die Gesamtbetriebszeit der Anlage reduziert. Im Gegensatz dazu zeigen vergleichbare Anwendungsfälle, dass eine zu späte Reinigung zu einer Verfestigung der Ablagerungen und somit zu einem erhöhten Reinigungsaufwand führen kann [105]. Das Ziel dieses Anwendungsfalls ist die Bestimmung der RUL bis zur nächsten betrieboptimalen Reinigung des RV. Neben der Bewertung des aktuellen Zustands des Wärmeübertragers sollen auch alternative Betriebsweisen als Basis für PresM ausgewiesen werden. Durch die Berechnung von Szenarien kann der Betrieb angepasst werden, um Abstellungen in der Nacht und an Wochenenden zu vermeiden. Somit können die Betriebs- und Instandhaltungskosten insgesamt optimiert werden.

3.3. Konkretisiertes Ziel der Arbeit

Anhand der in Unterkapitel 3.2 vorgestellten Anwendungsfälle wird das in Unterkapitel 1.3 skizzierte globale Ziel konkretisiert. Die Heterogenität, in Bezug auf die Komplexität sowie unterschiedliche Anforderungsprofile der Anwendungsfälle, zeigt, dass es nicht ein allgemeingültiges Überwachungskonzept gibt, sondern eine Teilspezialisierung notwendig ist. Der Lösungsraum für die konkrete Umsetzung wird in den Unterkapiteln 2.1 und 2.2 aufgespannt. Vor dem Hintergrund des Einsatzes in der chemischen Industrie wird die Methodenvielfalt anhand der Herausforderungen aus Unterkapitel 1.1 eingeschränkt und die konkreten Ziele dieser Arbeit daraus abgeleitet.

Für industrielle Anwendungen steht der in Unterkapitel 1.1 thematisierte Aspekt der Skalierbarkeit im Fokus. Aus diesem Grund soll ein Überwachungskonzept zur

Abbildung einfacher und häufig auftretender Anwendungsfälle entwickelt werden. Die Skalierung erfordert ein möglichst großes Maß an Automatisierung, wozu die notwendigen Einstellungen durch den Anwender minimiert werden sollen.

Bei der Entwicklung des Überwachungskonzeptes soll der Ansatz verfolgt werden, Methoden zu kombinieren, da auf diese Weise sowohl ein hoher Automatisierungsgrad als auch die Nutzung adaptiver Eigenschaften im Rahmen einer Onlineüberwachung ermöglicht werden. Dazu sollen grundlegende Techniken aus der Signalverarbeitung zur FD, OLS zur Optimierung mit Modellbildungsmethoden aus dem Bereich ML verknüpft werden.

Aufgrund der hohen Automatisierung des Überwachungskonzeptes liegt der Evaluierungsschwerpunkt auf der Simulation der Onlineüberwachung, die den Onlinemodellbildungsprozess während des Betriebs einschließt.

Die Überwachung von komplexen Anwendungsfällen, mit der Vorgabe Handlungsoptionen auszuweisen, erfordert anwendungsspezifische Modelle. Insbesondere der Einfluss von Eingangssignalen soll aufgrund der großen Vernetzung in verfahrenstechnischen Anlagen abgebildet werden. Die Limitierung der verfügbaren Daten sowie die anteilige Kenntnis über den Degradationsmechanismus setzen hohe Anforderungen an das adaptive Verhalten des Überwachungskonzeptes.

Der methodische Kern dieses Überwachungskonzeptes soll auf einem modellbasierten Ansatz aufbauen, um die schnelle und einfache Implementierung zu unterstützen. Die notwendigen Annahmen der modellbasierten Methoden, wie zum Beispiel Linearität oder Normalverteilung des Mess- und Prozessrauschens, sind für die heterogenen technischen Anwendungsfälle in der chemischen Industrie nicht immer gegeben. Um von den Vorteilen der modellbasierten Methoden zu profitieren, soll ein PF als grundlegende Methode zur RUL Schätzung in diesem Überwachungskonzept genutzt werden. Der modellbasierte Ansatz ermöglicht die Berechnung von verschiedenen Szenarien als Entscheidungsgrundlage.

Für die Nutzung des Überwachungskonzeptes auf Basis des PF ist die Bereitstellung eines geeigneten Modells erforderlich. Um die Abbildung des Degradationsverhaltens auch für *a priori* nicht bekannte Zusammenhänge zu ermöglichen, soll auf den Bereich des ML zurückgegriffen werden. Mit dem Fokus auf ein Höchstmaß an Transparenz und Akzeptanz der Anwender, soll ein lineares Regressionsmodell für einen konkreten Anwendungsfall entwickelt werden. Um auf nicht abbildbare Einflüsse reagieren zu können, soll das Überwachungskonzept adaptive Eigenschaften bereits während des Modellierungsprozesses berücksichtigen.

4. Angewandte Methoden

Abgeleitet von der globalen Einordnung des Stands der Technik in Kapitel 2, werden im nachfolgenden Kapitel die spezifischen Methoden aufbereitet, die für die Entwicklung von Konzepten zur RUL Schätzung benötigt werden.

Die Grundlage bilden Techniken der Statistik, die in Unterkapitel 4.1 vorgestellt werden. Darauf aufbauend werden in Unterkapitel 4.2 Methoden zur Vorverarbeitung von Daten vorgestellt. Dies ist insbesondere mit dem Fokus auf industrielle Messdaten von Bedeutung. In Unterkapitel 4.3 werden Methoden zur Modellbildung sowie Metriken zur Bestimmung der Modellqualität vorgestellt. Abschließend wird in Unterkapitel 4.4 in die Methode des PF eingeführt und damit verbundene Herausforderungen diskutiert.

4.1. Deskriptive Statistik

Statistische Kenngrößen sind ein elementarer Bestandteil der Analyse von Signalen. In Unterkapitel 4.1.1 werden grundlegende statistische Kennzahlen definiert. Nachfolgend wird in Unterkapitel 4.1.2 auf die Analyse der Monotonie im Detail eingegangen.

4.1.1. Grundlegende Kennzahlen

In diesem Unterkapitel werden Kennzahlen eingeführt, die einen Datensatz oder eine Messreihe im Ganzen beschreiben. Sei $X \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ ein Spaltenvektor mit $n_{\text{Mess.}}$ Messwerten, so kann dieser auch, wie in Abbildung 4.1 dargestellt, als Stichprobe einer allgemeinen Verteilung Λ angesehen werden.

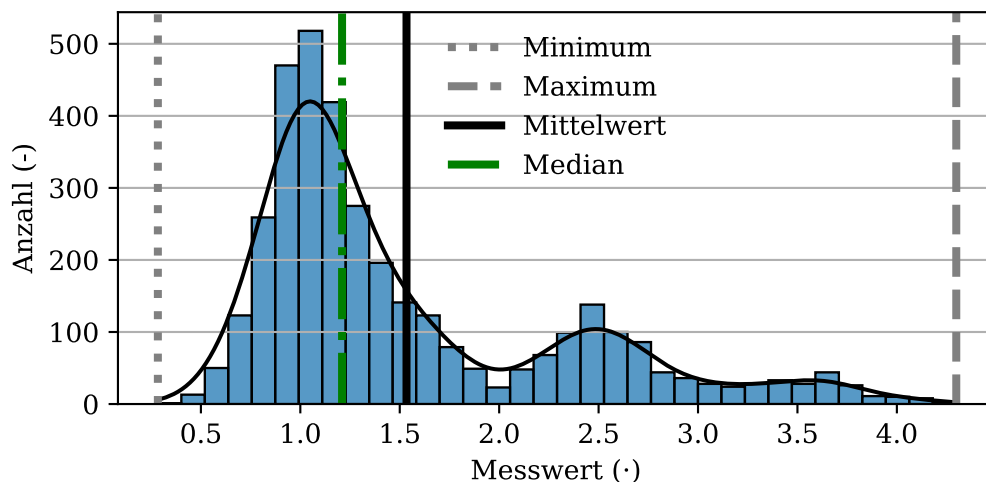


Abbildung 4.1.: Grafische Darstellung der Stichprobe einer allgemeinen Verteilung Λ mit Mittelwert μ , Median ξ sowie weiteren statistischen Kennzahlen.

Wenn die Verteilung bestimmte Eigenschaften erfüllt, wie beispielsweise eine Normalverteilung \mathcal{N} , ist eine kompakte Darstellung als Formel mit den dazugehörigen Parametern möglich. Die Beschreibung eines Systemausgangs ist allerdings durch die Eingänge sowie Störungen überlagert, sodass die Beschreibung durch eine Normalverteilung \mathcal{N} nicht in jedem Fall möglich ist. Unabhängig von den Eigenschaften der Messreihe X , kann der Spaltenvektor durch statistische Kennzahlen beschrieben werden. Eine grundlegende Information enthalten das Minimum \min_X und das Maximum \max_X als Extremwerte von X . Die kombinierte Aussage dieser beiden Extremwerte wird als Streumaß oder Spannweite (engl. Range) $d_{\text{Spa.}}$ bezeichnet und anhand von Gleichung 4.1 vorgestellt [106].

$$d_{\text{Spa.}, X} = \max_X - \min_X \quad (4.1)$$

Um den Schwerpunkt einer Messreihe zu bestimmen, wird das arithmetische Mittel μ oder kurz der Mittelwert berechnet. Für den Vektor X wird der Mittelwert μ_X in Gleichung 4.2 als Summe aller Einträge $x_j = X(j)$ geteilt durch die Länge des Vektors n_X berechnet [106].

$$\mu_X = \frac{1}{n_X} \sum_{j=1}^{n_X} X(j) = \frac{1}{n_X} \sum_{j=1}^{n_X} x_j \quad (4.2)$$

Die Beschreibung der Streuung einer Messreihe X erfolgt durch die Stichprobenvarianz var , deren Quadratwurzel die Standardabweichung σ ist [106]. Die Berechnung der Stichprobenvarianz var oder kurz Varianz wird in Gleichung 4.3 vorgestellt.

$$\text{var}_X = \sigma_X^2 = \frac{1}{n_X - 1} \sum_{j=1}^{n_X} (x_j - \mu_X)^2 \quad (4.3)$$

Die Gleichungen 4.2 und 4.3 beschreiben grundlegend die Eigenschaften einer Stichprobe entnommen aus einer allgemeinen Verteilung Λ . Neben dem Mittelwert μ und der Varianz var sind weitere Aussagen über eine Stichprobe möglich. Dazu gehören beispielsweise die Kennzahlen Schiefe oder Wölbung einer Verteilung, die an dieser Stelle nicht weiter beschrieben werden.

Basierend auf dem Mittelwert μ und der Varianz var ist die Standardisierung möglich. Das Ziel der Standardisierung eines Vektors X ist die Transformation auf den Mittelwert $\mu_X = 0$ und die Standardabweichung $\sigma_X = 1$ [107]. Neben der Standardisierung gibt es weitere Methoden, die in der Datenanalyse häufig unter dem Begriff Skalierer (engl. Scaler) zusammengefasst werden. Exemplarisch wird die Standardisierung anhand von Gleichung 4.4 für die Messreihe X dargestellt.

$$\bar{X} = \frac{X - \mu_X}{\sigma_X} \quad (4.4)$$

Neben der Beschreibung eines einzelnen Vektors durch statistische Kennwerte, kann auch der Zusammenhang zwischen zwei Vektoren $X \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ und $Y \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$, mit je $n_{\text{Mess.}} = n_X = n_Y$ Einträgen, bestimmt werden. Anhand der Gleichung 4.2 werden die Mittelwerte μ_X und μ_Y von der Messreihen X und Y berechnet, um die Messreihen zu zentrieren [108]. Gleichung 4.5 stellt die Berechnung der Kovarianz $\text{cov}_{XY} \in \mathbb{R}^{1 \times 1}$ der Stichproben exemplarisch vor.

$$\text{cov}_{XY} = \frac{1}{n_{\text{Mess.}} - 1} \sum_{j=1}^{n_{\text{Mess.}}} (x_j - \mu_X)(y_j - \mu_Y) \text{ mit } x_j = X(j), y_j = Y(j) \quad (4.5)$$

Durch Normierung der Kovarianz cov_{XY} auf das Produkt der Standardabweichung σ_X und $\sigma_{\mathcal{R}Y}$ beider Vektoren X und Y , kann aus der Kovarianz der Korrelationskoeffizient $corr_{XY} \in \mathbb{R}^{1 \times 1}$ abgeleitet werden [108], der unter anderem auf Galton [109] zurückgeht.

$$corr_{XY} = \frac{cov_{XY}}{\sigma_X \sigma_Y} \text{ mit } corr_{XY} \in \mathbb{R} \{-1, 1\} \quad (4.6)$$

Auf Basis von cov_{XY} sowie σ_X und σ_Y wird in Gleichung 4.6 der skalare Korrelationskoeffizient $corr_{XY}$ berechnet.

Ein Korrelationskoeffizient von $corr_{XY} > 0$ drückt eine positive Korrelation und $corr_{XY} < 0$ analog eine negative Korrelation aus. Je größer der Zahlenwert desto, höher das Korrelationsmaß. Demnach sind Korrelationskoeffizient von $corr_{XY} \approx 0$ Ausdruck für eine geringe Korrelation zwischen den Messreihen X und Y nach Pearson. Sowohl die Kovarianz- als auch die Korrelationsanalyse können analog auf eine Matrix $\mathbf{M} \in \mathbb{R}^{n_{\text{Mess.}} \times n_{\text{Var.}}}$ angewandt werden. Das Ergebnis ist eine quadratische Kovarianzmatrix $\mathbf{\Sigma} \in \mathbb{R}^{n_{\text{Var.}} \times n_{\text{Var.}}}$ bzw. Korrelationsmatrix $\mathbf{Corr} \in \mathbb{R}^{n_{\text{Var.}} \times n_{\text{Var.}}}$.

In technischen Anwendungen werden häufig Messsignale von Ursachen und Wirkungen miteinander verglichen. In Abhängigkeit von dem System, sind Zeitverzögerungen zwischen Ein- und Ausgängen ein mögliches Phänomen.

In diesem Zusammenhang kann der Korrelationskoeffizient $corr$ zur Quantifizierung der Verzögerung genutzt werden. Diese Methode ist unter dem Namen Kreuzkorrelation bekannt und im Gegensatz zur Berechnung des Korrelationskoeffizienten nach Pearson wird der Ausgangsvektor um jeweils einen Messwert Δn bzw. eine Zeiteinheit Δt verschoben. Exemplarisch wird für einen Eingangsvektor X und einen Ausgangsvektor Y der dazugehörige Korrelationskoeffizient $corr_{XY}(\Delta n)$ berechnet. Dieses Vorgehen wird für alle $\Delta n \in \mathbb{N} \{-n_{\text{Mess.}}/2, +n_{\text{Mess.}}/2\}$ durchgeführt. Die zu erwartende Zeitverzögerung $\tau_{\text{Ver.}}$ wird anhand der Position des maximalen Korrelationskoeffizienten zwischen Ein- und Ausgangsvektor in Gleichung 4.7 berechnet.

$$corr(\Delta n_{\text{Vers.}}) = \arg \max_{\Delta n} corr(\Delta n) \quad (4.7)$$

Für die Bestimmung der Verzögerung durch die Kreuzkorrelation gilt die Annahme eines statischen Systems mit proportionaler Übertragung zwischen Ein- und Ausgang. Die Anzahl des Versatzes $\Delta n_{\text{Vers.}}$ ist bei äquidistantem Messabstand proportional zur zeitlichen Verzögerung $\tau_{\text{Ver.}}$.

4.1.2. Analyse der Monotonie

Ein essenzieller Aspekt der Analyse von Zeitreihen ist die Bewertung der chronologischen Entwicklung des Signals. Die Monotonie mon berücksichtigt im Gegensatz zu den Methoden aus Unterkapitel 4.1.1 die Reihenfolge innerhalb einer Messreihe und beschreibt deren Verhalten. Konkret werden die reellen Zeitfunktionswerte $f(t)$ miteinander verglichen und geprüft, ob diese mit größeren Werten für t sinken, konstant bleiben oder wachsen. Mit dem Zeitpunkt $t_j \leq t_l$ und dem korrespondierenden Funktionswert $f(t_j) \leq f(t_l)$ folgt, dass f monoton steigt. Allgemein gilt, dass die Monotonie $mon \in \mathbb{R} \{-1, 1\}$ mit $mon = -1$ einen stark monoton sinkenden bzw. $mon = +1$ einen stark monoton steigenden Trend beschreibt. Bei bekannten und differenzierbaren

Funktionen kann die Monotonie gemäß 4.8 ausgedrückt werden.

$$\frac{df}{dt} < 0 \quad \text{monoton fallend} \quad (4.8)$$

$$\frac{df}{dt} = 0 \quad \text{konstant} \quad (4.9)$$

$$\frac{df}{dt} > 0 \quad \text{monoton steigend} \quad (4.10)$$

Für die Bewertung der Monotonie von Messdaten ist die Funktion in den meisten Fällen nicht bekannt und kann somit nicht differenziert werden. Eine mögliche Bewertung der Monotonie mon von Messreihen basiert auf der Bildung von finiten Differenzen. Anhand von Gleichung 4.11 wird die finite Differenz für $n_{\text{Mess.}}$ Messwerte mit konstanter Zeitdifferenz Δt zwischen den Messpunkten abgebildet.

$$\frac{df}{dt} \approx \frac{f(t+1) - f(t)}{\Delta t} \propto f(t+1) - f(t) \quad (4.11)$$

Auf Grundlage der finiten Differenzen kann die Anzahl der positiven- $n_{\text{Mess.}, df/dt > 0}$ sowie negativen Differenzen $n_{\text{Mess.}, df/dt < 0}$ ausgewertet werden. Dieser naheliegende Ansatz wird unter anderem von Lei u. a. [9] in folgender Form angeführt.

$$mon_{\text{Diff.}} = \frac{|n_{\text{Mess.}, df/dt > 0} - n_{\text{Mess.}, df/dt < 0}|}{n_{\text{Mess.}} - 1} \quad (4.12)$$

Die Berechnung der Monotonie $mon_{\text{Diff.}}$ anhand von Gleichung 4.12 ist bezogen auf die Rechenleistung ressourcenschonend, da die finiten Differenzen lediglich gebildet und gezählt werden. Reale Messwerte enthalten in vielen Fällen einen Rauschanteil, der die Aussagekraft begrenzt. In diesen Fällen kann eine Glättung des Signals mit den Methoden aus Unterkapitel 4.2.1 die Ergebnisse verbessern.

Ferner gibt es in der Statistik Hypothesentests, die zur Detektion von Trends in Zeitreihen eingesetzt werden [110]. Eine Möglichkeit ist die Berechnung des Rangkorrelationskoeffizienten nach Spearman [28]. Dieser kann als Sonderfall des Pearsonschen Korrelationskoeffizienten $corr$ in Gleichung 4.6 verstanden werden. Anstelle von den Einträgen der zwei Vektoren, werden die Ränge der Vektoren als Grundlage für die Bewertung der Korrelation verwendet. Der Rang $\mathcal{R}_X(l)$ gibt die Position eines Vektorelements $x_l = X(l)$ innerhalb des sortierten Vektors an. Analog zur Berechnung des Korrelationskoeffizienten nach Pearson werden für die Berechnung der Rangmittelwert $\mu_{\mathcal{R}_X}$ bzw. $\mu_{\mathcal{R}_Y}$ des Rangvektor \mathcal{R}_X bzw. \mathcal{R}_Y benötigt. In Gleichung 4.13 wird die Berechnung des Rangkorrelationskoeffizienten nach Spearman vorgestellt.

$$mon_{\text{Rang}} = \frac{\sum_{j=1}^{n_{\text{Mess.}}} \left(\mathcal{R}_X(j) - \mu_{\mathcal{R}_X} \right) \left(\mathcal{R}_Y(j) - \mu_{\mathcal{R}_Y} \right)}{\sqrt{\sum_{j=1}^{n_{\text{Mess.}}} \left(\mathcal{R}_X(j) - \mu_{\mathcal{R}_X} \right)^2} \sqrt{\sum_{j=1}^{n_{\text{Mess.}}} \left(\mathcal{R}_Y(j) - \mu_{\mathcal{R}_Y} \right)^2}} \quad (4.13)$$

Eine weitere Möglichkeit basiert auf dem von Kendall [110] vorgestellten MK Test. In Gleichung 4.14 wird die grundlegende Vergleichsoperation des MK Tests vorgestellt.

$$n_{\text{MK}} = \sum_{l=1}^{n_{\text{Mess.}}-1} \sum_{j=l+1}^{n_{\text{Mess.}}} \text{sgn}(x_j - x_l) \quad \text{mit} \quad \text{sgn}(x_j - x_l) = \begin{cases} +1 & \text{für } x_j - x_l > 0 \\ 0 & \text{für } x_j - x_l = 0 \\ -1 & \text{für } x_j - x_l < 0 \end{cases} \quad (4.14)$$

Das Ergebnis der paarweisen Vergleiche ist die Summe n_{MK} . Für die Vergleichsoperation wird die Signumfunktion sgn der Differenz genutzt, um eine vergleichbare Aussage zu erhalten. Durch das Normieren der Summe n_{MK} auf die Anzahl der Vergleiche ergibt sich die Monotonie mon_{MK} anhand von Gleichung 4.15.

$$\text{mon}_{\text{MK}} = \frac{2n_{\text{MK}}}{n_{\text{Mess.}} (n_{\text{Mess.}} - 1)} \quad (4.15)$$

Neben den statistischen Methoden werden auch datengetriebene Verfahren zur Bestimmung der Monotonie eingesetzt. Exemplarisch stellt Melek u. a. [111] eine Variation von unterschiedlichen Methoden zur Detektion von Trends in physiologischen Zeitreihen vor. Manche dieser Methoden, wie beispielsweise die k-Mittelpunktsklassifizierung (engl. k Means Clustering (KMC)), nutzen nicht die gesamte Messreihe als Einheit, sondern untersuchen einzelne Sequenzen. Für die einzelnen Sequenzen werden zusätzliche Informationen, wie beispielsweise der Schwerpunkt, berechnet.

Besonders mit dem Fokus auf die Verarbeitung von Zeitreihen aus der Industrie, ist die Bewertung der Monotonie auf bestimmte Teilabschnitte zu beschränken. Die Aussage der Gesamtheit der Zeitreihe sowie der Sequenz sind nicht notwendigerweise gleich und sind daher zu unterscheiden. Dieser Aspekt der Trendanalyse wird von Sharma u. a. [112] beschrieben und ist ein elementarer Bestandteil der Trendanalyse.

4.2. Allgemeine Datenvorverarbeitung

Als Erweiterung zu den in Unterkapitel 4.1 vorgestellten statistischen Kennzahlen, werden nachfolgend verschiedene Methoden der Datenvorverarbeitung vorgestellt. Ein Aspekt der Vorverarbeitung ist die Filterung, die in Unterkapitel 4.2.1 vorgestellt wird. Weiterhin werden verschiedene Verfahren zur Ausreißerdetektion (engl. Outlier Detection (OD)) in Unterkapitel 4.2.2 beschrieben. Darauf aufbauend wird in Unterkapitel 4.2.3 die Detektion von CP diskutiert und daraus der Aspekt der Datensequenzen in Unterkapitel 4.2.4 abgeleitet.

4.2.1. Glättung und Filterung

Für die Filterung von Signalen werden unterschiedliche Methoden eingesetzt, von denen eine Teilmenge auf der Faltung basiert. Wird ein gemessenes Signal S und eine rechteckige Filterfunktion f_{Filter} gefaltet, so entspricht das gefilterte Signal \tilde{S} einem gleitenden Mittelwert. Durch die Wahl der Filterfunktion f_{Filter} und der Fensterbreite $h_{\text{Filt.},S}$ werden die Eigenschaften des Filters eingestellt. Somit ist es möglich beispielsweise neuere Messwerte mehr zu gewichten.

Ergänzend werden nichtlineare Filter, wie der Rangordnungsfilter, zur Signalvorverarbeitung angewendet. Analog zur Faltung besitzen Rangordnungsfilter eine definierte Breite $h_{\text{Filt.},S}$, die über das Signal S gleitet. Ein Beispiel eines Rangordnungsfilters ist der Medianfilter, der zum Beispiel für die Rekonstruktion von Bildern eingesetzt wird [113]. Bei der Verarbeitung mit einem Medianfilter werden die Messwerte innerhalb der Fensterbreite $h_{\text{Filt.},S}$ sortiert und der Messwert an der mittleren Position des sortierten Signals als gefiltertes Signal zurückgegeben. Rabiner u. a. [113] stellen die Robustheit des Medianfilters gegenüber einzelnen Ausreißern heraus, weiterhin wird die Erhaltung von scharfen Kanten im Signal unterstrichen. Die Erhaltung von diskreten Kanten ist besonders bei dem Vergleich von Signalen mit Sprüngen notwendig. Durch die endliche

Fensterbreite $h_{\text{Filt.},S}$, ist die Filterung an den Rändern des Signals mit einer Breite von $h_{\text{Filt.},S}/2$ nicht möglich. Eine Lösung ist die kontinuierliche Verkleinerung des Fensters im Randbereich oder eine künstliche Verlängerung des Signals über den Anfang bzw. das Ende der Messreihe hinaus [114]. Beide Ansätze wirken sich auf das Filterverhalten und somit auch auf das gefilterte Signal aus und werden je nach Anwendung abgewogen. Diese Art der Filterung kann auch auf mehrdimensionale Fälle angewendet werden, wie beispielsweise die Filterung von Bildern [114]. Neben den Vorzügen hat der Medianfilter auch Kehrseiten, wie beispielsweise das Herausfiltern von zyklischen Signalen bei spezifischen Fensterbreiten $h_{\text{Filt.},S}$. Für eine detaillierte Diskussion der Eigenschaften wird auf Gallagher u. a. [115] verwiesen.

Die vorgestellten Methoden zur Filterung werden durch frequenzbasierte Filtermethoden, wie den Hoch-, Tief- oder Bandpass, ergänzt. Auf Grundlage bekannter Signaleigenschaften, wie beispielsweise bei der Schwingungsanalyse von mechanischen Systemen, erzielen frequenzbasierte Filter und deren Weiterentwicklungen sehr gute Ergebnisse. Aufgrund der notwendigen spezifischen Kenntnisse des zu filternden Signals werden diese Methoden an dieser Stelle nicht weiter ausgeführt.

4.2.2. Detektion von Ausreißern

In technischen Anwendungen ist die Information des Signals häufig durch Rauschen und Anomalien überlagert. Eine Teilmenge der Anomalien sind Ausreißer, die Werte innerhalb einer Messreihe beschreiben, die sich deutlich von den restlichen Werten der Messreihe unterscheiden [116]. Aufgrund der Eigenschaften der Ausreißer werden weitere Bearbeitungsschritte, wie zum Beispiel die Berechnung des Mittelwerts, verfälscht. Daher ist die Bereinigung der Ausreißer für die Folgeverarbeitung notwendig.

Die zuvor in Unterkapitel 4.2.1 beschriebenen Filtermethoden können als Basis zur OD genutzt werden. Beispielsweise kann die Differenz des Ursprungssignals S und des median-gefilterten Signals \hat{S} in Kombination mit einem definierten Grenzwert $\omega_{\text{Aus.}}$ zur OD genutzt werden.

Diese grundlegende Methode zur OD ist auf eine Messreihe beschränkt, wohingegen die Mahalanobis Distanz $d_{\text{Maha.}}$ eine mehrdimensionale Abweichung bewertet [117]. Konkret werden mehrere Messreihen in der Matrix \mathbf{M} zusammengefasst. Die unterschiedlichen Standardabweichungen σ und Mittelwerte μ der einzelnen Messreihen gehen durch die Kovarianzmatrix $\Sigma_{\mathbf{M}}$ in die Berechnung mit ein. Anhand von zwei beliebigen mehrdimensionalen Punkten $\mathbf{M}(l)$, $\mathbf{M}(j)$ folgt die Mahalanobis Distanz $d_{\text{Maha.}}$ in Gleichung 4.16.

$$d_{\text{Maha.}} = \sqrt{\left(\mathbf{M}(l) - \mathbf{M}(j)\right)^T \Sigma_{\mathbf{M}}^{-1} \left(\mathbf{M}(l) - \mathbf{M}(j)\right)} \quad (4.16)$$

Die Mahalanobis-Distanz $d_{\text{Maha.}}$ ist eine Möglichkeit multidimensionale Ausreißer zu identifizieren. Der Sonderfall der Euklidischen-Distanz ergibt sich aus der Mahalanobis-Distanz, wenn die Kovarianzmatrix $\Sigma_{\mathbf{M}}$ die Einheitsmatrix ist.

Da die Mahalanobis-Distanz von einer multidimensionalen Verteilung um einen Mittelwert ausgeht, können Ausreißer nur effektiv für einen klar definierten Arbeitspunkt ausgewiesen werden. Mehrere Arbeitspunkte führen zu multimodalen Verteilungen und einer verzerrten Aussage.

In diesen Fällen bietet sich der Local Outlier Factor (LOF) an. Der LOF gibt die Distanz an, die notwendig ist, um k -Nachbarn des ausgewählten Punktes $\mathbf{M}(l)$ zu erreichen. Somit ist es ein Dichtemaß, das die Umgebung des Punktes beschreibt. Bei einer geringen Dichte um den gesuchten Punkt $\mathbf{M}(l)$ ist die Distanz zum Erreichen der nächsten k -Nachbarn höher als bei Punkten mit hoher Dichte. Dieses Verfahren kann verschiedene Betriebspunkte in einem Datensatz berücksichtigen und vereinzelte Ausreißer können wirkungsvoll identifiziert werden.

Die Auswahl des OD Verfahrens ist an die Eigenschaften des Datensatzes gebunden. Demnach gibt es keine universelle Methode, die für alle Anwendungsfälle eingesetzt werden kann, sondern es steht vielmehr die Auswahl der spezifischen Methode im Vordergrund.

4.2.3. Wechselpunkt Detektion

Ein CP ist der Punkt, an dem sich die Eigenschaften des Signals S chronologisch vor bzw. nach dem CP unterscheiden. Anhand von Abbildung 4.2 werden verschiedene Arten von CP illustriert, wobei die Variation der Eigenschaften unterschiedlicher CP deutlich wird.

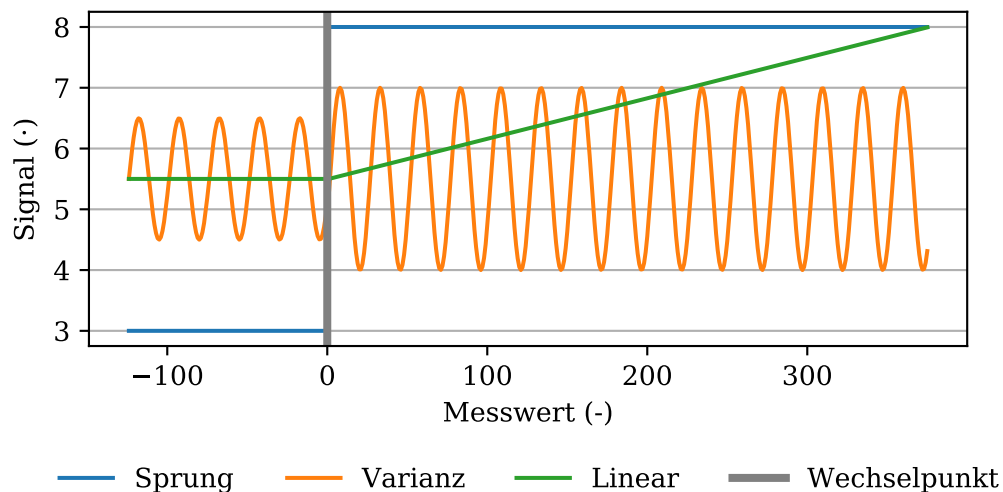


Abbildung 4.2.: Grafische Darstellung unterschiedlicher Arten von möglichen Wechselpunkten in einem Signal S .

Die Detektion von CP kann als Spezialfall der OD Methoden aus Unterkapitel 4.2.2 interpretiert werden und ist ein zentraler Aspekt in der Vorverarbeitung von Zeitreihen. Durch die Kenntnis der CP Position wird die Unterteilung des Signals S an den CP in einzelne Sequenzen ermöglicht. Die Teilung in einzelne Abschnitte ist die Grundlage für die Analyse anhand der zuvor vorgestellten Methoden.

Truong u. a. [118] stellen verschiedene Methoden zur Detektion von CP vor, basierend auf der Annahme, dass das zu untersuchende Signal S stückweise konstant ist. Die Ansätze werden durch eine bekannte bzw. unbekannt Anzahl der CP differenziert. Für industrielle Anwendungsfälle ist die Detektion von CP unbekannter Anzahl im Fokus. Die Identifikation der CP umfasst nach Truong u. a. [118] eine Kostenfunktion, eine

Suchmethode sowie eine Beschränkung.

Die Kostenfunktion $f_{\hat{\kappa}}$ ist ein Qualitätsmaß und drückt indirekt die Güte der Unterteilung an den CP aus. Exemplarisch werden die Kosten eines Vektors X in Gleichung 4.17 als die Summe der quadratischen Abweichung jedes Elementes $x_j = X(j)$ vom Mittelwert μ_X dargestellt.

$$f_{\hat{\kappa}}(X) = \sum_{j=1}^{n_{\text{Mess.}}} \|x_j - \mu_X\|_2^2 \quad (4.17)$$

Die quadratische Kostenfunktion hat die Eigenschaft negative Abweichungen in einen positiven Wert zu überführen und größere Abweichungen stärker zu gewichten. Die Auswahl der Kostenfunktionen $f_{\hat{\kappa}}$ kann in Abhängigkeit vom Anwendungsfall variiert werden.

Eine intuitive Suchmethode ist das Bisektionsverfahren, bei dem das ursprüngliche Signal, beziehungsweise in den nachfolgenden Schritten das Teilsignal, in zwei Teile unterteilt wird. Die iterative Unterteilung hat einen Rechenaufwand von $\mathcal{O}(n_{\text{Mess.}} \log(n_{\text{Mess.}}))$. Mit jeder Teilung werden kleinere Änderungen als mögliche CP identifiziert und somit die deutlichsten Änderungen zu Beginn detektiert. Eine weitere Suchmethode ist das gleitende Fenster, das die Kostenfunktion $f_{\hat{\kappa}}$ auf zwei gleich große, aneinandergrenzende Fenstern mit der Breite $h_{\text{Filt.,S}}$ anwendet. Die Kostenfunktion wird in beiden Fenstern einzeln sowie gemeinsam für beide Fenster zusammen ausgewertet. Anhand von Gleichung 4.18 kann der Unterschied zwischen den Abschnitten auf Basis der Kostenfunktion $f_{\hat{\kappa}}$ quantifiziert werden.

$$\Delta f_{\hat{\kappa}i} = f_{\hat{\kappa}}(X(l:j)) - f_{\hat{\kappa}}(X(l:i)) - f_{\hat{\kappa}}(X(i:j)) \quad (4.18)$$

Die beiden Fenster haben jeweils eine Breite von $h_{\text{Filt.,S}} = 0.5(j-l)$ mit $l < i < j$, wobei die Position i des CP die Grenze zwischen beiden Fenstern repräsentiert. Ist das Signal innerhalb der Fenster chronologisch vor bzw. nach i ähnlich, so ergibt sich für den gesamten Bereich zwischen l und j etwa der doppelte Wert im Vergleich zum Bereich l, i bzw. i, j und in Folge dessen geht $\Delta f_{\hat{\kappa}i}$ gegen 0. Liegt ein CP vor, so unterscheidet sich $\Delta f_{\hat{\kappa}i}$ deutlich von 0 und Änderungspunkte können als Maxima von $\Delta f_{\hat{\kappa}}$ identifiziert werden. Der Rechenaufwand der gleitenden Fenster Methode beträgt $\mathcal{O}(n_{\text{Mess.}})$ und steigt linear mit der Anzahl der Messwerte.

Auf Basis der zuvor identifizierten Maxima wird nachfolgend eine Teilmenge als CP ausgegeben. Bei bekannter Anzahl an CP werden die prominentesten CP ausgewählt. Im Falle einer unbekanntem Anzahl ist ein Grenzwert notwendig, bei dem die CP Detektion abgebrochen wird. Zu diesem Zweck wird der Abbildungsgenauigkeit eine Bestrafung durch zusätzliche CP gegenübergestellt.

Die Grundlage für die Bewertung der Detektion ist die Position $i_j = I(j)$ des einzelnen CP, die mit weiteren CP einen Vektor $I \in \mathbb{N}^{n_{\text{CP}} \times 1}$ bildet. Für die Bewertung der CP haben sich unterschiedliche Kennwerte bewährt. Eine intuitive Methode basiert auf dem in Gleichung 4.19 vorgestellten Residuum zwischen dem Positionsvektor der CP I und dessen Schätzung \hat{I} .

$$Res_{\text{CP}} = |\hat{I} - I| \quad (4.19)$$

Neben dem Residuenvektor Res_{CP} werden auch weitere Maßeinheiten, wie beispielsweise der Hausdorff Abstand, zur Bewertung eingesetzt. Dieser wird unter anderem für den

Vergleich von Bildern genutzt [119], [120]. Weiterhin kann die Quantifizierung der CP durch den Randindex ermöglicht werden. Dieser setzt die Größen der sich aus der Teilung an den CP ergebenden Sequenzen mit deren Schätzung ins Verhältnis und geht auf Hubert u. a. [121] zurück.

4.2.4. Datensequenzen

Eine Messreihe kann im Sinne von Unterkapitel 4.1 als eigenständig angesehen werden. Der aktuelle Zeitpunkt eines Zeitreihenvektors $X \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ wird als Ende definiert, wobei der Anfangspunkt ein beliebiger Zeitpunkt in der Vergangenheit ist. Der Vektor X hat eine endliche Länge und kann in $n_{\text{Sequ.}} \in \mathbb{N}$ Teilmessreihen X_{Teil} aufgeteilt werden. Diese einzelnen Teilmessreihen werden Datensequenz oder Datenbatch genannt und anhand von Gleichung 4.20 definiert.

$$X_{\text{Teil}} = X(j : l) \quad \text{mit } j < l \text{ und } l, j \in \mathbb{N}\{1, n_{\text{Mess.}}\} \quad (4.20)$$

Mit dem Unterschied zu einem konstanten Betriebspunkt kann eine Datensequenz zum Beispiel eine kontinuierliche Veränderung des Systems beinhalten. Aus diesem Grund ist die Zerlegung einer endlich langen Zeitreihe in einzelne Datensequenzen naheliegend und ermöglicht eine Differenzierung zwischen unterschiedlichen Datensequenzen und darauf aufbauend das Herausarbeiten von möglichen Einflussfaktoren.

Für den Vergleich von wiederkehrenden Datensequenzen ist es unter Umständen notwendig, die einzelnen Datensequenzen zeitlich zu harmonisieren [122]. Konkret werden Messungen eines ähnlichen zeitlichen Verlaufs mit unterschiedlicher Länge lokal so gewichtet, dass die Messungen aufeinander abgebildet werden können.

Die Bewertung der einzelnen Datensequenzen erfolgt anhand von Kennzahlen, die das Verhalten der darin enthaltenen Messwerte charakterisieren. Aufgrund der Eigenschaften werden diese charakteristischen Kenngrößen auch als Landmarke (engl. Landmark (LM)) oder Fingerabdruck (engl. Fingerprint (FIP)) bezeichnet [123]. Grundsätzlich können alle Kennzahlen angewendet werden, die das Verhalten der Datensequenz als Zahl bzw. Kategorie ausdrücken. Eine Grundlage bieten die in Unterkapitel 4.1 vorgestellten Kennzahlen der Statistik. Die Wahl des Kennwertes hängt von dem konkreten Anwendungsfall ab und kann neben statistischen Werten auch komplexe Kennzahlen umfassen, welche die Eigenschaften innerhalb einer Datensequenz beschreiben.

4.3. Grundlegende Modellbildung

Basierend auf der grundlegenden Datenvorverarbeitung in Unterkapitel 4.2 werden nachfolgend Methoden zur Abbildung eines Systems vorgestellt. Diese umfassen die Methode der linearen Regression in Unterkapitel 4.3.1 sowie PLS in Unterkapitel 4.3.2. Abschließend werden in Unterkapitel 4.3.3 Metriken zur Evaluierung einer Abbildung vorgestellt.

4.3.1. Lineare Regression

Die lineare Regression ist eine statistische Methode, um die Abhängigkeit zwischen einem Regressor $X \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ und einem Regressand $Y \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ auszudrücken.

Basierend auf dem Regressor X und den Parametern c_1 und c_2 wird der Regressand Y anhand von Gleichung 4.21 geschätzt.

$$\hat{Y} = c_1 + Xc_2 \quad (4.21)$$

Aufbauend auf Gleichung 4.21 können mehrere in der Matrix \mathbf{M} enthaltene Regressoren mit $\hat{Y} = \mathbf{M}C$ berücksichtigt werden. Die Abbildung durch eine Linearkombination der einzelnen Regressoren wird als multiple lineare Regression bezeichnet.

Zur Bestimmung des Parametervektors C wird unter anderem die OLS Methode eingesetzt. Gleichung 4.22 zeigt das Optimierungsproblem der linearen Regression, bei dem der Parametervektor C angepasst wird, sodass der Abbildungsfehler $\epsilon_{\text{lin.Reg.}}$ minimal wird.

$$\epsilon_{\text{lin.Reg.}} = \arg \min_C \left(\|Y - \hat{Y}(C)\|_2^2 \right) \quad (4.22)$$

Basierend auf *a priori* Wissen werden die Regressoren für eine bestimmte Abbildung identifiziert und ausgewählt. Methodisch kann dieser Prozess durch die Ridge- oder LASSO-Regression unterstützt werden. Gleichung 4.23 zeigt das Optimierungsproblem der LASSO-Regression, das im Vergleich mit Gleichung 4.22 die L1-Norm des Parametervektors C mit Vorfaktor α_{LASSO} enthält.

$$\epsilon_{\text{LASSO}} = \arg \min_C \left(\|Y - \hat{Y}(C)\|_2^2 + \alpha_{\text{LASSO}} \|C\|_1 \right) \quad (4.23)$$

Die LASSO-Regression setzt für die Regularisierung eine L1-Norm ein, die im Vergleich zur L2-Norm der Ridge-Regression, das zu Null Setzen einzelner Einträge des Parametervektors C ermöglicht. Folglich bestimmt die Wahl von α_{LASSO} indirekt die Anzahl der Regressoren. Diese Eigenschaft ist besonders für die automatisierte Selektion einer großen Anzahl von Features und bei einem exploratorischen Analyseansatz hilfreich.

4.3.2. Multivariate Analyse

Die multivariate Analyse (engl. Multivariate Analysis (MVA)) umfasst mehrere Verfahren wie die PCA, CCA, PLS und weitere. Diese Methoden basieren auf statistischen Grundlagen, wobei die Schnittmenge die Anwendung auf mehrere Zufallsvariablen bzw. Messgrößen zugleich ist, die Motivation der einzelnen Verfahren jedoch verschieden ist. Der Kern ist die Maximierung unterschiedlicher Zielgrößen, wie Varianz durch die PCA, Kovarianz durch die PLS und Korrelation durch die CCA, wobei die einzelnen Schritte der Verfahren große Ähnlichkeiten aufweisen [124].

Abweichend von der Definition dieser Arbeit, werden in Anlehnung an die Literatur für die MVA Methoden, Matrizen auf Basis von Zeilenvektoren verwendet [125]. Das Vorgehen wird anhand der Matrix $\mathbf{M} \in \mathbb{R}^{(n_{\text{Var.,Ein.}} + n_{\text{Var.,Aus.}}) \times n_{\text{Mess.}}}$ vorgestellt, die $n_{\text{Mess.}}$ Messwerte und $n_{\text{Var.}} = n_{\text{Var.,Ein.}} + n_{\text{Var.,Aus.}}$ Variablen umfasst. Im Gegensatz zur PCA wird sowohl für die CCA als auch die PLS der Datensatz in ein Set aus $n_{\text{Var.,Ein.}}$ Eingängen und $n_{\text{Var.,Aus.}}$ Ausgängen aufgeteilt. Demnach ergeben sich die Eingangsmatrix $\mathbf{X} \in \mathbb{R}^{n_{\text{Var.,Ein.}} \times n_{\text{Mess.}}}$ und die Ausgangsmatrix $\mathbf{Y} \in \mathbb{R}^{n_{\text{Var.,Aus.}} \times n_{\text{Mess.}}}$. Für die Verarbeitung werden sowohl die Eingangsmatrix \mathbf{X} als auch die Ausgangsmatrix \mathbf{Y} pro Variable anhand von Gleichung 4.4 normiert.

Die nachfolgende Darstellung basiert auf der Einführung von Ding u. a. [29]. Grundlegend für die folgende Aufarbeitung ist die Annahme einer Normalverteilung der

einzelnen Messgrößen. Die zuvor normierten Matrizen $\bar{\mathbf{X}}$ und $\bar{\mathbf{Y}}$ werden anhand von Gleichung 4.24 in einen Erwartungswertvektor E sowie die Kovarianzmatrix Σ aufgliedert.

$$\bar{\mathbf{M}} = \begin{bmatrix} \bar{\mathbf{X}} \\ \bar{\mathbf{Y}} \end{bmatrix} \sim n \left(\begin{bmatrix} E_{\bar{\mathbf{X}}} \\ E_{\bar{\mathbf{Y}}} \end{bmatrix}, \begin{bmatrix} \Sigma_{\bar{\mathbf{X}}} & \Sigma_{\bar{\mathbf{X}}\bar{\mathbf{Y}}} \\ \Sigma_{\bar{\mathbf{Y}}\bar{\mathbf{X}}} & \Sigma_{\bar{\mathbf{Y}}} \end{bmatrix} \right) \quad (4.24)$$

Eine gemeinsame Beschreibung erfolgt nachfolgend anhand der Matrix \mathcal{Z} , die jeweils für PCA, PLS und CCA gebildet wird. Im Anschluss erfolgt die Beschreibung der Verfahren erneut gemeinsam.

Die PCA besitzt in der grundlegenden Form keine Zuordnung von Ein- und Ausgängen. Das Ziel der PCA ist die Varianz des Datensatzes durch die Linearkombination einer Teilmenge der zur Verfügung stehenden Einflussgrößen zu erklären. Aus diesem Grund wird die PCA unter anderem zur Dimensionsreduktion genutzt.

Darüber hinaus zeigen Ding u. a. [126] die Anwendung im Bereich der FD und FDI zur Prozessüberwachung auf. MacGregor u. a. [127] und He u. a. [128] wenden die PCA im industriellen Kontext an und verdeutlichen sowohl die technische Relevanz als auch die Aktualität der Methode. Neben der statischen Basismethode, ist die Abbildung dynamischen Verhaltens durch Erweiterungen möglich [29]. Grundlegend erfolgt die Berechnung von \mathcal{Z} für die PCA anhand von Gleichung 4.25.

$$\mathcal{Z}_{\text{PCA}} = \Sigma_{\bar{\mathbf{X}}} \quad (4.25)$$

Die PLS ist eine multivariate Betrachtung, der in Unterkapitel 4.3.1 vorgestellten Regression. Es ist eine statistische Methode zur Datenanalyse und Fehlerdetektion, die auf Wold [129] zurückgeht. Ding [125] stellt die Grundlagen sehr übersichtlich dar, grenzt die Methode zur OLS Methode ab und skizziert den Einsatz zur FD. In Gleichung 4.26 wird \mathcal{Z} für die PLS beschrieben.

$$\mathcal{Z}_{\text{PLS}} = \Sigma_{\bar{\mathbf{X}}\bar{\mathbf{Y}}} \quad (4.26)$$

Die CCA identifiziert die größtmögliche Korrelation zwischen einer Linearkombination der Eingangsmatrix $\bar{\mathbf{X}}$ und einer Linearkombination der Ausgangsmatrix $\bar{\mathbf{Y}}$. Auf Basis von Gleichung 4.6 kann die Korrelationsmatrix **Corr** wie in Gleichung 4.27 ausgedrückt werden.

$$\mathcal{Z}_{\text{CCA}} = \Sigma_{\bar{\mathbf{X}}}^{-0.5} \Sigma_{\bar{\mathbf{X}}\bar{\mathbf{Y}}} \Sigma_{\bar{\mathbf{Y}}}^{-0.5} \quad (4.27)$$

Die MVA Methoden PCA, PLS und CCA teilen die gleiche Vorverarbeitung durch die Standardisierung anhand von Gleichung 4.4. In Abhängigkeit der unterschiedlichen Weiterverarbeitung liegt unabhängig vom eingesetzten Verfahren mit \mathcal{Z} ein Zwischenergebnis als Matrix vor. Anhand von Gleichung 4.28 erfolgt zum Zwecke der Maximierung die Singulärwertzerlegung (engl. Singular Value Decomposition (SVD)) in Singulärwerte und Singulärvektoren.

$$\text{SVD}(\mathcal{Z}) = \mathbf{L}_{\text{SVD}} \mathbf{\Xi} \mathbf{R}_{\text{SVD}}^T \quad (4.28)$$

Die Singulärwerte sind in der diagonalen Matrix $\mathbf{\Xi}$ enthalten. Geometrisch entsprechen die Singulärwerte einer Skalierung. Die Matrix \mathbf{L}_{SVD} bzw. \mathbf{R}_{SVD} enthalten Singulärvektoren, die auch als Linkssingulärvektoren bzw. Rechtssingulärvektoren bezeichnet werden. Die Eigenvektormatrizen können geometrisch als Rotation verstanden werden. Auf Grundlage der absteigend sortierten Singulärwerte können die größten Einträge der

Matrix Ξ und die korrespondierenden Singulärvektoren ausgewählt werden. Diese Teilmenge der Singulärvektoren wird im Falle der PCA als Hauptkomponenten bezeichnet und ermöglicht die Visualisierung im Hauptkomponentenraum. Neben den einzelnen Messungen können auch die Features in einer Gewichtungsgrafik (engl. Loading Plot) dargestellt und deren Beitrag zum Maximierungsziel ausgewertet werden.

In Abhängigkeit des Ziels der Analyse ist eine geeignete MVA Methode auszuwählen oder unter Umständen eine Kombination der Methoden durchzuführen.

4.3.3. Metriken zur Bewertung der Modellgüte

Unabhängig von der Modellbildung an sich, wird eine Bewertungsgrundlage zum Vergleich verschiedener Schätzmodelle benötigt. Im Folgenden werden die Metriken anhand des Ergebnisvektors $Y \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ und dessen Schätzung $\hat{Y} \in \mathbb{R}^{n_{\text{Mess.}} \times 1}$ verdeutlicht. Eine grundlegende Methode zur Bewertung einer Abbildung ist die Berechnung des Bestimmtheitsmaßes R^2 . Gleichung 4.29 normiert die summierte quadratische Abweichung zwischen Messwert $y_j = Y(j)$ und Schätzwert \hat{y}_j auf die summierte quadratische Abweichung zwischen y_j und μ_Y [130]. Der Wertebereich ist auf $R^2 \in \mathbb{R} \{-\infty, 1\}$ beschränkt, wobei $R^2 = 1$ eine perfekte Abbildung wiedergibt.

$$R^2 = 1 - \frac{\sum_{j=1}^{n_{\text{Mess.}}} (y_j - \hat{y}_j)^2}{\sum_{j=1}^{n_{\text{Mess.}}} (y_j - \mu_Y)^2} \quad (4.29)$$

Basierend auf der R^2 Metrik wird in Gleichung 4.30 die angepasste (engl. adjusted) R^2_{Adj} Metrik vorgestellt. Diese ist besonders für den Vergleich verschiedener linearer Modelle unterschiedlicher Komplexität geeignet und bezieht die Parameteranzahl n_C mit ein.

$$R^2_{\text{Adj.}} = 1 - \left(\frac{(1 - R^2)(n_{\text{Mess.}} - 1)}{n_{\text{Mess.}} - n_C - 1} \right) \quad (4.30)$$

Im Gegensatz zu den R^2 basierten Metriken wird der mittlere quadratische Fehler (engl. Root Mean Squared Error (RMSE)) nicht auf die summierte Abweichung zum Mittelwert normiert. Gleichung 4.31 zeigt, dass für eine bessere Handhabung die Quadratwurzel aus der Summe der quadrierten Differenzen gebildet wird.

$$RMSE = \sqrt{\frac{1}{n_{\text{Mess.}} - 2} \sum_{j=1}^{n_{\text{Mess.}}} (y_j - \hat{y}_j)^2} \quad (4.31)$$

Durch das Beziehen auf die absolute Höhe des Messwertes wird der Vergleich der Abweichung vereinfacht. Der mittlere absolute Fehler (engl. Mean Absolute Error (MAE)) wird anhand von Gleichung 4.32 in Prozent (engl. Mean Absolute Percentage Error (MAPE)) vorgestellt.

$$MAPE = \frac{100}{n_{\text{Mess.}}} \sum_{j=1}^{n_{\text{Mess.}}} \left| \frac{y_j - \hat{y}_j}{y_j} \right| \quad (4.32)$$

Bei der Modellauswahl auf Basis der vorgestellten Metriken wird der Metrik eine zentrale Rolle zugeordnet. Anscombe [131] illustriert an drei einfachen Beispielen, dass die Bewertung einer Schätzung anhand von Metriken klaren Grenzen unterliegt. So können

Ausreißer einen großen Einfluss besitzen und das Verhalten wesentlich ändern. Die Bewertung einer Schätzung durch eine Metrik ist aus diesem Grund nur bedingt aussagekräftig.

Neben den allgemeinen Metriken zur Bewertung von Modellen gibt es spezifische Metriken für die Bewertung der RUL Schätzungen. Eine grundlegende Metrik basiert auf der Differenz von geschätzter und gemessener RUL. Diese Differenz wird auch als Residuum der RUL Res_{RUL} bezeichnet und anhand von Gleichung 4.33 beschrieben.

$$res_{RUL} = t_{RUL}^{\hat{}} - t_{RUL} \text{ mit } res_{RULj} = Res_{RUL}(j) \quad (4.33)$$

Eine weitere Metrik ist das Punktemaß $Score_{RUL}$ (engl. Score), das für die Bewertung der RUL Schätzungen im Rahmen der PHM Prediction Challenge 2008 eingesetzt wird [132]. Die Berechnung erfolgt anhand von Gleichung 4.34 und basiert auf dem Residuenvektor Res_{RUL} der RUL.

$$Score_{RUL} = \begin{cases} \sum_{j=1}^{n_{\text{Mess.}}} \left(\exp(-Res_{RUL}/10) - 1 \right) & \text{für } Res_{RUL} < 0 \\ \sum_{j=1}^{n_{\text{Mess.}}} \left(\exp(Res_{RUL}/13) - 1 \right) & \text{für } Res_{RUL} \geq 0 \end{cases} \quad (4.34)$$

Gleichung 4.34 bestraft ein Überschätzen der RUL stärker im Vergleich zum Unterschätzen. Somit wird sichergestellt, dass konservativere Schätzungen besser bewertet werden bei betragsmäßig gleicher Abweichung. Saxena u. a. [132] skizzieren den Nachteil der Metrik durch eine fehlende Normierung zur RUL.

Neben den aufgeführten Methoden gibt es weitere Metriken zur Bewertung der RUL Schätzung, wie beispielsweise die α - λ -Metrik, die an dieser Stelle nicht weiter ausgeführt wird [65].

4.4. Partikelfilter im Detail

Im Folgenden werden bekannte industrielle Anwendungen des PF in Unterkapitel 4.4.1 vorgestellt. Anschließend wird der PF in Unterkapitel 4.4.2 vom KF abgegrenzt. Auf dieser Grundlage wird die Methode des PF in Unterkapitel 4.4.3 detailliert eingeführt. Darauf aufbauend werden in Unterkapitel 4.4.4 und 4.4.5 Herausforderungen und Lösungsansätze dieser Methode diskutiert.

4.4.1. Einsatzgebiete des Partikelfilters

Die vorgestellten Anwendungsfälle des PF aus dem Bereich der RUL Schätzung aus Unterkapitel 2.2.3 werden im Folgenden durch weitere Anwendungen ergänzt. Wie Kapitel 2 zeigt, ist das wissenschaftliche Interesse an Batterietechnologien im Allgemeinen ausgeprägt. Die wachsenden Anwendungsfälle von Batterien erhöhen die Notwendigkeit deren Überwachung. Der PF kann den Zustand einer Batterie überwachen, wie beispielsweise An u. a. [133] anhand einer Lithium-Ion Batterie zeigen. Die Anwendungsbeispiele sind umfassend, jedoch in den meisten Fällen mit einer Fragestellung im Bereich RUL verknüpft.

Ein weiterer Anwendungsfall ist die Schätzung des Risswachstums, der ebenfalls eng mit dem Kontext der RUL Schätzung verbunden ist, wobei die Anwendungsfälle stark variieren. Beispielsweise beschreiben An u. a. [133] die Grundfunktionen des PF anhand eines Anwendungsfalls zur Risswachstumsschätzung auf Basis des Paris-Erdogan-Modells

[134]. Das Paris-Erdogan-Modell ist bis heute ein grundlegendes Modell, das auch für industrielle Anwendungsfälle genutzt wird. Beispielsweise stellen Orchard u. a. [135] eine Schätzung des Risswachstums an einer Turbinenschaufel vor. Die Methode wird auf einen weiteren Anwendungsfall zur Schätzung des Risswachstums einer Getriebeplatte des UH60 Hubschraubers übertragen und weiterentwickelt [136]. Zur Detektion des Übergangs zwischen fehlerhaftem und fehlerfreiem Zustand werden zwei Modelle gleichzeitig evaluiert, wobei eines den fehlerhaften und das andere den fehlerfreien Zustand beschreibt. Die Entwicklung von Rissen ist folglich auch für industrielle Anwendungsfälle besonders im Bereich der Mechanik von Bedeutung.

Ein weiteres Anwendungsgebiet von PF ist die Schätzung der Position auf Basis von Bewegungsgleichungen. Ein bekannter Teilbereich ist die Lokalisierung von Staubsaugerrobotern innerhalb einer Räumlichkeit. Sileshi u. a. [137] kombinieren die Lokalisierung mit der Kartenerstellung auf Grundlage eines Lasersensors. Dieser Teilbereich ist verknüpft mit den hohen Stückzahlen der Staubsaugerroboter, wohingegen auch Anwendungen mit geringeren Stückzahlen realisiert werden. Zum Beispiel setzt Bergman [138] den PF zur Positionsbestimmung von Flugzeugen ohne den Einsatz von Satelliten und Radarsystemen ein. Die Grundlage ist ein Abgleich mit einer bekannten Höhenkarte, die mit Hilfe einer Distanzmessung des Flugzeugs über Grund und der Information der Höhe über Meeresspiegel abgeglichen wird. Diese Art der Positionierung funktioniert jedoch nicht über großen Flächen ohne deutliche Höhenänderung, wie Seen oder dem Meer. Eine artverwandte Anwendung ist die Verfolgung von mobilen Zielen. Pardal u. a. [139] stellen eine Möglichkeit vor, die Position von Satelliten und deren Bewegung auf einem Orbit zu schätzen. Die grundlegenden Beschreibungen von Labbe [140] unterstreichen den Anwendungsbereich von Positionierungs- und Trackingaufgaben.

Neben diesen Anwendungsfeldern gibt es auch Einzelanwendungen, in denen der PF eingesetzt wird. Beispielsweise setzen Arifin u. a. [141] einen PF zur Leckage Detektion auf Basis eines einfachen diskretisierten thermodynamischen Modells zur Schätzung des Drucks an verschiedenen Positionen einer Pipeline ein. Insgesamt skizzieren die unterschiedlichen Anwendungsfälle die vielseitigen Einsatzmöglichkeiten des PF.

4.4.2. Abgrenzung zum Kalmanfilter

Der PF ist ein ZRM, das auch unter den Namen sequenzielle Monte-Carlo Methode oder Stiefelriemen (engl. Boot Strapping (BS)) Filter bekannt ist und zu der Klasse der stochastischen Zustandsschätzer gehört [142]. Bedingt durch die Struktur des PF kann dieser auch als Spezialfall eines HMM angesehen werden [143]. Die Filterung durch den PF erfolgt rekursiv, das heißt, dass neue Informationen sequentiell abgearbeitet werden, ohne auf historische Daten zurückgreifen zu müssen [142].

Grundlegend baut der PF auf dem von Kalman [144] vorgestellten KF auf. Die Verarbeitung der Daten innerhalb des KF folgt einer festgelegten Struktur, die anhand der zeitlich diskretisierten Gleichung 4.35 und 4.36 vorgestellt wird.

$$\text{ZG: } \Phi_t = \mathbf{A}_{\text{KF}}\Phi_{t-1} + \mathbf{B}_{\text{KF}}\Gamma_{t-1} + K_\Phi \quad (4.35)$$

$$\text{AG: } \Psi_t = \mathbf{C}_{\text{KF}}\Phi_t + \mathbf{D}_{\text{KF}}\Gamma_t + K_\Psi \quad (4.36)$$

Die ZG weist die Produkte aus dem Zustandsvektor Φ_{t-1} und der Systemmatrix \mathbf{A}_{KF} sowie dem Eingangsvektor Γ_{t-1} und der Eingangsmatrix \mathbf{B}_{KF} aus. Weiterhin wird der Prozessrauschenfluss durch den Rauschvektor K_Φ berücksichtigt. Summiert ergeben

die Terme einen aktualisierten Zustandsvektor Φ_t in Gleichung 4.35.

Analog bildet die in Gleichung 4.36 vorgestellte AG den Ausgangsvektor Ψ_t als Summe des Produktes aus Zustandsvektor $\Phi_{p,t}$ und Ausgangsmatrix \mathbf{C}_{KF} , Eingangsvektor Γ_t und Durchgangsmatrix \mathbf{D}_{KF} sowie dem Messrauscheinfluss in Form des Rauschvektors K_Ψ ab. Die relevanten Verarbeitungsschritte des KF werden anhand von Abbildung 4.3 visualisiert.

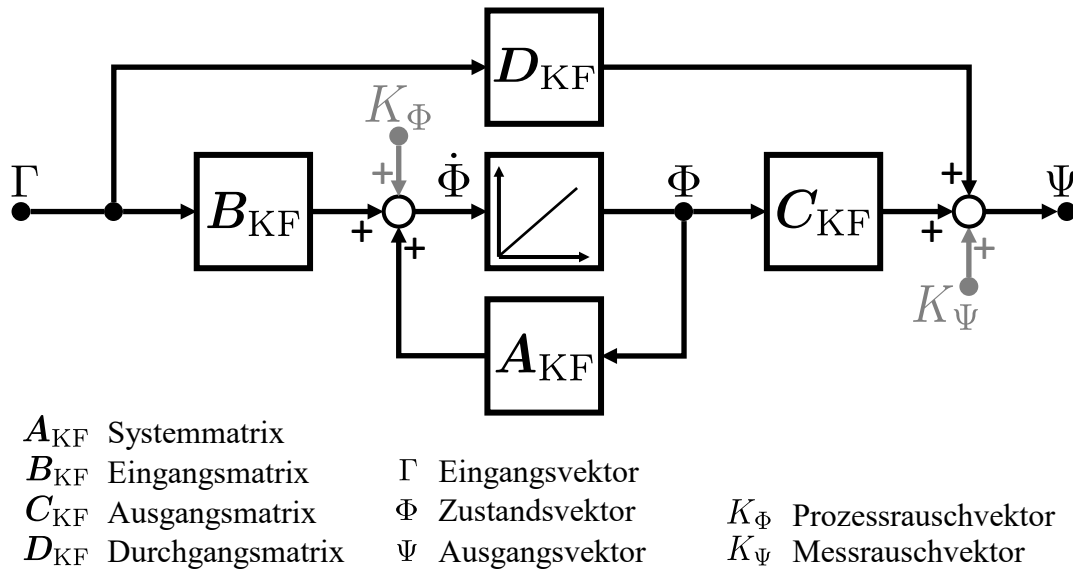


Abbildung 4.3.: Grafische Darstellung der Funktionsweise eines Kalman Filters auf Basis von Eingangsvektor Γ_t , Zustandsvektor Φ_t und Ausgangsvektor Ψ_t , der Systemmatrix A_{KF} , Eingangsmatrix B_{KF} , Ausgangsmatrix C_{KF} und Durchgangsmatrix D_{KF} sowie Messrauscheinfluss K_Ψ und Prozessrauscheinfluss K_Φ .

Bedingt durch die Struktur des KF ist dieser auf lineare Abbildungen sowie eine Normalverteilung für das Mess- K_Ψ und Prozessrauschen K_Φ festgelegt [142]. Falls diese Annahmen gerechtfertigt sind, ist der KF die optimale Lösung. Für einige reale Anwendungsfälle treffen diese Annahmen jedoch nicht zu.

Der KF kann für eine verbesserte Adaption an reale Anwendungsfälle linearisierte Daten eines dynamischen Systems verarbeiten. Dieses Vorgehen ist als erweiterter KF (engl. Extended Kalman Filter (EKF)) bekannt [142]. Die Normalverteilungen des Mess- K_Ψ und Prozessrauschens K_Φ bleiben eine notwendige Annahme, die im industriellen Umfeld nicht immer zutreffend ist.

Im Gegensatz zum EKF kann der PF sowohl dynamische Systeme als auch nicht normalverteiltes Mess- K_Ψ und Prozessrauschen K_Φ abbilden. Dies ermöglicht die Lösung von Systemen für die es keine geschlossene Form gibt [143]. Darüber hinaus können die geschätzten Verteilungen von Mess- K_Ψ und Prozessrauschen K_Φ mehrere Moden besitzen und sind nicht notwendigerweise normalverteilt [10].

Die Flexibilität des PF zur Abbildung dynamischer Systeme in Kombination mit keinen Voraussetzungen im Hinblick auf die Verteilungen des Mess- K_Ψ und Prozessrauschens K_Φ beinhaltet andere Herausforderungen. Durch das Glivenko-Cantelli Theorem wird belegt, dass wenn die Anzahl der Partikel gegen Unendlich geht, auch die zu

schätzende Verteilung konvergiert [145]. Die Anzahl der Partikel n_φ ist in der Realität limitiert, da die Lösung rechenaufwändig ist [143]. Im Rahmen der Weiterentwicklung sind aus diesen Grundmethoden wie der unterstützte PF (engl. Auxiliary Particle Filter (APF)) sowie der Rao-Blackwell PF entwickelt worden [143].

4.4.3. Grundlegende Funktionsweise

Die nachfolgende Beschreibung basiert auf den Ausführungen von Arulampalam u. a. [142] und An u. a. [133]:

Im Kern eines PF steht die Beschreibung eines Systems als ZRM basierend auf einer endlichen Anzahl n_φ von Partikeln, die im Folgenden als Partikelset bezeichnet werden. Ein Partikel p beschreibt auf Basis eines Parametervektor $\Theta_{p,t}$ einen korrespondierenden Zustandsvektor $\Phi_{p,t}$ zur Zeit t . Die Abbildung durch AG und ZG berücksichtigt den Ein- Γ_t sowie Ausgangsvektor Ψ_t und wird anhand von Abbildung 4.4 visualisiert.

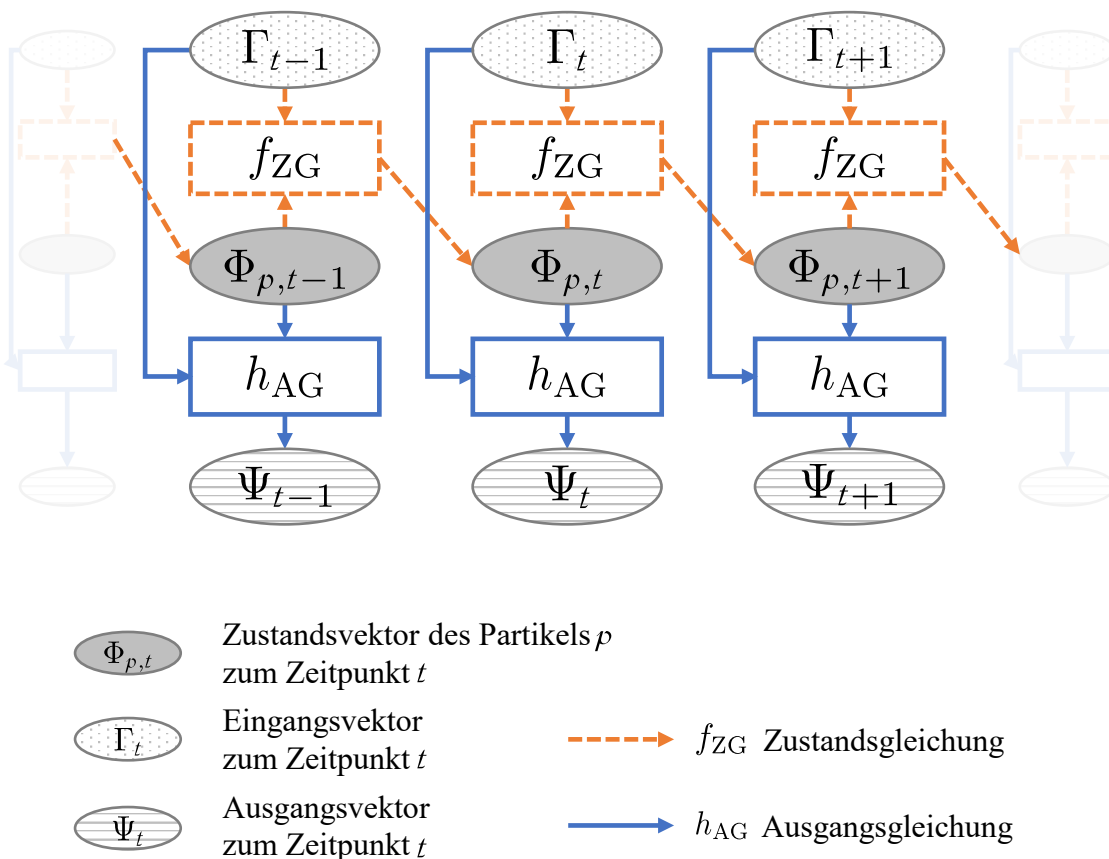


Abbildung 4.4.: Grafische Darstellung der Verknüpfung zwischen Eingangsvektor Γ_t , Zustandsvektor $\Phi_{p,t}$ und Ausgangsvektor Ψ_t durch die Zustandsgleichung f_{ZG} und Ausgangsgleichung h_{AG} für einen Partikel p zum Zeitpunkt t .

Die Transition zwischen den Zuständen $\Phi_{p,t-1}$ und $\Phi_{p,t}$ wird durch die ZG in Gleichung 4.37 beschrieben und hängt im Wesentlichen von dem Eingangsvektor Γ_{t-1} und dem Parametervektor $\Theta_{p,t-1}$ ab.

$$\Phi_{p,t} = f_{ZG}(\Gamma_{t-1}, \Phi_{p,t-1}, \Theta_{p,t-1}, K_{\Phi_{t-1}}) \quad (4.37)$$

Die ZG f_{ZG} kann statische und dynamische Systeme abbilden und enthält den Parametervektor $\Theta_{p,t-1}$ sowie den Rauschvektor $K_\Phi \sim \Lambda$. Das Rauschen ist nicht notwendigerweise normalverteilt und folgt einer beliebigen Verteilung Λ .

Der Ausgangsvektor Ψ_t ist durch die AG h_{AG} in Gleichung 4.38 mit dem Zustandsvektor $\Phi_{p,t}$ und dem Eingangsvektor Γ_t verknüpft. Analog zur ZG enthält die AG ebenfalls einen Rauschvektor $K_\Psi \sim \Lambda$, der nicht notwendigerweise normalverteilt ist.

$$\Psi_t = h_{AG}(\Gamma_t, \Phi_{p,t}, K_{\Psi,t}) \quad (4.38)$$

Neben der Berechnung der Zustandstransition, bewertet der PF auch die damit verbundene Wahrscheinlichkeit eines Partikels p . Grundlegender Bestandteil ist das Bayessche Theorem, das die bedingten Wahrscheinlichkeiten $p(\Pi_A \cap \Pi_B) = p(\Pi_A|\Pi_B)p(\Pi_B) = p(\Pi_B|\Pi_A)p(\Pi_A)$ miteinander verknüpft [146].

Übertragen auf die Bewertung der Schätzung wird die Wahrscheinlichkeit p_t zur Zeit t , dass der Zustandsvektor $\Phi_{p,t}$ unter dem Ausgangsvektor Ψ_t eintritt, in Gleichung 4.39 beschrieben.

$$p_t(\Phi_{p,t}|\Psi_t) = \frac{p_t(\Psi_t|\Phi_{p,t})}{p_t(\Psi_t)} p_t(\Phi_{p,t}) \quad (4.39)$$

Posterior Prior

Der Term $p_t(\Phi_{p,t})$ gibt die Wahrscheinlichkeit eines spezifischen Zustandsvektors $\Phi_{p,t}$ an und wird auch als „Prior“ bezeichnet. Initial kann dieser Term auf einen bestimmten Wert definiert werden und gilt somit als bekannt.

Auf der linken Seite von Gleichung 4.39 wird die Wahrscheinlichkeit $p_t(\Phi_{p,t}|\Psi_t)$ des Zustandsvektors $\Phi_{p,t}$ unter Bedingung des Ausgangsvektors Ψ_t ausgewiesen. Dieser Term wird auch als „Posterior“ bezeichnet und besagt, dass die bekannte Wahrscheinlichkeit $p_t(\Phi_{p,t})$ auf Basis des Ausgangsvektors Ψ_t eingeschränkt werden kann. Innerhalb des PF ist das Posterior das Ergebnis des Aktualisierungsprozesses.

Der Zähler des mittleren Terms $p_t(\Psi_t|\Phi_{p,t})$ in Gleichung 4.39 gibt die Wahrscheinlichkeit des Ausgangsvektors Ψ_t unter der Bedingung des Zustandsvektors $\Phi_{p,t}$ an. Auf Basis einer gegebenen Wahrscheinlichkeitsdichtefunktion (engl. Probability Density Function (PDF)) und einem bekannten Ausgangsvektor Ψ_t wird die Wahrscheinlichkeit eines Zustandsvektors $\Phi_{p,t}$ berechnet, die auch als Likelihood bezeichnet wird.

Unter der Bedingung eines Zustandsvektors $\Phi_{p,t} = \Phi_t(p)$ für einen spezifischen Partikel p folgt die Likelihood $\ell_{p,t} = \mathcal{L}_t(p)$. Aufgrund der endlichen Partikelanzahl n_ϕ ist der Likelihoodvektor \mathcal{L}_t nur eine Annäherung an die PDF. Infolgedessen wird die Wahrscheinlichkeit des Ausgangsvektors $p_t(\Psi_t)$ anhand von Gleichung 4.40 approximiert.

$$p_t(\Psi_t) \approx \sum_{l=1}^{n_\phi} \ell_{p,t}(\Psi_t|\Phi_{p,l}) \quad (4.40)$$

Exemplarisch wird die Berechnung der Likelihood $\ell_{p,t}$ zur Zeit t anhand des Eingangs- Γ_t und Ausgangsvektors Ψ_t und des Zustandsvektors $\Phi_{p,t} = \Phi_t(p)$ eines Partikels p auf Basis einer Normalverteilung in Gleichung 4.41 ausgedrückt. Die duale Berechnung der Ausgangsgleichung h_{AG} wird durch \circ gekennzeichnet und beschreibt das Vertauschen von Ein- und Ausgängen. Für die Bestimmung der Likelihood $\ell_{p,t}$ kann der Toleranzvektor $T_{Tol.}$ entweder als Teil des Parametervektors $\Theta_{p,t}$ geschätzt oder alternativ auf einen definierten Wert festgelegt werden.

$$\ell_{p,t}(\Psi_t|\Phi_{p,t}) = \frac{1}{\sqrt{2\pi}T_{Tol.}} \exp\left(-\frac{1}{2}\left(\frac{h_{AG}^\circ(\Psi_t, \Gamma_t) - \Phi_{p,t}}{T_{Tol.}}\right)^2\right) \quad (4.41)$$

Vor der Aktivierung des PF ist die Initialisierung der n_φ Partikel notwendig. Diese umfasst für den Partikel p das Setzen geeigneter Werte für den Zustandsvektor $\Phi_{p,t=0}$, den Parametervektor $\Theta_{p,t=0}$ sowie die Prior Wahrscheinlichkeit $p_{p,t=0}$.

Der Parameterraum (PR) bietet die Grundlage auf Basis einer Gleichverteilung zufällige Kombinationen daraus abzuleiten. Bei einem vergleichsweise unbekanntem System ist dieser Ansatz naheliegend, jedoch wird durch dieses Vorgehen eine Vielzahl von Partikeln durch unwahrscheinliche Kombinationen verschwendet. Spiegelt die initiale Verteilung bereits die Eigenschaften wider, so kann der Großteil der Partikel erhalten bleiben [142]. Naheliegendermaßen initialisieren Cai u. a. [70] die Parametermatrix $\Theta_{t=0}$ auf Basis von bekannten Betrieb-bis-zum-Fehler (engl. Run-to-Failure) Daten. Dazu wird der aktuelle Zustand $\Phi_{\text{Akt.}}$ mit historischen Zuständen Φ_t verglichen und der korrespondierende historische Parametervektor Θ_t mit der größten Übereinstimmung als Grundlage für die Initialisierung der Parametermatrix $\Theta_{t=0}$ genutzt.

Analog zur Initialisierung des Parametervektors $\Theta_{p,t=0}$, kann der Zustandsraum (ZR) für die Initialisierung des Zustandsvektors $\Phi_{p,t=0}$ verwendet werden, wobei die Eingrenzung auf einen lokalen Betriebspunkt zielführend ist.

Die initiale Prior Wahrscheinlichkeit $p_{t=0}$ kann auf Basis von historischen Erfahrungswerten ebenfalls spezifiziert werden. Falls kein Wissen zur Initialisierung zur Verfügung steht, ist die Ableitung der Prior Wahrscheinlichkeit $p_{t=0}$ in Anlehnung an eine Gleichverteilung naheliegend.

Im Anschluss an die Initialisierung ermöglicht der PF durch die Kombination aus Zustandsschätzung und Zustandsaktualisierung die iterative Verbesserung der geschätzten Zustände jedes Partikels p in der Zustandsmatrix $\hat{\Phi}$ über die Betriebszeit t . Nachfolgend werden verschiedene Schätzverfahren in Anlehnung an die Darstellung von Ding [147] vorgestellt. Diese Verfahren bilden die Grundlagen zur Schätzung der RUL.

Die Schätzung des Zustandsvektors $\hat{\Phi}_{p,t}$ eines Partikels zum Zeitpunkt t auf Basis der letzten j Zustandsvektoren $\Phi_{p,t-j}$ bis $\Phi_{p,t}$ und den korrespondierenden Eingangsvektoren Γ_{t-j} bis Γ_t wird als Filterung bezeichnet. Demgegenüber kann der PF auf Basis der bekannten Zustandsvektoren $\Phi_{p,t-j}$ bis $\Phi_{p,t-1}$ und Eingangsvektoren Γ_{t-j} bis Γ_{t-1} den Zustandsvektor $\hat{\Phi}_{p,t}$ schätzen, das als Prädiktion bezeichnet wird. Auf Grundlage bekannter Eingangsvektoren Γ_t , kann die Schätzung beliebig viele Zeitschritte in die Zukunft fortgesetzt werden. Wird der Zustandsvektor $\hat{\Phi}_{p,t}$ auf Grundlage der Zustandsvektoren $\Phi_{p,t-j}$ bis $\Phi_{p,t+l}$ und Eingangsvektoren Γ_{t-j} bis Γ_{t+l} geschätzt, wird das Verfahren als Rückberechnung (engl. Smoothing) bezeichnet.

4.4.4. Herausforderung Partikel Degeneration

Auf Basis einer beispielsweise sehr breiten Initialisierung des PF ist es möglich, dass ein wesentlicher Anteil der n_φ Partikel die Transition zwischen den Zuständen nicht ausreichend repräsentiert. In Folge dessen weisen die korrespondierenden Einträge dieser Partikel im Likelihoodvektor \mathcal{L}_t geringe Werte aus. Diese Herausforderung ist als Partikelverfall (engl. Particle Degeneration (PD)) bekannt und wird unter anderem von Ma u. a. [60] beschrieben.

$$w_{p,t} = W_t(p) = \left(\ell_{p,t}(\Psi_t | \Phi_{p,t}) \right) \left(\sum_{l=1}^{n_\varphi} \ell_{p,t}(\Psi_t | \Phi_{l,t}) \right)^{-1} \quad (4.42)$$

In Gleichung 4.42 wird das relative Gewicht $w_{p,t}$ zur Zeit t als normierte Likelihood $\ell_{p,t}$ eingeführt. Die PD kann anhand des Partikelgewichts $w_{p,t}$ gemessen werden. Nach wenigen Iterationsschritten wird der Großteil des Gesamtgewichts W_t durch wenige der insgesamt n_φ Partikel bestimmt, wobei alle anderen Partikel vernachlässigbares Gewicht besitzen [142]. Die Maßeinheit für PD ist die effektive Stichprobengröße (engl. Effective Sample Size (ESS)), die in Gleichung 4.43 für einen Zeitpunkt t definiert wird [140], [142], [148].

$$q_{\text{ESS}t} \approx \left(\sum_{l=1}^{n_\varphi} (w_{l,t})^2 \right)^{-1} \quad (4.43)$$

Zur wirksamen Vermeidung von PD wird die Methode der Wiederholungsstichprobe (engl. Resampling) angewendet. Das Resampling ist ein elementarer Schritt für den effektiven Betrieb eines PF. Die Grundidee ist, Partikel mit kleinem Gewicht $w_{p,t}$ zu eliminieren und stattdessen die dadurch frei werdenden Partikel als Duplikate der Partikel mit großem Gewicht zu nutzen. Im Vergleich zu Ansätzen ohne Resampling, steigt die Varianz der Schätzung stetig an, wobei das Resampling eine Möglichkeit ist Partikel mit geringem Gewicht aus dem Partikelset zu entfernen [143]. Der Vorgang des Resamplings kann durch unterschiedliche Methoden, wie multinomiales- (engl. Multinomial), restbasiertes- (engl. Residual), geschichtetes- (engl. Stratified), systematisches- (engl. Systematic) und wichtigkeitsbasiertes- (engl. Importance) Resampling erfolgen [140], [149]. Die einzelnen Methoden unterscheiden sich im Wesentlichen durch die Intensität der Verstärkung bzw. Reduzierung des einzelnen Partikeleinflusses sowie die benötigte Rechenleistung. Als Grundlage dient der Partikelgewichtsvektor W , der für das Resampling kumuliert summiert und als kumulierter Partikelgewichtsvektor $W_{\text{Kum.}}$ bezeichnet wird. Nachfolgend werden die unterschiedlichen Methoden im Detail vorgestellt.

- **Importance Resampling:** Das Importance Resampling ist eine grundlegende und effektive Methode des Resamplings. Auf Basis von einer Gleichverteilung zwischen 0 und 1 werden n_φ zufällige Werte generiert. Anhand des Vergleichs der Zufallszahl mit den Einträgen des Partikelgewichtsvektors $W_{\text{Kum.}}$ können die Positionen der wahrscheinlichsten Partikel gezogen werden. Da der kumulierte Partikelgewichtsvektor $W_{\text{Kum.}}$, durch sehr unterschiedliche Partikelgewichte w_p , mitunter große Sprünge aufweist, werden die wahrscheinlicheren Partikel öfter gezogen. Im Gegensatz dazu haben Partikel mit geringem Gewicht w_p eine geringere Wahrscheinlichkeit zur erneuten Wahl. Durch mehrfache Ausführung des Resamplings werden Partikel mit geringem Gewicht w_p sukzessive eliminiert. Zum besseren Verständnis wird der Vorgang des Importance Resamplings anhand von Abbildung 4.5 veranschaulicht.
- **Residual Resampling:** Eine Abwandlung des Importance Resamplings ist das Residual Resampling. Durch Multiplikation des kumulierten Gewichtsvektors $W_{\text{Kum.}}$ mit der Partikelanzahl n_φ entstehen ein Vektor, der die Anzahlen der Partikel enthält, wobei diese durch Abrunden in natürliche Zahlen überführt werden. Durch das Abrunden entsteht ein Rest, der zufällig auf alle Partikel verteilt wird. Dieses Verfahren ist im Vergleich zum Importance Resampling weniger rechenintensiv und der zufällige Einfluss wird reduziert.
- **Systematic Resampling:** Bei dem Systematic Resampling wird der Zahlenbereich zwischen 0 und 1, der durch den Partikelgewichtsvektor $W_{\text{Kum.}}$ aufgespannt

wird, in n_ϕ äquidistante Bereiche unterteilt. Kombiniert mit einem zufälligen Versatz wird die nächstkleinere Partikelposition gesucht. Durch den zufälligen Versatz wird sichergestellt, dass nicht die gleichen Partikel in jeder Ausführung des Resamplings gezogen werden.

- **Stratified Resampling** Im Gegensatz zum Systematic Resampling, wird der Offset für jeden einzelnen Bereich variiert, was zu einer größeren Variation zwischen den Resampling Vorgängen führt.

Sowohl das in Abbildung 4.5 dargestellte Importance Resampling als auch das Residual Resampling fokussieren das Partikelset auf die Partikel mit dem größten Gewicht w_p . Diese Eigenschaft ist insbesondere bei großen Spannen innerhalb der einzelnen Partikeldimensionen sinnvoll. Aufgrund des Rechenaufwands des Importance Resamplings wird von Alam u. a. [150] ein Ansatz zur Beschleunigung vorgestellt.




Abbildung 4.5.: Grafische Darstellung eines exemplarischen Resampling Vorgangs an der Hand der Importance Resampling Methode für den Zustand $\Phi(1)$ im Rahmen des Partikelfiltermoduls.

Im Gegensatz dazu tragen das Systematic- und das Stratified Resampling zum Erhalt der Partikelspanne bei. Beide Verfahren verstärken dazu extreme Partikel mit geringen Gewichten w_p , die dadurch länger im Partikelset erhalten bleiben. Diese Eigenschaft ist

vor allem zum Erhalt einer großen Variation innerhalb der Partikel hilfreich. Insgesamt ist eine Einbettung des Resamplings in einen iterativen bzw. rekursiven Prozess möglich, der zu einer Erhöhung der Genauigkeit bei gleichzeitiger Vergrößerung des Rechenaufwands führt [69].

4.4.5. Herausforderung Partikel Verarmung

Die Ausführung des Resamplings löst die Herausforderung der PD effektiv, kann jedoch auch zu Folgeherausforderungen führen. Bei intensivem Einsatz des Resamplings gibt es nach einigen Zyklen nur noch wenig Variation zwischen den einzelnen Partikeln und somit nur eine eingeschränkte Abbildung der gesamten Zustandsverteilung [142]. Insbesondere Prozesse mit geringem Rauschen sind diesem Problem ausgesetzt [142]. Dies wird auch als Partikelverarmung (engl. Particle Impoverishment (PI)) bezeichnet. Eine grundlegende Möglichkeit PI vorzubeugen ist die aktive Steuerung des Resamplings. Die Aktivierung des Resamplings kann dazu an die *ESS* gekoppelt werden [142], [145]. In der Literatur wird das Resampling häufig bei $ESS < 0.5n_\varphi$ empfohlen [143]. Im Folgenden werden einige Strategien vorgestellt, um PI zu vermeiden:

- **Dynamisches Resampling:** Genau genommen handelt es sich bei dieser Methode auch um eine Variante des Resamplings. In Abhängigkeit der *ESS*, wird auf Grundlage des Partikelgewichtsvektor W das Resampling auf eine Teilmenge der n_φ Partikel beschränkt [145].
- **Roughening:** Das Aufrauen (engl. Roughening) oder auch Zittern (engl. Jittering) ist eine grundlegende Methode, um den Auswirkungen von PI entgegenzuwirken. Nach dem Resampling werden die Partikel mit zufälligem Rauschen beaufschlagt, sodass neue Kombinationen des Parametervektors Θ durch die Partikel abgebildet werden [139]. Als Einstellmöglichkeit bietet sich die Intensität des Rauschterms an. Ein zu geringes Roughening führt lediglich zu einer lokalen Optimierung der Partikel, wohingegen eine zu große Variation viele unpassende Partikel generiert.
- **Vorherige Bearbeitung:** Diese Methode wird im Englischen auch als vorherige Bearbeitung (engl. Prior Editing) bezeichnet und basiert auf dem Roughening. Die Partikel werden nach dem Roughening mit der ZG einen Schritt in die Zukunft berechnet und mit den verfügbaren Messwerten verglichen. Ist die Abweichung zu groß, wird der Prozess des Roughenings wiederholt, bis das Ergebnis in der Toleranz liegt. Besonders bei mehrdimensionalen Partikeln oder großen Wertebereichen der einzelnen Dimensionen ist dieses Vorgehen rechenintensiv [139]. Vor allem durch die Zufälligkeit ist es möglich, dass ein geeigneter Partikel erst nach vielen Iterationen oder gar nicht gefunden wird.
- **Partikelschwarm:** Die Grundidee basiert auf dem Schwarmverhalten von Tieren. Jedes Tier evaluiert dabei die Wahrscheinlichkeit von Nahrung in seiner Umgebung. Daraus ergibt sich die Trajektorie, in die sich das Individuum bzw. der Partikelschwarm weiterentwickeln. Die Richtung des Individuums ist eine Linearkombination aller Individuen. Analog entspricht das Individuum einem Partikel p sowie der Schwarm dem Partikelset. Die Gewichtung zwischen dem einzelnen Partikel und dem Partikelset bestimmt das Verhalten maßgeblich und führt in den Extremen zu einer globalen oder lokalen Suche [151]. Ein in Ansätzen

ähnliches Verfahren bildet Partikel aus der Linearkombination von zu löschenden und sehr guten Partikeln [68].

- **Migration:** Der Ansatz der Migration ist eine weitere Methode, die in Kombination mit dem Roughening implementiert werden kann. Die Optimierung durch das Roughening ist nur in einem lokalen Umfeld effektiv und sinnvoll. Im Falle von großen Abweichungen sind die Unterschiede so groß, dass keine sinnvolle Abbildung durch den PF mehr möglich ist. Durch die Migration werden Partikel, die den Prozess abbilden, aber den falschen Zustand besitzen, in die gemessenen Zustandsregionen verschoben [152]. Durch die Migration werden Teile des Partikels durch den aktuell gemessenen Zustand aktualisiert und somit die Abbildung des PF verbessert.

Weiterführend sind auch Methoden wie resample-move, regularization, bridging densities und partitioned sampling bekannt, die an dieser Stelle jedoch nicht genauer ausgeführt werden. Für weitere Informationen wird auf Arulampalam u. a. [142] verwiesen.

Es wird deutlich, dass zur effektiven Begrenzung von PI verschiedene Strategien zur Verfügung stehen. In Abhängigkeit von den möglichen Ressourcen kann die Strategie ausgewählt werden, jedoch immer in Kombination mit einem geeigneten Ansatz zur Ausführung des Resamplings.

5. Überwachungskonzepte

Die Berechnung der RUL hat in der Industrie unterschiedliche Ausrichtungen. Es gibt eine Vielzahl an Prozessen, deren Degradationsverhalten *a priori* nicht genauer bekannt oder zu komplex ist. Eine detaillierte Modellierung ist daher nur eingeschränkt möglich und unter Umständen kostenintensiv. Um eine grobe Schätzung zu ermöglichen, wird ein einfacher und robuster Ansatz mit dem ETM in Unterkapitel 5.1 vorgestellt. Zum anderen gibt es Bereiche, in denen ein Modell für die Degradation bekannt ist und die RUL durch Prozesseingriffe aktiv verändert werden kann. Als Grundlage für eine bestmögliche Entscheidung wird die Schätzung unterschiedlicher Szenarien benötigt. Für die Überwachung dieser komplexen Modelle wird in Unterkapitel 5.2 das PFM vorgestellt.

Sowohl die Entwicklung als auch die Implementierung des ETM bzw. PFM erfolgt auf Basis der Software Python in der Version 3.8.1. Im Wesentlichen wird auf bekannte Pakete, wie `numpy`, `pandas`, `scipy` und `sklearn` zurückgegriffen, wobei auch weniger bekannte Pakete genutzt werden. Die vollständige Auflistung der benötigten Pakete kann in Kapitel C.1 eingesehen werden.

5.1. Entwicklung des Einzeltrendmoduls

Ein wesentlicher Anteil der Equipments in den verfahrenstechnischen Prozessen der chemischen Industrie ist im Hinblick auf die Verfügbarkeit unkritisch. Die detailliertere Überwachung dieser Equipments ist, entweder aufgrund einer geringen Kritikalität oder eines komplexen verfahrenstechnischen Prozesses, zu umfangreich und damit nicht verhältnismäßig. Dies ist die Motivation ein Überwachungskonzept zu entwickeln, das auf eine Vielzahl unterschiedlicher Anwendungsfälle übertragbar ist sowie im industriellen Kontext eingesetzt werden kann.

Die Entwicklung des ETM wird initial durch die einfachen Modellen von Li u. a. [63] inspiriert, wobei das grundlegende Verhalten der zu schätzenden Signale erst zu einem sehr späten Zeitpunkt identifiziert wird. Ebenso ist der von Di Maio u. a. [58] verdeutlichte Aspekt der sprunghaften Signaländerungen ein grundlegender Bestandteil, der berücksichtigt wird.

Für die vollautomatisierte Nutzung zur Überwachung von sehr heterogenen Signalen, ist es notwendig die wesentlichen Signalverläufe, Monotonie sowie mögliche CP zu detektieren. Weiterhin soll die Eingabe von beliebig vielen Grenz- und Konfidenzwerten einen vielseitigen Einsatz ermöglichen. Im Gegensatz dazu soll das ETM auch gezielt durch *a priori* Wissen eingeschränkt werden können, um Teile des Lösungsraums auszuschließen und somit die Rechenzeit zu verkürzen sowie die Qualität der RUL Schätzung zu erhöhen. Nachfolgend werden die wesentlichen Anforderungen spezifiziert:

- Wechsellpunkt: Die CP Position i kann auf Grundlage von Expertenwissen für die Berechnung vorgegeben werden, sodass die CP Schätzung übersprungen wird.

- Monotonie: Die Vorgabe der Monotonie *mon* des Signals S schränkt dessen Abbildung ein, um technisch nicht plausible Signalverläufe auszuschließen.
- Funktion: Einschränkung auf eine bestimmte Funktion, wenn das Verhalten der Degradation bereits bekannt ist.

Die Implementierung des ETM basiert auf den nachfolgenden Annahmen:

Das Eingangssignal basiert auf einer Messstelle. Die automatisierte Überprüfung von mehreren möglichen Einflussfaktoren und die damit einhergehende Bewertung und Modellbildung ist vollautomatisiert im industriellen Umfeld zu komplex.

Für die Schätzung wird ein im Wesentlichen stetiges Signal S vorausgesetzt. Indirekt bedeutet dies, dass für die Schätzung des vergangenen Signalverlaufs die gleichen Betriebsbedingungen angenommen werden, wie für die Schätzung des zukünftigen Signals. Das Verhalten verschiedener Degradationsverläufe muss ausreichend gut durch eine geringe Anzahl einfacher Funktionen beschrieben werden können.

Das Ziel ist die Schätzung des Signals S und die Berechnung der RUL bis zum Erreichen eines Grenzwerts ω_S . Dazu wird zunächst die Position \hat{i} des CP geschätzt, dessen Bestimmung in Unterkapitel 5.1.1 beschrieben wird. Die anschließende Abbildung des Teilsignals S_{CP} mit einer geeigneten Funktion wird in Unterkapitel 5.1.2 beschrieben. Im letzten Schritt wird das Signal S auf Basis von Unterkapitel 5.1.3 fortgesetzt und daraus die RUL abgeleitet. Zur Evaluierung des ETM wird in Unterkapitel 5.1.4 ein Datengenerator und in Unterkapitel 5.1.5 eine standardisierte visuelle Auswertung vorgestellt.

5.1.1. Schätzung des Wechsellpunktes

Ein CP beschreibt in einer Zeitreihe den Zeitpunkt, an dem das Signal grundlegende Eigenschaften ändert. Die Änderung kann unterschiedliche Erscheinungsformen annehmen. Eine triviale Änderung des Signals ist eine Mittelwertänderung, die auch als Sprung bekannt ist. In der Industrie werden Sprünge vor allem bei Änderungen der Stellgrößen verursacht. Komplexer ist die Änderung der Funktion, die beispielsweise durch die Änderung der Steigung eines Signals S beschrieben werden kann. Die Detektion von Funktionsänderungen ist eine Herausforderung, da anfängliche Anzeichen häufig durch Rauschen maskiert werden. Für die Implementierung innerhalb des ETM wird auf das Python Paket „rupture“ von Truong u. a. [118] zurückgegriffen. Einige der in Unterkapitel 4.2.3 beschriebenen Methoden sind im Paket implementiert, wobei die Detektion auf Sprünge limitiert ist. Somit können die in Abbildung 4.2 dargestellten Änderungsformen nicht ohne Weiteres detektiert werden und müssen zunächst in Sprünge überführt werden.

Der chronologische Ablauf der Überführung der CP in Sprünge sowie deren Detektion werden anhand des Algorithmus 1 veranschaulicht. Zunächst wird der Vektor \hat{I} der geschätzten CP als Liste initialisiert und die maximale Anzahl an finiten Differenzen $n_{\text{Max.Diff.}} = 5$ festgelegt. Weiterhin wird ein Vektor verschiedener Fenstergrößen H_{CP} für die CP Detektion auf Basis von $2^{n_{h,CP}} \leq n_S$ mit der Länge n_S des Signals S und $n_{h,CP}, n_S \in \mathbb{N}^{1 \times 1}$ generiert.

Innerhalb der for-Schleife wird zunächst der Zähler der finiten Differenz $n_{\text{Diff.}}$ mit Null initialisiert und das Signal S in die Variable des gefilterten Signals \tilde{S} kopiert. Für den

Algorithmus 1 Pseudocode der Überführung unterschiedlicher Arten von Wechselpunkten in Sprünge und deren Detektion durch das Einzeltrendmodul.

```

1:  $\hat{I} = []$ 
2:  $n_{\text{Max.Diff.}} = 5$ 
3:  $H_{\text{CP}} = [2^1, 2^2, 2^3, \dots, 2^{n_h, \text{CP}}]$ 
4: for  $h_{\text{CP}}$  in  $H_{\text{CP}}$  do
5:    $n_{\text{Diff.}} = 0$ 
6:    $\tilde{S} = S$ 
7:    $h_{\text{Filt.,S}} = \text{getSmoothParameter}(\tilde{S})$ 
8:    $\Sigma_{\text{Roll,S}} = \text{rollingStandardDeviation}(\tilde{S}, h_{\text{Filt.,S}})$ 
9:   while  $n_{\text{Diff.}} \leq n_{\text{Max.Diff.}}$  do
10:     $h_{\text{Filt.,S}} = \text{getSmoothParameter}(\tilde{S})$ 
11:     $h_{\text{Filt.,}\sigma} = \text{getSmoothParameter}(\Sigma_{\text{Roll,S}})$ 
12:     $\hat{I} = [\hat{I}, \text{findCP}(\tilde{S}, h_{\text{Filt.,S}}, h_{\text{CP}})]$ 
13:     $\tilde{S} = \text{medianFilter}(\tilde{S}, h_{\text{Filt.,S}})$ 
14:     $\hat{I} = [\hat{I}, \text{findCP}(\tilde{S}, h_{\text{Filt.,S}}, h_{\text{CP}})]$ 
15:     $\hat{I} = [\hat{I}, \text{findCP}(\Sigma_{\text{Roll,S}}, h_{\text{Filt.,}\sigma}, h_{\text{CP}})]$ 
16:     $\Sigma_{\text{Roll,S}} = \text{medianFilter}(\Sigma_{\text{Roll,S}}, h_{\text{Filt.,}\sigma})$ 
17:     $\hat{I} = [\hat{I}, \text{findCP}(\Sigma_{\text{Roll,S}}, h_{\text{Filt.,}\sigma}, h_{\text{CP}})]$ 
18:     $\tilde{S} = \text{differentiate}(\tilde{S})$ 
19:     $\Sigma_{\text{Roll,S}} = \text{differentiate}(\Sigma_{\text{Roll,S}})$ 
20:     $n_{\text{Diff.}} = n_{\text{Diff.}} + 1$ 
21:   end while
22: end for
23:  $\hat{I} = [0, \hat{I}]$ 

```

ersten Durchlauf werden die charakteristische Fensterbreite $h_{\text{Filt.,S}}$ des Signals sowie die rollierende Standardabweichung $\Sigma_{\text{Roll,S}}$ auf Basis von \tilde{S} und $h_{\text{Filt.,S}}$ gebildet.

Die Funktion `getSmoothParameter` wählt für ein übergebenes Signal \tilde{S} automatisch die optimale Fenstergröße $h_{\text{Filt.,S}}$ für den Median-Filter aus. Die in der Funktion enthaltene Logik basiert auf Gleichung 5.1 und berechnet die Spannweite $d_{\text{Spa.,Res}}$ anhand von Gleichung 4.1.

$$d_{\text{Spa.,Res}} = \text{range}(\text{Res}_{\text{Filter,S}}) \text{ mit } \text{Res}_{\text{Filter,S}}(j) = (S - \text{medianFilter}(S, j)) \quad (5.1)$$

Allgemein wird der Filterresiduenvektor $\text{Res}_{\text{Filter,S}}$ anhand von unterschiedlichen Fenstergrößen j berechnet. Im Anschluss wird das kleinste Fenster $h_{\text{Filt.,S}}$ identifiziert, dessen nächstkleineres und nächstgrößeres Fenster den gleichen Wert der Spannweite $d_{\text{Spa.,Res}}$ besitzen. Durch die Filterung mit zu kleiner Fensterbreite verbleibt zu viel Rauschen im gefilterten Signal \tilde{S} . Wenn das gesamte Rauschen aus dem Signal extrahiert wird und die Fenstergröße j weiter vergrößert wird, wächst die Spannweite $d_{\text{Spa.,Res}}$ des Fil-

terresiduums $Res_{\text{Filter},S}(j)$ erst ab der Fensterbreite wieder an, wenn der Median-Filter neben dem Rauschen auch Signalanteile entfernt. Als beste Filterfensterbreite werden $h_{\text{Filt.},S}$ für das gefilterte Signal \tilde{S} sowie $h_{\text{Filt.},\sigma}$ für die gefilterte rollierte Standardabweichung $\Sigma_{\text{Roll.},S}$ berechnet.

Die CP von \tilde{S} werden auf Basis des in Unterkapitel 4.2.3 beschriebenen Vorgehens geschätzt. Durch die Bearbeitung werden die im Vektor \hat{I} enthaltenen CP Schätzungen mit weiteren Einträgen ergänzt. Um etwaige Änderungen in \tilde{S} , die durch das Rauschen maskiert werden, herauszuarbeiten, wird \tilde{S} mit der Funktion `medianFilter` geglättet und im Anschluss erneut nach CP durchsucht. Analog werden die CP für das rollierende Standardabweichungssignal $\Sigma_{\text{Roll.},S}$ bestimmt.

Die while-Schleife wird durch das finite Differenzieren der Vektoren \tilde{S} und $\Sigma_{\text{Roll.},S}$ abgeschlossen.

Am Ende der CP Detektion wird die nullte Position als möglicher CP hinzugefügt, da diese im Rahmen des Pakets nicht identifiziert werden kann.

5.1.2. Abbildung des Betriebszustands

Die übergeordnete Motivation ist die Abbildung des generellen Signaltrends im Gegensatz zum detaillierten zeitlichen Verlauf des Signals S . Dazu können beliebige Basisfunktionen genutzt werden, die neben den zu bestimmenden Parametern nur von der Position innerhalb des Vektors abhängig sind.

Algorithmus 2 Pseudocode der Funktionsauswahl und Parametrierung für alle potenziellen Wechsellpunkte durch das Einzeltrendmodul.

```

1: for  $\hat{i}$  in  $\hat{I}$  do
2:    $S_{\text{CP}} = S[\hat{i} : n_S]$ 
3:    $S_{\text{CP,Train}} = \text{random}(S_{\text{CP}}, 80\%)$ 
4:    $S_{\text{CP,Test}} = \text{random}(S_{\text{CP}}, 20\%)$ 
5:   for  $f_{\text{ETM}}$  in  $F_{\text{ETM}}$  do
6:      $mo_{\text{CP}} = \text{fit}(S_{\text{CP,Train}}, f_{\text{ETM}})$ 
7:      $S_{\text{CP,Train}}^{\hat{}} = \text{predict}(S_{\text{CP,Train}}, mo_{\text{CP}})$ 
8:      $S_{\text{CP,Test}}^{\hat{}} = \text{predict}(S_{\text{CP,Test}}, mo_{\text{CP}})$ 
9:      $R^2_{\text{Train}} = \text{calcMetric}(S_{\text{CP,Train}}, S_{\text{CP,Train}}^{\hat{}})$ 
10:     $R^2_{\text{Test}} = \text{calcMetric}(S_{\text{CP,Test}}, S_{\text{CP,Test}}^{\hat{}})$ 
11:     $q_{\text{CP}} = \text{getWorstMetric}(R^2_{\text{Train}}, R^2_{\text{Test}})$ 
12:     $Q_{\text{CP}} = [Q_{\text{CP}}, q_{\text{CP}}]$ 
13:     $Mo_{\text{CP}} = [Mo_{\text{CP}}, mo_{\text{CP}}]$ 
14:   end for
15:    $mo_{\text{CP,Beste}}, q_{\text{CP,Beste}} = \text{getBestModel}(Mo_{\text{CP}}, Q_{\text{CP}})$ 
16:    $Mo = [Mo, mo_{\text{CP,Beste}}]$ 
17:    $Q = [Q, q_{\text{CP,Beste}}]$ 
18: end for
19:  $mo_{\text{Beste}} = \text{getBestModel}(Mo, Q)$ 

```

Die Auswahl der Kombination aus CP und geeigneter Funktion wird anhand des Algorithmus 2 vorgestellt. Basierend auf einem Vektor geschätzter CP \hat{I} wird, für jeden

im Vektor \hat{I} enthaltenen CP \hat{i} , das Signal S an der Position \hat{i} gesplittet. Alle weiteren Daten, die zeitlich vor \hat{i} liegen, werden verworfen. Der verbleibende Signalanteil S_{CP} wird zufällig in den Trainingsdatensatz $S_{CP,Train}$ und den Testdatensatz $S_{CP,Test}$ aufgeteilt. Ein Anteil von 80% von S_{CP} wird für das Training verwendet und der verbliebene Anteil für den Test. Durch die zufällige Zuordnung entsteht kein Fehler durch das Unterteilen in zusammenhängende Sequenzen. Zur Erzeugung von reproduzierbaren Ergebnissen kann ein Startwert (engl. Random Seed (RS)) gesetzt werden, der variiert werden kann, aber bei gleicher Wahl immer zu den gleichen Ergebnissen führt.

Auf Basis einer OLS Optimierung des Paketes *scipy optimize* kann die Parametrierung der Funktionen f_{ETM} auf Grundlage von $S_{CP,Train}$ erfolgen. Um das schnelle und erfolgreiche Konvergieren des Optimierungsalgorithmus zu unterstützen, werden geeignete Startwerte vorgegeben. Die Details zur Bestimmung der Startwerte können in Unterkapitel C.3 eingesehen werden.

Das sich daraus ergebende Modell mo_{CP} wird auf $S_{CP,Train}$ und $S_{CP,Test}$ angewendet. Basierend auf den Schätzungen der Signalanteile $S_{CP,Train}$ und $S_{CP,Test}$ kann, anhand der in Unterkapitel 4.3.3 vorgestellten Metriken, die Qualität der Abbildung bewertet werden. Exemplarisch wird das Vorgehen anhand der R^2 Metrik vorgestellt, wobei im ETM auch andere Metriken implementiert sind. Daraus folgen die Ergebnisse R^2_{Train} und R^2_{Test} . Um eine möglichst gute Abbildung auf allen Daten S_{CP} zu ermöglichen, wird der schlechteste Metrikwert q_{CP} von Test und Training ausgewählt. Alle aufgelisteten Modelle Mo_{CP} des geschätzten CP \hat{i} können anhand der korrespondierenden gelisteten Metrik Q_{CP} bewertet und das beste Modell $mo_{CP,Beste}$ ausgewählt werden.

Analog wird für alle geschätzten CP \hat{i} in Vektor \hat{I} verfahren und abschließend aus allen verfügbaren Modellen Mo anhand des Metrikvektors Q erneut das beste globale Modell mo_{Beste} ausgewählt.

5.1.3. Schätzung der Restlebenszeit

Auf Basis eines definierten CP und des ausgewählten Modells mo_{Beste} , sind zwei Modi zur Berechnung möglich:

- mds_h : Der zukünftige Erwartungswert des Signals $S_{Zuk.}$ wird für den Schätzhorizont $h_{Präd.}$ auf Basis von mo_{Beste} geschätzt.
- mds_ω : Der zukünftige Erwartungswert des Signals $S_{Zuk.}$ wird auf Grundlage von mo_{Beste} so weit in die Zukunft fortgesetzt, bis der Signalgrenzwert ω_S oder der maximale Schätzhorizont $h_{Präd.,max}$ erreicht wird.

Beide Schätzmodi werden anhand von Algorithmus 3 vorgestellt. Im Falle des Betriebsmodus mds_h ist das Fortsetzen des Signals lediglich eine Rechenoperation, die anhand des zur Verfügung stehenden Modells mo_{Beste} ausgeführt wird. Bei der Übergabe des Signals S an das ETM wird ein Index aus natürlichen Zahlen erstellt. Bei der Wahl des CP wird das Signal und somit auch der Index aufgeteilt. Die Schätzung des zukünftigen Signals $S_{Zuk.}$ beginnt ab dem CP mit dem dazugehörigen Index und wird gleichartig in die Zukunft prädiziert.

Für den Modus mds_ω ist die Anzahl der notwendigen Schätzschritte nicht bekannt und daher wird der Schätzhorizont $h_{Präd.}$ so lange verdoppelt, bis der Grenzwert ω_S oder der maximale Schätzhorizont $h_{Präd.,max}$ erreicht wird. Dieser Vorgang wird in Algorithmus 3 vereinfacht dargestellt, da innerhalb des ETM auch weitere Eigenschaften

Algorithmus 3 Pseudocode der Schätzung des zukünftigen Signals sowie der Restlebenszeit durch das Einzeltrendmodul.

```

1: if  $mds == mds_h$  then
2:    $h_{Präd.} = \text{userInterface}()$ 
3:    $S_{Zuk.}^{\hat{}} = \text{forecast}(mo_{Beste}, h_{Präd.})$ 
4: else if  $mds == mds_{\omega}$  then
5:    $n_{RUL} = \text{defaultValue}()$ 
6:    $h_{Präd.} = 1$ 
7:    $\omega_S = \text{userInterface}()$ 
8:    $b_{Stop} = \text{False}$ 
9:   while  $b_{Stop} == \text{False}$  do
10:     $S_{Zuk.}^{\hat{}} = \text{forecast}(mo_{Beste}, h_{Präd.})$ 
11:    if  $\min(S_{Zuk.}^{\hat{}}) \leq \omega_S$  and  $\omega_S \leq \max(S_{Zuk.}^{\hat{}})$  then
12:       $b_{Stop} = \text{True}$ 
13:       $n_{RUL} = \text{getRUL}(S_{Zuk.}^{\hat{}}, \omega_S)$ 
14:    else if  $h_{Präd.} \geq h_{Präd., \max}$  then
15:       $b_{Stop} = \text{True}$ 
16:    else
17:       $h_{Präd.} = 2h_{Präd.}$ 
18:    end if
19:  end while
20: end if

```

überprüft werden. Dazu zählen unter anderem, dass bei mehreren Grenzwerten das Signal fortgesetzt wird, bis alle Grenzwerte erreicht werden. Ebenso gilt dies auch für die Konfidenzintervalle, sodass der in Algorithmus 3 skizzierte Ablauf nur einen Anteil der Prüfungen darstellt.

Zur Ableitung der RUL wird überprüft, ob das geschätzte zukünftige Signal $S_{Zuk.}^{\hat{}}$ überhaupt den Grenzwert ω_S quert. Bei manchen Funktionen besteht die Möglichkeit, dass die Funktionen abschnittsweise monoton fallend oder steigend sind. Aus diesem Grund werden die naheliegenden Indizes der Querung vermerkt und lediglich diese weiter evaluiert, die größer als der Index des CP sind. Falls mehrere Querungen vorhanden sind, wird für die Berechnung der RUL die chronologisch früheste Querung gewählt. Der Index dieser Querung entspricht abzüglich des CP Index der RUL in der Anzahl an Berechnungsschritten n_{RUL} . Das Verfahren wird analog für die Berechnung des Konfidenzintervalls sowie auf alle Einträge des Grenzwertvektors Ω_S angewendet.

5.1.4. Datengenerator des Einzeltrendmoduls

Für das Testen des ETM werden Signale mit bekannten CP sowie bekannten Funktionen benötigt. Zu diesem Zweck werden reproduzierbare Testsignale generiert, die auf den zufälligen Werten einer Normalverteilung $\mathcal{N}(\mu = 0, \sigma = 1)$ basieren. Zur Reproduzierbarkeit aller zufälligen Werte wird ein RS eingesetzt. Für die Erstellung der Signale sind folgende Eingaben erforderlich:

- $n_{S, \text{Synth.}}$: Gesamtanzahl der Messpunkte des synthetischen Signals $S_{\text{Synth.}}$.
- $i_{\text{Proz.}}$: Prozentuale Angabe der Position des CP, wobei 0% dem ersten und 100%

dem letzten Wert von $S_{\text{Synth.}}$ entspricht.

- w_κ : Faktor für den Einfluss des Rauschens.

Die Erzeugung der synthetischen Daten wird in Gleichung 5.2 beschrieben und basiert auf der ausgewählten Funktion f_{ETM} , die auch für die Schätzung des Signals S zur Verfügung steht. Demnach ist der Funktionswert bis zum CP konstant und nimmt bei einem Index $idx_j > i$, den Funktionswert der voreingestellten Funktionen an. Der Übergang zwischen beiden Bereichen ist stetig. Sowohl $f_{\text{ETM}}(i, C_{\text{ETM}})$ als auch C_{ETM} werden zufällig gewählt.

$$y = \begin{cases} f_{\text{ETM}}(i, C_{\text{ETM}}) & \text{für } idx_j \leq i \\ f_{\text{ETM}}(idx_j, C_{\text{ETM}}) & \text{für } idx_j > i \end{cases} \text{ mit } idx_j = \text{Idx}(j) \in \mathbb{N}\{1, n_{S, \text{Synth.}}\} \quad (5.2)$$

Die unterschiedlichen Signale können zusätzlich mit einem Rauschanteil versehen werden, wenn $w_\kappa > 0$. Zuvor wird dazu der Basissignalvektor Y normiert, um den Einfluss des Rauschens, unabhängig von der Funktion, vergleichbar zu machen. Es kann zwischen zwei möglichen Rauschfunktionen gewählt werden mit $K \sim \mathcal{N}(0, 1)$, wie Gleichung 5.3 und 5.4 zeigen.

$$\text{additiveNoise:} \quad S_{\text{Synth.}} = Y + c_{\text{Skal.}} \mu_Y w_\kappa K \quad (5.3)$$

$$\text{multiplicativeNoise:} \quad S_{\text{Synth.}} = Y (1 + c_{\text{Skal.}} w_\kappa K) \quad (5.4)$$

Das grundlegende Signal Y kann durch den Parameter $c_{\text{Skal.}}$ mit zufälligem Rauschen erweitert werden. Dazu kann additives Rauschen, wie in Gleichung 5.3 oder multiplikatives Rauschen, wie in Gleichung 5.4, eingesetzt werden.

Neben dem Rauschen können auch zusätzliche Strukturen mit dem synthetischen Signal $S_{\text{Synth.}}$ überlagert werden, wobei das Vorgehen vergleichbar mit dem Hinzufügen des Rauschens ist.

Zum Abschluss werden alle generierten Signale normiert, gespeichert oder für die weitere Verarbeitung übergeben.

5.1.5. Ergebnisvisualisierung des Einzeltrendmoduls

Die Auswertung der Ergebnisse erfolgt zur besseren Vergleichbarkeit auf Basis von standardisierten Abbildungen, die alle wesentlichen Informationen enthalten und nachfolgend exemplarisch vorgestellt werden.

Abbildung 5.1 ist in vier kleinere Darstellungen aufgeteilt, die alle über die Betriebszeit in Stunden aufgetragen werden. Die unterste Darstellung enthält das gemessene Signal S in Blau sowie den zugrunde gelegten Grenzwert ω_S in Grau. Da es sich um eine generelle Funktionalität des ETM handelt, wird die Einheit mit \cdot gekennzeichnet. In der zweiten Darstellung von unten wird die Monotonie mon als grauer und die geschätzte Monotonie $m\hat{on}$ als farbiger Punkt dargestellt. Die Farbe drückt dabei das Residuum res_{RUL} zwischen der geschätzten zu der gemessenen RUL aus, wobei eine dunkelrote Färbung eine starke Abweichung ausdrückt.

Die zweite Darstellung von oben stellt die möglichen Funktionen der Liste F_{ETM} des ETM dar, wobei die zugrundeliegende Funktion durch graue Punkte dargestellt wird und die geschätzte Funktion $f_{\text{ETM}}^{\hat{}}$ durch einen Farbpunkt abgebildet wird. Die $R^2_{\text{Adj.}}$ Metrik wird in der zweiten Darstellung von oben durch die Farbe der Punkte wiedergegeben,

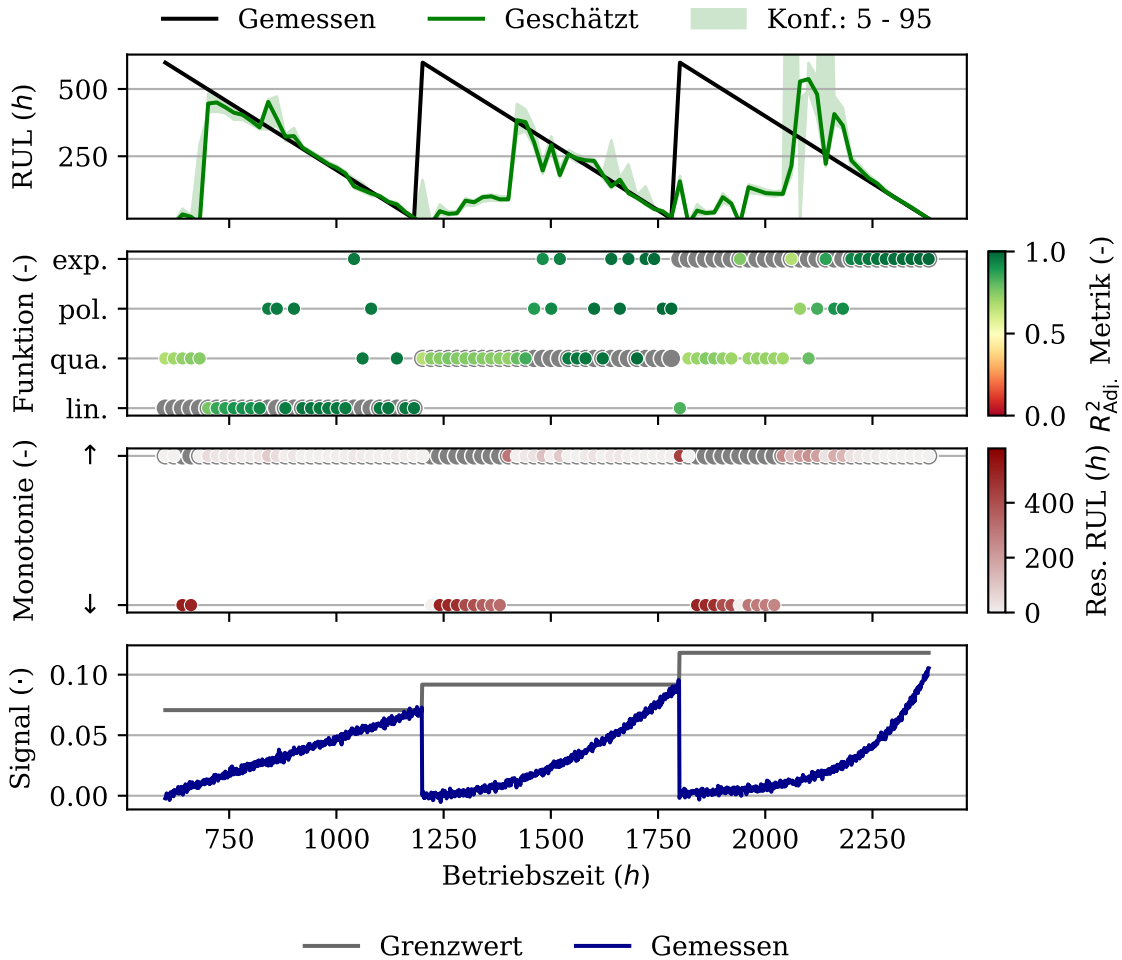


Abbildung 5.1.: Exemplarische Darstellung der Ergebnisse des Einzeltrendmoduls.

wobei Grün eine hohe bzw. Rot eine sehr geringe $R^2_{Adj.}$ Metrik ausdrückt. Abgeschlossen wird die Abbildung durch die oberste Darstellung, in der die RUL t_{RUL} in Schwarz mit deren RUL Schätzung \hat{t}_{RUL} in Grün gegenübergestellt wird. Das Konfidenzintervall entspricht dem grünen ausgefüllten Bereich.

Die Visualisierung einer konkreten Schätzung wird durch eine weitere Darstellung unterstützt, die exemplarisch in Abbildung 5.2 vorgestellt wird. Der aktuelle Zeitpunkt wird durch eine graue vertikale Linie beim relativen Messwert 0 gekennzeichnet und ermöglicht die optische Unterscheidung zwischen dem durch eine blaue Linie dargestellten vergangenen Signal S sowie der Prädiktion des Signals $\hat{S}_{Zuk.}$. Diese wird durch eine grüne Linie dargestellt, die in einem ebenfalls grünen Konfidenzbereich eingebettet ist. Mögliche erreichte Grenzwerte Ω_S werden entlang der Schätzung mit einem grünen Punkt markiert. Zur besseren Einordnung der Prädiktion kann, falls der zukünftige Signalverlauf $S_{Zuk.}$ bekannt ist, dieser dem geschätzten Signalverlauf $\hat{S}_{Zuk.}$ in Orange gegenübergestellt werden. Die Indices Idx_{CP} der geschätzten CP werden durch grau gepunktete vertikale Linien sowie der für die Prädiktion zugrunde gelegte geschätzte CP \hat{i} durch einen roten Kreis markiert.

Abschließend wird das vergangene Residuum Res_S anhand von Abbildung 5.3 ver-

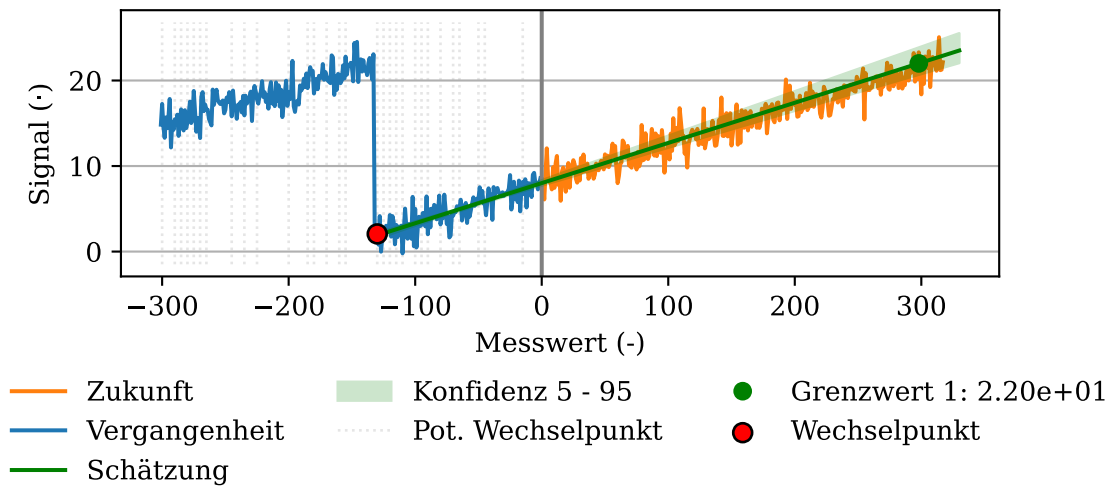


Abbildung 5.2.: Exemplarische Darstellung der Prädiktion des Einzeltrendmoduls.

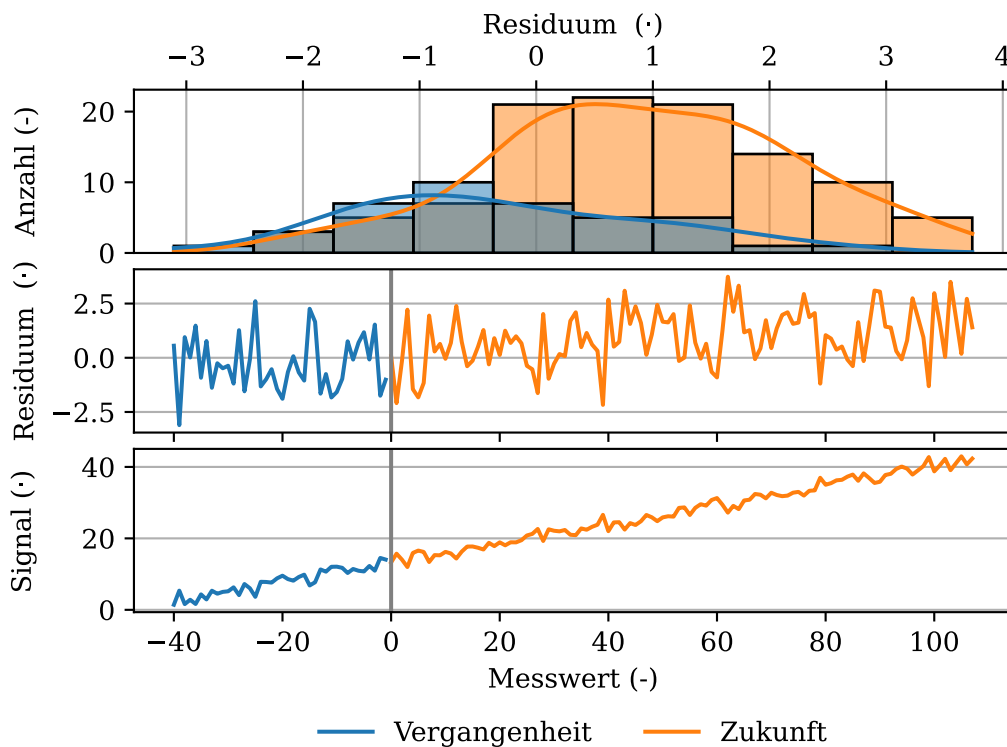


Abbildung 5.3.: Exemplarische Darstellung des Schätzresiduums des Einzeltrendmoduls.

anschaulicht. Die Visualisierung besteht aus drei Darstellungen, wobei die oberste über das Residuum des Signals Res_S aufgetragen wird. Im Gegensatz dazu werden die unteren zwei über dem relativen Messwert aufgetragen. In diesem Fall werden vergangene- von zukünftigen Daten durch eine vertikale graue Linie unterteilt. Die farbliche Kennzeichnung gilt für die gesamte Abbildung und zeigt zukünftige Daten in Orange und vergangenen Daten in Blau.

Die oberste Abbildung stellt die Verteilung der Residuen vor. Neben dem vergangenen Residuum Res_S in Blau kann, bei bekanntem zukünftigen Signalverlauf $S_{Zuk.}$, auch das

zukünftige Residuensignal $Res_{S,Zuk.}$ in Orange veranschaulicht werden.

Die mittlere Darstellung visualisiert den zeitlichen Verlauf des Residuums Res_S in Blau und gegebenenfalls auch den zeitlichen Verlauf des zukünftigen Residuensignals $Res_{S,Zuk.}$ in Orange. Die Darstellung unterstützt bei der Erkennung von sich stetig entwickelnden Abweichungen sowie lokalen Ausreißern.

Die unterste Darstellung zeigt den vergangenen- S und falls vorhanden den zukünftigen Signalverlauf $S_{Zuk.}$ und dient als Referenz für die Darstellung der Residuensignale.

5.2. Entwicklung des Partikelfiltermoduls

Das PFM basiert auf den grundlegenden Methoden aus Unterkapitel 4.4. Im Rahmen der Implementierung werden einige Sonderfälle behandelt, um einen stabilen Onlinebetrieb zu ermöglichen. Im Folgenden werden die wesentlichen funktionalen Entwicklungen des PFM anhand des Algorithmus 4 skizziert.

Algorithmus 4 Pseudocode der wesentlichen Bearbeitungsschritte in der Hauptfunktion des Partikelfiltermoduls.

```

1: if  $\Phi_{Ges.}$  and  $\Theta_{Ges.}$  are available then
2:    $\Phi, \Theta = \text{load}(\Phi_{Ges.}, \Theta_{Ges.})$ 
3: end if
4:  $\mathbf{X}_{Ver.} = \text{preprocessing}(\mathbf{X})$ 
5: if  $b_{Zuk.bek.} == \text{True}$  then
6:    $\mathbf{X}_{Zuk.} = \text{preprocessing}(\mathbf{X})$ 
7: end if
8:  $V_{Szen.} = \text{getScenarios}(\mathbf{X}_{Ver.})$ 
9:  $b_{Stat.} = \text{operationalStatus}(\mathbf{X}_{Ver.})$ 
10: if  $b_{Stat.} == \text{True}$  then
11:   if  $\Phi$  or  $\Theta$  are not available then
12:      $\Phi = \text{initializeState}(\mathbf{X}_{Ver.})$ 
13:      $\Theta = \text{initializeParameter}(\mathbf{X}_{Ver.})$ 
14:   end if
15:    $V_{Erg.} = \text{particleFilterRUL}()$ 
16:    $V_{Szen.} = \text{unwrap}(V_{Erg.})$ 
17: else
18:    $V_{Szen.} = \text{fillDefaultValue}()$ 
19: end if
20:  $\Phi_{Ges.}, \Theta_{Ges.} = \text{prepareAndSave}(\Phi, \Theta)$ 

```

Der PF ist ein ZRM und schätzt auf Basis des aktuellen Zustandsvektors Φ die zukünftige Zustandsmatrix $\hat{\Phi}_{Zuk.}$ aller vorhandenen Partikel. Vor dem Hintergrund, dass die Berechnung nicht dauerhaft aktiv ist, sondern vielmehr zu festgelegten Zeiten ausgeführt wird, ist es notwendig die Zustandsmatrix Φ als $\Phi_{Ges.}$ bzw. die Parametermatrix Θ als $\Theta_{Ges.}$ zu speichern.

Initial werden die gespeicherten Matrizen $\Phi_{Ges.}$ und $\Theta_{Ges.}$, falls diese vorhanden sind, sowie alle verfügbaren Betriebsdaten in Form von Matrix \mathbf{X} , geladen. Die Matrix $\mathbf{X} = [\mathbf{\Gamma} \ \mathbf{\Psi}]$ besteht grundlegend aus der Systemeingangs- $\mathbf{\Gamma}_{Ver.}$ sowie der Systemausgangsmatrix $\mathbf{\Psi}_{Ver.}$, die spaltenweise die einzelnen Messgrößen und zeilenweise die

definierten Zeitstempel in aufsteigender Reihenfolge aufführen. Weiterhin kann die Betriebsdatenmatrix \mathbf{X} neben den gemessenen Größen auch berechnete Features enthalten.

Algorithmus 5 Pseudocode der Vorverarbeitung von Zeitreihen durch die Funktion preprocessing des Partikelfiltermoduls.

- 1: $\mathbf{X} = \text{mapping}(\mathbf{X})$
 - 2: $\mathbf{X}_{\text{Ver.}}, \mathbf{X}_{\text{Zuk.}} = \text{splitting}(\mathbf{X})$
 - 3: $\mathbf{X}_{\text{Ver.}} = \text{featureGeneration}(\mathbf{X}_{\text{Ver.}})$
 - 4: $\mathbf{X}_{\text{Zuk.}} = \text{featureGeneration}(\mathbf{X}_{\text{Zuk.}})$
 - 5: $\mathbf{X}_{\text{Ver.}} = \text{shifting}(\mathbf{X}_{\text{Ver.}})$
 - 6: $\mathbf{X}_{\text{Zuk.}} = \text{shifting}(\mathbf{X}_{\text{Zuk.}})$
-

Die Vorverarbeitung der Betriebsdaten \mathbf{X} erfolgt durch die Funktion preprocessing, deren sequentieller Ablauf in Algorithmus 5 vorgestellt wird. Grundlegend umfasst die Funktion preprocessing verschiedene Aspekte der Aufbereitung. Im ersten Bearbeitungsschritt wird durch die Funktion mapping das Format der Zeitstempel konvertiert sowie die kryptischen Messstellennamen in sprechende und standardisierte Namen überführt. Weiterhin erfolgt die Umrechnung in SI-Einheiten und die Anpassung der Ein- bzw. Ausgänge des Systems mit einem Versatz und einem Faktor, um beispielsweise relative in absolute Drücke umzuwandeln.

Im Anschluss werden durch die Funktion splitting aus der Betriebsdatenmatrix \mathbf{X} die vergangene Betriebsdatenmatrix $\mathbf{X}_{\text{Ver.}}$ und falls vorhanden die zukünftige Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ des aktuellen Zyklus herausgelöst. Anhand von verschiedenen Messwerten wird ein Logikvektor erstellt, der die Aufspaltung in Zyklen ermöglicht. Der Fokus auf den aktuellen Zyklus ist besonders vor dem Hintergrund wichtig, da der Systemzustand durch eine Reinigungs- oder Instandsetzungsmaßnahme verändert wird. Dieses Vorgehen stellt sicher, dass ausschließlich die Betriebsdaten des aktuellen Zyklus für dessen Vorhersage verwendet werden. Die Zustandsschätzung basiert auf der vergangenen Betriebsdatenmatrix $\mathbf{X}_{\text{Ver.}}$. Im Gegensatz dazu ist die zukünftige Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ für eine Onlinesimulation oder eine Szenarienberechnung vorhanden und kann für die Visualisierung und Validierung verwendet werden.

Durch die Funktion generateFeature werden notwendige und anwendungsspezifische Features erzeugt. Diese Features werden vor der Übergabe an das PFM in die vergangene- $\mathbf{X}_{\text{Ver.}}$ bzw. zukünftige Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ integriert.

Im Rahmen der Modellerstellung wird sichergestellt, dass Ursache und Wirkung innerhalb des Datensatzes synchronisiert werden. Die Synchronisierung basiert auf den Methoden aus Unterkapitel 4.1.1, deren Umsetzung im Onlinebetrieb durch die Funktion shifting erfolgt. Besonders nach der Einteilung der Daten in Zyklen sowie das Synchronisieren der Daten, ist es notwendig zu prüfen, ob ausreichend Daten für die weiteren Verarbeitungsschritte vorhanden sind. Das Ergebnis sind die vorverarbeiteten Betriebsdatenmatrizen $\mathbf{X}_{\text{Ver.}}$ bzw. $\mathbf{X}_{\text{Zuk.}}$.

Da im Onlinebetrieb die zukünftige Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ unbekannt ist, werden für den Entscheidungsprozess Szenarien gebildet, die beispielsweise verschiedene Lastzustände widerspiegeln können und in der Szenarienliste $V_{\text{Szen.}}$ abgelegt. Ausgehend von dem jüngsten Zeitstempel von $\mathbf{X}_{\text{Ver.}}$ und der Funktion generateFeature, werden die notwendigen Szenarien initialisiert. Basierend auf den gewählten Randbedingungen

für die Szenarien, wird für jedes Szenario ein Datensatz im gleichen Format wie die Betriebsdatenmatrix $\mathbf{X}_{\text{Ver.}}$ erstellt. Ein Szenario enthält mindestens zwei Zeitstempel, wobei der erste die Transition vom aktuellen in den neuen Betriebspunkt und der zweite den konstanten neuen Betriebspunkt beschreibt.

Anhand der Funktion `operationalStatus` wird der aktuelle Betriebszustand überprüft. Für den Betrieb des PFM werden zwei Möglichkeiten unterschieden:

Interne Logik: $b_{\text{Stat.}} = b_{\text{Bet.}}$ and $b_{\Omega\text{Ok}}$ and b_{mon} and not $b_{\text{Abs.}}$

Externe Logik: $b_{\text{Stat.}} = b_{\text{Extern}}$ and $b_{\Omega\text{Ok}}$ and not $b_{\text{Abs.}}$

Die interne Logik überprüft auf Basis von $\mathbf{X}_{\text{Ver.}}$, ob die Anlage zum aktuellen Zeitpunkt in Betrieb ist $b_{\text{Bet.}}$ und sich die Messwerte innerhalb der Grenzwerte $\Omega_{\mathbf{X}}$ befinden $b_{\Omega\text{Ok}}$. Weiterhin wird geprüft, ob sich zu mindestens einem Zeitpunkt in der Vergangenheit die Degradation monoton verhalten hat b_{mon} und das PFM nicht während des Betriebs ausgeschaltet wird $b_{\text{Abs.}}$, da das Modell die Realität nicht abbilden kann.

Im Vergleich dazu bietet der externe Indikator b_{Extern} die Möglichkeit das PFM auf Basis einer unabhängigen FD in Betrieb zu nehmen. In diesem Zusammenhang werden weiterhin die grundlegenden Bedingungen $b_{\Omega\text{Ok}}$ und $b_{\text{Abs.}}$ überprüft, um den grundlegenden Anforderungen zu genügen.

Wenn $b_{\text{Stat.}} == \text{True}$ gilt, wird überprüft, ob die Zustands- Φ und Parametermatrix Θ verfügbar sind und neben dem korrekten Datentyp auch die richtigen Dimensionen aufweisen. Sowohl die Zustandsmatrix Φ als auch die Parametermatrix Θ spannen durch n_{φ} Partikel und eine bestimmte Anzahl an Zuständen bzw. Parametern eine Matrix auf. Diese zweidimensionale Matrix wird für die Prädiktion bzw. das Smoothing um die zeitliche Dimension erweitert, wodurch ein dreidimensionaler Tensor entsteht. Der methodische Kern des PFM ist die Funktion `particleFilterRUL`, die anhand von Unterkapitel 5.2.1 in Bezug auf den Aktualisierungsvorgang sowie in Unterkapitel 5.2.2 mit dem Fokus auf die Schätzung genauer beschrieben wird.

Die Ergebnisse aus dieser Funktion werden durch die Funktion `unwrap` den unterschiedlichen Szenarien zugeordnet und können anschließend ausgegeben und visuell dargestellt werden. Abschließend werden die aktualisierte Zustands- Φ und Parametermatrix Θ für den Export vorbereitet. Für die Speicherung ist es notwendig, Matrizen und Tensoren in eindimensionale Listen zu überführen. Dieser Vorgang ist reversibel, da die Dimensionen ebenfalls gespeichert werden, sodass bei erneuter Ausführung die Listen reversibel in Matrizen und Tensoren zurück überführt werden.

5.2.1. Aktualisierung des Zustands

Innerhalb der Funktion `particleFilterRUL` ist `updatePF` eine Kernfunktionen des PFM. Zunächst wird die initialisierte bzw. geladene Zustandsmatrix Φ mit Hilfe der Parametermatrix Θ und der ZG f_{ZG} in den aktuellen Zustand überführt. Anschließend kann die Aktualisierung auf Basis von Algorithmus 6 erfolgen.

Am Anfang des Aktualisierungsvorgangs werden zunächst die Fensterbreiten für die Bestimmung des Partikelgewichts $h_{\text{Smoo.}}$ bzw. für die Optimierung $h_{\text{Opt.}}$ berechnet.

Algorithmus 6 Pseudocode der Aktualisierungsfunktion des Partikelfiltermoduls mit Resampling, Roughening und Partikeloptimierung.

```

1: if  $n_{\text{Betr.}} > 0$  then
2:    $h_{\text{Opt.}} = \min(n_{\text{Betr.}}, h_{\text{Opt.}})$ 
3:    $h_{\text{Smo.}} = \min(n_{\text{Betr.}}, h_{\text{Smo.}})$ 
4:    $\hat{\Phi}_{\text{Ver.}}, \underline{\Phi}_{\text{Ver.}} = \text{pastEvaluation}(\Theta, \Phi, \mathbf{X}_{\text{Ver.}}, h_{\text{AG}}, f_{\text{ZG}}, h_{\text{Smo.}})$ 
5:    $W_h = \text{stateWeight}(\hat{\Phi}_{\text{Ver.}}, \underline{\Phi}_{\text{Ver.}})$ 
6:    $q_{\text{ESS}} = \text{effectiveSampleSize}(W_h)$ 
7:   if  $q_{\text{ESS}} < \omega_{\text{ESS}}$  then
8:      $idx_{p, \min W} = \text{findWorstParticle}(W_{\text{Kum.}})$ 
9:      $\Phi_{\text{Akt.}} = \text{getActualState}(\mathbf{X}_{\text{Ver.}})$ 
10:     $\Omega_{\Phi} = \text{getBoundState}(\Phi_{\text{Akt.}})$ 
11:     $\Theta, \Phi = \text{optimizeParameter}(\Omega_{\Phi}, \Omega_{\Theta}, h_{\text{Opt.}}, \text{pastEvaluation})$ 
12:     $\hat{\Phi}_{\text{Ver.}}, \underline{\Phi}_{\text{Ver.}} = \text{pastEvaluation}(\Theta, \Phi, \mathbf{X}_{\text{Ver.}}, h_{\text{AG}}, f_{\text{ZG}}, h_{\text{Smo.}})$ 
13:     $W_h = \text{stateWeight}(\hat{\Phi}_{\text{Ver.}}, \underline{\Phi}_{\text{Ver.}})$ 
14:     $\Theta, \Phi = \text{resampleParticle}(\Theta, \Phi, W_h)$ 
15:     $\Theta, \Phi = \text{roughenParticle}(\Theta, \Phi)$ 
16:   end if
17: end if

```

Die Benutzereingaben der Fensterbreiten $h_{\text{Opt.}}$ bzw. $h_{\text{Smo.}}$ wird mit der bisherigen Betriebszeit $n_{\text{Betr.}}$ verglichen, um ausreichend historische Daten für die Berechnung zur Verfügung zu stellen. Anhand der Funktion `pastEvaluation` wird, basierend auf der Parameter- Θ und Zustandsmatrix Φ , der in die Vergangenheit gerichtete geschätzte Zustandstensor $\hat{\Phi}_{\text{Ver.}}$ sowie der Zustandstensor $\underline{\Phi}_{\text{Ver.}}$ durch Smoothing bestimmt. Innerhalb der Funktion `stateWeight` wird der Partikelgewichtsvektor $W_{h,t}$ der $h_{\text{Smo.}}$ vergangenen Zustände für alle Partikel zum Zeitpunkt t anhand von Gleichung 5.5 berechnet.

$$W_{h,t} = \sum_{j=t-h_{\text{Smo.}}}^t \frac{W_j}{h_{\text{Smo.}}} \quad (5.5)$$

Gleichung 5.5 zeigt, dass der Gewichtsvektor $W_{h,t}$ für alle n_{φ} Partikel zum Zeitpunkt t als arithmetisches Mittel der vergangenen Gewichtsvektoren W_j verstanden werden kann. Alternativ zur Summe könnten die Gewichtsvektoren W_t mittels eines Produkts zusammengeführt werden. Beim Auftreten von Ausreißern wäre das einzelne Partikelgewicht w_{pt} durch die Zusammenführung mittels eines Produkts sehr klein bzw. null, wohingegen die Summe nur einen kleinen Summanden enthält. Dies macht das Zusammenführen der Gewichtsvektoren W_t durch Summieren über die Fensterbreite $h_{\text{Smo.}}$ robuster gegen Ausreißer.

Mit dem kumuliert summierten Gewichtsvektor $W_{\text{Kum.}}$ berechnet die Funktion `effectiveSampleSize` auf Basis von Gleichung 4.43 die ESS. Falls die ESS q_{ESS} kleiner als der ESS-Grenzwert ω_{ESS} ist, wird das Resampling und optional die Optimierung aktiviert.

Im Falle einer aktiven Partikeloptimierung werden vorbereitende Maßnahmen getroffen. Dazu zählen die Bestimmung des Indexes des schlechtesten Partikels $idx_{p, \min W}$ mit `findWorstParticle`, der sich durch den geringsten Zahlenwert des Gewichtsvektors $W_{\text{Kum.}}$ auszeichnet. Der ZR wird anhand des aktuellen Zustandsvektors $\Phi_{\text{Akt.}}$ und den daraus

resultierenden Vektoren der unter- $\Phi_{\text{U.Grenz.}}$ bzw. oberen Grenzwerte $\Phi_{\text{O.Grenz.}}$ durch die Grenzwertmatrix $\Omega_{\Phi} = [\Phi_{\text{U.Grenz.}} \quad \Phi_{\text{O.Grenz.}}]$ beschränkt. Analog wird der PR durch die Grenzwertmatrix $\Omega_{\Theta} = [\Theta_{\text{U.Grenz.}} \quad \Theta_{\text{O.Grenz.}}]$ anhand des unteren- $\Theta_{\text{U.Grenz.}}$ bzw. oberen Grenzwertvektors $\Theta_{\text{O.Grenz.}}$ beschränkt und ist durch eine Nutzereingabe zu diesem Zeitpunkt bekannt. In dem beschränkten PR bzw. ZR sucht die Funktion `optimizeParameter` den optimalen Partikel und ruft dazu die Funktion `pastEvaluation` für das Smoothing des Zustands auf. Die durch das Smoothing geschätzten und in die Vergangenheit gerichteten Zustandsmatrizen $\hat{\Phi}_t = \hat{\Phi}(t)$ zum Zeitpunkt t werden mit den historischen Zustandsvektoren Φ_t verglichen. Für die Übersichtlichkeit stellt Gleichung 5.6 den Vergleich des Zustands mit dessen Schätzung durch einen Partikel vor, wobei der Vergleich für alle Partikel durchgeführt wird.

$$MAE_h = \sum_{j=1}^{n_{\Phi}} \sum_{l=t-h_{\text{Smo.}}}^t \frac{|\bar{\Phi}_l(j) - \tilde{\Phi}_{p,l}(j)|}{h_{\text{Smo.}} \cdot n_{\Phi}} \quad (5.6)$$

Da der Zustandsvektor Φ_t mehrere Zustände n_{Φ} umfassen kann, die unterschiedlich skaliert sind, werden sowohl der zeitliche Verlauf eines Zustands j , als auch dessen Schätzung normiert. Dazu wird ein Skalierer auf den Zustandsverlauf trainiert und auf den Zustandsverlauf sowie dessen Schätzung angewendet, um den n_{Φ} Zuständen ein gleichwertiges Gewicht zu verleihen.

Die normierte Summe aus den Abweichungen aller Zustandsverläufe MAE_h wird im Rahmen der Optimierung minimiert. Das Ergebnis der Funktion `optimizeParameter` ist ein optimierter Zustands- $\Phi_{\text{Opt.}}$ bzw. Parametervektors $\Theta_{\text{Opt.}}$, deren Minimierungsproblem in Gleichung 5.7 vorgestellt wird.

$$\Theta_{\text{Opt.}}, \Phi_{\text{Opt.}} = \arg \min_{\Theta, \Phi_{\text{Akt.}}} MAE_h(\Phi, \Psi, \Theta, f_{\text{ZG}}, h_{\text{AG}}, h_{\text{Opt.}}) \quad (5.7)$$

Um das Gewicht des optimierten Partikels $\mathcal{P}_{\text{Opt.}}$ festzustellen, wird die Funktion `stateWeight` erneut ausgeführt. Auf Grundlage des aktualisierten Partikelgewichtsvektors W_h sowie der Zustands- Φ bzw. Parametermatrix Θ kann das Resampling eingeleitet werden. Die Funktion `resampleParticle` basiert auf den vorgestellten Methoden aus Unterkapitel 4.4.4. Nach dem Resampling wird durch `roughenParticle` das Partikelset variiert. Die grundlegenden Methoden werden in Unterkapitel 4.4.5 vorgestellt, wobei verschiedene Optionen zur Verfügung stehen. In Folge des Resamplings existieren eine Vielzahl an Duplikaten im Partikelset, wovon ein Partikel ohne Veränderung übernommen wird. Alle weiteren Duplikate werden mit zufälligen Einflüssen überlagert. Die erste Option ermöglicht eine uniforme Verteilung mit einer definierten Streuung zur Variation der Partikel. Im Gegensatz dazu basiert die zweite Option auf einer Normalverteilung, die tendenziell eine Partikelsuche im lokalen Umfeld unterstützt.

5.2.2. Zustandsschätzung und Restlebenszeitberechnung

Die Schätzung des zukünftigen Zustandstensors $\hat{\Phi}_{\text{Zuk.}}$ durch den PF ist die Grundlage für die Schätzung der RUL. Analog zu der Smoothing basierten Funktion `pastEvaluation` kann die Berechnung zur Prädiktion auch in die Zukunft gerichtet werden. In Abhängigkeit verschiedener Szenarien variiert die Entwicklung des geschätzten

Algorithmus 7 Pseudocode der Schätzfunktion des Partikelfiltermoduls zur Prädiktion zukünftiger Zustände.

```

1:  $h_{\text{Präd.}} = 0$ 
2:  $B_{\Omega\text{err.}} = \text{False}$ 
3:  $B_{\text{Ber.}} = \text{False}$ 
4:  $B_{\text{Deak.}} = B_{\Omega\text{err.}}$  or  $B_{\text{Ber.}}$ 
5:  $\hat{\Phi}_{\text{Zuk.}}(1, :, :) = \Phi$ 
6: while all( $B_{\text{Deak.}}$ ) == False and  $h_{\text{Präd.}} < h_{\text{Präd., max}}$  do
7:   if  $h_{\text{Präd.}} < \text{length}(\mathbf{X}_{\text{Zuk.}})$  then
8:      $X_{\text{Iter.}} = \mathbf{X}_{\text{Zuk.}}(h_{\text{Präd.}}, :)$ 
9:   else
10:     $X_{\text{Iter.}} = \mathbf{X}_{\text{Zuk.}}(\text{length}(\mathbf{X}_{\text{Zuk.}}), :)$ 
11:   end if
12:    $X_{\text{Iter.}} \rightarrow \Gamma_{\text{Iter.}}$ 
13:    $B_{\Omega\text{err.}} = \text{isThresholdCrossed}(\hat{\Phi}_{\text{Zuk.}})$ 
14:    $B_{\text{Ber.}} = \text{isWrongBoundCrossed}(\hat{\Phi}_{\text{Zuk.}})$ 
15:    $B_{\text{Deak.}} = B_{\Omega\text{err.}}$  or  $B_{\text{Ber.}}$ 
16:    $\hat{\Phi}_{\text{Iter.}} = f_{\text{ZG}}(\Gamma_{\text{Iter.}}, \hat{\Phi}_{\text{Zuk.}}(h_{\text{Präd.}}, :, :), \Theta)$ 
17:    $\hat{\Phi}_{\text{Zuk.}}(h_{\text{Präd.}} + 1, :, :) = \hat{\Phi}_{\text{Iter.}}$ 
18:    $\hat{\Phi}_{\text{Zuk.}} = \text{keepConstant}(\hat{\Phi}_{\text{Zuk.}}, B_{\text{Deak.}})$ 
19:    $h_{\text{Präd.}} = h_{\text{Präd.}} + 1$ 
20: end while
21:  $B_{\text{Ers., Ber.}} = \text{isWrongBoundCrossed}(\hat{\Phi}_{\text{Zuk.}})$ 
22:  $B_{\text{Ers., mon}} = \text{isNonMonoton}(\hat{\Phi}_{\text{Zuk.}})$ 
23:  $B_{\text{Ers.}} = B_{\text{Ers., Ber.}}$  or  $B_{\text{Ers., mon}}$ 

```

Zustandstensors $\hat{\Phi}_{\text{Zuk.}}$, weswegen die nachfolgenden Schritte für jedes vorhandene Szenario $v_{\text{Szen.}}$ berechnet und anhand von Algorithmus 7 exemplarisch vorgestellt werden.

Grundlegend für die Schätzung eines zukünftigen Zustands sind die aktuelle Zustandsmatrix Φ und Parametermatrix Θ . Aus der aktuellen zweidimensionalen Zustandsmatrix Φ entsteht durch die Schätzung ein dreidimensionaler Zustandstensor $\hat{\Phi}$. Für die Schätzung zukünftiger Zustände entfällt das Resampling und die Parametermatrix Θ bleibt während der Berechnung konstant.

Zunächst werden Maßnahmen zur Initialisierung vorgenommen, wie den Zähler $h_{\text{Präd.}} = 0$ zu setzen und die booleschen Listen $B_{\Omega\text{err.}}$ und $B_{\text{Ber.}}$ mit False zu überschreiben. Die beiden booleschen Listen haben einen Eintrag für jeden Partikel. Weiterhin wird der geschätzte Zustandstensor $\hat{\Phi}_{\text{Zuk.}}$ initial mit der aktuellen Zustandsmatrix Φ initialisiert. Da die Anzahl der Schätzungen nicht *a priori* bekannt ist, wird die Schätzung so lange fortgesetzt, bis entweder die maximale Anzahl an Iterationen $h_{\text{Präd., max}}$ oder alle Partikel einen im Grenzwertvektor Ω_{Φ} enthaltenen Grenzwert erreicht bzw. den zulässigen Wertebereich verlassen haben.

Die Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ kann entweder ein bekannter Datensatz als Grundlage für eine Onlinesimulation oder ein zuvor definiertes Szenario sein. Bei ausreichender Länge der zukünftigen Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$, wird der aktuelle Iterationsschritt $h_{\text{Präd.}}$

ausgewählt, um den Eingangsvektor $\Gamma_{\text{Iter.}}$ zu bestimmen. Wenn die Schätzung weiter in die Zukunft reicht, als die zukünftige Betriebsdatenmatrix $\mathbf{X}_{\text{Zuk.}}$ Zeilen besitzt, wird der letzte verfügbare Betriebsdatenvektor weiter fortgeschrieben. Da die gemessenen Daten nicht in einen konstanten Betriebspunkt sondern zum Beispiel mit einem Sprung als letztem Eintrag enden können, wird für reale Simulationsdaten zwischen den letzten zehn Betriebsdaten variiert.

Es folgen die Prüfungen des geschätzten Zustandstensors $\hat{\Phi}_{\text{Zuk.}}$. Mit der Funktion `isThresholdCrossed` wird geprüft, ob der gewünschte Grenzwertvektor Ω_{Φ} bereits erreicht wird. Dazu erfolgt die Überprüfung der geschätzten Trajektorie jedes einzelnen Partikels. Besonders nach der Initialisierung kann es möglich sein, dass einzelne Partikel eine falsche Monotonie aufweisen und somit nie den Grenzwert erreichen. Die Prüfung dieser Eigenschaft wird durch die Funktion `isWrongBoundCrossed` umgesetzt. Beide Prüfungen werden durch die Disjunktion beider Ergebnisse in der Liste $B_{\text{Deak.}}$ zusammengefasst. Durch die ZG f_{ZG} kann mit der Parametermatrix $\hat{\Theta}$ sowie dem aktuellen Eingangsvektor $\Gamma_{\text{Iter.}}$ die nächste zukünftige Zustandsmatrix $\hat{\Phi}_{\text{Iter.}}$ geschätzt werden. Der Zustandstensors $\hat{\Phi}_{\text{Zuk.}}$ wird auf Grundlage der Zustandsmatrix $\hat{\Phi}_{\text{Iter.}}$ erweitert. Falls $B_{\text{Deak.}}$ für einen Partikel wahr ist, wird dieser Partikel nicht weiter in die Zukunft fortgeschrieben, sondern mit `keepConstant` auf dem letzten berechneten Wert gehalten. Die Begrenzung ist notwendig, da basierend auf heterogenen Partikeln und einem dynamischen System, sehr unterschiedliche Zustandsverläufe folgen, die in der Zeit bis zum Erreichen des Grenzwertvektors Ω_{Φ} stark variieren und zu numerischen Limitierungen führen können. Wenn entweder die Zustandsschätzungen $\hat{\Phi}_{\text{Zuk.}}$ für alle Partikel den Grenzwert erreichen oder die Bedingung der maximalen Anzahl an Schätzungen $h_{\text{Präd.,max}}$ erfüllt ist, werden abschließende Prüfungen durchgeführt. Diese umfassen mit der Funktion `isWrongBoundCrossed` eine Prüfung, ob der Wertebereich verlassen wird und mit der Funktion `isNonMonoton`, ob die Monotonie der Zustandstrajektorie jedes einzelnen Partikels zu der erwarteten Monotonie passt. Beide Ergebnisse werden mit einer Disjunktion zu $B_{\text{Ers.}}$ verknüpft und im Anschluss der Hauptfunktion des PFM zur Verfügung gestellt. Aufgrund des Verhaltens der in $B_{\text{Ers.}}$ enthaltenen Partikel, werden diese Partikel zufällig durch andere ersetzt.

Basierend auf der geschätzten zukünftigen Entwicklung des Zustandstensors $\hat{\Phi}_{\text{Zuk.}}$ wird in einem nachgelagerten Schritt die RUL berechnet. Anhand von Gleichung 5.8 werden alle Zustandstrajektorien jedes Partikels auf die erste Grenzwertüberschreitung überprüft.

$$N_{\text{RUL}} = \text{whichPosition} \left(\hat{\Phi}_{\text{Zuk.}} \text{mon}_{\text{Num.}} \geq \Omega_{\Phi} \text{mon}_{\text{Num.}} \right) \quad (5.8)$$

Die Variable $\text{mon}_{\text{Num.}} \in \mathbb{R} \{-1, 1\}$ ist eine numerische Repräsentation der Monotonie, wobei -1 für monoton fallende und 1 für monoton steigende Verläufe gesetzt wird. Dies hat den Vorteil, dass sich bei monoton fallenden Verläufen das Ungleichungssystem umkehrt und somit die Gleichung 5.8 für alle Anwendungsfälle eingesetzt werden kann. Der Ergebnisvektor $N_{\text{RUL}} \in \mathbb{N}^{1 \times n_{\Phi}}$ enthält die Anzahl der Messwerte, bis der Grenzwertvektor Ω_{Φ} durch die Zustandstrajektorie des jeweiligen Partikels erreicht wird. Alle RUL des Ergebnisvektors N_{RUL} ergeben eine Verteilung, deren Perzentile ζ für die Berechnung der Konfidenzintervalle sowie der Bestimmung des Erwartungswert der RUL ausgewertet werden. Falls der Grenzwertvektor Ω_{Φ} nicht erreicht wird, erfolgt das Setzen des maximalen Schätzzeitraums $h_{\text{Präd.,max}}$ als Ergebnis. Die Wahl von $h_{\text{Präd.,max}}$ sollte großzügig ausfallen, um Variationen in den Parametern und Zuständen gerecht

zu werden, wobei eine zu große Dimensionierung zusätzliche Berechnungen verursacht. Abschließend wird durch einen Dreisatz der Ergebnisvektor N_{RUL} zusammen mit der Messdatenfrequenz in eine Zeitvektor \mathcal{T}_{RUL} von RUL, umgerechnet.

5.2.3. Datengenerator des Partikelfiltermoduls

Für das Testen des PFM ist das standardisierte Erstellen von synthetischen Daten notwendig, die auf Basis einer AG h_{AG} und einer ZG f_{ZG} generiert werden. Im Gegensatz zur verwendeten Nomenklatur, werden die Eingangs- $\mathbf{\Gamma}_{\text{Synth.}}$, Ausgangs- $\mathbf{\Psi}_{\text{Synth.}}$ und Zustandsmatrix $\mathbf{\Phi}_{\text{Synth.}}$ nur durch die Anzahl der jeweiligen Mess- bzw. Zustandsgrößen sowie die Zeit t aufgespannt. Da die Daten synthetisch generiert werden, gibt es für diesen Prozessschritt keine Partikeldimension und folglich auch keine Tensoren. Eine Übersicht des Vorgehens wird anhand von Algorithmus 8 vorgestellt.

Algorithmus 8 Pseudocode der Generierung synthetischer Daten für die Evaluation durch das Partikelfiltermodul.

- 1: $\mathbf{\Gamma}_{\text{Synth.}} = \text{createDF}(n_{\text{Mess.,Synth.}}, n_{\text{Var.}}, n_{\text{Sprung}}, c_{\text{Vers.}}, c_{\text{Skal.}})$
 - 2: $\mathbf{\Phi}_{\text{Synth.}} = \text{createState}(\mathbf{\Gamma}_{\text{Synth.}}, \Theta, \Phi_{t=0}, n_{\Phi}, f_{\text{ZG}})$
 - 3: $\mathbf{M}_{\text{Synth.}} = \text{extendDF}(\mathbf{\Gamma}_{\text{Synth.}}, \mathbf{\Phi}_{\text{Synth.}})$
 - 4: $\mathbf{\Psi}_{\text{Synth.}} = \text{createMeasure}(\mathbf{M}_{\text{Synth.}}, h_{\text{AG}})$
 - 5: $\mathbf{M}_{\text{Synth.}} = \text{extendDF}(\mathbf{M}_{\text{Synth.}}, \mathbf{\Psi}_{\text{Synth.}})$
 - 6: $\mathbf{M}_{\text{Synth.}} = \text{addNoise}(\mathbf{M}_{\text{Synth.}})$
-

Anhand der unterschiedlichen Funktionen in Algorithmus 8 werden die synthetischen Daten $\mathbf{M}_{\text{Synth.}}$ erstellt. In einem ersten Schritt werden alle notwendigen Randbedingungen festgelegt, wie beispielsweise die Definition der Gesamtmesswertezahl $n_{\text{Mess.,Synth.}}$. Darüber hinaus werden für die Eingangsmatrix $\mathbf{\Gamma}_{\text{Synth.}}$, die Eingangszahl $n_{\text{Var.,Ein.}}$ sowie die in den einzelnen Signalen enthaltene Anzahl der Sprünge n_{Sprung} festgelegt. Für die Einstellung eines geeigneten Wertebereichs werden der Offset $c_{\text{Vers.}}$ bzw. der Faktor $c_{\text{Skal.}}$ definiert.

Auf Basis der Funktion `createDF` wird die Eingangsmatrix $\mathbf{\Gamma}_{\text{Synth.}}$ generiert. Dazu werden für jedes einzelne erzeugte Signal n_{Sprung} zufällige Werte zwischen 0 und 1 gewählt, um $c_{\text{Vers.}}$ Einheiten verschoben sowie mit dem Faktor $c_{\text{Skal.}}$ skaliert. Weiterhin werden n_{Sprung} ganzzahlige, zufällige Werte zwischen 1 und $n_{\text{Mess.,Synth.}}$ bestimmt, die nach dem Sortieren die Position der Sprünge von $\mathbf{X}_{\text{Synth.}}$ darstellen. Anhand der Position der Sprünge sowie der generierten Signalwerte kann der Zwischenraum zwischen den Sprüngen durch Halten des letzten geänderten Wertes aufgefüllt werden. Neben einem Zeitstempel werden die Eingangssignale mit Variablennamen versehen, die ein optionales benutzerdefiniertes Prefix und einen zusätzlichen alphabetischen Buchstaben tragen.

Anhand der bekannten ZG wird mit f_{ZG} und einem bekannten initialen Zustand $\Phi_{t=0}$ die Zustandsmatrix $\mathbf{\Phi}_{\text{Synth.}}$ berechnet. Gleichsam wie zuvor, werden die Zustände durch ein Prefix und einen zusätzlichen alphabetischen Buchstaben benannt. Durch die Funktion `extendDF` werden die Eingangsmatrix $\mathbf{\Gamma}_{\text{Synth.}}$ und die zeitliche Zustandsmatrix $\mathbf{\Phi}_{\text{Synth.}}$ in der Matrix $\mathbf{M}_{\text{Synth.}}$ zusammengeführt.

Auf Grundlage der Matrix $\mathbf{M}_{\text{Synth.}}$ folgt mit der AG h_{AG} die Ausgangsmatrix $\mathbf{\Psi}_{\text{Synth.}}$. In Abhängigkeit der Definition der AG ist die Anwendung einer dualen Berechnung notwendig, um von den Zuständen auf die Ausgänge zu schließen. Die Informationen

der Ausgangsmatrix $\Psi_{\text{Synth.}}$ werden der Matrix $\mathbf{M}_{\text{Synth.}}$ hinzugefügt. Abschließend werden mit `addNoise` die Daten der Matrix $\mathbf{M}_{\text{Synth.}}$ mit Rauschen überlagert. Für die eingangs- bzw. ausgangsbasierten Anteile der Matrix $\mathbf{M}_{\text{Synth.}}$ können unterschiedliche Rauschanteile gewählt werden. In diesem Zusammenhang ist auch die signalspezifische Zuweisung von Rauschen möglich und folgt immer einer Normalverteilung mit $\mathcal{N}(\mu = 0, \sigma)$. Die erzeugten Daten können im Anschluss weiter verarbeitet oder gespeichert werden.

5.2.4. Ergebnisvisualisierung des Partikelfiltermoduls

Für die Analyse der Leistungen des PFM zur RUL Schätzung werden nachfolgend standardisierte Plots vorgestellt.

Anhand von Abbildung 5.4 wird eine Übersichtsgrafik zur Bewertung des PFM vorgestellt. In der oberen Darstellung der Abbildung wird der RUL-Verlauf anhand des Zeitvektors \mathcal{T}_{RUL} als schwarze Linie visualisiert. In Abhängigkeit der unterschiedlichen Szenarien werden die geschätzten Zeitvektoren $\hat{\mathcal{T}}_{\text{RUL}}$ gemäß den Szenarien inklusive Konfidenzintervall abgebildet.

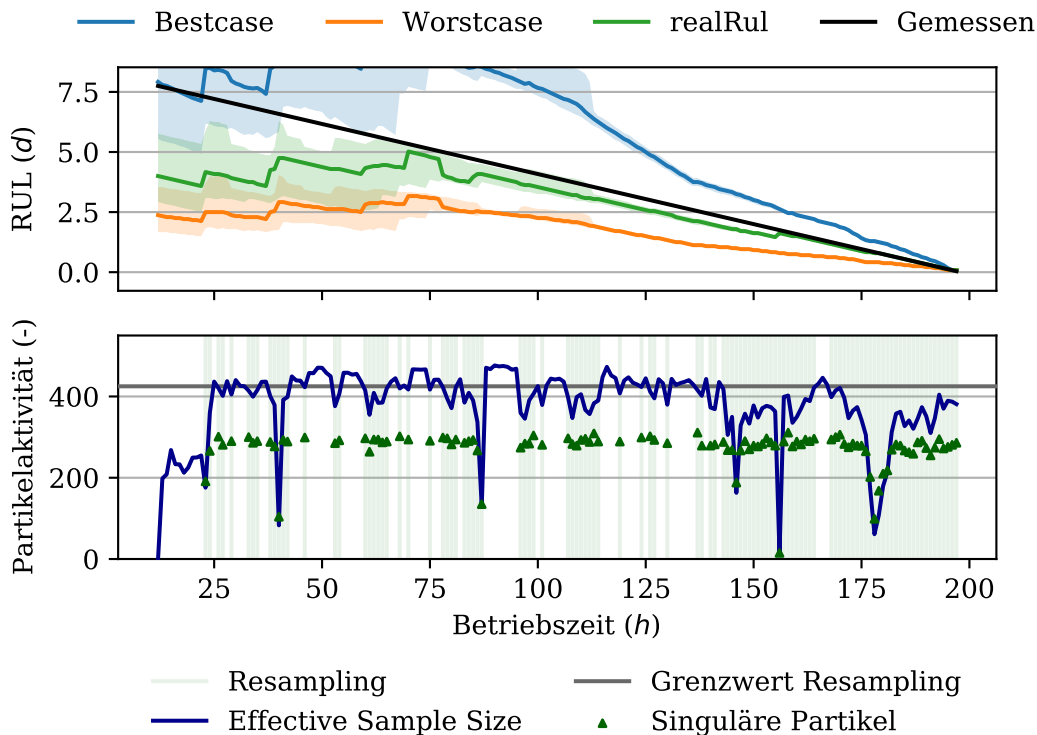


Abbildung 5.4.: Exemplarische Darstellung der Ergebnisse des Partikelfiltermoduls.

In der unteren Darstellung werden die Kenngrößen des PF anhand der Partikelaktivität vorgestellt. Dazu werden die ESS anhand des Qualitätsvektors Q_{ESS} in Blau und der Grenzwert für die Aktivierung des Resamplings ω_{ESS} in Grau dargestellt. Im Rahmen des Resamplings wird vor dem Roughening Schritt die Anzahl der singulären Partikel $n_{\phi_{\text{Sing.}}}$ berechnet, die eine Vergleichsgröße zu q_{ESS} ist. Beide Darstellungen werden über der Betriebszeit in Stunden aufgetragen.

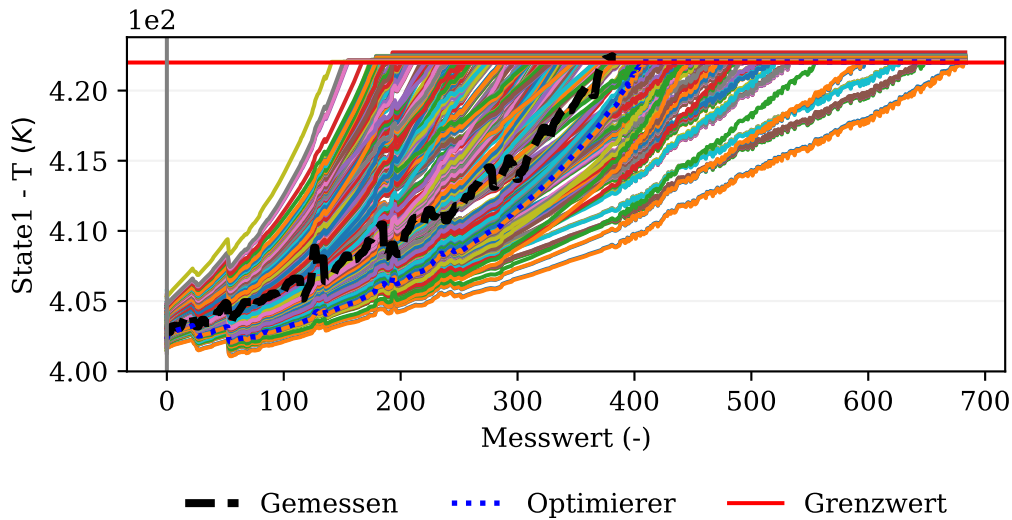


Abbildung 5.5.: Exemplarische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T .

Abbildung 5.5 stellt eine exemplarische Prädiktion eines Zustands vor. Diese umfasst den Zustandsverlauf des Zustandstensors $\underline{\Phi}(j)$ für einen Zustand $j \in \mathbb{N}\{1, n_{\Phi}\}$ in Schwarz, sowie den dafür definierten Grenzwert $\Omega_{\Phi}(j)$ in Rot. Die Trajektorie jedes einzelnen Partikels wird durch eine farbige Linie über die Zeit dargestellt. Je nach Betriebsoption und Verfügbarkeit existiert ein optimierter Partikel $\mathcal{P}_{\text{Opt.}}$, dessen Trajektorie in einer Blau gepunkteten Linie abgebildet wird. Dieser Plot ist für jeden Zustand j verfügbar und wird ebenso für die Visualisierung des Smoothings angewendet. Die Darstellung des Smoothings grenzt sich von der Darstellung der Prädiktion durch die Kennzeichnung des aktuellen Zeitpunkts mit einer vertikalen grauen Linie im rechten Bereich des Bildes sowie eine negative Achsenbeschriftung auf der Abszisse ab.

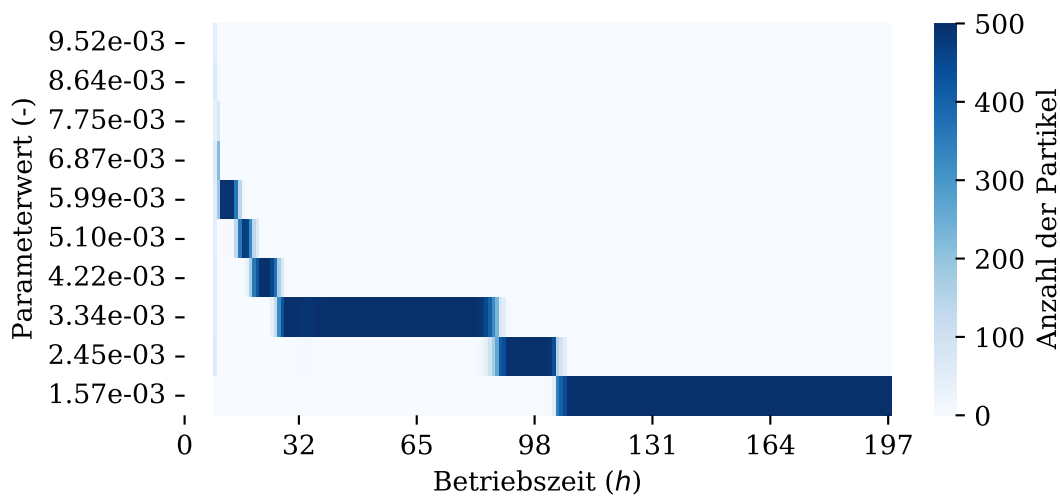


Abbildung 5.6.: Exemplarische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 1$.

Abschließend wird in Abbildung 5.6 exemplarisch die Darstellung der Partikeldichteverteilung vorgestellt. Diese stellt auf Grundlage des Parametertensors $\underline{\Theta}(j)$ für einen Parameter $j \in \mathbb{N}\{1, n_{\Theta}\}$ den zeitlichen Verlauf der Dichte vor. Dies ermöglicht die Visualisierung von Verschiebungen innerhalb eines Parameters j . Analog existiert diese Art der Visualisierung für einen Zustand $j \in \mathbb{N}\{1, n_{\Phi}\}$ des Zustandstensors $\underline{\Phi}(j)$.

6. Modellbildung

Die Ursachen der Entwicklung einer Messgröße über die Zeit sind vielfältig und variationsreich. Neben prozessbedingten sind vor allem die degradationsbedingten Änderungen für die Modellbildung von Interesse. Nachfolgend werden in Unterkapitel 6.1 die Modellbildung für das ETM vorgestellt. Da die Modellbildung während der Onlineüberwachung erfolgt, werden in dem Unterkapitel lediglich die grundlegenden Funktionen vorgestellt. Im Gegensatz dazu wird in Unterkapitel 6.2 die konkrete Modellierung des in Unterkapitel 3.2.3 vorgestellten RV diskutiert.

6.1. Modellportfolio des Einzeltrendmoduls

Das Portfolio der Modelltypen wird durch die Anwendungsfälle in Unterkapitel 3.2 inspiriert, sodass geeignete Funktionen zur Modellbildung abgeleitet werden. Viele Degradationsvorgänge lassen sich grob als linear, polynomial oder exponentiell einteilen, wobei diese Kategorien keinen Anspruch auf Vollständigkeit erheben.

Das lineare Degradationsverhalten ist die Basis für komplexere Degradationsvorgänge und wird in Gleichung 6.1 vorgestellt.

$$f_{\text{Deg.Lin.}}(t) = c_{\text{ETM1}} + c_{\text{ETM2}}t \quad (6.1)$$

Auf Basis der linearen Degradationsfunktion $f_{\text{Deg.Lin.}}$ ist die Modellierung von einfachen Degradationsvorgängen möglich. Der Parameter c_{ETM1} beschreibt einen konstanten Versatz und wird durch den Parameter c_{ETM2} ergänzt, der einen proportionalen Zuwachs der Degradation mit der Zeit t abbildet. Da nur zwei Parameter für die Beschreibung der Degradation notwendig sind, ist die Abbildung der Messdaten robuster im Vergleich zu komplexeren Modellen. Durch positive bzw. negative Wert im Parametervektor C_{ETM} sind eine Vielzahl an unterschiedlichen Abbildungen möglich.

Exemplarisch schätzt Tang u. a. [44] auf Grundlage der linearen Gleichung eines WP die RUL von Batterien. Dies verdeutlicht exemplarisch, dass lineare Degradationsfunktionen trotz der Einfachheit reale Degradationen abbilden können.

Die konsequente Erweiterung der linearen Funktion zu höheren Ordnungen sind die polynomialen Funktionen. Diese werden anhand von Gleichung 6.2 vorgestellt.

$$f_{\text{Deg.Pol.}}(t) = c_{\text{ETM1}} + c_{\text{ETM2}}t^{c_{\text{ETM3}}} \quad (6.2)$$

Als Erweiterung der linearen- kann die polynomialische Degradationsfunktion $f_{\text{Deg.Pol.}}$ durch den zusätzlichen Parameter c_{ETM3} höhere Ordnungen abbilden. Somit können auch beschleunigte Degradationsvorgänge berücksichtigt werden.

Die Reduktion eines allgemein definierten Polynoms auf die höchste Ordnung ermöglicht die Abbildung der potenziell kritischen Degradationseigenschaft. Die Ergänzung um die kleineren Ordnungen verbessert die Abbildung, jedoch auf Kosten von mehr

Freiheitsgraden, die durch das ETM geschätzt werden müssten.

Beispielhaft stellt Sun u. a. [66] die Schätzung der RUL am Beispiel von Batterien vor, wobei die Modellierung der Eigenschaftsänderung auf einem Polynom dritten Grades beruht.

Das beschleunigte Degradationsverhalten kann durch die polynomische Degradationsfunktion $f_{\text{Deg.Pol.}}$ abgebildet werden, wobei einige Degradationsvorgänge exponentiellen Charakter besitzen. Dieser Umstand wird durch Gleichung 6.3 berücksichtigt.

$$f_{\text{Deg.Exp.}}(t) = c_{\text{ETM}1} + c_{\text{ETM}2} (1 + \exp(c_{\text{ETM}3}t)) \quad (6.3)$$

Die exponentielle Degradationsfunktion $f_{\text{Deg.Exp.}}$ umfasst, wie die polynomische Degradationsfunktion $f_{\text{Deg.Pol.}}$, einen Parametervektor C_{ETM} mit drei Einträgen. Parameter $c_{\text{ETM}3}$ bestimmt das exponentielle Verhalten maßgeblich und ist bei längeren Schätzhorizonten sensitiv im Hinblick auf die Schätzung des zukünftigen Signalverlaufs. Gleichung 6.3 ist ein Sonderfall einer allgemeinen Exponentialfunktion. Vor dem Hintergrund, dass das Modell während des laufenden Betriebs durch das ETM gewählt und parametrisiert wird, ist dies insbesondere für den gewählten Optimierungsalgorithmus eine Herausforderung. Um ein schnelles Konvergieren zu unterstützen, werden geeignete initiale Startparameter benötigt, die anhand von Unterkapitel C.3 bestimmt werden. Di Maio u. a. [58] stellen ein Beispiel für exponentielles Wachstum anhand der Entwicklung eines Wälzkörperlagerschadens vor. Konkret beschleunigt der ursprüngliche Schaden die weitere Beschädigung.

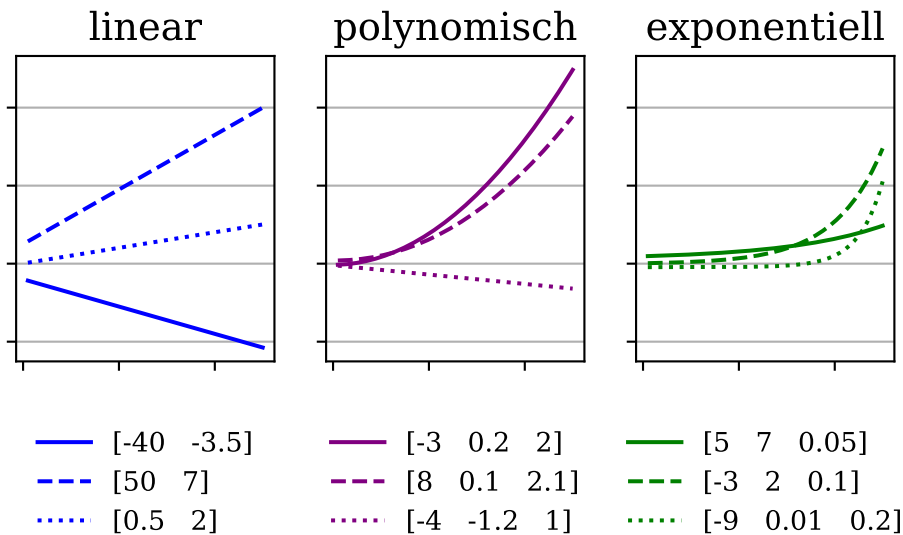


Abbildung 6.1.: Grafische Darstellung der verfügbaren Funktionen des Einzeltrendmoduls und den dazugehörigen Parametervektoren C_{ETM} .

Abbildung 6.1 zeigt die Vielfältigkeit der vorgestellten Funktionen auf Basis eines zufälligen Parametervektors C_{ETM} . Neben den beiden extremen Ausprägungen einer linearen- und exponentiellen Degradationsfunktion, werden die Modelle durch die polynomische Degradationsfunktion $f_{\text{Deg.Pol.}}$ ergänzt. Diese kann auf der einen Seite nichtlineare Zusammenhänge abbilden und ist auf der anderen Seite, verglichen mit

einer exponentiellen Funktion, im Wachstum reduziert. Genau genommen ist die lineare Degradationsfunktion $f_{\text{Deg. Lin.}}$ ein Sonderfall der Polynomfunktion, wobei die Schätzung des zukünftigen Verhaltens bereits bei geringem Abweichen der linearen Eigenschaften eine deutliche Abweichung erzeugen kann. Daher ist die lineare Degradationsfunktion eine eigenständige Funktion zur Abbildung eines Degradationssignals S .

6.2. Modellbildung des Partikelfiltermoduls

Die grundlegende Modellierung des RV aus Unterkapitel 3.2.3 könnte anhand der in Unterkapitel 6.1 vorgestellten Modelltypen des ETM erfolgen. Auf Basis von mehreren messbaren Ein- und Ausgängen, einem lediglich anteilig bekannten Degradationsverhalten sowie der Notwendigkeit verschiedene Szenarien zu berechnen, ist der Anwendungsfall deutlich komplexer. Kombiniert mit der geringen Instrumentierung sowie keinen quantifizierten Informationen der Degradation des RV folgt eine umfangreiche Modellbildung, die im Gegenzug eine präzisere Schätzung der RUL ermöglicht.

Als Grundlage wird in Unterkapitel 6.2.1 das Modell des Wärmeübergangs vorgestellt und darauf aufbauend bekannte Degradationsmodelle eingeführt. Der konkrete Modellierungsprozess der Degradation des RV umfasst die grundlegende Aufbereitung der Daten in Unterkapitel 6.2.2. Darauf aufbauend wird in Unterkapitel 6.2.3 der vorverarbeitete Datensatz erweitert. Erstmals werden die einzelnen Degradationszyklen in Unterkapitel 6.2.4 betrachtet und für den Modellierungsprozess ausgewählt. Als wesentlicher Modellierungsschritt werden die relevanten Feature in Unterkapitel 6.2.5 identifiziert. Auf Grundlage der ausgewählten Feature erfolgt die Beschreibung als ZRM und dessen Parametrierung als globales Modell in Unterkapitel 6.2.6. Das globale Modell beschreibt alle Degradationszyklen hinreichend genau, wobei die einzelnen Zyklen nicht ideal wiedergegeben werden. Die aus dem globalen Modell bekannten Einflussfaktoren werden auf die spezifische Modellbildung übertragen und auf jeden einzelnen Degradationszyklus in Unterkapitel 6.2.7 angewandt. Die zyklenspezifischen Modelle ermöglichen die präzisere Abbildung der Degradationsverläufe im Vergleich zum globalen Modell. Die abschließende Evaluierung der Modellbildung findet in Unterkapitel 6.2.8 statt.

6.2.1. Analogien zu Degradationsmechanismen

Eine spezielle Form der Degradation ist das sogenannte Fouling, das als Sammelbegriff für unterschiedliche Mechanismen verwendet wird. Die nachfolgende Einführung basiert auf der Darstellung von Müller-Steinhagen [105]:

Einer Befragung von Betreibern zu Folge besteht bei etwa 90% aller Wärmeübertrager ein Ablagerungsproblem. Demnach werden Kristallisations-, Partikel-, Reaktions-, Korrosions- und Biofouling als grobe Klassifizierung unterschieden. Der zeitliche Ablauf wird in verschiedene Phasen unterteilt. In der Eingangsphase erfolgt die Keimbildung, die weitestgehend ohne Beeinträchtigung des Betriebs abläuft. Im Anschluss folgt der Stofftransport über Diffusion an die Heizfläche, gefolgt von der Ablagerungsbildung durch Anlagerung. Neben der Alterung und der damit verbundenen Verfestigung der Ablagerung gibt es die Auto-Retardation, welche Teile der Ablagerung durch Strömungseffekte löst. Vereinfacht kann Fouling als zusätzlicher Wärmewiderstand $r_{\text{Foul.}}$ des

Gesamtwärmewiderstands $r_{\text{Ges.}}$ in Gleichung 6.4 verstanden werden.

$$r_{\text{Ges.}} = \frac{1}{\alpha_{\text{Konv. In.}} a_{\text{Fläche In.}}} + r_{\text{Foul. In.}} + r_{\text{Wand}} + \frac{1}{\alpha_{\text{Konv. Au.}} a_{\text{Fläche Au.}}} + r_{\text{Foul. Au.}} \quad (6.4)$$

Gleichung 6.4 stellt den Gesamtwärmewiderstand $r_{\text{Ges.}}$ eines Rohres mit der Innenoberfläche $a_{\text{Fläche In.}}$ und Außenoberfläche $a_{\text{Fläche Au.}}$ vor. Der Wärmeübergang zwischen den Fluiden und der Rohrwand wird anhand der Wärmeübergangskoeffizienten $\alpha_{\text{Konv. In.}}$ bzw. $\alpha_{\text{Konv. Au.}}$ abgebildet. Exemplarisch wird ein Fouling durch zusätzliche Wärmewiderstände an der Rohrinneoberfläche $r_{\text{Foul. In.}}$ sowie der Rohraußenoberfläche $r_{\text{Foul. Au.}}$ angenommen. Die Foulingschicht hat eine geringe Wärmeleitfähigkeit und damit einen hohen Wärmewiderstand, der den Gesamtwärmewiderstand $r_{\text{Ges.}}$ beeinflusst.

Eine Möglichkeit um das Fouling während des Betriebs zu tolerieren, ist die Überdimensionierung des Wärmeübertragers. Exemplarisch führt eine Überdimensionierung von 30% bis 40% zu etwa 25% höheren Anschaffungskosten [105]. Eine mögliche Folge der Überdimensionierung ist die Veränderung der Störung, die ebenfalls zu einer Erhöhung des Foulings führen kann [105].

Somit wird deutlich, dass der Umgang mit Degradationsvorgängen in Wärmeübertragern nicht vollständig durch eine korrekte Auslegung umgangen werden kann. Für ein besseres Verständnis möglicher Einflussfaktoren und der Ableitung von Analogien, werden nachfolgend das Fouling durch Acrylsäure und Rohöl vorgestellt.

Acrylsäure

Die Herstellung und Lagerung von Acrylsäure ist, im Sinne der Stabilisierung, eine Herausforderung. Die nachfolgenden Ausführungen basieren auf Fried [153], der die Einflussfaktoren der Polymerisation von Acrylsäure zusammenfasst. Demnach besitzen Acrylverbindungen eine hohe Reaktionsbereitschaft. Der wichtigste Prozess der Polymerisation ist der radikalische Prozess. Für die Startreaktion wird eine hohe Aktivierungsenergie benötigt, die beispielsweise durch Wärme zugeführt werden kann. Die radikalischen Enden bereits bestehender Ketten aktivieren weitere Acrylmonomere und führen zu einer sehr schnellen Reaktion. In Kombination mit der bei der Polymerisation freiwerdenden Reaktionswärme, ist die Selbstentzündung bzw. das Bersten von Behältern möglich. Der Temperatureinfluss als Beschleunigung der Reaktion und dessen Abbildung durch einen Arrhenius-Ansatz sind bekannt.

Neben diesen Einflussgrößen stellen Schulze u. a. [154] den Einfluss von Sauerstoff in den Fokus. Besonders für die Lagerung von unstabilisierter Acrylsäure nimmt der Sauerstoff eine wichtige Funktion ein, da dieser nach gewisser Zeit zum Kettenabbruch führt. Bei diesem Vorgang wird sehr viel Sauerstoff gebunden.

Um die Kettenbildung zu reduzieren, werden sogenannte Stabilisatoren/ Inhibitoren eingesetzt. Die Stabilisatoren werden in anerobe und aerobe unterschieden [153]. Schulze u. a. [154] verweisen auf den Einsatz moderner Stabilisatoren, wie MeHQ und PTZ zur Vermeidung von Polymerisation bei der Lagerung, die durch Verweilzeit und höhere Lagertemperaturen hervorgerufen wird. Trotz der intensiven Entwicklung von Stabilisatoren ist die Bildung von unerwünschten Polymeren in großtechnischen Anlagen möglich.

Dies verdeutlicht die Herausforderung bei deren Verarbeitung und Lagerung von Acrylsäure im Konkreten. Die zu Grunde liegenden Ursachen für Polymerisation von Acryl-

säure können sinnbildlich auf weitere chemische Verbindungen übertragen werden und skizzieren mögliche Einflussfaktoren für Degradation im Allgemeinen.

Rohölfouling

In der Literatur liegt ein Fokus auf der Beschreibung des Foulings von Rohöl. Die Foulingeigenschaften des Rohöls werden, unter anderem von Ebert u. a. [155] und Nasr u. a. [156], auf Basis des Arrhenius-Ansatzes abgebildet, der in Gleichung 6.5 vorgestellt wird.

$$\frac{dr_{\text{Foul.}}}{dt} = c_{\text{Arr.}} \exp\left(\frac{-e_{\text{Akt.}}}{c_{\text{Gas}} t_{\text{Char.}}}\right) \quad (6.5)$$

Die Arrhenius Gleichung bildet eine Exponentialfunktion ab, die auf dem Quotienten zwischen der Aktivierungsenergie $e_{\text{Akt.}}$ und dem Produkt aus universeller Gaskonstante c_{Gas} und der charakteristischen Temperatur $t_{\text{Char.}}$ basiert. Als präexponentieller Faktor wird $c_{\text{Arr.}}$ eingeführt. Der Faktor $c_{\text{Arr.}}$ skaliert den exponentiellen Term und ist in Abhängigkeit der abgebildeten Größe einheitsbehaftet. Alle eingehenden Größen, mit Ausnahme der charakteristischen Temperatur $t_{\text{Char.}}$, sind Konstanten. Dies unterstreicht den Einfluss der Temperatur auf das Fouling.

Eine empirische Erweiterung des Zusammenhangs geht auf Ebert u. a. [155] zurück, der im Rahmen eines Forschungsprojektes von Exxon und dem US Department of Energy die Gleichung 6.6 ableitet.

$$\frac{dr_{\text{Foul.}}}{dt} = c_{\text{Foul.1}} z_{\text{Dim.Re}}^{c_{\text{Foul.2}}} \exp\left(\frac{-e_{\text{Akt.}}}{c_{\text{Gas}} t_{\text{Char.}}}\right) - c_{\text{Foul.3}} \tau_{\text{Scher.}} \quad (6.6)$$

Die zeitliche Änderung des Foulingwiderstands $r_{\text{Foul.}}$ wird auch als Foulingrate bezeichnet und ist abhängig von der Reynolds-Zahl $z_{\text{Dim.Re}} = \rho u d_{\text{Char.}} / \eta = u d_{\text{Char.}} / \nu$. Die Reynolds-Zahl ist eine dimensionslose Kennzahl und setzt die Geschwindigkeit u und die charakteristische Länge $d_{\text{Char.}}$ mit der kinematischen Viskosität ν ins Verhältnis. Die empirische Foulingrate berücksichtigt eine Änderung der Filmtemperatur $t_{\text{Char.}}$, die mit der Aktivierungsenergie $e_{\text{Akt.}}$ sowie der universellen Gaskonstante c_{Gas} in einen Arrhenius-Ansatz eingebettet sind. Dem akkumulierenden Term steht ein negativer Term gegenüber, der einen Abtrag des Foulings in Abhängigkeit von der Oberflächenspannung $\tau_{\text{Scher.}}$ berücksichtigt. Vervollständigt wird der Ansatz durch die stoffspezifische Konstanten $c_{\text{Foul.1}}$, $c_{\text{Foul.2}}$ und $c_{\text{Foul.3}}$.

Das grundlegende Modell von Ebert u. a. [155] ist die Basis für eine Vielzahl abgewandelter Modelle. Zum Beispiel hat Nasr u. a. [156] die abtragende Wirkung anstelle der Oberflächenspannung $\tau_{\text{Scher.}}$ durch einen Reynoldszahl-Term $z_{\text{Dim.Re}}^{0.4}$ berücksichtigt. Im Gegensatz dazu hat Polley u. a. [157] den foulingbildenden Term, wie in Gleichung 6.7 dargestellt, um den Faktor $z_{\text{Dim.Pr}}^{-0.33}$ erweitert. Die dimensionslose Prandtl-Zahl $z_{\text{Dim.Pr}} = \nu/a$ setzt die kinematische Viskosität ν und Temperaturleitfähigkeit a ins Verhältnis.

$$\frac{dr_{\text{Foul.}}}{dt} = c_{\text{Foul.1}} z_{\text{Dim.Re}}^{-0.8} z_{\text{Dim.Pr}}^{-0.33} \exp\left(\frac{-e_{\text{Akt.}}}{c_{\text{Gas}} t_{\text{Char.}}}\right) - c_{\text{Foul.2}} z_{\text{Dim.Re}}^{0.8} \quad (6.7)$$

Auch das Modell von Yang u. a. [158] basiert auf der Grundideen von Ebert u. a. [155] und sieht das Fouling als Summe eines auf- und abbauenden Foulingterms die gegeneinander gerichtet sind. Hinzu kommt die Einteilung in die zeitlichen Abschnitte, Initiierung, Transport, Ablagerung, Entfernung und Alterung. Ferner wird die Alterung als Einflussgröße auf den Wärmeleitkoeffizienten gesehen, der exponentiell von der Zeit sowie indirekt von der Temperatur abhängt.

Eine Zusammenfassung bekannter Modelle gibt Wang u. a. [159] mit dem Fokus auf die Umsetzung im Rahmen eines Laboraufbaus.

Sowohl die Polymerisation, wie auch das Rohölfouling sind zwei sehr unterschiedliche Degradationsmechanismen. Beide Ansätze enthalten Einflussfaktoren, die auf Stoffeigenschaften zurückgehen. Weiterhin werden betriebsbedingte Einflüsse, wie beispielsweise die Temperatur oder das Strömungsverhalten des Fluides, berücksichtigt.

Aufgrund der Bauform des RV und der verfügbaren Messtechnik, ist der Großteil der für die Beschreibung notwendigen Einflussfaktoren unbekannt. Aus diesem Grund werden die Wirkmechanismen auch im Hinblick auf andere Stoffsysteme, durch einen hybriden Ansatz abgebildet. Dazu werden die zuvor vorgestellten physikalischen Erkenntnisse berücksichtigt und mit den methodischen Möglichkeiten aus dem Bereich ML verknüpft.

6.2.2. Initiale Vorverarbeitung der Daten

Zur Erlangung eines generellen Verständnisses des verfahrenstechnischen Prozesses sowie möglicher Einflussgrößen auf das Degradationsverhalten, wird die erweiterte Umgebung des RV anhand der multivariaten Methoden CCA aus Unterkapitel 4.3.2 analysiert. Die Ergebnisse bilden mit der Expertise des Betreibers die Grundlage für die Vorauswahl der Sensoren aus dem größeren verfahrenstechnischen Prozess.

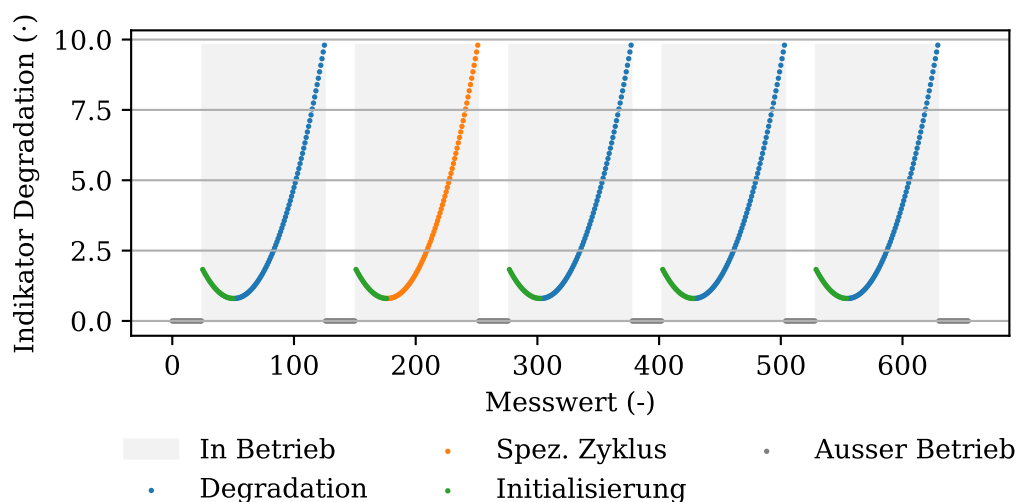


Abbildung 6.2.: Grafische Darstellung eines schematischen Degradationsprozesses und dessen Aufgliederung in unterschiedliche Datenkategorien.

Das Degradationsverhalten des Wärmeübertragers erfolgt in Zyklen, die schematisch in Abbildung 6.2 dargestellt werden. Ein Zyklus beginnt mit der Initialisierungsphase. In diesem Abschnitt wird die Anlage angefahren und das System in den Betriebspunkt

gebracht. Bedingt durch die hohe Instationarität ist die Abbildung dieses Zeitraumes nur mit sehr großem Aufwand und zusätzlichen Messwerten möglich.

Auf die Initialisierung folgt die stationäre Betriebsphase, in der die Anlage im gewünschten Betriebspunkt betrieben wird und keine wesentlichen Veränderungen in der Degradation gemessen werden. Im konkreten Fall beginnt das Fouling nahezu zeitgleich mit dem Anfahren der Anlage. Dadurch entsteht keine konstante Betriebsphase, sondern vielmehr ein direkter Übergang in die Foulingphase.

Die Foulingphase zeichnet sich durch eine zumeist stetige Verschlechterung des Betriebs aus und endet, wenn ein definierter Grenzwert überschritten wird. Nach der Überschreitung wird die Anlage ausgeschaltet und durch unterschiedliche Verfahren gereinigt. Im Anschluss daran kann die Anlage erneut angefahren werden und es beginnt ein neuer Degradationszyklus.

Die für die Modellierung notwendigen Daten werden in einem PIMS historisiert, das in Unterkapitel 3.1.1 genauer beschrieben wird. Der RV verfügt über die in Abbildung 3.5 dargestellten Messwerte, die grundlegend für die Modellbildung sind. Konkret werden 1990 Tage Daten mit einem äquidistanten Abstand von einer Stunde aus dem PIMS geladen. Der sich hieraus ergebende Datenabzug wird nachfolgend als Rohdaten bezeichnet.

Im Rahmen der initialen Datenaufbereitung werden die Datentypen überprüft und, falls nötig, korrigiert. Dies betrifft insbesondere den Zeitstempel. Zu diesem Zweck wird das Datum in Form einer Zeichenkette in ein Datumsformat überführt, das die weitere Verarbeitung vereinfacht. Weiterhin wird sichergestellt, dass die Messwerte nur numerisch sind und keine Fehlstellen, wie *NaN*-Werte, besitzen. Zur besseren Interpretation durch Experten sowie eine Reduzierung der Fehleranfälligkeit werden alle Messdaten in SI-Einheiten überführt. Konkret bedeutet dies die Umrechnung der Temperaturen in *K*, der Drücke in den Absolutdruck *bar* und der Durchflüsse in *kg/s*. Neben der Konsistenz der Daten müssen verschiedene Betriebszustände gekennzeichnet werden. Dazu wird die kategoriale Messstelle $kat_{\text{Betr.}}$ genutzt, die eine Unterteilung in die Kategorien *Betrieb*, *Reinigung* oder *Auszustand* durch eine numerische Zuordnung ermöglicht. Da der Messwert $kat_{\text{Betr.}}$ Zeitintervalle dem Zustand *Betrieb* zuordnet, in denen die Anlage formal im Betrieb ist, sich jedoch nicht in einem angefahrenen Zustand befindet, wird der Betriebsindikator weiter eingeschränkt:

$$b_{\text{Bet.}} = (kat_{\text{Betr.}} == \text{„Betrieb“}) \text{ and } (\phi \geq 1.6) \quad (6.8)$$

Der Dampfdruck ϕ stellt somit eine untere Schranke bei Werten kleiner als 1.6bar dar. Der Wert von 1.6 resultiert aus der Sichtung der Messwerte sowie der Diskussion mit den Anlagenbetreibern.

Abbildung 6.3 gibt einen ersten Überblick über die Datengrundlage sowie die Betriebszustände. Der mittlere Dampfdruck zwischen den einzelnen Zyklen variiert und auch das Änderungsverhalten des Dampfdrucks ϕ ist sehr unterschiedlich.

Trotz der initialen Aufbereitung der Rohdaten enthält der Datensatz verschiedene Anomalien, wie zum Beispiel Ausreißer. Da die Ausreißer durch eine große Änderung auch mit einem Sprung verwechselt werden können, werden die Signale zunächst anhand des Wertes $b_{\text{Bet.}}$ in die einzelnen Zyklen zerlegt. Somit ist sichergestellt, dass Signale, wie zum Beispiel der Dampfdruck ϕ , die einen steigenden oder fallenden Trend beinhalten, beim Ein- oder Ausschalten nicht als Ausreißer klassifiziert werden. Anhand




Abbildung 6.3.: Grafische Darstellung der verfügbaren Datengrundlage des Robertverdampfers anhand des Dampfdrucks ϕ sowie der Kennzeichnung aktiver Betriebszustände.

von Gleichung 6.9 werden die Ursprungssignale S in Anlehnung an Unterkapitel 4.2.1 trendbereinigt, wodurch die Abweichung $Res_{\text{Filter},S}$ verbleibt.

$$Res_{\text{Filter},S}(h_{\text{Filt.},S}) = S - \text{medianFilter}(S, h_{\text{Filt.},S}) \quad (6.9)$$

In diesem Zusammenhang bestimmen die Fenstergröße $h_{\text{Filt.},S}$, wie auch der Grenzwert $\omega_{\text{Aus.}}$ die Zuweisung als Ausreißer. Für alle Signale wird die Fenstergröße mit $h_{\text{Filt.},S} = 24$ Stunden festgelegt. Der signalspezifische Grenzwert $\omega_{\text{Aus.}}$ basiert auf der sechsfachen Standardabweichung des Residuenvektors $Res_{\text{Filter},S}$ und wird für jedes Signal S ermittelt. Die binäre Klassifizierung als Ausreißer erfolgt anhand von Gleichung 6.10.

$$b_{\text{Ausr.}} = |Res_{\text{Filter},S}| > \omega_{\text{Aus.}} \quad (6.10)$$

Sprunghafte Änderungen des Signals, können durch den Filter abgebildet werden, wohingegen einzelne Ausreißer wirkungsvoll herausgefiltert werden. Insgesamt enthalten die Daten 2.61% Ausreißer, die im Rahmen der Vorverarbeitung durch NaN -Werte ersetzt und anschließend durch lineare Interpolation aufgefüllt werden. Zusätzlich werden grundlegende Messgrößen für die nachfolgende Featurebildung wie tci , ϕ und fhi mit einem Medianfilter der Fenstergröße $h_{\text{Filt.},S} = 5$ gefiltert, um das Fortpflanzen von spezifischen Strukturen in die Feature zu vermeiden.

6.2.3. Bildung von degradationsspezifischen Features

Auf Basis von Abbildung 3.5 stehen verschiedene Messstellen für Modellbildung zur Verfügung die im Rahmen der initialen Vorverarbeitung aus Unterkapitel 6.2.2 be-

reits vorbereitet werden. Zur besseren Abbildung des Verhaltens werden nachfolgend unterschiedliche Merkmale aus den Grundsignalen entwickelt, die auch als Feature bezeichnet werden. Durch die Featurebildung können Betriebserfahrungen wie der Einfluss der Last auf die Foulinggeschwindigkeit, bekannte Zusammenhänge aus der Thermodynamik oder benachbarten Disziplinen wie Gleichung 6.7 berücksichtigt werden.

Im Folgenden werden die unterschiedlichen Feature Varianten anhand von zwei exemplarischen Messreihen S_a und S_b vorgestellt. Für die Messgrößen können, wie in Gleichung 6.11 und 6.12 beschrieben, die zeitliche Differenz sowie die Inverse des Signals gebildet werden.

$$dS_{a_dt} = S_{a(l+1)} - S_{al} \approx \frac{dS_a}{dt} \quad (6.11)$$

$$invS_a = \frac{1}{S_a} \quad (6.12)$$

Ferner werden spezifische Feature gebildet, die das Produkt bzw. den Quotienten zweier Messwerte oder bereits vorverarbeiteter Features bilden und in Gleichung 6.13 und 6.14 vorgestellt werden.

$$S_{a_}S_b = S_a S_b \quad (6.13)$$

$$S_{a_}div_S_b = \frac{S_a}{S_b} \quad (6.14)$$

Zur Einschränkung des Lösungsraums werden nicht alle möglichen Kombinationen von Produkt- und Quotient-Features gebildet, sondern nur ausgewählte Kombinationen berechnet. Die zuvor eingeführten datenbasierten Features werden im Folgenden durch Feature mit physikalischem Bezug anhand von Gleichung 6.15 bis 6.20 ergänzt [160].

$$thi = f_{\text{WDT}}(phi) \quad (6.15)$$

$$deltat = thi - tci \quad (6.16)$$

$$sumt = thi + tci \quad (6.17)$$

$$ratiot = \frac{thi}{tci} \quad (6.18)$$

$$qh = f_{\text{WDT}}(fhi, thi) \quad (6.19)$$

$$r = \frac{deltat}{qh} \quad (6.20)$$

Die Grundlagen der physikalischen Features sind die Zusammenhänge zwischen Druck und Temperatur von Wasser in unterschiedlichen Aggregatzuständen. Für die elementaren thermodynamischen Zusammenhänge wird auf Baehr u. a. [99] verwiesen. Als Basis für die Berechnung der Features sind die Stoffdaten von Wasser erforderlich, die empirisch ermittelt und in sogenannten Wasser Dampf Tabelle (WDT) zusammengefasst werden. Die Stoffdaten der WDT werden in der Funktion f_{WDT} zusammengefasst. Die Dampftemperatur thi wird mit der Funktion f_{WDT} in Abhängigkeit des Dampfdrucks phi berechnet. Dazu wird angenommen, dass der Zustand des Dampfes genau auf der Taulinie liegt und somit weder überhitzt noch teilkondensiert ist. Durch die Dampfinfrastruktur innerhalb der BASF SE in Ludwigshafen und das Ableiten von Kondensat zwischen Erzeugern und Verbrauchern ist diese Annahme in guter Näherung

gerechtfertigt.

Auf Grundlage der Dampftemperatur thi ergibt sich die Enthalpiedifferenz der vollständigen Kondensation. Der Dampfmassenstrom fhi sowie der Dampftemperatur thi sind die Basis für die Berechnung des Wärmestroms qh .

Als weitere Features werden die Beziehung zwischen der Dampf- thi sowie der Sumpftemperatur tci der Kolonne ausgedrückt. Dazu werden die Differenz $deltat$, die Summe $sumt$ und das Verhältnis $ratiot$ der Temperaturen gebildet.

Der Quotient der Temperaturdifferenz $deltat$ und des Wärmestroms qh ist der Wärmedurchgangswiderstand r , der ein charakteristischer Kennwert für die Berechnung und Beschreibung von Wärmeübertragern ist.

Der ursprüngliche Datensatz verfügt über 36 Messwerte des RV und dessen direkter Prozessumgebung. Durch die Featurebildung wird der Datensatz auf insgesamt 113 Features vergrößert.

6.2.4. Auswahl der Degradationszyklen

Zur Abbildung des Foulingverhaltens werden die aufgearbeiteten Daten anhand des Features $b_{Bet.}$ in einzelne Zyklen zerlegt. Insgesamt stehen 61 Zyklen, die mehr als 36 Stunden lang sind, zur Verfügung. Einige Zyklen enthalten Anomalien, die keine einzelnen Messfehler, sondern vielmehr ein über einen größeren Zeitraum vorhandenes und andersartiges Verhalten aufweisen. Eine lokale Korrektur durch Verwerfen bzw. Interpolieren der Daten ist nicht sinnvoll, da der aufbauende Charakter dadurch verfälscht würde. Ein Beispiel für eine solche Anomalie ist die eingeschränkte bzw. fehlerhafte Funktionsweise des Kondensatabscheiders, der zu einer Veränderung der wärmeübertragenden Fläche und in Folge dessen der gesamten Betriebsweise führt. Nach Rücksprache mit dem Anlagenbetreiber werden Zyklen mit Anomalien vollständig verworfen. Für die Klassifizierung wird auf Wissen des Betreibers zurückgegriffen, wobei Grenzfälle im Sinne der Modellbildung eher verworfen werden, um keine falschen Einflüsse im Modell abzubilden. Bedingt durch die Auswahl der Zyklen reduziert sich deren Umfang auf insgesamt 35 Stück.

Anhand von Abbildung 6.2 geht hervor, dass sich nur Teilbereiche eines Zyklus für die Modellierung des Foulings eignen. Die Differenzierung zwischen der Initialisierung und der Degradation ist automatisiert nur eingeschränkt möglich, da die Betriebspunkte sowie das Anfahrverhalten stark variieren und keine direkte Messung des Foulings verfügbar ist. Aus diesem Grund werden die Zyklen manuell auf Basis des Features r selektiert und lediglich der degradationsrelevante Betriebsbereich für die Modellbildung berücksichtigt.

Aufbauend auf den in Unterkapitel 6.2.3 gebildeten Features werden zykluspezifische Feature hinzugefügt. Diese Features umfassen einen Betriebszeitähler, der den zeitlichen Einfluss abbildet. Darauf aufbauend werden Folgefeatures wie eine quadrierte oder invertierte Variante des Betriebszeitählers abgeleitet. Ferner wird ein auf den Fouling-Start initialisierter Wärmedurchgangswiderstand $r_{t=0}$ berechnet, um den Einfluss des Offsets zu bereinigen.

Abbildung 6.4 zeigt die Spanne zwischen Start- und Endwert des Wärmedurchgangswiderstandes r der verfügbaren Degradationszyklen aufgetragen über der Betriebszeiten in Stunden. Der Wärmedurchgangswiderstand gibt Aufschluss über den Zustand des

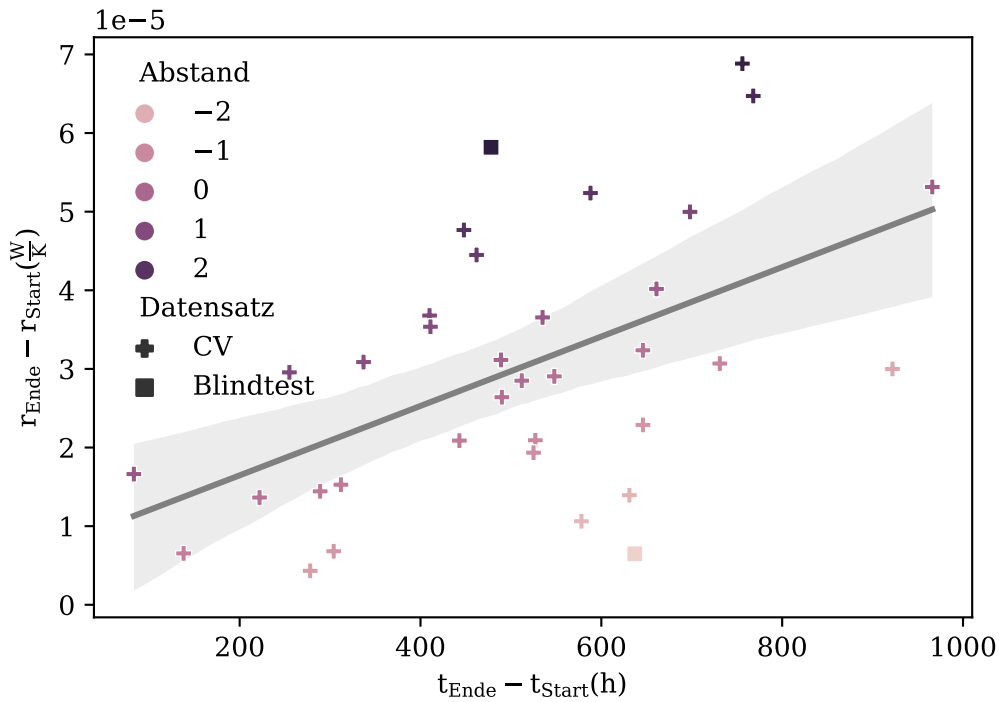


Abbildung 6.4.: Grafische Darstellung des Vergleichs zwischen der Differenzbetriebszeit und dem Differenzwärmedurchgangswiderstand für alle ausgewählten Zyklen des Robertverdampfers sowie deren Unterteilung in Kreuzvalidierungs- und Blindtestzyklen.

Wärmeübertragers, wobei sowohl Betriebs- als auch Degradationseinflüsse sich auf die Kennzahl auswirken. Als Vorbereitung für die Validierung des Modells werden die Zyklen mit der größten positiven bzw. negativen Abweichung zum erwarteten zeitlichen Verhalten des Wärmedurchgangswiderstands aus allen verfügbaren Zyklen bestimmt. Zu diesem Zweck wird ein einfaches lineares Modell mit Gleichung 6.21 aufgestellt.

$$(r_{Ende} - r_{Start}) = c_1 + c_2 (t_{Ende} - t_{Start}) \quad (6.21)$$

Die Parametrierung des Modells in Gleichung 6.21 basierend auf den degradations-spezifischen Anteilen der 35 Zyklen. Anhand von Gleichung 6.22 wird das Residuum res_r des Modells berechnet.

$$res_r = (r_{Ende} - r_{Start}) - (\hat{r}_{Ende} - \hat{r}_{Start}) \quad (6.22)$$

Das in Gleichung 6.22 vorgestellte Residuum des Wärmedurchgangswiderstands res_r wird zur Auswahl der Validierungszyklen verwendet. Dazu werden der größte- sowie der kleinste Wert des Residuums res_r identifiziert und der dazugehörige Zyklus für die Modellbildung exkludiert. Dieses Vorgehen ermöglicht eine Validierung auf Basis der Extremzustände und unterstreicht dadurch die Funktionsweise des Ansatzes. Abschließend werden alle aufgearbeiteten Informationen zu einem Datensatz inklusive der Zuordnung zu den jeweiligen Zyklen zusammengeführt.

6.2.5. Selektion relevanter Features

Ein wesentlicher Teil der Modellbildung ist die Auswahl relevanter Features. Die Art des Modells kann vielfältig sein und reicht von linearen Modellen hin zu Modellen aus

dem Bereich der künstlichen Intelligenz. Auf Grundlage der begrenzten Menge an Daten sowie der Anforderung, dass das Verhalten des Modells erklärbar sein soll, wird ein lineares Modell gewählt. Trotz der linearen Eigenschaften können nichtlineare Anteile durch Features abgedeckt werden. Dies ermöglicht neben dem Aspekt der Erklärbarkeit auch den Einsatz von bekannten Basismethoden zur Modellbildung. Weiterhin zeigen beispielsweise Mathew u. a. [77], dass trotz der Einfachheit von linearen Modellen wesentliche Systemeigenschaften abgebildet werden können.

Vor der Modellbildung werden alle erzeugten Features anhand des Vorgehens in Gleichung 4.4 standardisiert. Die Standardisierung ermöglicht eine bessere Vergleichbarkeit der einzelnen Einträge des Featurevektors $M_{\text{Feat.}}$ sowie eine verbesserte Konvergenz beim Lösen des Minimierungsproblems. Durch den Einsatz einer kreuzvalidierten LASSO Regression auf Basis der in Unterkapitel 4.3.1 beschriebenen Methode werden sowohl die aussagekräftigen Features selektiert als auch der Parametervektor Θ bestimmt. Gemäß Gleichung 4.23 beeinflusst der Hyperparameter α_{LASSO} die Lösung des Minimierungsproblems und somit auch indirekt die Anzahl der für die Abbildung ausgewählten Features. Konkret umfasst die Kreuzvalidierung 100 unterschiedliche Training-Test Datensätze. Die LASSO Regression nähert für jeden Training-Test Datensatz die Abbildung der finiten Differenz des Wärmedurchgangswiderstands Δr durch die Variation eines Parametervektors Θ und des Hyperparameters α_{LASSO} gemäß Gleichung 6.23 an.

$$\Delta r = \sum_{j=1}^{n_{\Theta}} \Theta(j) M_{\text{Feat.}}(j) \quad (6.23)$$

Das Ergebnis der Kreuzvalidierung ist der Hyperparameter $\alpha_{\text{LASSO}} = 7.5e - 4$ und die zur Abbildung der finiten Differenz des Wärmedurchgangswiderstands Δr ausgewählt und in Tabelle 6.1 aufgeführten Elemente des Featurevektors $M_{\text{Feat.}}$. Das erste Element des Featurevektors $M_{\text{Feat.}}$ ist der konstante Achsenabschnitt *intercept* des linearen Modells.

Tabelle 6.1.: Tabellarische Auflistung aller Merkmale des Featurevektors $M_{\text{Feat.}}$ und deren Formeln zur Abbildung der Degradation des Robertverdampfers.

Symbol	Formel	Symbol	Formel
<i>intercept</i>	c	<i>dfci_dt</i>	$\frac{fci_{t+1} - fci_t}{\Delta t}$
<i>dinv_fhi_dt</i>	$\frac{\Delta t}{fhi_{t+1} - fhi_t}$	<i>dhci_dt</i>	$\frac{tci_{t+1} - tci_t}{\Delta t}$
<i>r_dfci_div_fhi_dt</i>	$r_t \frac{\frac{fci_{t+1} - fci_t}{fhi_{t+1}} - \frac{fci_t}{fhi_t}}{\Delta t}$	<i>r_dfhi_dt</i>	$r_t \frac{fhi_{t+1} - fhi_t}{\Delta t}$
<i>r_dfhi_div_fci_dt</i>	$r_t \frac{\frac{fhi_{t+1} - fhi_t}{fci_{t+1}} - \frac{fhi_t}{fci_t}}{\Delta t}$	<i>r_dfci_dt</i>	$r_t \frac{fci_{t+1} - fci_t}{\Delta t}$
<i>r_dinv_fhi_dt</i>	$r_t \frac{fhi_{t+1} - fhi_t}{\Delta t}$	<i>tci</i>	tci_t
<i>sumt</i>	$thi_t + tci_t$	<i>expdeltat</i>	$\exp(thi_t - tci_t)$
<i>fci_div_fhi</i>	$\frac{fci_t}{fhi_t}$	<i>inv_fhi</i>	$\frac{1}{fhi_t}$
<i>r_fci</i>	$r_t fci_t$		

6.2.6. Entwicklung eines globalen Zustandsraummodells

Für die Überwachung eines Equipments durch das PFM ist die Systembeschreibung als ZRM notwendig. Anhand der grundlegenden Einführung in Unterkapitel 4.4.3 erfolgt die Abbildung des RV im ZR.

Für den konkreten Anwendungsfall des RV besteht der Eingangsvektor Γ aus der Sumpftemperatur tci , dem Dampfmassenstrom fhi sowie dem in die Kolonne eingehenden Massenstrom fci . Der Zustand des Systems wird durch den Zustandsvektor Φ beschrieben. Dieser umfasst den Wärmedurchgangswiderstand r und die Temperatur des kondensierenden Dampfes thi . Der Ausgangsvektor Ψ umfasst mit dem Dampfdruck phi lediglich eine einzige Messgröße.

Eingangs- Γ , Zustands- Φ und Ausgangsvektor Ψ werden anhand von Gleichung 6.24 bis 6.26 beschrieben.

$$\Gamma = [tci \quad fhi \quad fci] \quad (6.24)$$

$$\Phi = [r \quad thi] \quad (6.25)$$

$$\Psi = [phi] \quad (6.26)$$

Der Zusammenhang zwischen Zustands- Φ und Ausgangsvektor Ψ wird durch die AG h_{AG} in Gleichung 6.27 und 6.28 beschrieben.

$$thi = f_{WDT}(phi) \quad (6.27)$$

$$r = \frac{f_{WDT}(phi) - tci}{f_{WDT}(phi) fhi} \quad (6.28)$$

Der zeitliche Übergang zwischen den Zuständen erfolgt anhand der ZG f_{ZG} auf Grundlage der LASSO Regression, die bereits in Gleichung 6.23 eingeführt wird. Zur Vollständigkeit erfolgt die Darstellung in Gleichung 6.29.

$$\Delta r = \sum_{j=1}^{n_{\Theta}} \Theta(j) M_{\text{Feat.}}(j) \quad (6.29)$$

Basierend auf den selektierten Features der LASSO Regression aus Unterkapitel 6.2.5 wird ein globales Modell trainiert. Das globale Modell dient als Referenz für weitere Modelle und als Anhaltspunkt für die Güte der Abbildung allgemein.

Zunächst wird der Skalierer auf alle relevanten Features und Zustände trainiert. Anhand einer OLS wird mit den skalierten Features die Änderung des skalierten Zustands Δr ausgedrückt. Bei der Lösung des Minimierungsproblems werden keine Grenzen für den Parametervektor Θ vorgegeben, sodass keine Einschränkungen gemacht werden. Das Ergebnis dieses initialen Modells sind die Koeffizienten der Eingänge. Anhand dieses ersten Ergebnisses wird das globale Modell und weitere spezifische Modelle beschränkt. Für die Bewertung bezüglich der Abbildungsqualität wird der Datensatz in 100-fältige Training-Testdatensätze unterteilt. Somit können 100 Modelle trainiert und die Abbildung auf den unbekannt Testdaten evaluiert werden. Die Wertebereiche der einzelnen Parameter Θ werden halbunendlich beschränkt, sodass ein positiver Koeffizient zwischen $0 \leq \text{Koeffizient} \leq \infty$ annehmen kann. Gleichsam werden negative Koeffizienten des globalen Modells für das 100-fältige Training-Test-Vorgehen auf $0 \geq \text{Koeffizient} \geq -\infty$ beschränkt. Eine Ausnahme stellt der Achsenabschnitt $\Theta(1) = \text{intercept}$ des linearen

Modells dar, der zur Abbildung aller Möglichkeiten anhand von $-\infty \leq intercept \leq \infty$ nicht begrenzt wird.

Im Gegensatz zum initialen Modell wird ein Minimierungsproblem auf Basis des kumulierten geschätzten Zustands Δr aufgebaut. Das kumulierte Zustandssignal $\Delta r_{\text{Kum.}}$ wird für die Berechnung sowie das Minimierungsproblem verwendet, da nicht das Rauschen, sondern vielmehr die Sprünge und der Trend des Degradationssignals abgebildet werden. Zur Bewertung wird die R^2 Metrik aufgrund der einfachen Interpretierbarkeit und robusten Anwendung für lineare Abbildungen eingesetzt. Exemplarisch wird die Berechnung des kumulierten Zustands $\Delta r_{\text{Kum.}}$ anhand von Gleichung 6.30 vorgestellt.

$$\Delta r_{\text{Kum.},j} = \sum_{l=1}^j \Delta r_l \text{ mit } j \in \mathbb{N} \{1, n_{\text{Mess.}}\} \quad (6.30)$$

Gleichung 6.30 gilt nur für die Berechnung eines Zyklus. Für die Anwendung auf den zusammenhängenden Trainingsdatensatz, der mehrere Degradationszyklen enthält, werden das kumulierte Zustandssignal und dessen Schätzung an den Startpunkten der Zyklen auf den Wert 0 zurückgesetzt. Beispielhaft erfolgt das Zurücksetzen für $j = 1$ anhand von $\Delta r_{\text{Kum.},j=1}^{\hat{}} = \Delta r_{\text{Kum.},j=1} = 0$ und wird in gleicher Weise für die weiteren Zyklen umgesetzt. Der zurückgesetzte Zustand $\Delta r_{\text{Kum.}}$ wird im Rahmen der Optimierung anhand von Gleichung 6.31 minimiert.

$$\epsilon = \arg \min_{\Theta} \sum_{j=1}^{n_{\text{Mess.}}} \left(\Delta r_{\text{Kum.},j}^{\hat{}}(\Theta) - \Delta r_{\text{Kum.},j} \right)^2 \quad (6.31)$$

Auf Basis des in Gleichung 6.31 vorgestellten Minimierungsproblems, werden die 100-fältigen Modelle anhand der R^2 Metrik verglichen. Abbildung 6.5 visualisiert die Verteilungen der R^2 Metriken auf Grundlage der 100-fältigen Trainings- und Testdatenaufteilung.




Abbildung 6.5.: Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines 100-fältig globalen Degradationsmodells des Robertverdampfers.

Der Median der Trainingsdaten Verteilungen ergibt $\xi_{\text{Train.}} = 0.699$ bzw. $\xi_{\text{Test}} = 0.701$

für die Testdaten Verteilung. Die Streuung der R^2 -Metriken auf den Testdaten ist im Vergleich zu den R^2 Metriken der Trainingsdaten stärker ausgeprägt, wobei der Wertebereich insgesamt vergleichbar ist. Die gemittelte R^2 Metrik ergibt einen Wert von 0.7 und zeigt, dass grundlegende Anteile des kumulierten Zustands $\Delta r_{\text{Kum.}}$ mit dessen Schätzung $\hat{\Delta r}_{\text{Kum.}}$ übereinstimmen, jedoch nicht alle Details in den Verläufen abgebildet werden.

Neben dem Gütemaß der Schätzung lassen sich aus dem globalen Modell auch die Wertebereiche aller Elemente des Parametervektors Θ sowie deren Sensitivität ableiten.

6.2.7. Parametrieren zyklenspezifischer Zustandsraummodelle

Das in Unterkapitel 6.2.6 vorgestellte globale Modell zeigt, dass grundlegende Charakteristika des Modells bereits abgebildet werden. Allerdings ist Fouling ein komplexes Degradationsphänomen, das mehrere Einflussfaktoren enthält. Besonders die bekannten Einflüsse, wie Stoffzusammensetzung, lokale Temperatureinflüsse und weitere werden nicht von der prozesstechnischen Instrumentierung gemessen.

Aus diesem Grund liegt es nahe, dass das globale Modell weitere Parameter oder eine Erweiterung des Wertebereichs des Parametervektors Θ benötigt, um die individuellen Degradationsvorgänge jedes einzelnen Zyklus besser abbilden zu können. Zu diesem Zweck wird die Anpassung des globalen Modells an jeden einzelnen Zyklus vorgenommen. Dazu wird der Datensatz in einzelne Zyklen unterteilt und innerhalb eines Zyklus eine zufällige Aufteilung in einen Test- und Trainingsdatensatz vorgenommen. Im Gegensatz zum globalen Modell wird der mögliche Wertebereich für jeden Parameter j des Parametervektors Θ anhand von Gleichung 6.32 und 6.33 bestimmt.

$$\Theta_{\text{U.Grenz.}}(j) = \min\left(\Theta_{\text{Glob.Mod.}}(j), \Theta_{\text{Init.Mod.}}(j)\right) \quad (6.32)$$

$$\Theta_{\text{O.Grenz.}}(j) = \max\left(\Theta_{\text{Glob.Mod.}}(j), \Theta_{\text{Init.Mod.}}(j)\right) \quad (6.33)$$

Auf Basis der Ergebnisse des globalen Modells wird festgestellt, dass nicht alle Eigenschaften der Degradation abgebildet werden. Die nicht abgebildeten Features lassen sich in zwei Klassen unterteilen:

- Trend-Faktor: Grundlegende Änderungsrate wird auf Basis des globalen Modells teilweise unter- und teilweise überschätzt.
- Form-Faktor: Das Verhalten der einzelnen Degradationszyklen variiert in einem Spektrum von linear bis höherer Ordnung.

Inspiziert durch die zeitvariate Modellbildung von Si u. a. [161], werden Freiheitsgrade in das Modell integriert. Im Gegensatz zum vorgestellten Modell von Si u. a. [161], können diese Freiheitsgrade jedoch nicht als Funktion ausgedrückt werden, da diese weder bekannt sind, noch die notwendigen Daten für die Berechnung gemessen werden. Aus diesem Grund werden die Parametergrenzvektoren $\Theta_{\text{U.Grenz.}}$ und $\Theta_{\text{O.Grenz.}}$ für einzelne Parameter geöffnet, um eine Abbildung des Verhaltens zu ermöglichen. Dazu wird der Wertebereich des Parameters *intercept* geöffnet, um die Einflüsse des Trends abbilden zu können. Weiterhin werden die Grenzen des Parameters *sumt* erweitert, um einen höheren Einfluss der Temperatur auf das Fouling zu ermöglichen. Somit kann eine höhere Ordnung im Zeitverlauf abgebildet werden. Basierend auf den 100-fältigen globalen Modellen werden die minimalen bzw. maximalen Parameter der jeweiligen Dimension

als Basis genommen und mit einem Faktor von 10 multipliziert bzw. dividiert, um den PR zu erweitern.

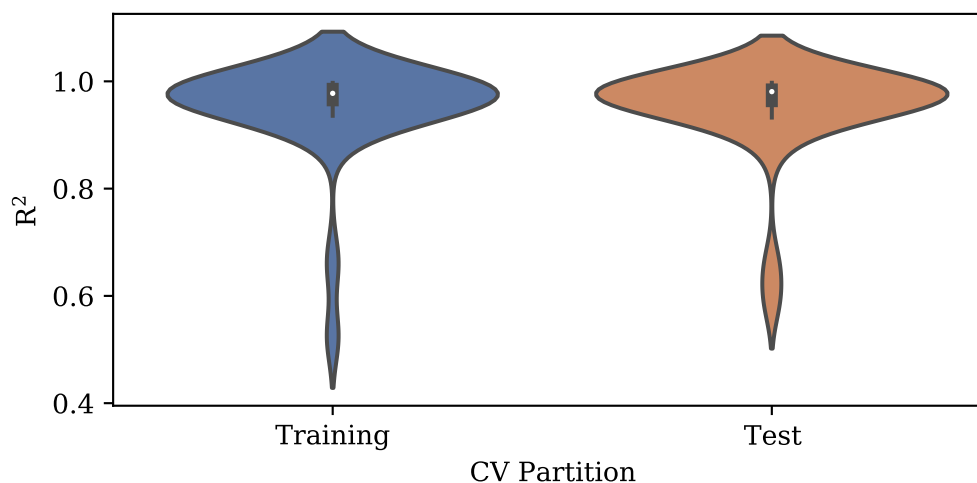


Abbildung 6.6.: Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines zyklusspezifischen Degradationsmodells des Robertverdampfers auf Basis der Trainingszyklen.

Gleichsam, wie in Unterkapitel 6.2.6, wird ein lineares Modell zur Abbildung der Änderung des Zustands Δr gebildet und das in Gleichung 6.31 vorgestellte Minimierungsproblem gelöst. Daraus ergeben sich 33 zyklenspezifische Modelle. Durch die Aufteilung in Test- und Trainingsdaten kann die Abbildungsgüte durch die R^2 Metrik berechnet und in Abbildung 6.6 dargestellt werden. Vergleichbar mit der Güte des globalen Modells in Abbildung 6.5, gibt es unter den zyklenspezifischen Modellen in Abbildung 6.6 Ausreißer, die eine mäßige Abbildungsqualität ausweisen. Einige Beispiele werden nachfolgend genauer diskutiert.

In Abbildung 6.7 wird der Degradationsverlauf auf Basis der kumulierten finiten Differenz des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ dargestellt. Nach etwa dem ersten Drittel der Betriebszeit reduziert sich der Wärmedurchgangswiderstand deutlich. Auffällig ist, dass innerhalb der nächsten 50 Messwerte eine ähnliche Steigung wie zuvor enthalten ist, die im Anschluss für nahezu 200 Messwerte stagniert. Dies ist eine Anomalie, die nicht durch das Modell erklärt werden kann. Ein ähnlicher, aber geringer ausgeprägter Verlauf wird in Abbildung C.2 gezeigt.

Anomalien können im realen Betriebsablauf auftreten und beeinflussen sowohl die Parameterschätzung als auch die Zusammensetzung des Partikelsets. Nachdem die Anomalie aus dem Optimierungsfenster $h_{\text{Opt.}}$ herausgeschoben wird, kann das PFM einen optimierten Partikel $\mathcal{P}_{\text{Opt.}}$ identifizieren, der das System abbildet. Falls die Anomalie außerhalb des Toleranzbereichs ist, der durch den Toleranzvektors $T_{\text{Tol.}}$ aufgespannt wird, schaltet sich das PFM automatisch ab. Erst nach einer erneuten Initialisierung schaltet sich das PFM wieder automatisch ein. Besonders für den Einsatz im industriellen Umfeld ist diese Eigenschaft notwendig, da eine qualitative Bewertung bereits im PFM vorgenommen wird und auf diese Weise der Anwender unterstützt wird.

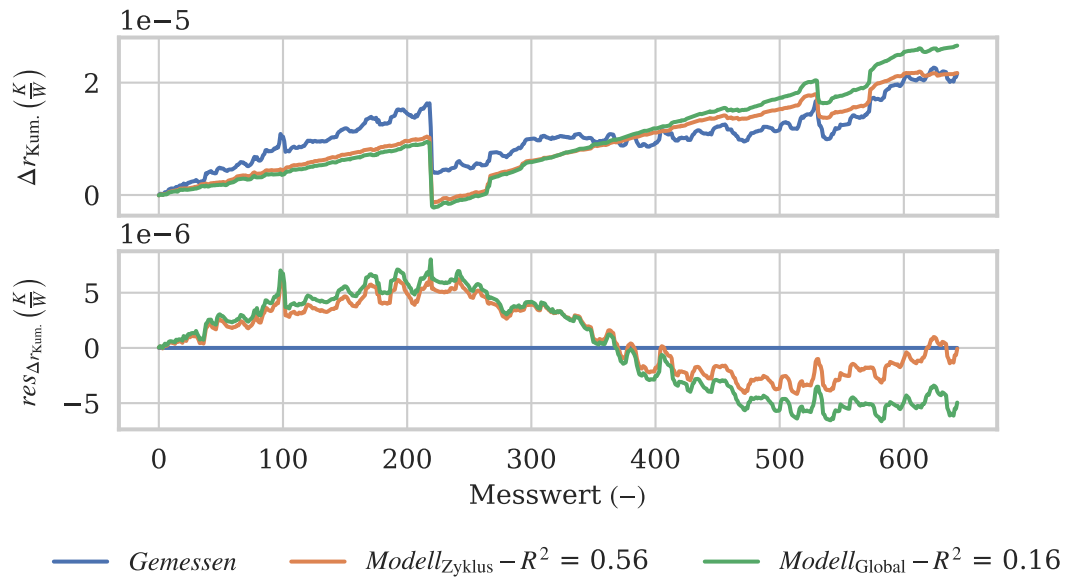


Abbildung 6.7.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Zyklus 22.




Abbildung 6.8.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Zyklus 19.

Abbildung 6.8 zeigt beispielhaft einen Zyklus, in dem die Erweiterung des PR sichtbar ist. Die Anwendung des globalen Modells auf Zyklus 19 bildet die Sprünge im Signal sehr gut ab, allerdings wird der Trend deutlich überschätzt, was zu einer massiven

Fehleinschätzung der RUL führen würde. Durch die Erweiterung des PR kann das langsamere Degradationsverhalten nahezu perfekt durch das zyklenspezifische Modell abgebildet werden.

Ergänzend zu Abbildung 6.8 zeigt Abbildung C.3 einen Zyklus, der durch das globale Modell unterschätzt wird. Durch die zusätzlichen Freiheitsgrade des PR kann das Degradationsverhalten sowie der Trend abgebildet werden.

Zusammenfassend zeigt der wesentliche Anteil der lokalen Modelle eine deutliche Verbesserung der R^2 Metrik mit einem Median von $\xi_{\text{Train.}} = 0.977$ für die Trainings- und $\xi_{\text{Test}} = 0.979$ für die Testdaten. Um den PR des Parametervektors Θ während des Onlinebetriebs des PFM zu beschränken, werden die Erkenntnisse aus dem initialen- und dem globalen Modell sowie den lokalen Modellen analog zu Gleichung 6.32 und 6.33 zusammengefasst. Vor dem Hintergrund, dass die Validierungszyklen die Extremwerte des Betriebs darstellen, werden die obere und untere Grenze des Parameters *intercept* und *sumt* für den Onlinebetrieb mit einem Faktor 1.25 erweitert. Daraus folgt der in Tabelle C.2 durch die Parametergrenzvektoren $\Theta_{\text{U.Grenz.}}$ und $\Theta_{\text{O.Grenz.}}$ aufgespannte PR.

6.2.8. Validierung des Modells

Nachfolgend wird das in Unterkapitel 6.2.6 entwickelte ZRM validiert. Für die Evaluierung wird der PR gemäß der in Unterkapitel 6.2.7 abgeleiteten und in Tabelle C.2 zusammengefassten Parametergrenzvektoren $\Theta_{\text{U.Grenz.}}$ und $\Theta_{\text{O.Grenz.}}$ beschränkt.




Abbildung 6.9.: Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines zyklusspezifischen Degradationsmodells des Robertverdampfers auf Basis der Validierungszyklen.

Die Abbildungsgüte des Modells wird anhand von Abbildung 6.9 dargestellt. Im Vergleich zum globalen Modell in Abbildung 6.5, bilden die zyklenspezifischen Modelle in Abbildung 6.6 die Degradation deutlich besser ab. Innerhalb der Validierung wird für das Training eine R^2 -Metrik von $\xi_{\text{Train.}} = 0.936$ bzw. $\xi_{\text{Test}} = 0.94$ für den Test erreicht. Obgleich die Medianwerte geringer sind, verglichen zur Modellbildungsphase, so ist

das Ergebnis bezogen auf einen industriellen Anwendungsfall und unbekannte Daten sehr gut. Zur Verdeutlichung werden die Schätzungen der Verläufe von $\Delta r_{\text{Kum.}}$ für das globale und zyklenspezifische Modell in den Abbildungen 6.10 und 6.11 dargestellt.

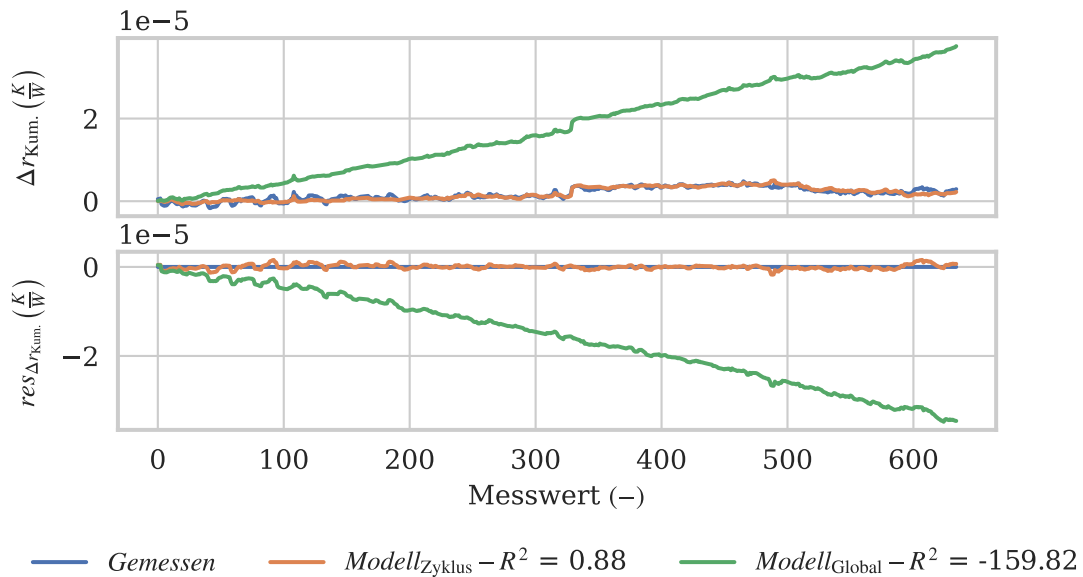


Abbildung 6.10.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Validierungszyklus 18.




Abbildung 6.11.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Validierungszyklus 2.

Abbildung 6.10 zeigt ein sehr langsames Degradationsverhalten. Das globale Modell bildet den Sprung bei Messwert 330 quantitativ richtig ab, jedoch wird der Trend deutlich überschätzt. Durch die Freiheitsgrade innerhalb des PR kann das zyklenspezifische Modell an die aktuellen Gegebenheiten angepasst werden. Bis auf kleinere Abweichungen ist das Residuum gleichmäßig verteilt und enthält wenige Strukturen.

Im Vergleich dazu wird in Abbildung 6.11 der zweite Validierungszyklus vorgestellt. Das globale Modell unterschätzt die Degradation des zweiten Validierungszyklus. Besonders die beschleunigte Degradation am Ende des Zyklus wird durch das globale Modell nicht ausreichend abgebildet, wobei das zyklenspezifische Modell den Trend und die Dynamik sehr gut abbilden kann.

Im Gegensatz zu Abbildung 6.10 fällt auf, dass das Residuum des zyklenspezifischen Modells zwar keine systematische Abweichung besitzt, jedoch deutliche Ausschläge anzeigt. Dieser Aspekt ist besonders für die Onlinesimulation im Hinblick auf die Einstellung des Toleranzvektors T_{Tol} wichtig.

6.3. Zusammenfassung Modellbildung

In Unterkapitel 6.1 wird die grundlegende Beschreibungen von Degradationssignalen vorgestellt. Die dort beschriebenen Funktionen basieren auf einer einfachen Struktur und sind einzig abhängig von der Zeit t . Diese Eigenschaften ermöglicht in Kombination mit einer geringen Parameteranzahl den Einsatz im ETM und eine robuste Modellbildung. Bedingt durch die Struktur der Funktionen werden nicht alle Eigenschaften des Signals abgebildet, sondern der Fokus auf die wesentlichen Anteile des Veränderungsprozesses gelegt.

Aufbauend auf den grundlegenden Gedanken aus Unterkapitel 6.1 wird in Unterkapitel 6.2 die konkrete Modellbildung für das PFM erläutert. Der hohe Aufwand für die Datenvorbereitung verdeutlicht, dass die Modellbildung nur für wichtige Anwendungsfälle sinnvoll ist.

Die partielle Öffnung des PR wird in Folge der nicht vollständig beschreibbaren realen Systeme benötigt. Durch das Öffnen wird die Modellbildung mittels eines ZRM trotz unvollständiger Beschreibung ermöglicht und bildet die Grundlage für die Anwendung des PFM. Diese Eigenschaften sind insbesondere für industrielle Anwendungen wichtig, da sowohl der Modellbildungsaufwand sowie die Instrumentierung beschränkt sind.

Innerhalb der Modellbildung werden somit zwei unterschiedliche Arten der Modellierung vorgestellt, wobei beide Überwachungskonzepte einen adaptiven Charakter während der Betriebszeit aufweisen.

7. Synthetische Evaluation

In diesem Kapitel werden die Ergebnisse der in Kapitel 5 vorgestellten Überwachungskonzepte zur Schätzung der RUL anhand von synthetischen Daten vorgestellt. Unterkapitel 7.1 stellt die Ergebnisse des ETM vor. Der Fokus liegt auf der Abbildung von unterschiedlichen Signalverläufen. Analog wird das PFM in Unterkapitel 7.2 vorgestellt und auf Basis von synthetischen Daten getestet. Im Hinblick auf die Auswertung werden vor allem die Einstellungsmöglichkeiten des PFM untersucht.

7.1. Beurteilung des Einzeltrendmoduls

Nachfolgend werden die Ergebnisse des ETM vorgestellt. Für die Evaluierung werden in Unterkapitel 7.1.1 die Parameter zur Generierung von synthetischen Daten festgelegt und die sich daraus ergebenden Degradationsverläufe präsentiert. Als Metrik für die Bewertung des Modells innerhalb des ETM wird die R^2_{Adj} Metrik festgelegt.

Eine Variante der synthetischen Daten bildet einen sägezahnförmigen Signalverlauf ab. Die Ergebnisse auf diesem sogenannten Sägezahn-Datensatz werden in Unterkapitel 7.1.2 diskutiert. Eine analoge Auswertung basierend auf dem sogenannten Kurven-Datensatz, der in Unterkapitel 7.1.3 vorgestellt wird. Abschließend werden die Erkenntnisse des ETM auf Basis der synthetischen Daten anhand von Unterkapitel 7.1.4 zusammengeführt. Alle Ergebnisse werden anhand von standardisierten Abbildungen ausgewertet. Eine Übersicht der unterschiedlichen Darstellungen sowie eine detaillierte Einführung kann in Unterkapitel 5.1.5 eingesehen werden.

7.1.1. Generierung synthetischer Daten - Einzeltrendmodul

Für die Entwicklung und Validierung des ETM werden zwei Datensätze genutzt, die unterschiedliche Eigenschaften abbilden und nachfolgend vorgestellt werden.

Sägezahn-Datensatz

Das wesentliche Merkmal des ETM ist die Detektion von Änderungen im Signal sowie dessen Schätzung. Im industriellen Kontext liegen Änderungen des Betriebspunktes im Wesentlichen als Sprung vor. Die Degradationsverläufe entwickeln sich häufig sukzessive, wobei nach erfolgter Instandhaltung ebenfalls Sprünge in den Signalen entstehen. Modellhaft kann der einfachste Degradationsverlauf $f(I dx)$ als Funktion des Indexvektors $I dx$ folglich als linearer Zusammenhang ausgedrückt werden. Die Erstellung des Datensatzes erfolgt anhand von Gleichung 7.1. Der Index $i dx$ ist ein Element einer kontinuierlich ansteigenden Zahlenfolge aus natürlichen Zahlen im Vektor $I dx \in \mathbb{N} \{1, \max(I dx)\}$. Die Zahlenfolge hat einen äquidistanten Abstand von 1 und den Startwert $i dx_1 = 1$.

$$f(I dx) = c_{\text{ETM1}} \frac{I dx}{\max(I dx)} + c_{\text{ETM2}} \quad \text{mit } j \in I dx \quad (7.1)$$

Anhand von Gleichung 7.1 und den drei Parametersätzen in Tabelle 7.1 werden die Basiszyklen 1, 2 und 3 erzeugt. Alle drei Basiszyklen werden sequentiell miteinander

Tabelle 7.1.: Tabellarische Auflistung der Eigenschaften eines sägezahnförmigen synthetischen Signals für die Evaluierung durch das Einzeltrendmodul.

Zyklus	Länge	Faktor	Versatz
		c_{ETM1}	c_{ETM2}
1	450	20	2
2	300	30	2
3	150	40	2

verbunden und ergeben das Basissignal $S_{Bas.}$. Aus dem Basissignal $S_{Bas.}$ wird durch Überlagerung von normalverteiltem Rauschen das zu überwachende Signal S anhand von Gleichung 7.2 entwickelt.

$$S = S_{Bas.} + \mathcal{n}(\mu_S = 0, \sigma_S = \max(|S_{Bas.}|) w_\kappa) \quad (7.2)$$

Der Mittelwert μ_S des Rauschens ist 0 und besitzt eine Standardabweichung σ_S , die auf dem maximalen Betrag des Signals $S_{Bas.}$ multipliziert mit einem Rauschfaktor w_κ basiert. Um schwaches bzw. starkes Rauschen abzubilden, wird das Rauschgewicht w_κ mit 0.01 sowie 0.03 festgelegt. Für die Schätzung der RUL wird mindestens ein Grenzwert ω_S benötigt. Um eine Variation abbilden zu können und dennoch S bestmöglich zu nutzen, wird der Grenzwert ω_S als der maximale Wert jedes Zyklus ohne Rauschen definiert. Das sich daraus ergebende Signale S sowie der dazugehörige Grenzwert ω_S werden in Abbildungen 7.1 sowie 7.2 dargestellt.




Abbildung 7.1.: Grafische Darstellung eines Sägezahn-Signals S mit drei unterschiedlich ausgeprägten Steigungen und Rauschfaktor 0.01.

Zur Schätzung der RUL durch das ETM werden die vergangenen Betriebsdaten benötigt. Um die Arbeitsweise des ETM im ersten Zyklus abbilden zu können, ist es notwendig




Abbildung 7.2.: Grafische Darstellung eines Sägezahn-Signals S mit drei unterschiedlich ausgeprägten Steigungen und Rauschfaktor 0.03.

vor dem ersten Zyklus bereits Daten zur Verfügung zu haben. Um möglichst realistische Bedingungen zu schaffen, wird der erste Zyklus von Signal S als Duplikat vor dem Anfang der Datenreihe angefügt.

Kurven-Datensatz

Die Detektion des Beginns eines Degradationsphänomens ist aufgrund der kontinuierlichen Entwicklung sehr anspruchsvoll. In praktischen Anwendungen kommt hinzu, dass die Annahme eines linearen Degradationsmechanismus nicht gegeben ist. Zur Bewertung

Tabelle 7.2.: Tabellarische Auflistung der Eigenschaften heterogener synthetischer Signale für die Evaluierung durch das Einzeltrendmodul.

Eigenschaft	Einstellung
Zykluslänge $n_{\text{Mess.}}$	600
CP Position $i_{\text{Proz.}}$	0%/ 20%
Rauschfaktor w_{κ}	0.005/ 0.015
Rauschtyp	additiv
Funktion	linear/ quadratisch/ exponentiell

des ETM im Hinblick auf diese Eigenschaften werden Degradationszyklen auf Basis des in Unterkapitel 5.1.4 vorgestellten Datengenerators erzeugt. Für die Generierung der Daten werden die Einstellungen in Tabelle 7.2 festgelegt.

Analog zum Sägezahn-Datensatz werden die einzelnen gleichlangen Zyklen zu einem Signal S zusammengefügt und exemplarisch in Abbildungen 7.3 dargestellt. Die Reihenfolge der abgebildeten Funktion wird als linear, quadratisch und exponentiell definiert. Die Berechnung erfolgt anhand der in Unterkapitel 5.1.4 vorgestellten Gleichungen. Für die Generierung der Daten werden die prozentuale Position des CP im Zyklus zwischen $i_{\text{Proz.}} = 0\%$ und $i_{\text{Proz.}} = 20\%$ der Zykluslänge sowie der Rauschfaktor von $w_{\kappa} = 0.005$




Abbildung 7.3.: Grafische Darstellung eines linearen, quadratischen und exponentiellen Signals S mit Rauschfaktor $w_\kappa = 0.015$ und einem Wechsellpunkt bei $i_{\text{Proz.}} = 0\%$.

und $w_\kappa = 0.015$ variiert.

Für die Evaluierung wird analog zur Verfahrensweise auf Grundlage des Sägezahn-Datensatzes der erste Zyklus als Duplikat an den Anfang der Datenreihe angefügt. Gleichsam zu Abbildungen 7.3 stellt Abbildung D.1 das Signal S sowie den jeweiligen Grenzwert ω_S grafisch dar, der auf Basis des maximalen Wertes des jeweiligen Zyklus bestimmt wird.

7.1.2. Ergebnisse des Sägezahn-Datensatzes

Die Leistungsfähigkeit des ETM wird anhand des Sägezahn-Datensatzes evaluiert und die Ergebnisse vorgestellt. Dazu werden die folgenden Einstellungsmöglichkeiten des ETM variiert.

- Funktion: alle/ linear
- Rauschen: schwach/ stark
- Monotonie: unbekannt/ steigend

Aus den Einstellungsmöglichkeiten leiten sich unterschiedliche Kombinationen ab. Zunächst wird der allgemeinste Fall mit allen möglichen Funktionen, starkem Rauschen sowie nicht bekannter Monotonie diskutiert. Im Anschluss wird die Monotonie auf steigende Verläufe eingeschränkt. In einer weiteren Kombination werden die möglichen Funktionen auf lineare Verläufe begrenzt. Abschließend wird zum Vergleich die letzte Kombination mit einem geringeren Rauschanteil ausgewertet.

Sägezahn-Datensatz - Funktion: alle, Rauschen: stark, Monotonie: unbekannt

In diesem Abschnitt werden die Ergebnisse der RUL Schätzung mittels des ETM anhand von Abbildung 7.4 vorgestellt.

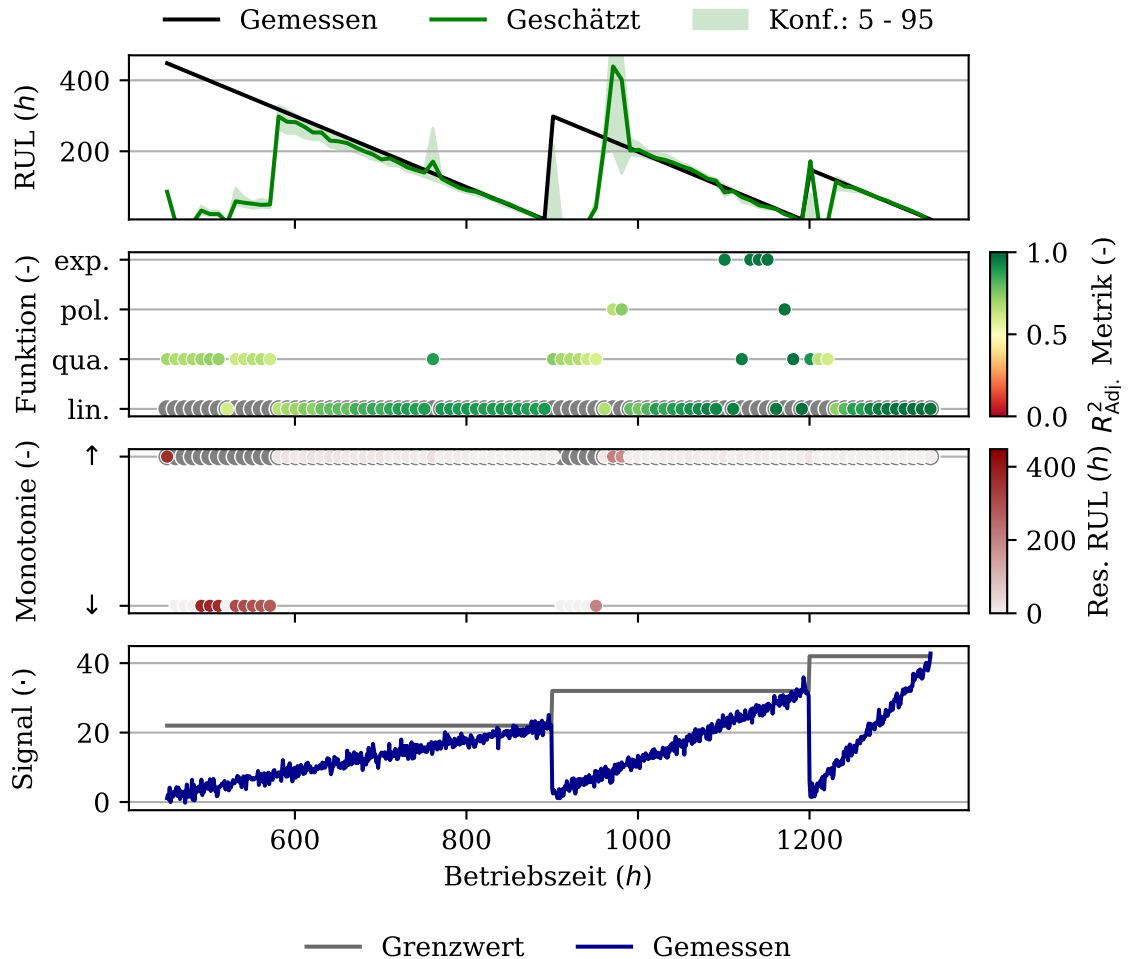


Abbildung 7.4.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekannt Monotonie.

Die oberste Darstellung von Abbildung 7.4 stellt die RUL und deren Schätzung gegenüber. Auffällig ist, dass das ETM zu Beginn eines Zyklus geringe RUL mit $t_{\text{RUL}} < 100h$ ausweist, bevor das Residuum der RUL Schätzung einen Wert von $res_{\text{RUL}} = 20h$ ausweist. Über die Zeit wird das Residuum geringer, wobei Abweichungen wie zur Betriebszeit $t = 761h$ existieren. Der Vergleich der drei Zyklen zeigt, dass die Anfangszeiträume, in denen die Schätzung stark von der RUL abweicht, für den ersten, zweiten und dritten Zyklus mit 130, 90 und 30 Messwerten kleiner werden. Besonders zu Beginn der Zyklen gibt es Berechnungen, die nur Teile des Konfidenzintervalls abbilden, zum Beispiel zur Betriebszeit $t = 901h$ oder $t = 1201h$. Durch die Berechnung des Konfidenzintervalls mittels BS folgen unterschiedliche Abbildungen in Abhängigkeit der verwendeten Messwerte. Besonders die geschätzten Signale mit langsamer Entwicklung erreichen den Grenzwert ω_S nicht innerhalb des maximalen Schätzhorizonts $h_{\text{Präd.,max}}$.

Aus diesem Grund kann die RUL nur für die Varianten berechnet werden, die den Grenzwert ω_S erreichen, alle anderen werden auf vordefinierte Werte gesetzt. Die zweite Darstellung von Abbildung 7.4 verdeutlicht, dass besonders zu Beginn der Degradation nicht die gegebene lineare Funktion identifiziert wird, sondern vielfach eine quadratische oder vereinzelt polynomische bzw. exponentielle Funktion zur Modellbildung ausgewählt wird. Um die Betriebszeit $t = 761h$ ist ein Wechsel zwischen der linearen und der quadratischen Funktion zu sehen. Die Werte der Metriken für die Betriebszeiten $t = 751h, 761h, 771h$ sind mit $R^2_{Adj.} = 0.889, 0.889, 0.904$ sehr ähnlich. Basierend auf der $R^2_{Adj.}$ Metrik beeinflusst die Fehlklassifizierung der Funktion die Modellgüte nicht, wobei die RUL in der ersten Darstellung dennoch verändert wird. Die vorletzte Darstellung von Abbildung 7.4 erweitert die bisherigen Informationen um die geschätzte Monotonie \hat{mon} . In diesem Betriebsfall ist die Monotonie mon für das ETM nicht bekannt. Synchron mit den geringen $R^2_{Adj.}$ Metrikwerten erfolgt in diesen Zeitbereichen häufig die falsche Klassifizierung der Monotonie. Daraus ergeben sich große Residuen während der Anfangszeit der Degradationszyklen mit bis zu $res_{RUL} = 443h$. Abschließend wird das gemessene Signal S in der untersten Darstellung von Abbildung 7.4 über die Betriebszeit aufgetragen. Die drei Zyklen weisen eine unterschiedliche Steigung auf und werden mit dem jeweiligen Grenzwert ω_S kombiniert. Die Darstellung ermöglicht das einfache Referenzieren innerhalb des gesamten Signals S sowie die Verknüpfung mit den anderen Darstellungen in Abbildung 7.4.




Abbildung 7.5.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 711h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.

Eine erfolgreiche Schätzung wird exemplarisch anhand des ersten Zyklus vorgestellt. Abbildung 7.5 zeigt dazu die Schätzung des Signals \hat{S} zur Betriebszeit von $t = 711h$. Aufgrund der Bewertung von 300 historischen Werten ist neben dem aktuellen auch der vergangene Zyklus in der Trainingsdatenbasis enthalten. Das starke überlagerte Rauschen prägt den Verlauf, wobei der CP bei Messwert $i = -261$ die zwei Zyklen trennt und optisch gut zu erkennen ist. Der CP wird korrekt identifiziert, allerdings werden rauschbedingt auch weitere potenzielle CP im Signal S vorgeschlagen, die unregelmäßige

Abstände zueinander aufweisen. Aus den potenziellen CP wird der richtige für die Modellierung ausgewählt. Die Gegenüberstellung des Signals S und dessen Schätzung \hat{S} zeigt eine hohe Modellgüte durch den Metrikwert von $R^2_{\text{Adj.}} = 0.87$. Rauschbedingt weicht die RUL Schätzung mit $res_{\text{RUL}} = 8h$ von der RUL ab, wobei der Erwartungswert des Signals S sehr gut wiedergegeben wird. Die Qualität der Schätzung geht ebenso aus Abbildung 7.6 hervor.

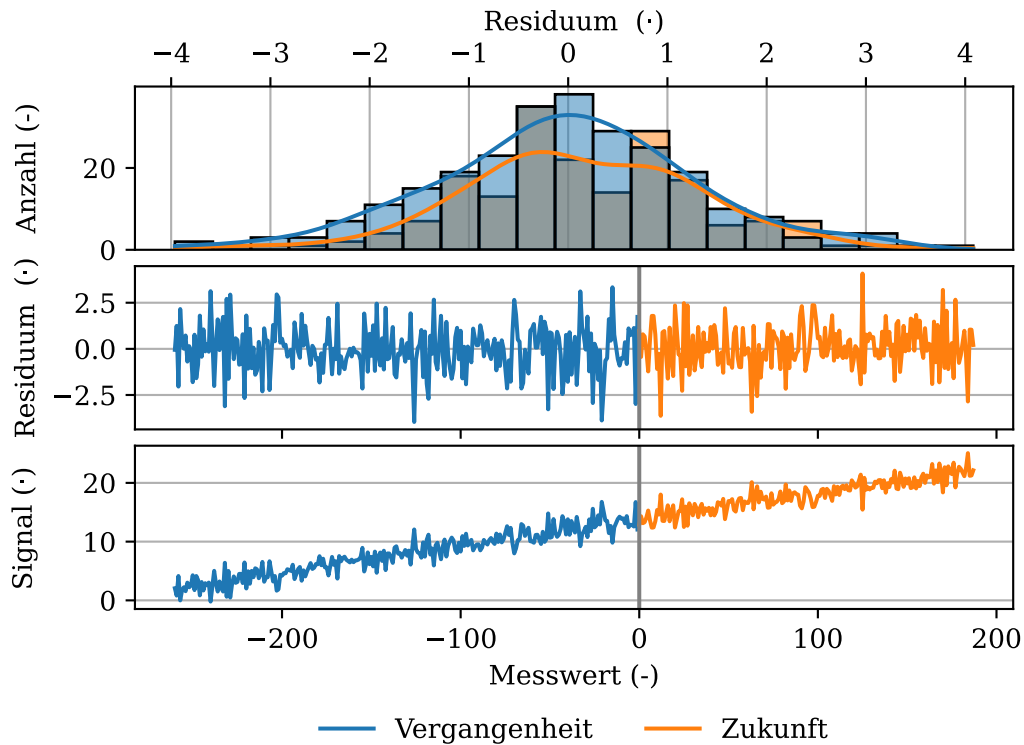


Abbildung 7.6.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 711h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekanntem Monotonie.

In der untersten Darstellung wird das für die Modellbildung genutzte vergangene Signal S sowie dessen zukünftiger Verlauf $S_{\text{Zuk.}}$ dargestellt. Der zur Verfügung stehende Trainingsdatensatz wird an der Position des CP aufgespalten und nur der zeitlich letzte Teil für die Modellbildung verwendet. Das sich aus der Schätzung ergebende vergangene Signalresiduum Res_S besitzt einen um den Wert 0 zentrierten Verlauf, in dem im Wesentlichen der Rauschanteil erhalten ist. Bezüglich des zukünftigen Signalresiduums $Res_{S,\text{Zuk.}}$ stimmt die Schätzung zum Großteil ebenfalls überein, wobei eine geringe Abweichung des gemittelten Signalresiduums in Richtung negativer Werte zu erkennen ist. Die Mittelwertverschiebung wird durch das Histogramm in der ersten Darstellung untermauert. Die gemessene sowie die geschätzte Verteilung ähneln sich durch eine vergleichbare Standardabweichung und bilden das Rauschen ab. Die vorherige Vermutung einer Abweichung des gemittelten zukünftigen Signalresiduums $Res_{S,\text{Zuk.}}$ wird bestätigt und die geringfügige Überschätzung der RUL in Abbildung 7.6 mit der Unterschätzung des Signals S belegt.

Aus Abbildung 7.4 geht hervor, dass besonders der Wechsel zwischen zwei Zyklen für

die Berechnung der RUL kritisch sein kann. Daher wird diese Sequenz für den Wechsel zwischen dem nullten und ersten Zyklus im Detail untersucht und der zeitliche Verlauf der Schätzungen chronologisch aufgearbeitet.

Abbildung D.2 zeigt die Schätzung zu Beginn des ersten Zyklus. Von den 300 historischen Messwerten entfällt lediglich einer auf den ersten Zyklus. Aufgrund des einen Messwerts kann der CP nicht identifiziert werden und für die Modellbildung wird der CP bei $i = 0$ gewählt. Der einzige Messwert des ersten Zyklus beeinflusst die Modellbildung und anstelle einer linearen wird eine quadratische Funktion verwendet. Trotz des quadratischen Verhaltens kann der definierte Grenzwert ω_S erreicht werden.




Abbildung 7.7.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 461h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.

Die Schätzung zur Betriebszeit $t = 461h$ wird in Abbildung 7.7 vorgestellt. Der Vergleich mit Abbildung D.2 zeigt die Ähnlichkeit auf, wobei bedingt durch die größere Anzahl an Messwerten im ersten Zyklus die quadratische Funktion stärker ausgeprägt ist. Eine Ursache für die Abbildung dieses Verhaltens ist der Freiheitsgrad der unbekannt Monotonie. Der wesentliche Grund ist jedoch die Kombination der geringen Anzahl an Messwerten im ersten Zyklus mit einem starken Rauschanteil, der den linearen Verlauf maskiert.

Eine positive Monotonie wird erstmals in Abbildung D.3 identifiziert. Anhand dieser Abbildung wird deutlich, dass der steigende Trend innerhalb der gemessenen Daten des ersten Zyklus berücksichtigt wird. Da es eine quadratische Funktion ist, entspricht die Monotonie, nach dem Durchschreiten des Tiefpunktes des geschätzten Signals \hat{S} der steigenden Monotonie des Signals S . Für die Schätzung wird nicht der korrekte CP genutzt, da der Trend durch das Rauschen maskiert wird. Anhand von Gleichung 4.29 und 4.30 wird deutlich, dass mit steigender Anzahl an Messwerten im ersten Zyklus das Rauschen weniger ins Gewicht fällt. Im Falle eines korrekt gewählten Modells nähert sich der R^2_{Adj} Metrikwert somit sukzessive einem Grenzwert an, der lediglich durch die nicht modellierten Abweichungen des Rauschens limitiert wird. Folglich wird für die Schätzung nicht der CP verwendet, sondern ein geschätzter CP, der durch die

Abbildung von mehr Messwerten eine bessere R^2_{Adj} Metrik aufweist. Die Nutzung von wenigen Messwerten für die Modellbildung wird auch anhand des Konfidenzintervalls sichtbar, das sich im Bereich des zukünftigen geschätzten Signals deutlich aufweitet. Dies verdeutlicht, dass die Auswahl der einzelnen Messwerte für die Modellbildung zu einer starken Variation der Schätzung führt. Somit ist dies ebenfalls ein Indikator für die erhöhte Unsicherheit des Modells zu diesem Zeitpunkt.

Mittels Abbildung D.4 wird die zuvor erfolgte Argumentation gestützt, dass mit einer größeren Anzahl von Messwerten in dem zu schätzenden Zyklus, sowohl die Wahl des CP, als auch die Schätzung automatisch korrigiert werden. Dies ermöglicht die Identifikation der Monotonie mon und führt zu einer RUL Schätzung mit $res_{\text{RUL}} < 20h$ Abweichung. Abbildung D.4 zeigt, dass ab diesem Zeitpunkt eine Schätzung generell möglich ist. Das Modell basiert auf $n_{\text{Mess.,Train.}} = 130$ Messwerten, das im Kontext mit der geringen Steigung des Signals S anfällig für Störungen ist.

Die Sensitivität der Schätzung gegenüber Störungen wird anhand von Abbildung D.5 dargestellt. Der CP für die Schätzung wird qualitativ richtig gewählt und bindet den Großteil der Messwerte des ersten Zyklus in die Modellierung ein. Trotz der größeren Anzahl an Messwerten im ersten Zyklus im Vergleich zu Abbildung D.4, führt das starke Rauschen zur Abbildung des Degradationsverhaltens mittels einer quadratischen Funktion. Die Ursache kann anhand von Abbildung D.6 nachvollzogen werden. Das Histogramm in der ersten Darstellung zeigt für die gemessenen Daten eine Abweichung der Normalverteilung in Form einer Schiefe auf. Folglich versucht das ETM ein möglichst homogen verteiltes Residuum Res_S zu erhalten und wählt daher eine quadratische Funktion zur Modellbildung aus. Demzufolge weicht das geschätzte Signal $S_{\text{Zuk.}}^{\hat{}}$ in Abbildung D.5 von der Trajektorie des Signals $S_{\text{Zuk.}}$ ab und das Verhalten des Zyklus wird nur anteilig wiedergegeben. Die größere Unsicherheit der Schätzung wird durch die Vergrößerung des Konfidenzintervalls berücksichtigt und ermöglicht die quantitative Bewertung der Ergebnisse. Zwischen der Betriebszeit $t = 751h$ und $t = 761h$ steigt demnach die Differenz zwischen dem oberen und unteren Konfidenzwert von $t_{\text{Konf.}} = 21h$ auf $t_{\text{Konf.}} = 147h$ an.

Sägezahn-Datensatz - Funktion: alle, Rauschen: stark, Monotonie: steigend

Die Kenntnis über das Verhalten des Signals S in Bezug auf die Monotonie ist eine Zusatzinformation, die für die Schätzung genutzt werden kann.




Abbildung 7.8.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.

Abbildung 7.8 zeigt die Ergebnisse der RUL Schätzung mit der Beschränkung auf monoton steigende Trends. Im Vergleich zu Abbildung 7.4 wird die Schätzqualität am Ende der Zyklen durch die Einschränkung der Monotonie nur unwesentlich verändert. Basierend auf den vorherigen Erkenntnissen genügt eine ausreichende Menge von Messdaten eines Zyklus zur effektiven Beschreibung des Verhaltens. Im Gegensatz wirkt sich die Beschränkung der Monotonie insbesondere zu Beginn eines neuen Zyklus aus. Im Vergleich zu Abbildung 7.4 wird deutlich, dass die RUL Schätzung während der Anfangsbereiche der Zyklen überschätzt wird. Konkret sind ohne Einschränkung der Monotonie im Wesentlichen die Abschnitte betroffen, in denen keine RUL Schätzung möglich ist und vordefinierte Werte ausgegeben werden. Die Ausgabe eines überschätzten RUL Wertes mit geeignetem Konfidenzintervall ist demzufolge ein Mehrwert im Vergleich zu keinem Ergebnis.

Das Erzwingen der Monotonie beeinflusst insbesondere in den Anfangszeiträumen der Zyklen die Metrik. Exemplarisch ist zur Betriebszeit $t = 461h$ der Metrikwert $R^2_{Adj.} = 0.3$. Im Vergleich dazu zeigt Abbildung 7.4 Metrikwerte von $R^2_{Adj.} > 0.5$. Die Einschränkung der Monotonie führt in der frühen Degradationsphase zur vermeintlich schlechteren Abbildungen des Signals S . Die $R^2_{Adj.}$ Metrik unterstützt die Interpretation der Ergebnisse, die durch das Beschränken auf Basis von *a priori* Wissen verbessert wird. Im konkreten Fall bedeutet dies, dass die Abbildung des Signals S ohne Beschränkung der Monotonie zwar einen höheren $R^2_{Adj.}$ Metrikwert erreicht, jedoch die für die Schätzung notwendige Monotonie nicht abbildet. Die Einschränkung führt folglich dazu, dass diese Schätzung in den herausfordernden Übergangsbereichen durch kleine $R^2_{Adj.}$ Metrikwerte besser identifiziert und die RUL Schätzung somit besser interpretiert werden kann.

Die Bewertung der Schätzqualität anhand des Signalresiduums in der zweiten Darstellung von unten erfordert eine Betrachtung des Betriebszustands des ETM. Abbildung 7.4 weist zu den Zeitpunkten, an denen vordefinierte Werte ausgegeben werden, ein Residuum von $res_{RUL} = 0$ aus. Zu diesen Zeitpunkten ist keine Schätzung möglich. Im Gegensatz dazu zeigt Abbildung 7.8 in den gleichen Bereichen hohe Residuen an. Dies ist durch die Tatsache begründet, dass eine Schätzung erfolgreich durchgeführt wird, jedoch stark von der RUL abweicht. Mit Beschränkung der Monotonie kann das ETM zu jedem Zeitpunkt eine Schätzung durchführen. Dies ist eine wesentliche Verbesserung durch die Einschränkung der Monotonie.




Abbildung 7.9.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.

Anhand von Abbildung 7.9 wird die Auswirkung des Erzwingens der Monotonie anhand der Startphase des ersten Zyklus aufgezeigt. Die Limitierung der Monotonie *mon* erzwingt einen Trend, der den Grenzwert ω_S erreicht. Der direkte Vergleich zu Abbildung D.7 verdeutlicht, dass das Erreichen des Grenzwerts ω_S nur durch die Einschränkung der Monotonie ermöglicht wird und somit zu einer Verbesserung der Schätzung führt. Der CP wird identifiziert, jedoch nicht für die Modellbildung verwendet.

Die Begründung für diese Wahl des CP ist die Maximierung R^2_{Adj} Metrik. Bezogen auf das Signalresiduum Res_S werden die Details in Abbildung D.8 dargestellt. Der Zeitverlauf des Residuums zeigt, dass das vergangene Signalresiduum Res_S deutliche Strukturen enthält. Im Hinblick auf das zukünftige Signalresiduum $Res_{S,Zuk.}$ ist zunächst eine Phase mit einem negativen-, gefolgt von einem nichtlinear ansteigenden positiven Residuum, zu erkennen. Der Vergleich der Residuen im Histogramm verdeutlicht, dass das vergangene Signalresiduum Res_S eine sehr geringe Verschiebung des Mittelwerts zu positiven Werten besitzt. Bedingt durch den Optimierungsalgorithmus des ETM werden die Abweichungen minimiert und nach Möglichkeit um 0 zentriert. Demgegenüber ist das zukünftige Signalresiduum $Res_{S,Zuk.}$ deutlich ausgeprägter und stark zu positiven Residuen verschoben. Dies unterstreicht die inkorrekte Abbildung der zur Verfügung stehenden Daten im Hinblick auf den gewählten CP sowie die dazu verwendete Funktion. Der Vorteil der Monotoniebeschränkung besteht in der Reduzierung der R^2_{Adj} Metrik, die eine Interpretation des Ergebnisses verbessert.




Abbildung 7.10.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1061h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.

Bedingt durch eine ausreichend große Anzahl an Messdaten werden die Enden eines Zyklus sehr gut durch das ETM abgebildet. Exemplarisch wird dies anhand von Abbildung 7.10 verdeutlicht. Abbildung 7.10 zeigt den Sprung innerhalb des Signals S bei Messwert -161 . Innerhalb der bekannten Historie von 300 Messwerten werden neben dem CP auch weitere geschätzte CP angezeigt. Für die Modellbildung wird ein geeigneter CP sowie eine lineare Funktion ausgewählt, die das Signal S sehr gut abbildet. Auf dieser Grundlage überschätzt das ETM die RUL mit $res_{RUL} = 12h$.

Sägezahn-Datensatz - Funktion: linear, Rauschen: stark, Monotonie: steigend

Eine weitere Einschränkungsmöglichkeit ist die Limitierung der Funktionen. In einigen technischen Anwendungen ist *a priori* Wissen der Degradationsfunktion vorhanden, das zur Verbesserung der Schätzung genutzt werden kann. Abbildung 7.11 zeigt die Ergebnisse des ETM auf Basis einer linearen Funktion und steigender Monotonie.




Abbildung 7.11.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.

Im Vergleich zu Abbildung 7.4 und 7.8 ist in der obersten Darstellung in Abbildung 7.11 zu sehen, dass deutlich früher eine bessere Schätzung der RUL möglich ist. Durch die Festlegung der Monotonie und der Funktion werden die Freiheitsgrade reduziert. Die Aufgabe besteht in der geeigneten Parametrierung der gewählten Funktion sowie der richtigen Wahl des CP. Durch weniger Freiheitsgrade kann die geringe Schätzqualität direkt nach einem Zykluswechsel verkürzt und die RUL Schätzung somit verbessert werden.

Die zweite Darstellung in Abbildung 7.11 verdeutlicht im Vergleich zu Abbildung 7.8, dass die R^2_{Adj} Metrikwerte zu Beginn eines Zyklus noch kleiner ausfallen. Exemplarisch liegt zur Betriebszeit $t = 501h$ mit $R^2_{Adj} = -0.02$ sogar ein negativer Wert für die

Metrik vor. Analog zu der Einschränkung der Monotonie führt die Festlegung der Funktion zu aussagekräftigeren Werten der R^2_{Adj} Metrik, die eine bessere Abgrenzung von validen Schätzergebnissen ermöglicht.

Die Güte der Schätzung geht aus den Residuen der RUL res_{RUL} in der dritten Darstellung hervor. Verglichen mit den RUL Residuen in Abbildung 7.8 werden besonders die frühen Schätzungen eines Zyklus im Hinblick auf die Genauigkeit der Schätzung verbessert. Eine vereinzelte Ausnahme bilden frühe Messwerte eines Zyklus, wie zum Beispiel zur Betriebszeit $t = 481h$ oder $t = 931h$, an denen der definierte Grenzwert ω_S nicht durch die Schätzung bzw. das Konfidenzintervall erreicht wird.




Abbildung 7.12.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 921h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.

Abbildung 7.12 zeigt, dass innerhalb des neuen Zyklus wenige Messwerte vorhanden sind, die zusätzlich mit starkem Rauschen überlagert werden. Durch die Beschränkung auf eine lineare Funktion sowie eine steigende Monotonie kann keine bessere Funktion gefunden werden, die die letzten gemessenen Punkte mitberücksichtigt. Die Konsequenz ist, dass Messwerte des vorherigen Zyklus zur Modellbildung genutzt werden und die Steigung der Schätzung somit flacher ausfällt. Der festgelegte Grenzwert ω_S wird folglich erst zu einem späteren Zeitpunkt erreicht und die RUL mit einem Residuum von $res_{\text{RUL}} = 1017h$ überschätzt.

In der Zeit, bis eine kritische Menge an Messwerten im neuen Zyklus erreicht wird, folgt eine stetige Zunahme des Einflusses der neuen Messwerte. Im weiteren Verlauf wird die Steigung bis an die Grenze des Monotoniekriteriums reduziert, sodass im Extremfall der Grenzwert ω_S durch das Signal \hat{S} nicht mehr innerhalb des maximalen Schätzhorizonts $h_{\text{Präd.,max}}$ erreicht werden kann.

Abbildung D.9 zeigt die erste valide Schätzung nach dem Zykluswechsel. Der gewählte CP wird durch das ETM richtig bestimmt und die $n_{\text{Mess.,Train.}} = 41$ verbleibenden stark verrauschten Messwerte werden zur Parametrierung der linearen Funktion genutzt. Bei einem Schätzhorizont von $h_{\text{Präd.}} = 259h$ wird die RUL mit $res_{\text{RUL}} = -35h$ unterschätzt. Die Unsicherheit der Schätzung wird durch die Konfidenzintervallbreite

von $t_{\text{Konf.}} = 104h$ sowie den Metrikwert von $R^2_{\text{Adj.}} = 0.12$ wirksam ausgedrückt.




Abbildung 7.13.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 511h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.

Abbildung 7.13 verdeutlicht die Herausforderung einer frühen Schätzung, da die für das Training zur Verfügung stehenden Messwerte von dem vorherigen Zyklus dominiert werden. Trotz der großen Anzahl an nicht verwendbaren Messwerten wird der CP korrekt identifiziert. Basierend auf $n_{\text{Mess.,Train.}} = 57$ Messwerten erfolgt trotz des starken Rauschens eine qualitativ richtige Schätzung des Signals \hat{S} , wobei die RUL durch das ETM mit $res_{\text{RUL}} = 146h$ überschätzt wird. Besonders vor dem Hintergrund der geringen Messdatenanzahl ist das Überschätzen der RUL akzeptabel, da die Unsicherheit durch das Konfidenzintervall, von $t_{\text{Konf. min}} = 274h$ bis $t_{\text{Konf. max}} = 846h$ ausgedrückt wird und den Signalverlauf S einschließt. Die Unsicherheiten der Schätzung werden somit anhand des Konfidenzintervalls transportiert und stehen als Grundlage für eine Handlungsempfehlung zur Verfügung.

Sägezahn-Datensatz - Funktion: linear, Rauschen: schwach, Monotonie: steigend

Ein starker Rauschanteil beeinflusst die Wahl des CP sowie die Wahl der Funktion negativ. Zur Bewertung des Rauscheinflusses werden in Abbildung 7.14 die Ergebnisse der RUL auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen vorgestellt.

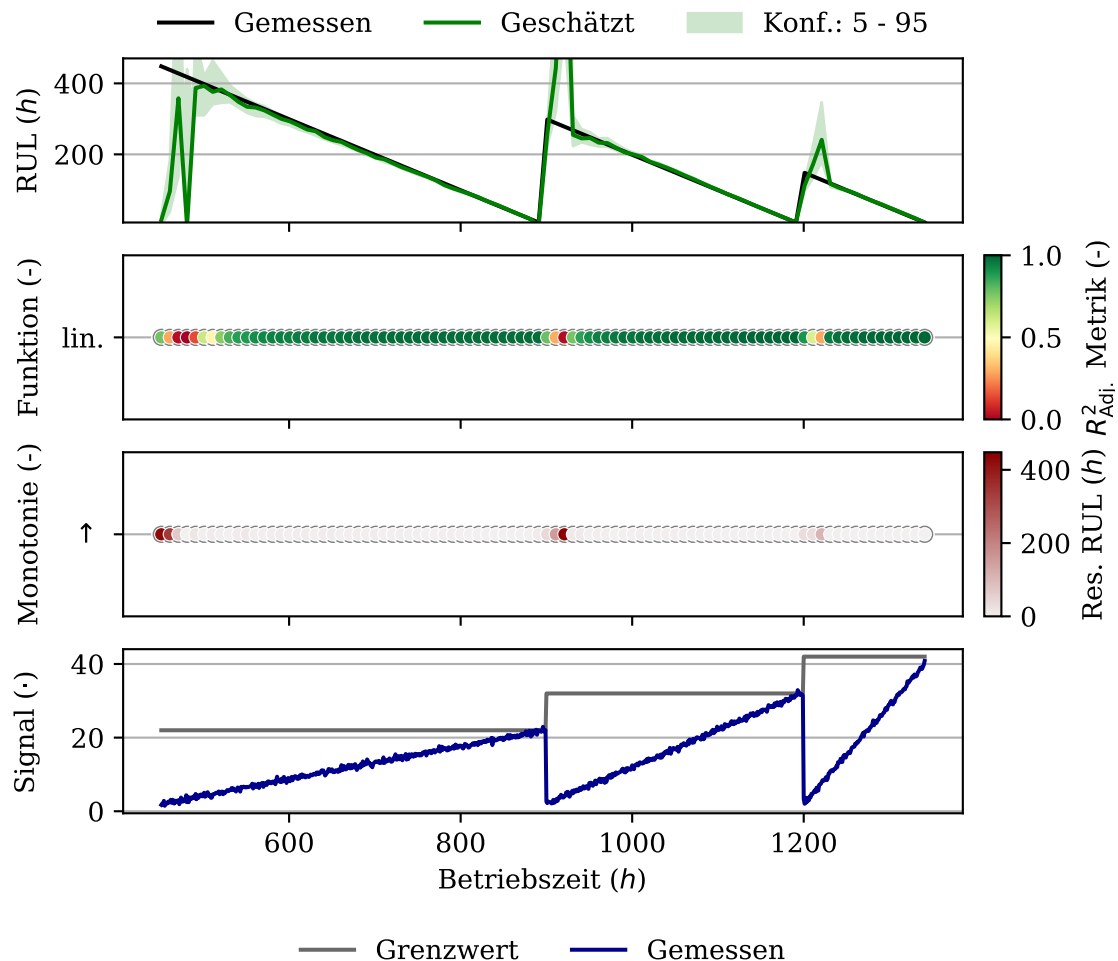


Abbildung 7.14.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.

Abbildung 7.14 zeigt im Vergleich zu Abbildung 7.11 ein schnelleres Konvergieren der RUL Schätzung gegen die RUL. Das schwache Rauschen des Signals S spiegelt sich auch in dem Konfidenzintervall wider, das geringer im Vergleich zum starkem Rauschen ausfällt. Bedingt durch die geringere Varianz des Rauschens werden weniger Modellvariationen bei der Abbildung der Messwerte ermöglicht. Beim Wechsel zwischen zwei Zyklen erreicht die RUL Schätzung nur noch an einer Stelle den definierten Grenzwert ω_S nicht innerhalb des maximal vorgegebenen Vorhersagefensters $h_{\text{Präd.}}$.

Der geringere Rauschanteil beeinflusst die $R^2_{\text{Adj.}}$ Metrik als Maß der Modellgüte positiv. Durch die frühere Abbildung des Signalverlaufs S werden höhere $R^2_{\text{Adj.}}$ Metrikkwerte im Vergleich zu Abbildung 7.11 erreicht. Beispielsweise wird für den ersten Zyklus bei den

Betriebszeiten $t = 521h$ bzw. $t = 561h$ eine Metrik von $R^2_{Adj.} = 0.74$ bzw. $R^2_{Adj.} = 0.92$ erreicht, die über den zeitlichen Verlauf weiter ansteigt. Somit werden größere Anteile des Signals S abgebildet, wodurch zu einem früheren Zeitpunkt eine bessere Bewertung ermöglicht wird.

Analog zu der Metrik wird auch das Residuum durch das geringere Rauschen positiv beeinflusst. Somit sind nur noch kurze Abschnitte zu Beginn eines Zyklus eine Herausforderung hinsichtlich der Schätzung, wobei diese Bereiche durch die $R^2_{Adj.}$ Metrik sowie das Konfidenzintervall effektiv von validen Schätzungen abgegrenzt werden.




Abbildung 7.15.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 501h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.

Abbildung 7.15 zeigt die erste valide Schätzung nach dem Zykluswechsel. Der neue Zyklus enthält 41 Messwerte, die zusätzlich in Test- und Trainingsdatensatz aufgeteilt werden. Auf Grundlage der sehr geringen Anzahl an Messwerten ist das Ergebnis mit einem Überschätzen der RUL von $res_{RUL} = 5h$ bereits sehr gut. Die mit dem schwachen Rauschen verbundene Unsicherheit wird durch die Spannweite des Konfidenzintervalls von $t_{Konf.} = 110h$ berücksichtigt und schließt die Entwicklung des Signals S mit ein. Trotz der rauschbedingten Abweichung der Schätzung von der RUL ist die sehr frühe Schätzung bereits für die Evaluierung der spezifischen Betriebssituation sowie der Ableitung von Handlungsempfehlungen verwendbar.

Zur Betriebszeit $t = 511h$ stehen für die Schätzung mehr Messwerte zur Verfügung. Der Vergleich zwischen Abbildung 7.15 und Abbildung 7.16 zeigt, dass die Trajektorie des geschätzten Signals \hat{S} um die Trajektorie des Signals S schwingt. Der Einfluss einzelner stärker verrauschter Messwerte ist bei der Schätzung der RUL am Anfang eines Zyklus stärker und ermöglicht eine Schwingung der RUL Schätzung. Mit zunehmender Anzahl an Messwerten fällt der Einfluss einzelner Messwerte immer weniger ins Gewicht, sodass die Schätzung des Erwartungswerts der RUL gegen die RUL konvergiert. Dies wird auch anhand von Abbildungen D.10 deutlich.




Abbildung 7.16.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 511h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.

Der direkte Vergleich der Schätzung mit starkem bzw. schwachem Rauschen ist anhand der Abbildungen 7.13 und 7.16 möglich. Das geringere Rauschen unterstützt eine qualitativ hochwertigere RUL Schätzung mit einer Unterschätzung von $res_{RUL} = -12h$. Der wesentlich schmalere Konfidenzbereich ist visuell zu erkennen und verdeutlicht den großen Einfluss des Rauschens auf die Schätzung.

7.1.3. Ergebnisse des Kurven-Datensatzes

Die Eigenschaften des ETM sind, dass kein *a priori* Wissen notwendig ist und die Anpassungsfähigkeit an unbekannte Degradationsverläufe. Für die Evaluierung dieser Charakteristika werden auf Basis des Kurven-Datensatzes folgende Einstellungen vorgenommen.

- Rauschen: schwach/ stark
- Monotonie: unbekannt/ steigend
- CP Position: 0%/ 20%

In Anlehnung an den Sägezahn-Datensatz wird zunächst ein Datensatz mit CP bei $i_{\text{Proz.}} = 0\%$ der Zykluslänge diskutiert. Im Anschluss wird der CP auf $i_{\text{Proz.}} = 20\%$ der Zykluslänge verschoben. Analog zur Evaluierung des Sägezahn-Datensatzes werden verschiedene Kombinationen aus Rauschen und Monotonieverhalten vorgestellt.

Kurven-Datensatz - Rauschen: stark, Monotonie: unbekannt, CP: 0%

Nachfolgend werden die Ergebnisse des ETM anhand des Kurven-Datensatzes mit starkem Rauschen und unbekannter Monotonie vorgestellt.

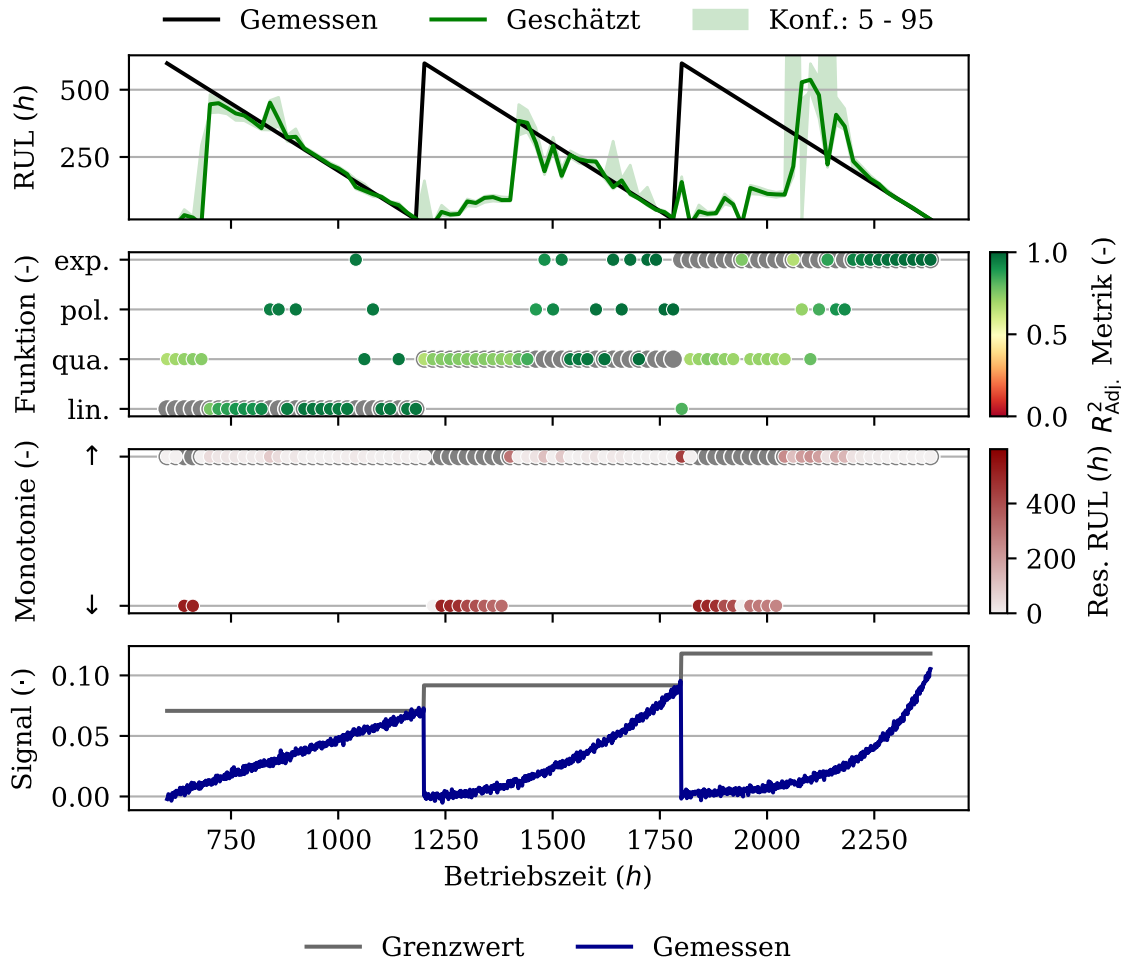


Abbildung 7.17.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und CP bei $i_{\text{Proz.}} = 0\%$.

Abbildung 7.17 zeigt in dem ersten linearen Zyklus ein schnelles Konvergieren der Schätzung gegen die RUL. Der zweite und dritte Zyklus basiert auf einer quadratischen sowie einer exponentiellen Funktion. Der Erwartungswert der RUL wird für beide nichtlinearen Funktionen in der ersten Hälfte der Zyklen unterschätzt.

Aus der zweiten Darstellung in Abbildung 7.17 geht hervor, dass die Abweichung der RUL Schätzung durch die fehlerhafte Auswahl der abzubildenden Funktion begleitet wird. Auffällig ist in diesem Zusammenhang, dass die Fehlklassifizierung des exponentiellen Verlaufs vorwiegend am Anfang stattfindet, wohingegen der quadratische Verlauf vorwiegend am Ende mit anderen Funktionen modelliert wird.

Die wesentlichen Erkenntnisse der Auswertung des Sägezahn-Datensatzes werden bestätigt, sodass die größten Residuen des RUL während der Startphase der Zyklen auftreten. Durch die fehlende Beschränkung der Monotonie sind es insbesondere die Anfänge der

Degradationsverläufe, deren Monotonie nicht korrekt identifiziert werden.

Nachfolgend werden die zuvor identifizierten Auffälligkeiten im Detail diskutiert. Abbildung D.11 zeigt die Schätzung des Erwartungswerts der RUL auf Basis eines linearen Degradationsverlaufs. Der CP wird korrekt ausgewählt und weicht lediglich rauschbedingt um $res_{CP} = 5$ Messwerte ab. Im Gegensatz dazu erfolgt die Abbildung des Signals S durch einen polynomischen und nicht durch einen linearen Zusammenhang. Das Polynom wird aufgrund der Maximierung der R^2_{Adj} Metrik durch den Algorithmus ausgewählt. Im Hinblick auf die Schätzung des Signals \hat{S} führt die geringfügige Abweichung von einem linearen Zusammenhang bei einem Schätzhorizont $h_{Präd.} < 370$ Messwerten bereits zu einer Abweichung von $res_{RUL} \approx 100h$. Mit dem Fokus auf das Konfidenzintervall wird deutlich, dass wenige stark ausgeprägte Rauschwerte bereits die Abweichung von einem linearen Zusammenhang begründen. Die Fehlidentifizierung der Funktion wird auch anhand der Residuen in Abbildung D.12 verdeutlicht.

Das vergangene Signalresiduum Res_S enthält im Wesentlichen das Rauschen und nur geringe Signalanteile. Über die Messwerte aufgetragen oszilliert das vergangene Residuum Res_S gleichmäßig um einen Mittelwert von annähernd 0. Innerhalb des Histogramms wird der Unterschied zwischen dem vergangenen- und dem zukünftigen Residuum $Res_{S,Zuk.}$ deutlich. Die Verteilung des zukünftigen Residuums $Res_{S,Zuk.}$ ist zu einem negativen Mittelwert verschoben und besitzt im Vergleich zum vergangenen Residuum Res_S eine größere Streuung. Im zeitlichen Verlauf in der zweiten Darstellung von Abbildung D.12 ist ein über die Zeit größer werdender Drift des zukünftigen Residuums $Res_{S,Zuk.}$ zu erkennen. Folglich wird der Fehler der RUL Schätzung durch das ETM mit wachsendem Schätzhorizont $h_{Präd.}$ größer.




Abbildung 7.18.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1461h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 0%.

Demgegenüber wird in Abbildung 7.18 die Schätzung des quadratischen Signals S zur Betriebszeit $t = 1461h$ vorgestellt. Das ETM identifiziert den CP korrekt und detektiert den nichtlinearen Zusammenhang. Die Schätzung des Signalverlaufs basiert auf einer

geeigneten Funktion, sodass sich die Verläufe des Signals S und dessen Schätzung \hat{S} sehr ähneln. Rauschbedingt wird die RUL unterschätzt, wobei die Variation innerhalb der verfügbaren Daten des Zyklus zu einem Konfidenzintervall führt, das den zukünftigen Signalverlauf $S_{\text{Zuk.}}$ einschließt.

Abbildung 7.17 zeigt, dass im Anschluss an die korrekte Modellbildung durch das ETM das Signal S bei Betriebszeit $t = 1479h$ durch eine exponentielle Funktion abgebildet wird. Diese Klassifikation führt zu einem Unterschätzen des Erwartungswerts der RUL um $res_{\text{RUL}} = -119h$. Die Ursache für die Abweichung ist die deutlich schnellere Entwicklung der exponentiellen Funktion, die besonders bei großen Schätzhorizonten $h_{\text{Präd.}}$, zu starken Abweichungen führt.




Abbildung 7.19.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2081h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 0%.

Der Einfluss der Funktionswahl auf die Güte der Schätzung zeigt sich auch in Abbildung 7.19. Das exponentielle Signal S wird von dem ETM durch ein Polynom abgebildet. In diesem Fall wird die RUL durch die deutlich schnellere Entwicklung der exponentiellen Funktion um $res_{\text{RUL}} = 203h$ überschätzt. Der funktionale Zusammenhang der Polynomfunktion ist durch Gleichung 6.2 gegeben. Anhand von Abbildung 7.19 zeigt sich die Sensitivität der Parameter anhand des Konfidenzintervalls. Dieses bildet eine Variation von einem nahezu linearen- bis zu einem ausgeprägt nichtlinearen Verhalten ab. Daraus folgt, dass die Schätzung zu diesem Zeitpunkt größere Unsicherheiten enthält. Die Ursache ist die zu geringe Anzahl an Messwerten in Kombination mit einem starken überlagerten Rauschen. Besonders durch die anfänglich geringe Entwicklung der Exponentialfunktion wird das Signal S unter- und somit die RUL deutlich überschätzt. Dieses Beispiel verdeutlicht, dass in den historischen Daten eine ausreichende Menge an Informationen enthalten sein muss, um eine valide Schätzung zu ermöglichen. Die in Unterkapitel 5.1 beschriebene Kombination mit einer vorherigen FD ist sinnvoll, um eine robuste Überwachung und die Ableitung von Handlungsempfehlungen zu ermöglichen.

Kurven-Datensatz - Rauschen: stark, Monotonie: unbekannt, CP: 20%

In der Realität existieren praktische Anwendungen, deren Degradation sich erst nach einer bestimmten Betriebszeit einstellt. Ebenso ist die Entwicklung der Fehler in manchen Fällen langsam und erfolgt stetig aus dem fehlerfreien Zustand heraus. Diese Fehlerkategorie wird auch als beginnender Fehler (engl. Incipient Fault) bezeichnet und besitzt sowohl in der Wissenschaft wie auch der Technik eine große Relevanz. In diesem Zusammenhang ist die richtige Wahl des CP die Grundlage für eine möglichst frühe Schätzung der RUL. Dieser Aspekt wird nachfolgend anhand des Kurven-Datensatzes mit einem CP bei $i_{\text{Proz.}} = 20\%$ diskutiert. Die Verzögerung wird durch die Verschiebung des CP um 120 Messwerte realisiert.




Abbildung 7.20.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.

Die Ergebnisse aufgrund von starkem Rauschen und einer unbekannter Monotonie werden in Abbildung 7.20 vorgestellt. Der Vergleich von Abbildung 7.17 und 7.20 auf Basis der untersten Darstellung zeigt, dass durch die Festlegung der Zyklenlänge und die gleichen Grenzwerte die Steigungen in Abbildung 7.20 größer sind. Die konstanten

Phasen fallen besonders bei dem ersten Zyklus auf und können visuell gut unterschieden werden. Optisch ist die Unterscheidung für den zweiten und dritten Zyklus nicht mehr möglich. Somit sind besonders die Übergänge für die Diskussion des ETM interessant. Die zweite Darstellung von Abbildung 7.20 zeigt im Vergleich zu Abbildung 7.17, dass der erste Zyklus länger durch eine quadratische anstelle einer linearen Funktion abgebildet wird. Ähnlich gilt dies auch für den dritten Zyklus.

Bedingt durch die längeren konstanten Abschnitte infolge der Verschiebung der CP ändert sich auch die Zuordnung der Monotonie in der dritten Darstellung. Auf Basis eines starken Rauschens und wenigen verfügbaren Daten kurz nach Abschluss des letzten Zyklus, erfolgt die Bewertung des Modells für den neuen Zyklus mit einem geringen Wert der R^2_{Adj} Metrik. Im Vergleich dazu weist ein Modell, das Teile des alten Zyklus mit abbildet, eine höhere R^2_{Adj} Metrik auf und wird somit ausgewählt.




Abbildung 7.21.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

Im Folgenden liegt der Fokus auf den Übergängen zwischen den Zyklen und den einzelnen Phasen sowie der Zuweisung des CP. Abbildung 7.21 zeigt die frühe Schätzung des Erwartungswertes der RUL. Für die Schätzung in Abbildung 7.21 werden unterschiedliche CP detektiert. Anstelle des korrekten CP bei Messwert $i = -179$ wird ein Wechselpunkt bei Messwert $\hat{i} = -220$ für die Modellierung genutzt. Folglich werden Anteile des stationären, fehlerfreien Zustands für die Modellbildung genutzt. Infolge dessen wird die RUL mit $res_{RUL} = -189h$ unterschätzt. Auf Grundlage von Gleichung 4.29 und 4.30 folgt für die Metrik, dass Fehler in der Abbildung durch eine größere Anzahl an Messwerten kompensiert werden können. Demnach wird der korrekte CP nicht gewählt, da die Metrik schlechter im Vergleich zum gewählten Modell ist. Die Auswirkung der Modellbildung durch eine Funktion höherer Ordnung wird auch in Abbildung D.15 deutlich. In der zweiten Darstellung ist das vergangene Residuum Res_S über die Messwerte aufgetragen. Innerhalb des vergangenen Residuums Res_S sind leichte Strukturen in der Umgebung des Knicks im Signal S bei Messwert -121 zu erkennen. Im Vergleich weicht das zukünftige Residuum $Res_{S,Zuk.}$ deutlich vom Mittelwert 0

ab. In Kombination mit Abbildung 7.21 folgt, dass das Signal im Knickbereich nicht vollständig durch Funktion höherer Ordnung abgebildet werden kann.




Abbildung 7.22.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 861h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

Im zeitlichen Verlauf wird diese frühe Abbildung durch mehr Messdaten korrigiert, wie Abbildung 7.22 zeigt. Die Daten vor dem Sprung des Signals \hat{S} zwischen dem nullten und ersten Zyklus werden nicht für die Modellbildung miteinbezogen, wie Abbildung 7.22 verdeutlicht. Der geschätzte CP wird in Richtung des CP korrigiert, umfasst jedoch noch einen geringen Anteil an Daten des fehlerfreien Zustands. Das Residuum der RUL wird auf $res_{RUL} = -42h$ reduziert, wohingegen die Spanne des Konfidenzintervalls auf $t_{Konf.} = 106h$ angehoben wird. Im Vergleich zu Abbildung 7.21 wird die Charakteristik der Funktion in Richtung eines linearen Verhaltens verbessert, sodass sich die Trajektorie des Signals S und deren Schätzung \hat{S} sehr ähnlich verhalten. Mit dem größer werdenden Einfluss von weiteren Messwerten im linear ansteigenden Teil wird der zusätzliche Gewinn durch Messwerte, die sich chronologisch vor dem CP befinden, geringer. Die Reduzierung des Einflusses von Messwerten chronologisch vor dem CP ist auch in Abbildung D.13 zu sehen.

Analog zu dem ersten Zyklus erfolgt, auf Basis einer größeren Datenmenge, auch die kontinuierliche Verbesserung der RUL Schätzung des zweiten Zyklus. Abbildung D.16 zeigt, dass zur Betriebszeit $t = 1341h$ der Start der Degradation lediglich 21 Messwerte zurückliegt. Durch das Erzwingen der RUL Berechnung zu diesem Betriebspunkt sucht das ETM nach einer geeigneten Abbildung, die infolge der steilen Flanke des vorherigen Zyklus sowie der konstanten Betriebsweise vor dem CP durch eine quadratische Funktion abgebildet wird. Infolgedessen wird die RUL mit einem Residuum von $res_{RUL} = 365h$ unterschätzt.

Vergleichbar mit den Schätzungen der linearen Verläufe, wird die Schätzung im weiteren zeitlichen Verlauf korrigiert. Exemplarisch wird eine korrigierte Schätzung in Abbildung D.17 dargestellt. Die spätere Schätzung zeigt, dass die Werte chronologisch vor

dem CP nicht für die Modellbildung einbezogen werden und der CP korrekt gewählt wird. Trotz der frühen Betriebsphase gibt der geschätzte Signalverlauf \hat{S} den Erwartungswert des Signals S sehr gut wieder. Infolgedessen wird auch RUL mit einem Residuum von $res_{RUL} = 3h$ und einer Spannweite des Konfidenzintervalls von $t_{Konf.} = 55h$ korrekt geschätzt.

Der Übergang des stationären Signalanteils in den exponentiellen Zyklus ist qualitativ ähnlich und wird daher nur skizziert. Analog zu Abbildung 7.22 wird der CP in Abbildung D.18 nach dem Wechsel zwischen den zweiten und dritten Zyklus positioniert. Allerdings wird auch in diesem Fall ein Anteil des konstanten Betriebszeitraums zur Modellbildung genutzt. Im Gegensatz zu Abbildung 7.21 führt es in diesem Fall zu einer Reduzierung der Ordnung und wird durch das ETM durch eine quadratische Funktion abgebildet. Dies resultiert in einer sichtbaren Überschätzung der RUL sowie einem Residuum von $res_{RUL} = 1572h$.




Abbildung 7.23.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2221h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.

Vergleichbar mit der Missklassifikation der Funktion in Abbildung D.16, erfolgt die Korrektur des CP mit einer größeren Anzahl an Messwerten. Die korrekte Klassifizierung als exponentielle Funktion wird exemplarisch in Abbildung 7.23 verdeutlicht. Bedingt durch die korrekte Funktionswahl wird der Signalverlauf S durch die Schätzung \hat{S} qualitativ sehr gut repräsentiert und die RUL wird mit $res_{RUL} = 23h$ gering überschätzt.

Kurven-Datensatz - Rauschen: schwach, Monotonie: unbekannt, CP: 20%

Auf Grundlage der Erkenntnisse aus dem Sägezahn-Datensatz hat das Rauschen einen großen Einfluss auf die Klassifizierung der Funktion zur Modellierung sowie die Bestimmung des CP.

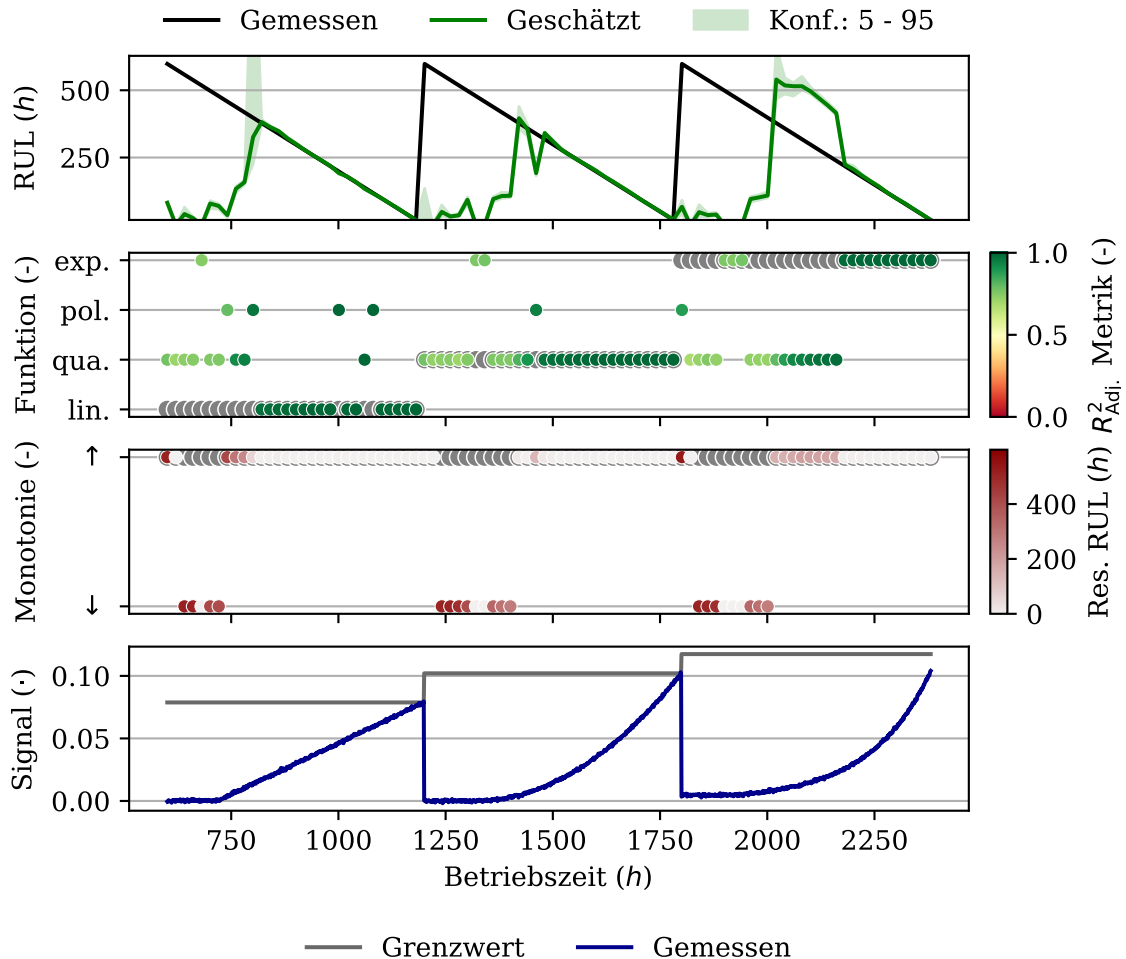


Abbildung 7.24.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.

Abbildung 7.24 zeigt die Ergebnisse der Auswertung durch das ETM mit einem CP bei $i_{\text{Proz.}} = 20\%$ der Zyklenlänge, schwachem Rauschen sowie einer unbekannter Monotonie. Der Vergleich der obersten Darstellung von Abbildung 7.20 und 7.24 verdeutlicht eine frühere und stabilere Schätzung des ersten sowie eine frühere und besser beschränkte Abbildung des dritten Zyklus.

Der Vergleich der zweiten Darstellung von Abbildung 7.20 und 7.24 zeigt die bessere Zuordnung der Funktion im Falle eines geringeren Rauschens. Dies ist besonders gut anhand des ersten und zweiten Zyklus zu erkennen. In der zweiten Hälfte der Zyklen kommt es an manchen Punkten zur falschen Wahl des Funktionstyps. Das geringere Rauschen reduziert die Fehlklassifikationen deutlich und ermöglicht eine bessere Schätzung. In diesem Zusammenhang kann auch gezeigt werden, dass sowohl die quadratische,

wie auch die lineare Funktion Spezialfälle der polynomischen Funktion sind. Demnach ist die Fehlklassifikation nicht im gleichen Maße einzuordnen, wie beispielsweise die Abbildung eines exponentiellen Signals S durch eine quadratische Funktion. Dennoch zeigt sich, dass der Freiheitsgrad des Exponenten des Polynoms bei kleiner Abweichung und einem langen Schätzhorizont $h_{\text{Präd.}}$ zu erheblichen Fehlern führen kann.

Die Monotonie wird durch einen geringeren Rauscheinfluss früher korrekt identifiziert. Implizit führt dies zu einer geringeren Ausprägung der RUL Residuen Res_{RUL} , was sich besonders an den Übergängen zwischen den Zyklen bzw. dem konstanten und dem steigenden Signalanteil zeigt.




Abbildung 7.25.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 901h$ auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

Die verbesserte Schätzung aufgrund des geringen Rauschens sowie die identifizierten Auffälligkeiten werden nachfolgend im Detail diskutiert. Dazu wird in Abbildung 7.25 die Schätzung des linearen Verlaufs vorgestellt. Der gewählte CP liegt mit $res_{\text{CP}} < 10$ Messwerte hinter dem CP. Somit werden nur relevante Daten für die Modellbildung genutzt. Die Schätzung des Erwartungswerts des Signals \hat{S} ist nahezu identisch mit dem Signalverlauf S . Das Konfidenzintervall ist mit $t_{\text{Konf.}} = 7h$ gering ausgeprägt und ergänzt den hohen Metrikwert von $R^2_{\text{Adj.}} = 0.99$. Folglich wird die RUL erfolgreich durch das ETM geschätzt mit einem Residuum von $res_{\text{RUL}} = 3h$.

Der Vergleich mit Abbildung D.13 zeigt, dass die lineare Funktion anhand von weniger Messwerten identifiziert wird und ermöglicht damit eine präzisere Schätzung des Erwartungswerts der RUL zu einem früheren Zeitpunkt. Die Schätzung zum Ende des ersten Zyklus spiegelt die RUL sehr gut wider. Im Falle eines nicht perfekten weißen Rauschens ist es möglich, dass die Verteilung des Rauschens der Stichprobe eine geringe Schiefe aufweist und diese durch einen nichtlinearen Fit wiedergegeben wird. Im Falle eines geringen Rauschens ist der Effekt sehr klein und beeinträchtigt die Schätzung kaum, wohingegen ein starkes Rauschen die Eigenschaften deutlich beeinflusst.




Abbildung 7.26.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2041h$ auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

Anhand der Schätzung der RUL zur Betriebszeit $t = 2041h$ zeigt Abbildung 7.26, dass bereits 121 Messwerte nach dem Beginn der Degradation eine für die Anzahl der Trainingsdaten valide Schätzung vorliegt. Im Gegensatz zu Abbildung D.14 wird ein CP nach dem Zykluswechsel gewählt. Der konstante Betriebsbereich vor dem CP wird zur Hälfte nicht für die Schätzung berücksichtigt. Das nichtlineare Verhalten des Signals S wird durch die erste Schätzung richtig identifiziert. Die Abbildung des exponentiellen Verlaufs durch eine quadratische Funktion wird durch den anteiligen konstanten Betriebsbereich in den Trainingsdaten begünstigt. Bedingt durch Fehlklassifikation der Funktion wird das Residuum der RUL mit $res_{RUL} = 160h$ überschätzt. Auf Basis einer größeren Anzahl an Messwerten kann das exponentielle Verhalten ab der Betriebszeit $t = 2181h$ identifiziert werden. Die Schätzung der RUL von $t_{RUL} = 224h$ mit einem Konfidenzintervall von $t_{Konf.} = 13h$ weicht mit einem Residuum von $res_{RUL} = 6h$ sehr geringfügig von der RUL ab.

Kurven-Datensatz - Rauschen: schwach, Monotonie: steigend, CP: 20%

Nachfolgend wird die Beschränkung der Monotonie anhand des Kurven-Datensatzes untersucht. Die Ergebnisse der RUL Schätzung durch das ETM werden anhand des Kurven-Datensatzes mit schwachem Rauschen, steigender Monotonie und einem CP bei $i_{\text{Proz.}} = 20\%$ in Abbildung 7.27 vorgestellt.

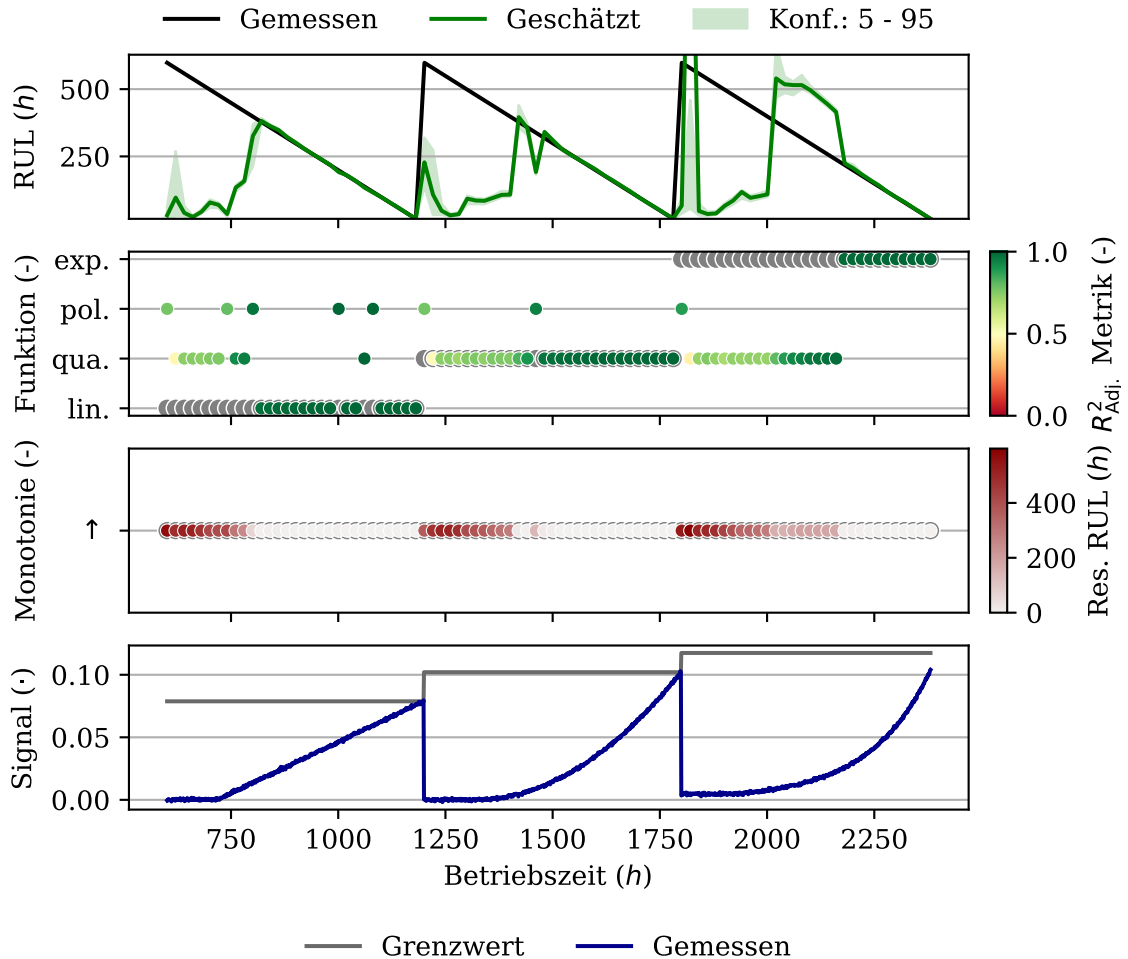


Abbildung 7.27.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, steigender Monotonie und Wechsellpunkt bei 20%.

Der Vergleich zwischen Abbildung 7.24 und 7.27 zeigt, dass die Unterschiede durch die Einschränkung der Monotonie anhand des Kurven-Datensatzes in der zweiten Hälfte der Zyklen gering sind. Auf Grundlage einer ausreichend großen Menge an Daten des zu modellierenden Zyklus ist die Monotonie keine beschränkende Eigenschaft, sondern vielmehr eine redundante Information. Aufgrund der analogen Thematik wird auf die Diskussion des Sägezahn-Datensatzes verwiesen.

Aus dem Vergleich von Abbildung 7.24 und 7.27 geht hervor, dass es in der initialen Degradationsphase ohne Beschränkung der Monotonie kurze Zeitbereiche gibt, die keine RUL ausweisen. In diese Bereiche wird die Monotonie des Signals S nicht korrekt erkannt

und folglich kann der gewünschte Grenzwert ω_S innerhalb des Schätzhorizontes $h_{\text{Präd., max}}$ nicht erreicht werden.

Die Beschränkung der Monotonie ermöglicht eine verbesserte Modellierung durch das ETM und vermeidet die Ausgabe von vordefinierten Werten wirkungsvoll.

7.1.4. Diskussion des Einzeltrendmoduls auf synthetischen Daten

Die grundlegenden Eigenschaften des ETM, sich adaptiv an geänderte Betriebsbedingungen anzupassen, wird anhand des Sägezahn-Datensatzes überprüft. Dieser Aspekt ist insbesondere im industriellen Anwendungsgebiet wichtig, da betriebsbedingte Änderungen unter Umständen kurzfristig vorgenommen werden und nicht zwangsweise vollautomatisch einem Modellbildungsprozess zugeführt werden können. Diese kurzfristigen Wechsel werden durch die Sprünge im Signal abgebildet und effektiv durch das ETM verarbeitet. Die adaptive Anpassung an das Degradationssignal ist mit dem Fokus auf den gesamten Degradationsprozess sehr gut. Besonders die Metrik sowie das Konfidenzintervall unterstützen bei der Interpretation der Ergebnisse. Die frühen Phasen der Degradation mit einer sehr geringen Anzahl an Messwerten sind eine Herausforderung, der durch die Kombination mit einem Modell aus dem Bereich FD wirkungsvoll begegnet werden kann.

Neben der Überprüfung der Basiseigenschaften des ETM wird die Variation unterschiedlicher Degradationsmechanismen anhand des Kurven-Datensatzes evaluiert. Industrielle Degradationsverläufe umfassen sowohl exponentielles- als auch lineares Verhalten. Auf Basis der grundlegenden linearen, polynomischen und exponentiellen Funktionen sind somit eine Vielzahl an Degradationsmechanismen abbildbar. In diesem Zusammenhang wird der Fall diskutiert, wenn der CP nicht mit den deutlichen Sprüngen zwischen den Zyklen zusammenfällt und die Degradation sich stetig aus dem fehlerfreien Signal entwickelt. Im industriellen Umfeld sind diese stetigen Veränderungen deutlich schwerer zu detektieren, da besonders in Kombination mit Rauschen der Übergang nicht eindeutig beschrieben werden kann.

Die Auswertung zeigt, dass diese Kombination eine Herausforderung für das ETM darstellt. Anhand des Kurven-Datensatz mit CP bei $i_{\text{Proz.}} = 20\%$ wird deutlich, dass ein linearer Zusammenhang in den Messdaten besonders am Anfang durch Modelle höherer Ordnung abgebildet wird, wohingegen bei einer größeren Datengrundlage auf ein lineares Modell gewechselt wird. Der frühe Wechsel sowie die Auswahl der Funktion wird durch den Einsatz der angepassten $R^2_{\text{Adj.}}$ Metrik unterstützt, die Abbildung mit weniger Freiheitsgraden bevorzugt. Dies reduziert die Fehlklassifizierung eines verrauschten linearen Trends als Polynom mit geringem nichtlinearen Anteil. Im Hinblick auf die Schätzung des Erwartungswerts der RUL kann gezeigt werden, dass eine geringfügige Abweichung von einem linearen Zusammenhang in Kombination mit einem großen Schätzhorizont $h_{\text{Präd.}}$ zu deutlichen Abweichungen führt.

Insgesamt ist die Schätzung der synthetischen Degradationssignale durch das ETM sehr erfolgreich. Im industriellen Umfeld ist besonders die adaptive Eigenschaft in Kombination mit dem vollautomatisierten Konzept ein starker Mehrwert. Je weniger Störungen im Signal enthalten sind bzw. je mehr das ETM im Hinblick auf Monotonie und Funktion eingeschränkt wird, desto besser ist das Ergebnis des geschätzten Signalverlaufs sowie die daraus abgeleitete RUL.

7.2. Beurteilung des Partikelfiltermoduls

Im nachfolgenden Kapitel wird das in Unterkapitel 5.2 entwickelte PFM anhand von synthetischen Testdaten bewertet. In Unterkapitel 7.2.1 werden die notwendigen Parameter zur Generierung der Daten festgelegt. Basierend auf einem Referenzbetrieb wird in Unterkapitel 7.2.2 die Initialisierung des PF und dessen Einfluss auf die Schätzung ausgewertet. In Unterkapitel 7.2.3 wird der Effekt der Variation von Partikeln untersucht. Darauf aufbauend werden grundlegende Strategien des Resamplings in Unterkapitel 7.2.4 gegenübergestellt. Um dem PI aktiv entgegenzuwirken, werden in Unterkapitel 7.2.5 die Möglichkeiten der Partikeloptimierung diskutiert. Auf Basis der industriellen Relevanz wird der Einfluss von Störungen in Unterkapitel 7.2.6 untersucht. Die Erkenntnisse der Evaluierung auf Grundlage der synthetischen Daten werden in Unterkapitel 7.2.7 zusammengeführt.

7.2.1. Generierung synthetischer Daten - Partikelfiltermodul

Um die Leistungsfähigkeit des PFM zur RUL Schätzung zu evaluieren, werden synthetische Daten benötigt, die anhand des Datengenerators aus Unterkapitel 5.2.3 erzeugt werden. Der synthetische Anwendungsfall umfasst den Eingangsvektor Γ_t , den Ausgangsvektor Ψ_t , den Parametervektor Θ_t der ZG, den Parametervektor C_t der AG sowie den Zustandsvektor Φ_t zum Zeitpunkt t . Anhand von Gleichung 7.3 bis 7.7 werden die Einträge der Vektoren veranschaulicht.

$$\Gamma_t = Input_t = [Input_t(A) \quad Input_t(B) \quad Input_t(C) \quad Input_t(D)] \quad (7.3)$$

$$\Psi_t = Measure_t = [Measure_t(A) \quad Measure_t(B)] \quad (7.4)$$

$$\Theta_t = [\Theta_t(1) \quad \Theta_t(2) \quad \Theta_t(3) \quad \Theta_t(4)] \quad (7.5)$$

$$C_t = [C_t(1) \quad C_t(2) \quad C_t(3) \quad C_t(4)] \quad (7.6)$$

$$\Phi_t = State_t = [State_t(A) \quad State_t(B)] \quad (7.7)$$

Zur Generierung der synthetischen Daten wird die Beschreibung des dynamischen Systems durch die ZG benötigt, die eine Transition zwischen den Zuständen $State_t$ und $State_{t+1}$ beschreibt. In Gleichung 7.8 und 7.9 werden die ZG für den synthetischen Fall beschrieben.

$$State_{t+1}(A) = State_t(A) \left(1 + (\Theta_t(1) Input_t(C) + \Theta_t(2) Input_t(D)) \right) \quad (7.8)$$

$$State_{t+1}(B) = State_t(B) \left(1 + (\Theta_t(3) Input_t(A) + \Theta_t(4) Input_t(B)) \right) \quad (7.9)$$

Durch die AG wird zum Zeitpunkt t der Ausgangsvektor $Measure_t$ mit dem Parametervektor C_t in den Zustandsvektor $State_t$ überführt. Die AG werden in Gleichung 7.10 und 7.11 beschrieben.

$$State_t(A) = C_t(1) Measure_t(A) + C_t(2) \quad (7.10)$$

$$State_t(B) = C_t(3) Measure_t(B) + C_t(4) \quad (7.11)$$

Zur Erzeugung der synthetischen Betriebsdaten werden die Einstellungen in Tabelle D.1 gewählt.

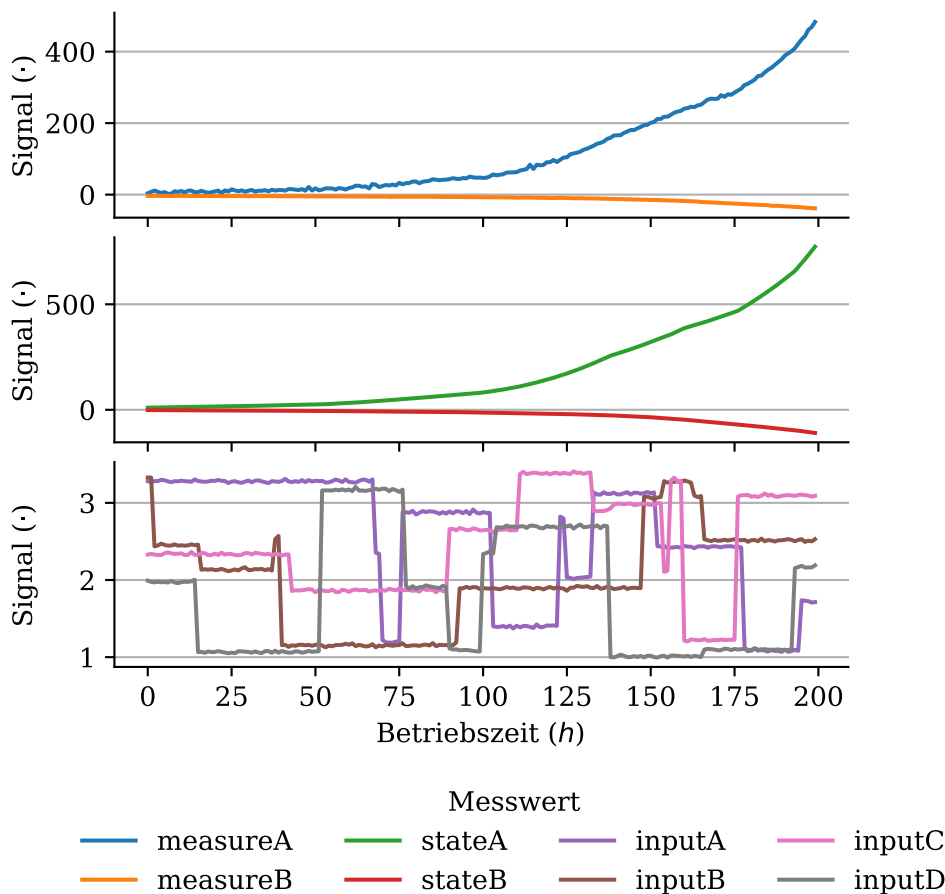


Abbildung 7.28.: Grafische Darstellung der synthetischen Eingangs-, Ausgangs- und Zustandssignale zur Evaluation des Partikelfiltermoduls mit überlagertem Rauschen.

Abbildung 7.28 veranschaulicht den generierten Eingangsvektor Γ_t , den Ausgangsvektor Ψ_t , sowie den Zustandsvektor Φ_t über die Zeit $t \in \mathcal{T}$ mit überlagertem Rauschen. Für die Schätzung durch das PFM werden drei unterschiedliche Szenarien vorgestellt:

- *realRul*: Die Basis für das *realRul* Szenario sind die zukünftigen Eingangsvektoren Γ .
- *Bestcase*: Das *Bestcase* Szenario entspricht einer minimalen Betriebslast, die zu einer geringen Degradation führt. Dazu werden alle Eingangssignale in einem ersten Schritt auf 1.1 und anschließend für den weiteren Betrieb auf 1.0 festgelegt (vgl. Abbildung 7.28).
- *Worstcase*: Die maximale Betriebslast wird durch das *Worstcase* Szenario ausgedrückt, das zu einer Beschleunigung der Degradation führt. Dazu werden alle Eingangssignale in einem ersten Schritt auf 3.4 und anschließend für den weiteren Betrieb auf 3.5 festgelegt (vgl. Abbildung 7.28).

Für die Simulation der RUL Schätzung durch das PFM werden die Einstellungen in Tabelle 7.3 festgelegt. Der Parametervektor C_t wird als konstant definiert und somit

nicht während der Simulation durch das PFM verändert. Diese Einstellungen werden im Folgenden als Referenzeinstellung bezeichnet.

Tabelle 7.3.: Tabellarische Auflistung der Referenzeinstellung des Partikelfiltermoduls zur Evaluierung auf Basis von synthetischen Daten.

Einstellung	Wert
Resampling Methode	Systematische
Anzahl Partikel n_φ	500
max. Schätzhorizont $h_{\text{Präd.,max}}$	300
Grenzwert ESS ω_{ESS}	85%
Konfidenz	5% , 95%
Monotonie Mon_{Measure}	[+1/steigend -1/fallend]
Grenzwerte Ω_{Measure}	[4.1 6.2]
Toleranz $T_{\text{Tol.}}$	[2.50 0.25]
Untere Grenze des PR $\Theta_{\text{U.Grenz.}}$	[$2.05e-3$ $3.35e-3$ $2.90e-3$ $1.95e-3$]
Oberer Grenze des PR $\Theta_{\text{O.Grenz.}}$	[$1.0e-2$ $2.0e-2$ $1.0e-2$ $1.5e-2$]

7.2.2. Initialisierung des Partikelfiltermoduls

Die Initialisierung des PF ist ein wesentlicher Aspekt für den erfolgreichen Betrieb des PFM. In diesem Zusammenhang kann sowohl die Initialisierung der Parametermatrix Θ als auch der Zustandsmatrix Φ variiert werden.




Abbildung 7.29.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit Referenzeinstellungen.

Exemplarisch wird die Initialisierung des PFM mit Referenzeinstellungen in Abbildung 7.29 dargestellt. Die Abbildung zeigt die Trajektorien des Zustands $State(A)$

aller Partikel über den maximalen Schätzhorizont von $h_{\text{Präd.,max}} = 250$ Messwerten. Die steileren Trajektorien führen zu kürzeren RUL und sind überdurchschnittlich häufig im Vergleich zu sehr langen Laufzeiten vertreten. Gleichung 7.8 zeigt, dass durch die Form der ZG bei positiven Eingangssignalen und etwa gleich großen zufälligen Parametern $\Theta(1)$ und $\Theta(2)$, die Mehrheit der Partikel eine Überschätzung abbildet. Hinzu kommt, dass der PR nicht zentriert um den Parametervektor Θ initialisiert wird. Dies hat zur Folge, dass nur sehr wenige Partikel den Zustandsverlauf annähernd abbilden.

Wertebereich des Parameterraums

Basierend auf den Referenzeinstellungen wird der PR in Tabelle 7.4 angepasst, um die Auswirkung auf die Initialisierung zu verdeutlichen.

Tabelle 7.4.: Tabellarische Auflistung der Grenzen des Parameterraums zur Evaluierung des Partikelfiltermoduls auf Basis von synthetischen Daten.

Einstellung	Wert
Untere Grenze des PR $\Theta_{\text{U.Grenz.}}$	$[3.1e-3 \quad 5.7e-3 \quad 2.9e-3 \quad 4.8e-3]$
Obere Grenze des PR $\Theta_{\text{O.Grenz.}}$	$[5.1e-3 \quad 7.7e-3 \quad 4.9e-3 \quad 6.8e-3]$

Gegenüber dem Referenzfall werden der untere- $\Theta_{\text{U.Grenz.}}$ und obere Parametergrenzvektor $\Theta_{\text{O.Grenz.}}$ angepasst, das den PR sowohl verkleinert als auch um den synthetischen Parametervektor $\Theta_{\text{Synth.}}$ zentriert. Durch die konstante Partikelanzahl n_{ϕ} im Vergleich zum Referenzfall sind die Partikel im PR dichter gepackt, wodurch eine bessere Abdeckung erfolgt.




Abbildung 7.30.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit reduziertem Wertebereich von Θ .

Abbildung 7.30 zeigt die Zustandsschätzung der einzelnen Partikel auf Grundlage eines reduzierten PR. Im Vergleich zu Abbildung 7.29 wird der zeitliche Verlauf des

Zustands $State(A)$ optisch besser abgebildet und die Varianz zwischen den Partikeln reduziert. Eine Verdichtung der Partikeltrajektorien mit Tendenz zur Überschätzung ist auch in diesem Fall zu beobachten.

Insgesamt ist die Beschränkung des PR eine zentrale Möglichkeit zur effektiven Initialisierung des PF.

Wertebereich des Zustandsraums

Die Initialisierung des ZR wird nachfolgend auf der Grundlage der Referenzeinstellungen variiert. Im Rahmen des PFM erfolgt die Initialisierung der Zustandsmatrix Φ durch den Toleranzvektor T_{Tol} . Die Toleranz wird im Folgenden auf $T_{\text{Tol}} = [10.00 \ 1.00]$ festgelegt. Grundlage für die Initialisierung der Zustandsmatrix Φ im PFM ist der aktuell verfügbare Ausgangsvektor Ψ , der durch die AG in einen Zustandsvektor Φ überführt wird. Der ZR wird durch $\pm 3T_{\text{Tol}}$ um den aktuellen Zustandsvektor Φ aufgespannt.




Abbildung 7.31.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit hoher Toleranz.

Abbildung 7.31 zeigt die erste Schätzung nach der Initialisierung basierend auf dem erweiterten Toleranzvektor T_{Tol} . Die Erhöhung des Toleranzvektors T_{Tol} ermöglicht die Abbildung von nicht monoton steigenden Verläufen für den Zustand $State(A)$. Durch das Aufspannen des ZR mit $\pm 3T_{\text{Tol}}$ ist es möglich monoton fallende Verläufe des Zustands $State(A)$ zu erzeugen. Die ZG in Gleichung 7.8 zeigt, dass durch die Multiplikation mit einem Zustandsvektor Φ das negative Vorzeichen nach der Initialisierung für alle zeitlich nachgelagerten Schätzungen erhalten bleibt. Die erweiterte Streuung bei gleicher Partikelanzahl n_{φ} reduziert die Dichte der Partikel und somit bilden wenige Partikel den Zustandsvektor Φ ab.

Für die Qualität der Schätzung ist die Wahl des Toleranzvektors T_{Tol} entscheidend für die effektive Berechnung im PFM, die nicht nur für die Initialisierung, sondern auch für die Gewichtung der Partikel genutzt wird.

Exemplarisch zeigt der Extremfall von sehr großen Einträgen im Toleranzvektor T_{Tol} ,

dass jeder Partikel innerhalb der Toleranz liegt und somit keine Selektivität vorhanden ist. Im Gegensatz dazu bewirken zu kleine Einträge im Toleranzvektor T_{Tol} , dass kaum bzw. kein Partikel innerhalb der Toleranz liegt.




Abbildung 7.32.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit Referenzeinstellungen.

Anhand von Abbildung 7.32 werden die Auswirkungen der Variation des Toleranzvektors T_{Tol} über den Schätzhorizont $h_{\text{Präd}}$ verdeutlicht. Die untere Darstellung zeigt, dass drei Resampling Vorgänge durchgeführt werden. In Folge des ersten Resamplings wird ein Großteil der enthaltenen Partikel Variation verworfen und das Konfidenzintervall von $t_{\text{Konf.}} = 3.42d$ auf $t_{\text{Konf.}} = 1.38d$ reduziert. Übrig bleibt ein Bruchteil der Partikel, die den Degradationsverlauf nicht abbilden. Zur Betriebszeit $t = 79h$ erfolgt ein weiterer Resampling Vorgang, der das Konfidenzintervall auf $t_{\text{Konf.}} = 0.00d$ absenkt. Aufgrund der unzureichenden Abbildung des Zustandsvektors Φ durch die Partikel wird das Gewicht aller Partikel mit $w_p = 0$ bewertet. Dies zeigt auch die obere Darstellung anhand der RUL Schätzung. Die grüne Linie des realRul Szenarios müsste im besten Fall deckungsgleich mit der RUL in Schwarz sein. In der zweiten Hälfte der Schätzung beträgt das Residuum der RUL konstant $res_{\text{RUL}} = 2.92d$. Infolgedessen ist die Abbildung der Realität durch die Partikel des PFM nicht gegeben.

Wenn kein Partikel die Realität in geeigneter Form wiedergeben kann, wird das PFM abgeschaltet, bis der aktuelle Zyklus abgeschlossen ist und das PFM zurückgesetzt wird. Dies ist eine Sicherheitsmaßnahme, um die Aussagekraft zu stärken und bei zu großen Ungenauigkeiten keine Schätzung auszugeben. Aus diesem Grund werden anstelle der 200 verfügbaren Simulationsdaten lediglich 79 geschätzt.

Abbildung E.1 visualisiert die Ergebnisse auf Basis der erhöhten Werte des Toleranzvektors T_{Tol} . Die Reduzierung der Partikel durch das erste Resampling erfolgt qualitativ

analog zu Abbildung 7.32. Das Konfidenzintervall wird durch das Resampling von $t_{\text{Konf.}} = 7.54d$ auf $t_{\text{Konf.}} = 1.91d$ reduziert und weist somit eine größere Intensität im Vergleich zu Abbildung 7.32 auf. Bedingt durch die größeren Einträge des Toleranzvektors $T_{\text{Tol.}}$ wird das PFM erst zur Betriebszeit $t = 110h$ abgeschaltet. Besonders mit dem Fokus auf die Bildung einer Grundlage für eine industrielle Handlungsempfehlung ist die größtmögliche Minimierung des Toleranzvektors $T_{\text{Tol.}}$ naheliegend.




Abbildung 7.33.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 13h$ auf Basis synthetischer Daten ohne Rauschen mit niedriger Toleranz.

Die Schätzung der RUL weicht mit einem Residuum von $res_{\text{RUL}} = 2.92d$ stark von der RUL ab und ist für eine Handlungsempfehlung nicht geeignet. Dies weist auch auf das Problem von PI hin, das in Abbildung 7.33 visualisiert wird. Die Schätzung des Zustands $State(A)$ zur Betriebszeit $t = 13h$ zeigt, dass alle $n_{\varphi} = 500$ Partikel in einer Zustandstrajektorie zusammenfallen, sodass keine Variation zwischen den Partikeln enthalten ist. Dieses frühe PI wird auch durch den zeitlichen Verlauf des geschätzten Parametertensors Θ deutlich, der exemplarisch für Parameter 2 anhand von Abbildung E.3 vorgestellt wird. Die Abbildung zeigt, dass infolge des zweiten Resamplings die zuvor bereits reduzierte Variation von Parameter 2 vollständig entfernt wird.

Insgesamt ist die initiale Wahl von der Parametermatrix Θ und Zustandsmatrix Φ von grundlegender Bedeutung für den erfolgreichen Betrieb des PFM. In diesem Zusammenhang ist auch die Wahl des Toleranzvektors $T_{\text{Tol.}}$ sowohl für die Initialisierung als auch die darauffolgenden Berechnungen von Bedeutung.

Eine geeignete Initialisierung wird anhand von Abbildung E.2 vorgestellt. Die Übersicht der RUL Schätzung basiert auf einem reduzierten PR zur Initialisierung der Parametermatrix Θ in Kombination mit einem geeigneten Toleranzvektors $T_{\text{Tol.}}$. Das Ergebnis ist eine deutlich verbesserte Schätzung, die insbesondere die Notwendigkeit einer möglichst präzisen Initialisierung des PFM unterstreicht.

Die diskutierten Beispiele verdeutlichen, dass das PFM mit Referenzeinstellungen keine Möglichkeit besitzt eine fehlerhafte Initialisierung zu korrigieren.

7.2.3. Variation der Partikel

Auf Basis der Diskussion zur Initialisierung des PF folgt die Fragestellung, wie eine nicht ideale Initialisierung während des Betriebs korrigiert werden kann, die mit dem Aspekt des PI eng verbunden ist. Im Folgenden werden die Ergebnisse auf Basis der Referenzeinstellungen mit der Variation der Partikel durch Roughening ergänzt. Zur Vergrößerung der Variation wird das in Unterkapitel 4.4.5 vorgestellte uniforme Roughening mit einer Intensität von 5% angewendet.




Abbildung 7.34.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.

Abbildung 7.34 zeigt, dass im Vergleich zu Abbildung 7.32 eine Verbesserung durch das uniforme Roughening erreicht wird. Trotz der anfänglichen Unterschätzung der RUL von $res_{RUL} = -3.54d$ nähert sich die Schätzung sukzessive der RUL an. Zur Betriebszeit $t = 28h$ beträgt das Residuum der RUL Schätzung $res_{RUL} = -1.5d$. Die Basis für die Verbesserung der Schätzung ist die Möglichkeit der Exploration. Das heißt, dass ein Partikel, der das Degradationsverhalten im Wesentlichen abbildet, als Grundlage benutzt wird, um zufällige neue Kombinationen daraus abzuleiten. Bei einer großen Anzahl von Partikeln sowie einer ausreichend langen Betriebszeit nähert sich der PF somit einem lokalen Optimum an. Das Residuum der RUL wird somit über die Zeit reduziert, allerdings konvergiert die Schätzung erst am Ende des Simulationszeitraums bei Betriebszeit $t = 160h$ gegen die RUL.

Die zweite Darstellung in Abbildung 7.34 zeigt, dass in jedem Schritt das Resampling durchgeführt wird. Dies ist für das Explorationsverhalten des PF vorteilhaft, da mit jedem Resampling Vorgang auch ein Roughening stattfindet. Anhand der ESS sowie der singulären Partikel ist zu erkennen, dass der Großteil der Partikel nicht die Realität

abbildet. In diesem Zusammenhang kann eine hohe Intensität des Roughenings zu Partikeln führen, die sehr weit von dem ursprünglichen Partikel entfernt sind. Somit ist eine zu hohe Intensität des Roughenings die Ursache für häufiges Resampling.




Abbildung 7.35.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 50h$ auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.

Exemplarisch zeigt Abbildung 7.35 die Schätzung des Zustands $State(A)$ zur Betriebszeit $t = 50h$. Die Veränderung des Zustands $State(A)$ wird qualitativ richtig wiedergegeben, wobei die Variationen aufgrund des Roughenings vielfältig sind. Die Explorationsfähigkeit wird anhand von Abbildung E.4 herausgestellt. Von dem anfänglich festgelegten Schwerpunkt des Parametervektorelements $\Theta(1) \approx 6e - 3$ iteriert der PF stetig an den unteren Rand des PR.

Eine weniger aggressive Strategie zur Variation der Partikel ist das normalverteilte Roughening. Anhand von Abbildung E.5 ist zu erkennen, dass die Schätzqualität im Vergleich zum uniformen Roughening nicht verbessert wird. Der wesentliche Grund für die vermeintlich schlechte Annäherung an die RUL ist die geringere Explorationseigenschaft des normalverteilten Roughenings im Vergleich zum uniformen Roughening. Der Vorteil hingegen besteht in der Konzentration der begrenzten Partikel auf einen Bereich um einen erfolgreichen Partikel. Besonders bei hochdimensionalen Parametervektoren Θ ist die Wahrscheinlichkeit eine erfolgreiche Kombination zufällig zu finden gering. Durch die Normalverteilung um einen erfolgreichen Partikel herum befinden sich die meisten Partikel in direkter Umgebung zu den bekannten Partikeln. Problematisch ist in diesem Zusammenhang, dass ausgehend von einem nicht erfolgreichen Partikel, die Möglichkeiten diesen Bereich zu verlassen begrenzt sind. Im konkreten Fall hat das uniforme Roughening eine bessere Chance zufällig eine geeignete Kombination im Wertebereich des PR zu finden.

Das Erhöhen des Roughening Anteils von 5% auf 25% vergrößert die Explorationseigenschaft bei gleichzeitigem Fokus auf die erfolgreichen Partikel. Abbildung 7.36 zeigt,




Abbildung 7.36.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen und mit 25% normalverteiltem Roughening.

dass mit Erhöhung der Intensität des normalverteilten Roughenings ähnliche Ergebnisse, verglichen mit dem uniformen Roughening von 5% in Abbildung 7.34, erreicht werden. Besonders der Vergleich der Anfangsphase bis zur Betriebszeit $t = 35h$ zeigt, dass das normalverteilte Roughening, bei geringen Unterschieden in dem Partikelgewichtsvektor W , sich langsamer von dem aktuellen Partikelschwerpunkt wegbewegt, verglichen mit dem uniformen Roughening.

Die singulären Partikel in der unteren Darstellung von Abbildung 7.36 nehmen ab der Betriebszeit $t = 50h$ stetig ab und zur Betriebszeit $t = 100h$ ist nur noch eine sehr geringe Anzahl vorhanden. Durch das Systematic Resampling wird das Bestehen von Partikel, die den realen Zustand nicht abbilden, in der Parameter- Θ bzw. Zustandsmatrix Φ ermöglicht. Durch die Exploration in Folge des Roughenings sinkt die Aussagekraft der Gesamtheit der Partikel über die Zeit.

Die zwei Roughening Methoden geben bei gleicher Intensität die Möglichkeit durch ein uniformes Roughening eine größere Exploration zu erreichen, wobei viele Partikel keine erfolgreichen Parameterkombinationen enthalten. Im Gegensatz dazu bietet das normalverteilte Roughening eine Möglichkeit, um erfolgreiche Partikel zu erhalten und selektiv in der lokalen Umgebung nach besseren Partikeln zu suchen.

7.2.4. Vergleich von Resampling Methoden

Das Systematic Resampling hat die Eigenschaft die Zusammenstellung der Partikel durch die zufällige Auswahl aus dem vorhandenen Partikelset zu variieren. Diese Funktionalität ist sinnvoll, falls der PR des Parameter- Θ bzw. der ZR des Zustandsvektors Φ

klein ist bzw. alle möglichen Kombinationen den Zustand beschreiben. Falls im Partikelset einzelne erfolgreiche Partikel enthalten sind, ist es sinnvoll speziell diese Partikel zu verstärken. Dieses Vorgehen wird auch als Importance Resampling bezeichnet und anhand von Abbildung 7.37 vorgestellt.




Abbildung 7.37.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit 25% normalverteiltem Roughening und Importance Resampling.

Der Vergleich von Abbildung 7.36 und 7.37 zeigt, dass durch das Importance Resampling der Schwerpunkt des Partikelsets während einer Iteration gezielt verlagert werden kann. Dieser Aspekt kommt besonders bei einem heterogenen Partikelset zum Tragen und wird exemplarisch durch die sprunghafte Änderung der RUL Schätzung zwischen Betriebszeit $t = 28h$ und $t = 29h$ verdeutlicht. Durch den Sprung wird das Residuum der RUL von $res_{RUL} = -3.08h$ auf $res_{RUL} = -2.33h$ reduziert.

Im Gegensatz zu Abbildung 7.36 werden die singulären Partikel in Abbildung 7.37 zwischen 200 und 300 Partikeln gehalten. Das bedeutet, dass nach dem Resampling etwa die Hälfte der Partikel den Degradationsverlauf beschreiben.

Mit dem Fokus auf ein schnelles Konvergieren der Schätzung gegen die RUL, ist die zielgerichtete Anpassung des Partikelsets sinnvoll, wobei dessen Qualität stark von der Einstellung des Toleranzvektors T_{Tol} abhängt. Beispielhaft zeigt Abbildung E.6 die Schätzung des Zustands $State(A)$ zur Betriebszeit $t = 75h$. Auf Basis der Ergebnisse in Abbildung 7.37 folgt, dass durch das Importance Resampling nur die besten Partikel ausgewählt und verstärkt werden. Zur Identifikation der Abbildung des Degradationsverhaltens ist diese Eigenschaft hilfreich, wobei die Gefahr des PI durch die konsequente Durchführung des Resamplings weiterhin besteht.

Das Resampling ist ein irreversibler Prozess, bei dem besonders Partikel an den Rändern des PR bzw. ZR unter Umständen nicht mehr durch Roughening wiederhergestellt werden können. Diese Eigenschaft gefährdet den robusten Betrieb im industriellen Umfeld.

7.2.5. Anwendung der Partikeloptimierung

Der Verlust von Partikeln durch das irreversible Resampling schränkt den robusten Betrieb beim Auftreten eines einzigen, nicht optimalen Resamplings deutlich ein. Zur Beschleunigung des Konvergierens der Schätzung des PFM gegen den Zustand, wird die Partikeloptimierung eingeführt.

Abweichend von den vorgestellten Referenzeinstellungen wird ein normalverteiltes Roughening von 5% sowie Importance Resampling für das folgende Unterkapitel definiert. Der Toleranzvektor wird auf die Werte $T_{\text{Tol.}} = [2.50 \ 0.50]$ festgelegt. Für die Partikeloptimierung werden $h_{\text{Opt.}} = 168$ bzw. für die Partikelgewichtsberechnung $h_{\text{Smo.}} = 1$ festgelegt.




Abbildung 7.38.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

In Abbildung 7.38 werden die Ergebnisse der RUL mit einer aktiven Partikeloptimierung vorgestellt. Die obere Darstellung zeigt die Schätzung der RUL auf Basis der synthetischen Daten. Die drei zuvor eingeführten Szenarien spannen den Handlungsraum für den Betreiber auf, wobei die tatsächliche Betriebsweise *realRul* von dem besten-*Bestcase* bzw. dem schlechtesten Betriebsfall *Worstcase* eingerahmt wird. Das Konfidenzintervall entwickelt sich über die Betriebszeit \mathcal{T} und verkleinert bzw. vergrößert

sich je nach Zusammensetzung des Partikelsets. Zu Anfang ist das Residuum der RUL mit $res_{RUL} = -3.54d$ vergleichbar zu den vorherigen Beispielen. Mit jedem Resampling Vorgang wird das Residuum sukzessive abgebaut.

Die Partikeloptimierung unterstützt das Resampling und stellt sicher, dass das Partikelset variantenreich bleibt und verworfene Partikel auf Grundlage der gemessenen Daten reproduziert werden können. Darüber hinaus ermöglicht die Partikeloptimierung, unabhängig von der Anzahl der Partikel, die Abbildung der Degradation durch den bestmöglichen Partikel. Der Sprung in der RUL Schätzung zwischen der Betriebszeit $t = 54h$ und $t = 55h$ wird durch die Partikeloptimierung ermöglicht und reduziert das RUL Residuum von $res_{RUL} = -2.38d$ auf $res_{RUL} = -0.13d$. Im weiteren Verlauf ist die Abweichung zwischen der RUL und deren Schätzung zu jeder Betriebszeit $|res_{RUL}| < 0.17d$.

Der Erfolg der Schätzung durch das PFM geht aus der Vergrößerung der Abstände zwischen den Resampling Vorgängen in der unteren Darstellung hervor. Am Ende des Zyklus erfolgt bei jeder Aktualisierung des PF eine Aktivierung des Resamplings, wobei die RUL Schätzung qualitativ und quantitativ konstant bleibt. Die gegen Ende gesteigerte Frequenz des Resamplings wird durch den starken Zuwachs von $State(A)$ verursacht, da der Toleranzvektor $T_{Tol.}$ über die Betriebszeit t konstant ist.




Abbildung 7.39.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Die Abbildungen 7.39 und E.7 zeigen die Variation der initialisierten Partikel zur Betriebszeit $t = 10h$ für beide Zustände des Zustandsvektors $State$. Das Partikelset bildet sowohl stärkere als auch schwächere Trajektorien im Vergleich zum Degradationsverhalten ab. Die hohe Diversität zu Beginn des Degradationsprozesses drückt sich durch das Konfidenzintervall von $t_{Konf.} = 3.42d$ in Abbildung 7.38 aus. Die Basis für die adaptive Anpassung des PFM bilden die bis zu $h_{Opt.} = 168$ vergangenen Zustandsvektoren $State$, wobei zu Beginn keine Historie verfügbar ist und diese mit jedem Ausgangsvektor $Measure$ anwächst.




Abbildung 7.40.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand $State(A)$ bei $t = 31h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

In Abbildung 7.40 wird das Smoothing des PFM zur Betriebszeit $t = 31h$ dargestellt. Der optimierte Partikel $\mathcal{P}_{Opt.}$ fällt optisch mit dem Verlauf des Zustands $State(A)$ zusammen. Die im Hintergrund befindlichen Trajektorien der anderen Partikel weichen von dem Signalverlauf aufgrund der kurzen Betriebszeit nur gering ab. Dennoch sind Unterschiede in den Steigungen der Trajektorien zu erkennen, die ineinander verschränkt sind und in nachfolgenden Berechnungsschritten divergieren.




Abbildung 7.41.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 31h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Die Schätzung des Zustands $State(A)$ zur Betriebszeit $t = 31h$ wird in Abbildung 7.41 dargestellt. Anhand der Trajektorien der Partikel wird deutlich, dass die meisten Partikel die RUL unterschätzen. Dies unterstreicht die Wichtigkeit einer Partikeloptimierung besonders vor dem Hintergrund, wenn die einzelnen Dimensionen des PR bzw. ZR sehr weit aufgefächert sind. Einige wenige Partikel, unter allen durch das Partikelset abgebildeten Verläufen, geben die Dynamik qualitativ besser wieder und entstammen früheren Optimierungsschritten.

Durch die zeitliche Abfolge der Partikeloptimierung nach dem Resampling ist es möglich, dass der optimierte Partikel $\mathcal{P}_{Opt.}$ durch das Resampling verworfen wird. Der Grund ist, dass das Gewicht des optimierten Partikels $w_{p,Opt.}$ nicht viel größer ist im Vergleich zu den Gewichten der restlichen Partikel und somit die Wahl des Partikels vom Zufall abhängt. Dies ändert sich bei einer größeren Divergenz zwischen dem Zustandsvektor Φ und dessen Schätzung $\hat{\Phi}$.

Zur Betriebszeit $t = 127h$ sind bereits alle Partikel, deren Schätzung $\hat{\Phi}$ stark vom Zustandsvektor Φ abweichen, aus dem Partikelset entfernt worden. Exemplarisch zeigt Abbildung E.8 das Smoothing des Zustands $State(B)$. Alle abgebildeten Trajektorien der zurückgerechneten Zustände bilden einen schlauchförmigen Bereich um den Zustand $State(B)$. Dies zeigt, dass die Partikel die Dynamik in einem hohen Maße abbilden. Beim Auftreten von geringfügigen Abweichungen zwischen Zustand $State(B)$ und dessen Schätzung $State\hat{(B)}$, die innerhalb der festgelegten Toleranz bleiben, wird kein Resampling durchgeführt.




Abbildung 7.42.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 127h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Die starke Adaption des PFM an die Degradationsdynamik wird durch die Prädiktion in Abbildung 7.42 veranschaulicht. Die Schätzung des Zustands $State(B)$ zur Betriebszeit $t = 127h$ zeigt, dass die Partikel an den konkreten Zustandsverlauf angepasst sind.

Der Vergleich der Partikeloptimierung mit einer Roughening Methode kann theoretisch zum gleichen Ergebnis führen. Das Hervorrufen einer gleichwertigen Änderung des Partikelsets durch Roughening benötigt jedoch entweder viele sequenzielle Ausführungen und somit viel Zeit oder viele parallele Versuche und somit viele Partikel. Beide Möglichkeiten sind ressourcenintensiv und aus diesem Grund ist die Partikeloptimierung eine Aufwertung der bekannten PF Methode, ohne sich in den anderen Betriebszuständen nachteilig auf die Rechenleistung auszuwirken.

7.2.6. Einfluss von Störungen

Das PFM ist vom Grundkonzept robust gegenüber Rauschen. Durch die Einstellung des Toleranzvektors T_{Tol} wird das Rauschen berücksichtigt und ermöglicht den Einsatz für industrielle Anwendungsfälle. Um nicht nur eine Robustheit gegenüber dem Mess- bzw. Prozessrauschen zu erhalten, sondern auch gegenüber nicht abgebildeten Strukturen, wird die Berechnung des Gewichtsvektors W über mehrere Zeitschritte eingeführt. Auf Grundlage der zurückgerechneten Trajektorien der Zustandsvektoren Φ kann das spezifische Gewicht $w_{p,t}$ eines Partikels p zum Zeitpunkt t berechnet werden. Üblich ist die Berechnung anhand des letzten Zustands, die anhand von Gleichung 5.5 auf das Zusammenführen einer bestimmten Anzahl vergangener Gewichtsvektoren W erweitert wird.




Abbildung 7.43.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

In Abbildung 7.43 werden die Ergebnisse des synthetischen Datensatzes mit überlagerterem Rauschen vorgestellt. Die Gemeinsamkeit von Abbildung 7.38 und 7.43 ist ein

Unterschätzen der RUL zu Beginn des Degradationsvorgangs. Anhand von Gleichung 7.8 und 7.9 folgt, dass durch das Summieren der Eingänge in der ZG der Großteil der Partikel zu einer Unterschätzung der RUL führt. Je geringer die Änderungsnotwendigkeit des Partikelsets ist, desto schneller kann die Lösung konvergieren. Demzufolge kann die Initialisierung einer uniformen und um den Erwartungswert zentrierten Verteilung den Prozess beschleunigen.

Des Weiteren ist die Änderung des Zustandsvektors *State* am Ende des Degradationszyklus deutlich größer und wird besonders am Anfang durch das additive Rauschen maskiert. In Folge dessen sind am Anfang der Berechnung starke Wechsel in der Erwartungswertschätzung der RUL möglich.




Abbildung 7.44.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand *State* (*A*) bei $t = 52h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Im Folgenden wird der chronologische Verlauf der Schätzung durch das PFM aufgezeigt. Abbildung 7.44 zeigt die Schätzung des Zustands *State* (*A*) zur Betriebszeit $t = 52h$. Basierend auf der initialen Vielfalt sind sowohl sehr flache als auch sehr steile Trajektorien nicht mehr im Partikelset enthalten.

Der weitere Verlauf der Schätzung wird anhand von Abbildung E.9 zur Betriebszeit $t = 76h$ veranschaulicht. Die extremen Trajektorien an den Randbereichen der Abbildung werden deutlich ausgedünnt. Die korrespondierenden Partikel der sehr steilen Zustandstrajektorien werden bis auf wenige Ausnahmen durch Partikel, die die Dynamik abbilden, ersetzt und somit bildet die Vielzahl der 500 Partikel die Charakteristik des Zustands *State* ab.

Abbildung 7.45 stellt die Schätzung zur Betriebszeit $t = 126h$ vor. Nahezu alle Partikel, die den Zustandsvektor *State* nicht innerhalb des festgelegten Toleranzvektors T_{Tol} beschreiben, sind nicht mehr im Partikelset enthalten und werden durch geeignete Partikel ersetzt. Trotz des flachen Verlaufs von Zustand *State* (*A*) in den historischen Daten, wird Zustand *State* (*A*) durch dessen Schätzung $\hat{\text{State}}(A)$ im Wesentlichen abgebildet.

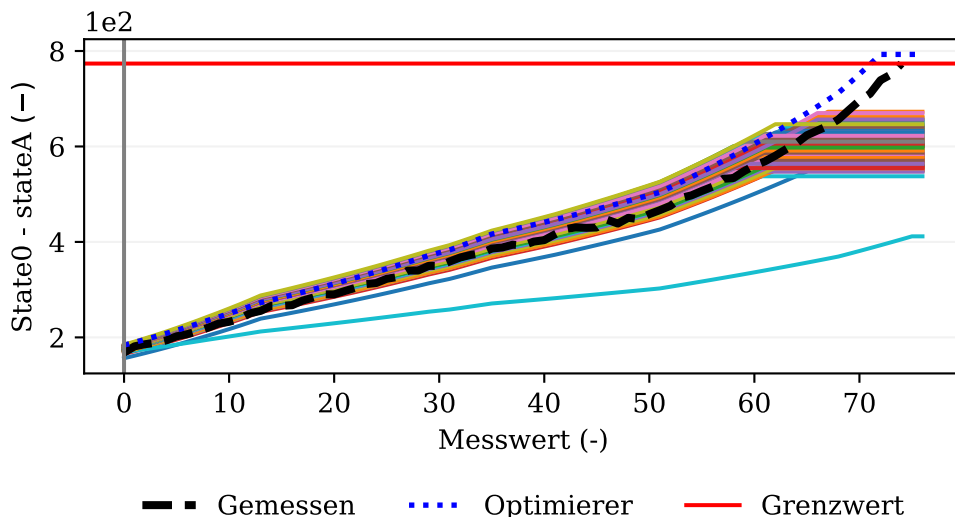


Abbildung 7.45.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 126h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Die Schar der Zustandstrajektorien der Partikel umfasst die zukünftige Entwicklung des Zustands $State(A)$. Das Konfidenzintervall von $t_{\text{Konf.}} = 0.29d$ und einem Residuum der RUL Schätzung von $res_{\text{RUL}} = -0.46d$ zeigen die Güte der Schätzung an.




Abbildung 7.46.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 126h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

Das Schreiben von konstanten Schätzwerten in Abbildung 7.45 ab Messwert 60, zeigt das Überschätzen der Degradation von Zustand $State(B)$ an. Abbildung 7.46 zeigt

die Schätzung des Zustands $State(B)$ zur Betriebszeit $t = 126h$. Die Vermutung der Unterschätzung wird durch das Schneiden des Grenzwerts $\Omega_{\Phi}(B)$ bei Messwert 60 belegt. Auf Grundlage des sehr guten optimierten Partikels, wird das Partikelset durch die Partikeloptimierung in den nachfolgenden Schätzungen verbessert.

Durch die Aktivierung der Berechnung über das Zeitfenster h_{smoo} wird die Aussagekraft der Abweichung gemittelt. Im Hinblick auf enthaltene Strukturen ermöglicht dies die robuste Abbildung des zu schätzenden Zustandsvektors $\hat{\Phi}$ ohne das vorschnelle Ersetzen von vermeintlich schlechten Partikeln. Besonders bei kurzen Zyklen wird dadurch jedoch die Reaktionszeit vergrößert, bis die Unterschiede innerhalb des Gewichtsvektors W groß genug sind.

Während eines Großteils der Überwachungsphase ist die generelle Charakteristik des Systems bekannt. Besonders vor dem Hintergrund von Anomalien oder kleinen Änderungen wird deutlich, dass die Optimierung der Partikel notwendig ist, um die Schätzqualität kontinuierlich zu verbessern und das Partikelset mit neuen Partikeln ausstatten zu können.

7.2.7. Diskussion des Partikelfiltermoduls auf synthetischen Daten

Der vorgestellte synthetische Datensatz bietet eine hohe Vergleichbarkeit mit realen Degradationsvorgängen in der chemischen Industrie. Neben beliebig vielen Eingängen und Zuständen können vielfältige Eigenschaften synthetisch generiert werden.

Die Schätzung eines exponentiellen Degradationsverlaufs ist eine Herausforderung, die maßgeblich durch die Initialisierung des PF bestimmt wird. Sowohl der Toleranzvektor T_{Tol} als auch die Beschränkung durch den unteren- $\Theta_{\text{U.Grenz}}$ und oberen Parametergrenzvektor $\Theta_{\text{O.Grenz}}$ sind wesentliche Einflussfaktoren für eine möglichst präzise Schätzung.

Durch die Diskussion von verschiedenen Einflussmöglichkeiten werden Herausforderungen sichtbar. Dazu gehört unter anderem die Variation der Partikel, die korrekt zwischen einer lokalen- und einer globalen Strategie eingestellt wird. Darüber hinaus ist ein wichtiger Aspekt die Wahl des Resamplingalgorithmus. Besonders bei einem großen PR bzw. ZR ist es notwendig unpassende Partikel wirksam aus dem Partikelset auszuschließen. Dies zeigt das Spannungsfeld zwischen keiner und einer rigorosen Selektivität auf.

Die Evaluation anhand des realitätsnahen Datensatzes mit überlagertem Rauschen zeigt, dass die generelle Funktionsweise des PFM mit Partikeloptimierung auch unter anspruchsvollen Bedingungen gegeben ist. Zu Beginn verzerrt das in den Ausgängen enthaltene Rauschen die Schätzung des aktuellen Zustands $\hat{\Phi}_{\text{Akt}}$. Aufgrund der geringen Anzahl an vergangenen Ausgangsvektoren Ψ_t am Anfang eines Zyklus, ist die Partikeloptimierung nur eingeschränkt möglich und wird mit jedem zusätzlichen Ausgangsvektor Ψ genauer.

Die Partikeloptimierung ist ein wirksames Mittel um besonders in nicht perfekten Anwendungsfällen einen robusten Betrieb zu ermöglichen. Besonders bei der Änderung des Verhaltens während des Betriebs oder einem weiten PR bzw. ZR, ist die Partikeloptimierung eine ressourcenschonende Alternative zur Erhöhung der Partikelanzahl oder mehrfachen Wiederholung des Resamplings.

Vor dem Hintergrund, dass verhältnismäßig lange Schätzhorizonte $h_{\text{Präd.}}$ geschätzt werden, ergibt sich ein großer Hebel, der zu einer starken Abweichung in der Schätzung des Zustandsvektors $\hat{\Phi}$ und der daraus abgeleiteten RUL führen kann. Die Herausforderungen wachsen mit der Anzahl der Zustände n_{Φ} bzw. Anzahl der zu schätzenden Parameter n_{Θ} . Der kontinuierliche Vergleich sowie die stetige Verbesserung der Schätzung durch das PFM sind die Basis für die Nutzung und Akzeptanz in industriellen Anwendungsfällen.

8. Onlinesimulation

Innerhalb dieses Kapitels wird die Leistungsfähigkeit der in Kapitel 5 entwickelten Überwachungskonzepte auf Basis der Anwendungsfälle aus Unterkapitel 3.2 evaluiert. In Unterkapitel 8.1 werden die Anwendungsfälle des ETM vorgestellt. Analog wird in Unterkapitel 8.2 der Anwendungsfall des PFM vorgestellt.

8.1. Ergebnisse des Einzeltrendmoduls

Das ETM wird anhand von zwei Anwendungsfällen bewertet. Als Grundlage für die Modellauswahl innerhalb des ETM wird die R^2_{Adj} Metrik ausgewählt. Zunächst werden in Unterkapitel 8.1.1 die Ergebnisse des HDMP Anwendungsfalls aus Unterkapitel 3.2.2 vorgestellt. In Unterkapitel 8.1.2 wird die Leistung des ETM auf Basis des ÖF Anwendungsfalls aus Unterkapitel 3.2.1 diskutiert. Unabhängig von dem konkreten Anwendungsfall wird die Messung mit der Degradationsinformation als Singal S bezeichnet.

8.1.1. Ergebnisse des Membranpumpen Anwendungsfalls

Bedingt durch die Degradation der Membran ergeben sich am Anfang längere Zyklen im Vergleich zu den kurzen Zyklen einer gealterten Membran. Beide Aspekte werden nachfolgend aufgegriffen, wobei die Fälle „kurzer Zyklus“ und „langer Zyklus“ unterschieden werden. Auf Basis von Expertenwissen des Betreibers werden folgende Parameter in Tabelle 8.1 festgelegt.

Tabelle 8.1.: Tabellarische Auflistung der Einstellungen des Einzeltrendmoduls zur Überwachung des realen Membranpumpen Anwendungsfalls.

Eigenschaft	Einstellung
Anzahl historischer Werte n_{Mess} .	300
Konfidenzintervall	5% - 95%
Einschaltwert ω_{Ein} .	0.5bar
Grenzwert ω_S	2bar
Monotonie	steigend

Membranpumpen-Datensatz - Funktion: alle, Zyklus: lang

Zur Evaluierung des ETM wird zyklweise der Maximalwert als Grenzwert ω_S gesetzt, da das Signal S der langen Zyklen den zuvor definierten Grenzwert nicht erreicht.




Abbildung 8.1.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Die Ergebnisse werden anhand von Abbildung 8.1 vorgestellt. Im Hinblick auf die RUL Schätzung gilt für alle drei Zyklen, dass sich die Schätzung der realen RUL annähert. Besonders im dritten Zyklus wird die RUL mit einer mittleren positiven Abweichung von $res_{RUL} = 27.1h$ überschätzt. Die Ursache liegt anteilig in dem frühen schwankungsbedingten Erreichen des Grenzwertes ω_S durch das Signal S . Die Schätzung des ersten Zyklus pendelt zunächst um den Wert der RUL, um dann bedingt durch eine Anomalie im Signal S , eine maximale Abweichung von $res_{RUL} = 193h$ zu erreichen. Insgesamt wird der Signaltrend qualitativ korrekt geschätzt und bis auf Ausnahmen spiegelt der Erwartungswert der RUL am Ende der Zyklen die RUL wider.

Im Hinblick auf die Funktionsauswahl wird besonders die polynomische Funktion zur Abbildung verwendet. Neben einzelnen Abweichungen findet besonders im ersten Zyklus eine Modellbildung anhand eines linearen Modells statt. Die sich daraus ergebenden

Werte der Metrik sind im Mittel bei $R^2_{\text{Adj.}} = 0.83$. An den Übergängen bricht die Metrik auf einen Wert von bis zu $R^2_{\text{Adj.}} = 0.34$ ein. Diese Eigenschaft ist auf Grundlage der Evaluation auf synthetischen Daten bekannt und kennzeichnet die geringe Modellgüte. Für die Überwachung ist die $R^2_{\text{Adj.}}$ Metrik ein wichtiger Qualitätsindikator, der die Interpretation der Ergebnisse und Handlungsableitung unterstützt.

In der untersten Darstellung werden die drei diskutierten Zyklen unterschiedlicher Länge sowie deren jeweiliger Grenzwert ω_S vorgestellt. Der gemessene Membraninnendruck S zeigt ein sägezahnförmiges Verhalten, das durch einen kontinuierlichen Anstieg während des Betriebs sowie durch die Entspannung des Membraninnendrucks in kurzen Abstellungen entsteht. Das Signal S weist neben einem erkennbaren Trend auch ein starkes überlagertes Muster auf. Dieses ergibt sich durch die geringe Auflösung der Messung und Anomalien.




Abbildung 8.2.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5338h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

In Abbildung 8.2 wird die Schätzung des Membraninnendrucksignals S sowie dessen Schätzung zur Betriebszeit $t = 5338h$ vorgestellt. Die letzten 300 Messwerte umfassen im Wesentlichen den vorherigen Zyklus. Besonders der stufenförmige Anstieg des Signals S im vergangenen Zyklus zeigt die Funktion der CP Detektion deutlich auf. Jede sprunghafte Änderung wird als ein möglicher Wechselpunkt detektiert. Für die Modellbildung wird der CP bei Messwert $\hat{i} = -50$ gewählt. Auf Basis der verbleibenden $n_{\text{Mess., Train.}} = 50$ Messwerte für das Training ist eine erste frühe Schätzung möglich. Die Schätzung \hat{S} bildet das Signal bis Messwert 100 ab, wobei das Signal S danach abflacht. Daraus resultiert eine Unterschätzung der RUL von $res_{\text{RUL}} = -84h$.




Abbildung 8.3.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Abbildung 8.3 zeigt, dass das ETM Anteile der abflachenden Kurve im Signal S detektiert und die Schätzung anpasst. Das Signal S wird gut durch die Schätzung repräsentiert und die RUL mit $res_{RUL} = 11h$ Differenz nahezu exakt bestimmt. Auf Basis der zusätzlichen Informationen in Abbildung F.1 folgt, dass das vergangene Residuum Res_S gleichmäßig verteilt ist. Dies trifft auch für den Beginn des zukünftigen Residuums $Res_{S,Zuk.}$ bis Messwert 50 zu. Im Anschluss weist die Grafik eine positive Abweichung vom Mittelwert aus, die erst am Ende des zukünftigen Residuumsignals $Res_{S,Zuk.}$ wieder in den Bereich des vergangenen Residuums Res_S zurückgeht. Auch im Hinblick auf die Verteilung lässt sich diese Anomalie im Histogramm mit einem von 0 abweichenden Mittelwert des zukünftigen Residuumsignals $Res_{S,Zuk.}$ feststellen. Im weiteren Verlauf wechselt das ETM basierend auf mehr Messdaten bei Betriebszeit $t = 5458h$ zu einem linearen Modell in Abbildung F.3. Als Reaktion auf die Anomalie innerhalb des Signals S verdeutlicht Abbildung F.4, dass zur Betriebszeit $t = 5482h$ die Messwerte durch eine polynomische Funktion abgebildet werden. Durch die Anomalie wird die RUL aufgrund der gekrümmten Funktion mit $res_{RUL} = 134h$ überschätzt.

Im Rahmen weiterer Schätzungen wird die Anomalie sukzessive ausgeglichen, wie Abbildung 8.4 zur Betriebszeit $t = 5578h$ zeigt. Trotz einer sehr guten Abbildung der Messwerte, wird durch den flachen Verlauf sowie das starke Muster im Signal S die RUL mit $res_{RUL} = 57h$ überschätzt. Das Konfidenzintervall zeigt mit $t_{Konf.} = 22h$ an, dass die zufällige Messdatenwahl wenig Variation hinsichtlich der Abbildung ermöglicht. Die Aussagen gelten analog für die Schätzung des zweiten Zyklus. Exemplarisch wird in Abbildung F.5 die Schätzung des Signals \hat{S} zur Betriebszeit $t = 5749h$ vorgestellt. Neben der korrekten Auswahl des CP wird auch der Verlauf sehr gut abgebildet und die RUL mit $res_{RUL} = 27h$ überschätzt.

Die Schätzung des Signals \hat{S} wird anhand des dritten Zyklus zur Betriebszeit $t = 5914h$ in Abbildung 8.5 dargestellt. Das Verhalten wird auf Basis von $n_{Mess.,Train.} = 100$ Mess-




Abbildung 8.4.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5578h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung 8.5.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5914h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

werten für das Training qualitativ gut beschrieben und die RUL von $t_{RUL} = 119h$ mit $res_{RUL} = -10h$ unterschätzt. Innerhalb der Grafik werden anteilig drei Zyklen dargestellt und dennoch wird der korrekte CP für die Modellbildung ausgewählt. Durch einen größeren Umfang an Messdaten wird die Schätzung präzisiert, wie Abbildung F.2 zur Betriebszeit $t = 5986h$ zeigt. Das Konfidenzintervall wird im Vergleich zu Abbildung 8.5 von $t_{Konf.} = 32h$ auf $t_{Konf.} = 24h$ reduziert. Die RUL wird mit $res_{RUL} = 37h$ überschätzt, das durch das Rauschen und dem damit verbundenen verfrühten Erreichen des Grenzwerts ω_S bei Messwert $50h$ zurückzuführen ist. Dies erklärt die konstante Überschätzung in Abbildung 8.1, trotz einer sehr guten Schätzung.

Membranpumpen-Datensatz - Funktion: alle, Zyklus: kurz

Nicht nur innerhalb eines Zyklus, sondern zyklenübergreifend verändern sich die Eigenschaften der Membran mit fortgeschrittener Degradation. Einen Überblick über diesen Prozess sowie die Ergebnisse der RUL Schätzung ist in Abbildung 8.6 dargestellt.




Abbildung 8.6.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Die Schätzung des Erwartungswerts der RUL in der oberen Darstellung von Abbildung 8.6 zeigt, dass die Schätzung nach einer kurzen Einlaufphase zu einer Überschätzung neigt. Im Anschluss nähert sich die Schätzung asymptotisch der RUL an. Sowohl der erste wie auch der dritte Zyklus weisen beispielsweise zur Betriebszeit $t = 8746h$ und $t = 8938h$ zu Beginn des Zyklus einen kurzen Einbruch auf.

Zur Modellbildung in den frühen Degradationsphasen des ersten und dritten Zyklus werden häufig quadratische Funktionen verwendet. Anschließend werden für ein kurzes Zeitintervall lineare Abbildung gewählt, die im Folgenden durch verschiedene Funktionen höherer Ordnung abgelöst werden.

Die unterste Darstellung in Abbildung 8.6 zeigt drei Zyklen, wobei der zweite Zyklus aufgrund der vorzeitigen Abschaltung und dessen kurzen Betriebslänge nicht im Detail

diskutiert wird. Die Heterogenität der Verläufe wird durch den mittleren Signalgradienten verdeutlicht, der selbst im linearen Teil der Degradation mehr als Faktor drei größer ist.

Aus dem Vergleich zwischen Abbildung 8.6 und 8.1 folgt, dass das annähernd lineare Verhalten der langen Zyklen in einen nichtlinearen Verlauf übergeht.




Abbildung 8.7.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8776h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Die Schätzung durch das ETM wird anhand des dritten Zyklus zur Betriebszeit $t = 8776h$ in Abbildung 8.7 vorgestellt. Insgesamt werden drei Zyklen im Betrachtungszeitraum abgebildet und die wesentlichen CP der Sprünge des Membraninnendrucks identifiziert. In einigen Teilabschnitten, zum Beispiel zwischen Messwert -250 und -180 , wird nur ein CP identifiziert und somit der Rechenaufwand reduziert. Die Modellbildung basiert auf einem kurzen Teilstück von $n_{\text{Mess.,Train.}} < 50$ Messwerten, auf deren Grundlage eine lineare Funktion ausgewählt wird. Die Schätzung des Signals \hat{S} stimmt in guter Näherung mit der Entwicklung bis Messwert 65 überein. In Folge der linearen Abbildung überschätzt das ETM die RUL mit $res_{\text{RUL}} = 13h$, da das Degradationsverhalten zu diesem Zeitpunkt noch nicht identifiziert werden kann.

Exemplarisch wird die Identifikation des nichtlinearen Zusammenhangs anhand von Abbildung 8.8 zur Betriebszeit $t = 8824h$ gezeigt. Der geschätzte Signalverlauf ist nahezu deckungsgleich mit dem gemessenen Signal S und weist nur eine sehr geringe Abweichung auf. Als Konsequenz ist das Residuum der RUL mit $res_{\text{RUL}} = 5h$ sehr gering. Für die Modellierung wird ein CP gewählt, der sich etwa $res_{\text{CP}} = 10$ Messwerte nach dem sprunghaften Wechsel zwischen den Zyklen befindet. Die Ursache ist die Änderung von einem konvexen hin zu einem konkaven Kurvenverlauf. Um den Fehler des Modells zu reduzieren, wird automatisch ein späterer CP ausgewählt, der durch die verfügbaren Funktionen besser abgebildet werden kann.

Eine nichtlineare Modellbildung wird in Abbildung 8.9 zur Betriebszeit $t = 8962h$




Abbildung 8.8.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8824h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung 8.9.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8962h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

vorgestellt. Die 255 Messwerte der vergangenen Zyklen sind nicht für die Modellbildung geeignet. Trotz wenigen verbleibenden Messwerten wird die nichtlineare Eigenschaft des Signals S identifiziert. Die RUL wird mit $res_{RUL} = -11h$ unterschätzt und weist durch ein Konfidenzintervall von $t_{Konf.} = 9h$ die Unsicherheit des Modells aus.

Die Kombination von Abbildung 8.9 und 8.6 zeigt, dass der dritte Zyklus zwischen der Über- und Unterschätzung der RUL wechselt. Der Vergleich von Abbildung 8.9 und 8.7 weist die Abhängigkeit der Funktionsauswahl von der Anzahl an Messwerten aus. Dieser Freiheitsgrad und das damit verbundene Verhalten sind gewünscht und kennzeichnen den adaptiven Charakter des ETM.

Membranpumpen-Datensatz - Funktion: exponentiell, Zyklus: lang

Basierend auf der zuvor vorgestellten Überwachung ohne Einschränkung der Funktionen für die Modellbildung, werden nachfolgend die langen Zyklen mit der Einschränkung auf eine exponentielle Funktion vorgestellt.




Abbildung 8.10.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Abbildung 8.10 gibt einen Überblick der Ergebnisse auf Basis des ETM. Im Vergleich zu Abbildung 8.1 verdeutlicht die oberste Darstellung ein früheres Annähern der Schätzung an die RUL. Die anfängliche Überschätzung im ersten Zyklus wird wirkungsvoll vermieden, es zeigt sich jedoch besonders zu Beginn eine Unterschätzung. Eine Ausnahme stellt die Anomalie zur Betriebszeit $t = 5482h$ innerhalb des ersten Zyklus dar, die zu einer Überschätzung der RUL von $res_{RUL} = 2085h$ führt. Der dritte Zyklus bildet die RUL in einem sehr hohen Maß ab und kann die Vorhersagequalität im Vergleich zur Modellbildung auf Basis von allen verfügbaren Funktionen deutlich steigern.

Bedingt durch die Beschränkung der Funktionen wird die Aussagekraft der R^2_{Adj} Metrik gestärkt. In den Anfangsbereichen der Zyklen ist die R^2_{Adj} Metrik häufig kleiner als 0,

da in diesen Bereichen die Messwerte nicht durch eine exponentielle Funktion abgebildet werden können. Beispielsweise kann zur Betriebszeit $t = 5314h$ kein Modell erstellt und somit auch keine RUL ausgegeben werden. Der Vergleich mit der Berechnung zur Betriebszeit $t = 5842h$ zeigt, dass ein Modell gebildet werden kann, das aufgrund einer Metrik von $R^2_{Adj.} = -0.13$ jedoch nicht valide ist. Die Metrik ermöglicht somit die Differenzierung der nicht validen Berechnung als Basis für die weitere Verarbeitung. Das Residuum der RUL in der dritten Darstellung wird durch die $R^2_{Adj.}$ Metrik qualitativ sehr gut widerspiegelt und verdeutlicht, dass besonders die Enden des ersten und dritten Zyklus mit Residuen der RUL von $res_{RUL} < 20h$ geschätzt werden.

Abbildung F.6 zeigt die Schätzung des Erwartungswerts anhand des ersten Zyklus des Membraninnendrucks. Die Gegenüberstellung des gemessenen Signals S mit dessen Schätzung \hat{S} verdeutlicht die Anomalie im Bereich von Messwert 20 bis 70. Die große Sensitivität der Parameter der exponentiellen Funktion wird anhand des sich aufspreizenden Konfidenzintervalls von $t_{Konf.} = 43h$ belegt. Das durch eine exponentielle Funktion abgebildete Signal S führt bei dessen Schätzung innerhalb des Schätzhorizonts $h_{Präd.}$ zu einem nahezu linearen Verlauf.




Abbildung 8.11.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Im weiteren Verlauf erfolgt die Abbildung des Signalabschnitts, der die Anomalie enthält. Abbildung 8.11 stellt die Schätzung zur Betriebszeit $t = 5482h$ dar, die ein deutliches Überschätzen durch die Modellbildung mittels einer exponentiellen Funktion kennzeichnet. Die geringe Anzahl an Messwerten für die Modellbildung ist in Kombination mit der Struktur sowie dem Plateau im Signal S die Grundlage für die Abbildung eines sehr flachen Signalverlaufs. Die exponentiellen Eigenschaften werden erst zu einem späteren Zeitpunkt auch visuell sichtbar. Der durch die Anomalie verfälschte sehr flache Verlauf ist die Ursache für die nicht valide Schätzung der RUL von $t_{RUL} = 2231h$. Basierend auf dem heterogenen Signalverlauf sowie dem geringen Messwertumfang ergeben sich für die Beschreibung des Konfidenzintervalls sehr unterschiedliche Tra-

jektorien. Die große Variation führt dazu, dass die Trajektorie zur Beschreibung des unteren Konfidenzintervalls bereits etwa bei Messwert 1200 den Grenzwert ω_S erreicht. Der Grenzwert ω_S wird durch die Schätzung des Signals \hat{S} etwa bei Messwert 2200 überschritten. Bedingt durch die iterative Fortführung der Berechnung bis auch die Trajektorie des oberen Konfidenzintervalls den Grenzwert ω_S überschreitet, erreicht die Funktionen des unteren Konfidenzintervalls den numerischen Sättigungsbereich und die Berechnung kann nicht bis Messwert 2200 fortgesetzt werden.

Die Überschätzung des ETM wird mit Durchschreiten der Anomalie innerhalb von 48h angepasst. Zur Betriebszeit $t = 5530h$ gibt das ETM eine valide Schätzung des Signals \hat{S} mit einem korrigierten Konfidenzintervall aus, die in Abbildung F.7 dargestellt wird.




Abbildung 8.12.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5962h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Abbildung 8.12 zeigt exemplarisch eine Schätzung des dritten Zyklus zur Betriebszeit $t = 5962h$. Der für die Modellbildung verwendete CP befindet sich nicht direkt am Übergang zwischen den zwei Zyklen, sondern mit $res_{CP} \approx 20$ Messwerte danach. Innerhalb der ersten Messwerte eines Zyklus baut sich der Membraninnendruck zunächst schnell und danach immer langsamer auf. Diese Aufbauphase des Signals S wird für die Modellbildung nicht berücksichtigt. Das führt zu einer verbesserten Abbildung des Signals S und wirkt sich somit auch positiv auf die Schätzung der RUL aus. Trotz der Ähnlichkeit des geschätzten Signals \hat{S} zu einer linearen Funktion werden die exponentiellen Eigenschaften anhand des Konfidenzintervalls deutlich. Mit einem Konfidenzintervall von $t_{Konf.} = 26h$ sowie einer Metrik von $R^2_{Adj.} = 0.74$ ist vor dem Hintergrund der deutlichen Strukturen im Signal S die Schätzung valide.

Membranpumpen-Datensatz - Funktion: exponentiell, Zyklus: kurz

Im Folgenden wird die RUL Schätzung auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes mit der Beschränkung auf exponentielle Funktionen untersucht und anhand von Abbildung 8.13 dargestellt.




Abbildung 8.13.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Die Schätzung des Erwartungswerts der RUL wird in der obersten Darstellung abgebildet. Aufgrund der geringen Messwertanzahl schwankt die Schätzung der RUL zunächst um den Wert der RUL. Mit steigender Anzahl an Messwerten nähert sich die Schätzung asymptotisch der RUL. Im Vergleich zu Abbildung 8.6 werden die Schwankungen durch die Beschränkung der möglichen Funktionen anteilig minimiert und die Vorhersagequalität somit verbessert. Mit dem Fokus auf den gesamten Zeitraum ist eine deutliche Überschätzung der RUL innerhalb des zweiten Zyklus festzustellen.

Die Beschränkung auf exponentielle Funktionen verbessert die Aussage über die Qualität des Modells anhand der $R^2_{Adj.}$ Metrik. Die zweite Darstellung von oben in Abbildung 8.13 zeigt, dass die $R^2_{Adj.}$ Metrik besonders zu Beginn der Zyklen Werte von $R^2_{Adj.} = 0$ ausweist. Die Zeitenintervalle, in denen die geringen Metriken vorkommen, spiegeln

die Bereiche wider, in denen kein valides Modell erstellt werden kann. Dies ist eine eindeutige Indikation, dass die Messwerte in diesem Bereich nicht durch eine exponentielle Funktion abgebildet werden können und die Ergebnisse nicht vertrauenswürdig sind. Im zeitlichen Verlauf steigt die R^2_{Adj} Metrik an und liegt im Mittel über allen drei Zyklen ohne die voreingestellten Werte bei $R^2_{Adj} = 0.84$.

Die Klassifikation durch die R^2_{Adj} Metrik fällt mit der Aussage des Residuums aus der dritten Darstellung zusammen. Demnach sind die zuvor benannten Schwankungen der RUL Schätzung innerhalb des Residuums vorhanden, jedoch können die validen Betriebszeiten anhand der R^2_{Adj} Metrik ausgewählt werden.

In der untersten Darstellung werden die kurzen Zyklen des Membranpumpeninnendruckes als Referenz veranschaulicht. Insbesondere der Vergleich des ersten und dritten Zyklus verdeutlicht die Beschleunigung der Degradation mit zunehmender Betriebszeit.




Abbildung 8.14.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8914h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Die deutliche Überschätzung der RUL zur Betriebszeit $t = 8914h$ wird anhand der Schätzung des Signals \hat{S} in Abbildung 8.14 veranschaulicht. Die Abbildung zeigt eine Schätzung innerhalb des zweiten Zyklus, die mit einem Residuum der RUL von $res_{RUL} = 52h$ von den vorherigen Schätzungen abweicht. Zum Zeitpunkt der Schätzung sind 25 Messwerte des zweiten Zyklus bekannt. Bedingt durch den konkaven Druckaufbau am Anfang des Zyklus werden mehrere CP detektiert. Die Modellbildung des linearen Anteils mit etwa 15 Messwerten führt, verglichen mit der Wahl eines früheren CP, zu einer schlechteren R^2_{Adj} Metrik. Aus diesem Grund wird ein CP zwei Zyklen vor dem aktuellen Zyklus ausgewählt und die R^2_{Adj} Metrik mit einem Wert von $R^2_{Adj} = 0.25$ maximiert. Die Schätzung der RUL wird mit $res_{RUL} = 52h$ deutlich überschätzt. Der Vergleich mit den zwei weiteren Zyklen anhand der R^2_{Adj} Metrik liefert für die Betriebszeit $t = 8854h$ sowie $t = 8992h$ Werte von $R^2_{Adj} = 0.99$. Somit ist die Schätzung zur Betriebszeit $t = 8914h$ sowie der zweite Zyklus in Gänze nicht valide und wird für die Handlungsempfehlung verworfen.




Abbildung 8.15.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8962h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.




Abbildung 8.16.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8824h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.

Im weiteren zeitlichen Verlauf wird die Membran entlüftet und zur Betriebszeit $t = 8962h$ erfolgt eine Schätzung des Signalverlaufs, die in Abbildung 8.15 vorgestellt wird. Zu dem Zeitpunkt der Schätzung liegen etwa 60 Messwerte aus dem dritten Zyklus vor. Analog zu Abbildung 8.14 wird der nichtlineare Druckaufbau für die Modellbildung nicht berücksichtigt. Auf Basis der etwa 40 verbleibenden Messwerte im dritten Zyklus wird ein exponentielles Modell gebildet, das aufgrund der geringen Anzahl an Messwerten eine große Variation in der Abbildung des Konfidenzintervalls aufweist. Die Schätzung bildet die Entwicklung des Signals S bis auf den Versatz bei Messwert 20 ab und ermöglicht eine qualitativ richtige Schätzung der RUL mit einem Residuum

von $res_{RUL} = -11h$. Die Güte der Schätzung wird durch eine Metrik von $R^2_{Adj.} = 0.98$ quantifiziert und ermöglicht eine effektive Handlungsempfehlung.

Analog zum dritten Zyklus wird eine gleichartige Schätzung des ersten Zyklus zur Betriebszeit $t = 8824h$ in Abbildung 8.16 dargestellt. Mit einer Metrik von $R^2_{Adj.} = 0.98$ sowie einem Konfidenzintervall von $t_{Konf.} = 6h$ ist dies ein weiteres Beispiel für die erfolgreiche Schätzung der RUL durch das ETM.

8.1.2. Ergebnisse des Ölfilter Anwendungsfalls

In diesem Unterkapitel werden die Ergebnisse des ETM anhand des in Unterkapitel 3.2.1 vorgestellten ÖF Anwendungsfalls diskutiert. Das Degradationsverhalten weist zyklenspezifisch eine unterschiedliche Intensität auf, ähnelt sich jedoch mit dem Fokus auf die abzubildende Funktion. Basierend auf Expertenwissen des Betreibers werden die Parameter anhand von Tabelle 8.2 definiert.

Tabelle 8.2.: Tabellarische Auflistung der Einstellung des Einzeltrendmoduls zur Überwachung des realen Ölfilter Anwendungsfalls.

Eigenschaft	Einstellung
Anzahl historischer Werte $n_{Mess.}$	300
Konfidenzintervall	5% - 95%
Einschaltwert $\omega_{Ein.}$:	0.4bar
Grenzwert ω_S	0.65bar
Monotonie	steigend

Für die Überwachung des ÖF ist kein niederschwelliger Einschaltwert $\omega_{Ein.}$ und kein Grenzwert ω_S definiert. Folglich wird ein geringer Einschaltwert $\omega_{Ein.}$ festgelegt, der in allen drei Zyklen enthalten ist. Analog wird der Grenzwert ω_S als ein möglichst hoher Wert festgelegt, der ebenfalls in allen Zyklen vorkommt.

Die Evaluierung des ETM anhand des Ölfilter-Datensatzes erfolgt zunächst auf Basis von allen verfügbaren Funktionen. In Folge der physikalischen Zusammenhänge wird im Anschluss eine quadratische Funktion zur Modellbildung genutzt.

Ölfiler-Datensatz - Funktion: alle

Abbildung 8.17 stellt die Ergebnisse der Evaluierung des Ölfiler-Datensatzes anhand des ETM dar.

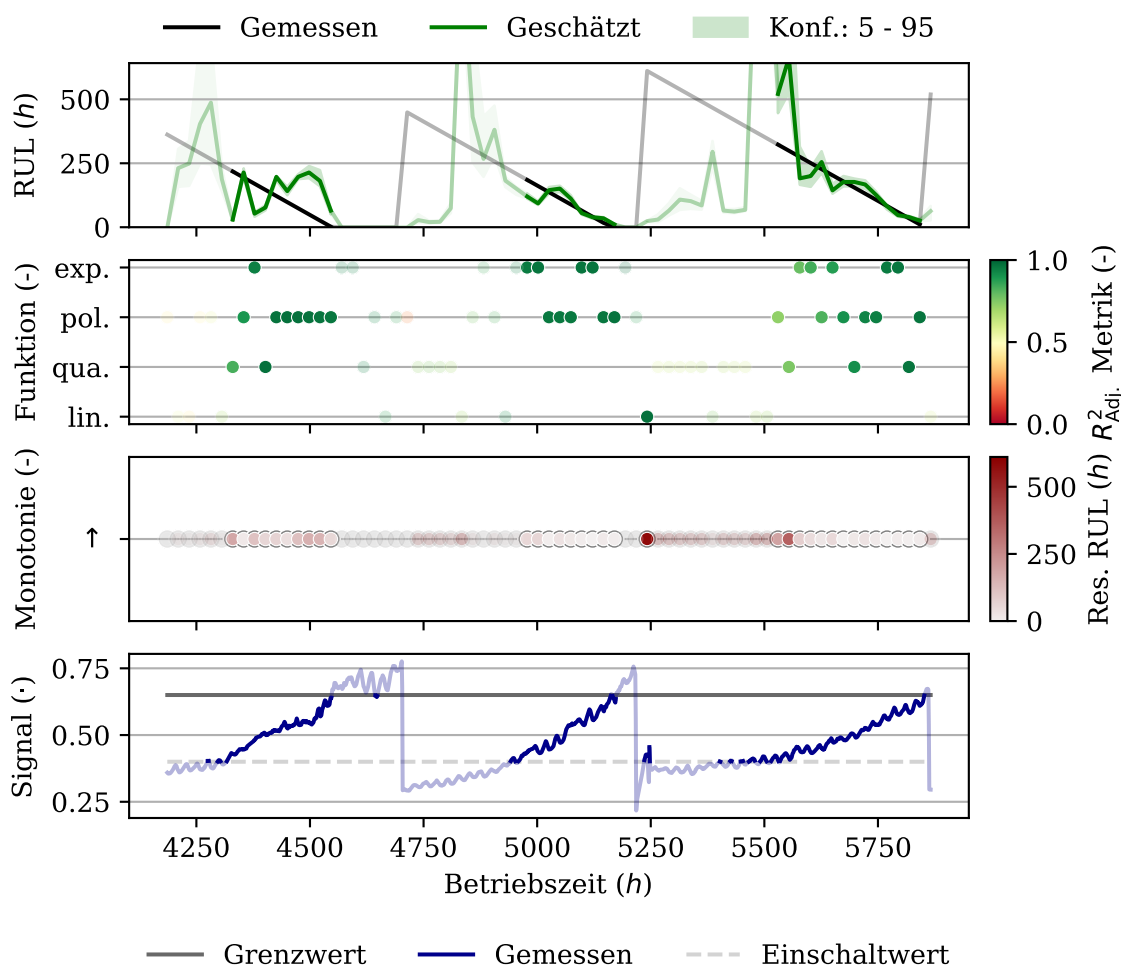


Abbildung 8.17.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Ölfiler-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Die oberste Darstellung stellt die Schätzung der RUL gegenüber. Vor dem Einschalten zeigt die Schätzung der RUL tendenziell ein Überschätzen der RUL, das mit einer Unterschätzung des Verlaufs durch die Abbildung von linearen und polynomialen Funktionen begründet wird. Bei einer verbleibenden Betriebszeit von $t = 200h$ bildet die Schätzung die RUL des zweiten und dritten Zyklus gut ab. Eine Ausnahme stellt der erste Zyklus dar, dessen RUL zur Betriebszeit $t = 4498h$ mit einem Residuum von $res_{RUL} = 164h$ überschätzt wird.

Innerhalb der zweiten Darstellung werden die für die Modellierung verwendeten Funktionen dargestellt. Der erste und zweite Zyklus wird, nach dem Beginn der Zyklen, durch wechselnde Funktionen abgebildet. Am Ende der Zyklen werden für die Modellbildung im Wesentlichen nichtlineare Modelle eingesetzt. Unterschiede bestehen in der Verwendung der quadratischen Funktion, die beim dritten, aber nicht am Ende des

zweiten Zyklus eingesetzt wird. Die Entwicklung der Modellqualität ist anhand des dritten Zyklus nachzuvollziehen. Zur Betriebszeit $t = 5314h$, $5554h$ bzw. $5770h$ liegt der Metrikwert bei $R^2_{Adj.} = 0.61$, 0.76 bzw. 0.96 . Somit verbessert sich die Abbildung \hat{S} des Signals S stetig mit der Zunahme der Messwerte. Analog entwickelt sich die Abbildung des zweiten Zyklus.

Die dritte Darstellung zeigt, dass vor allem zu Beginn des zweiten und dritten Zyklus hohe Residuen gemessen werden, die sich vor dem Einschaltzeitpunkt befinden. Exemplarisch wird zur Betriebszeit $t = 5506h$ das maximale Residuum der RUL mit $res_{RUL} = 818h$ berechnet. Die Ursache liegt in der Modellbildung durch eine lineare Funktion, die das Wachstum höherer Ordnung des Signals nicht nachbilden kann.

Der stetige Verlauf des zweiten und dritten Zyklus wird in der vierten Darstellung gezeigt. Im Gegensatz dazu enthält der erste Zyklus zwei Anomalien, die von dem vergleichbar stetigen Verlauf abweichen. Alle drei Zyklen weisen einen dynamischen Verlauf auf, der mit Rauschen überlagert ist.




Abbildung 8.18.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4402h$ auf Basis der kurzen Zyklen des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Die Anomalie des ersten Zyklus wird im Folgenden anhand von Abbildung 8.18 diskutiert. Das Signal S zeigt während der ersten 200 Messwerte ein überlagertes Muster, das einer Schwingung ähnelt. Die Präsenz des Musters begünstigt den Vorschlag von mehreren möglichen CP. Zum Zeitpunkt des Knicks etwa bei Messwert -90 verändert sich das Muster und weist eine geringere Varianz auf.

Zur Maximierung der $R^2_{Adj.}$ Metrik wird der CP für die Modellierung bei $i = -80$ ausgewählt. Die Abbildung des Signals S gibt die Realität der für die Modellierung verwendeten Daten wieder. Die zukünftige Entwicklung des Signals $S_{Zuk.}$ enthält bei Messwert 0 und 100 zwei weitere Knicke. Besonders der zweite Knick zeigt eine starke diskontinuierliche Veränderung, die sich auch in der Varianz des Signals S ausdrückt. Die Schätzung des Erwartungswerts der RUL wird demnach mit $res_{RUL} = -69h$ unterschätzt und kann nicht mit der quadratischen Funktion abgebildet werden.

Ergänzend wird in Abbildung F.8 das durch die Anomalie im Signal S hervorgerufene

und zeitlich nachgelagerte Phänomen der Überschätzung veranschaulicht. Das Residuum der RUL von $res_{RUL} = 155h$ ist, aufgrund der Metrik von $R^2_{Adj.} = 0.97$ und einem Konfidenzintervall von $t_{Konf.} = 63h$, kaum während des Überwachungsbetriebs zu identifizieren. Diese Tatsache zeigt, dass die Schätzung des ETM bei massiven Anomalien nicht valide ist.




Abbildung 8.19.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5674h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.

Im Gegensatz dazu zeigt Abbildung 8.19 die erfolgreiche Schätzung der RUL im dritten Zyklus zur Betriebszeit $t = 5674h$. Aufgrund des langsamen Degradationsvorgangs und der Beschränkung auf 300 historische Messwerte wird nur der aktuelle Zyklus veranschaulicht. Das gesamte Signal S ist mit dem zuvor beschriebenen Muster in ähnlicher Ausprägung überlagert. Für die Abbildung des Signals S wird die Gesamtheit der Messwerte durch die Wahl des CP bei $i = -300$ genutzt. Durch das überlagerte Muster ergeben sich Freiheitsgrade bezüglich des Konfidenzintervalls. Aufgrund der 300 für die Modellierung verfügbaren Messdaten beeinflusst das überlagerte Muster die Bildung des Konfidenzintervalls mit $t_{Konf.} = 40h$ nur geringfügig. Die Schätzung des Signals \hat{S} gibt den Signalverlauf S optisch sehr gut wieder. Daraus folgt eine sehr präzise Schätzung der RUL von $t_{RUL} = 177h$ mit einem Residuum von $res_{RUL} = 2h$. Ergänzend zu Abbildung 8.19 werden anhand von Abbildung F.9 die Verteilungen des Signalresiduums zur Betriebszeit $t = 5674h$ vorgestellt. Die vergangene Verteilung des Signalresiduums Res_{RUL} ist deformiert und somit auch nicht normalverteilt, wobei die Verteilung im Wesentlichen zentriert ist. Neben einer positiven Verschiebung des zukünftigen Residuums $Res_{S,Zuk.}$ ist die qualitative Abbildung sehr gut. Dies lässt sich besonders anhand des zeitlichen Verlaufs feststellen, der sowohl für das vergangene- Res_{RUL} als auch das zukünftige Signalresiduum $Res_{S,Zuk.}$ sehr gleichmäßig ist. Insgesamt werden das Signal S und die daraus abgeleitete RUL durch das ETM sehr präzise geschätzt.

Ölfiter-Datensatz - Funktion: quadratisch

In Anlehnung an die physikalischen Zusammenhänge zwischen Differenzdruck und Fließgeschwindigkeit in Gleichung 3.2, werden die Ergebnisse der RUL Schätzung in Abbildung 8.20 dargestellt.

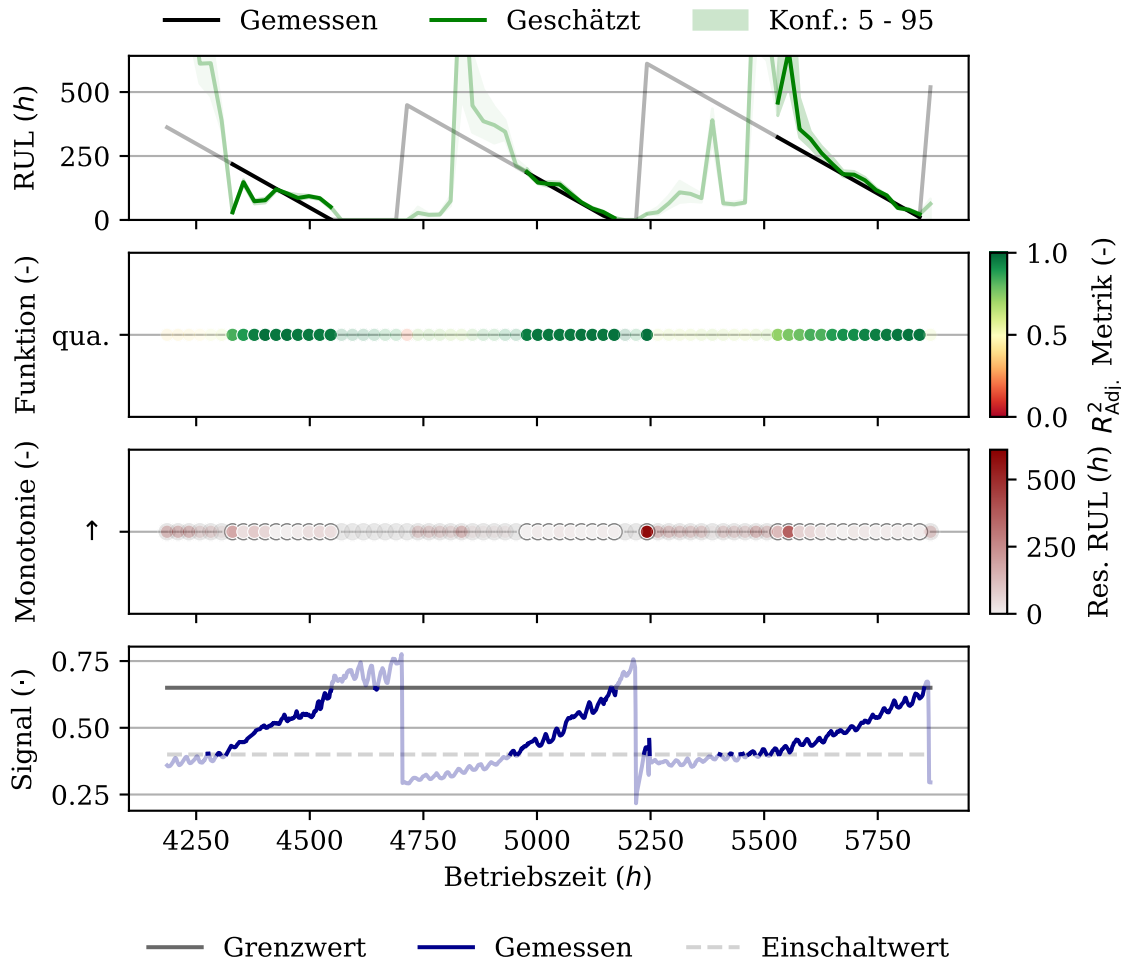


Abbildung 8.20.: Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Ölfiter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.

Im Vergleich zu Abbildung 8.17 zeigt Abbildung 8.20 keine Unterbrechungen des Überschätzens zu Beginn der Zyklen. Dies ist gekoppelt an die Einschränkung der Funktion auf einen quadratischen Zusammenhang. Damit einhergehend wird auch ein Wechsel der für die Modellierung genutzten Funktion zum Beispiel am Ende des dritten Zyklus vermieden, das zu einer Verbesserung der Schätzung und einem früheren Konvergieren gegen die RUL führt.

Aus der zweiten Darstellung folgt, dass sich die $R^2_{Adj.}$ Metrikerwerte zu Beginn der Zyklen auf einem Niveau von $R^2_{Adj.} \leq 0.7$ befinden. Im Gegensatz dazu sind die Metrikerwerte etwa 200h vor Zyklende bei $R^2_{Adj.} \geq 0.9$.

Die Einschränkung der Monotonie auf steigende Verläufe sowie die Modellierung auf Basis einer quadratischen Funktion schränken den Lösungsraum ein. Die Klassifikation

der Residuen weist dabei nur geringe Unterschiede aus. Im Vergleich zu Abbildung 8.17 wird das Oszillieren der RUL Schätzung durch die Festlegung der Funktion reduziert, das einen Mehrwert für die abgeleitete Handlungsempfehlung darstellt. Exemplarisch werden eine frühe sowie eine späte Schätzung des zweiten Zyklus vorgestellt.




Abbildung 8.21.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4858h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.

In Abbildung 8.21 wird die Schätzung des Signals \hat{S} zur Betriebszeit $t = 4858h$ dargestellt. Neben dem aktuellen sind auch Teile des vorherigen Zyklus in den letzten 300 Messwerten enthalten. Der CP wird exakt bestimmt und ermöglicht für die Modellbildung die vollständige Nutzung der $n_{\text{Mess.,Train.}} = 160$ Messwerte nach dem sprunghaften Zykluswechsel. Das nichtlineare Verhalten des Signals $S_{\text{Zuk.}}$ ist zu Beginn gering ausgeprägt. Bedingt durch das überlagerte Muster wird die zukünftige Entwicklung des Signals $\hat{S}_{\text{Zuk.}}$ zu flach abgebildet und folglich die RUL mit $res_{\text{RUL}} = 142h$ überschätzt. Die Unsicherheit des Modells wird durch das Konfidenzintervall von $t_{\text{Konf.}} = 308h$ in Kombination mit einer Metrik von $R^2_{\text{Adj.}} = 0.76$ durch das ETM ausgedrückt. Im zeitlichen Verlauf wird auf Basis einer größeren Anzahl von Messwerten die RUL Schätzung korrigiert.

In diesem Zusammenhang wird deutlich, dass trotz der Einschränkung der Monotonie und der Funktion, wesentliche Freiheitsgrade erhalten bleiben. Abbildung F.11 zeigt, dass die Modellierung eines nahezu linearen Verlaufs durch eine quadratische Funktion möglich ist. Die Schätzung des Signals \hat{S} ist einer linearen Funktion sehr ähnlich, wobei das Konfidenzintervall optisch belegt, dass es sich um eine nichtlineare Funktion handelt. Dies führt besonders am Anfang des Degradationsvorgangs zu einer Überschätzung der RUL.

Im weiteren zeitlichen Verlauf zeigt Abbildung 8.22 die Schätzung des Signals \hat{S} zur Betriebszeit $t = 5002h$. Das Signal S wird durch die Schätzung mit $R^2_{\text{Adj.}} = 0.97$ sehr gut abgebildet. Die Modellierung des Signals S basiert auf $n_{\text{Mess.,Train.}} = 285$ Messwerten, die durch ein gleichmäßiges Muster überlagert werden. Der direkte Vergleich zur Modellbildung auf Basis von allen verfügbaren Funktionen in Abbildung F.10 verdeutlicht




Abbildung 8.22.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5002h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.

die Vorteile der Limitierung. In Folge der Einschränkung des Funktionsumfangs wird in diesem konkreten Fall dem Unterschätzen der RUL wirksam entgegengewirkt und bietet somit die Basis für eine bessere Schätzung.

8.1.3. Diskussion des Einzeltrendmoduls auf realen Daten

In Unterkapitel 8.1.1 und 8.1.2 werden zwei unterschiedliche Anwendungsfälle des ETM vorgestellt.

Die Degradation der Membranpumpe zeigt, basierend auf den kurzen Zyklen, dass eine ausreichende Datenmenge zur Abbildung des Signals S durch eine geeignete Funktion vorhanden sein muss. In diesem Zusammenhang ist besonders die Definition des Einschaltwerts ω_{Ein} für die Schätzung wichtig. Das Festlegen des Einschaltwertes ω_{Ein} ist generell beliebig, jedoch ist die Nutzung des kleinsten im Betrieb verwendeten Grenzwertes des Signals S ein sinnvoller Richtwert.

Der Signalverlauf der kurzen Zyklen des Membranpumpen-Datensatzes legt nahe, dass der Funktionsumfang unter Umständen zu gering ist. In diesem Fall entspricht der Degradationsverlauf eher einem S-förmigen Verlauf und kann somit nur effektiv nach der Druckaufbauphase abgebildet werden. Durch die Variation und Veränderung des Degradationsverlaufs begründet der Membranpumpen-Datensatz die notwendige Anpassungsfähigkeit der Algorithmen zur Schätzung. Die adaptive Anpassung des ETM bildet diese Änderungen ab und ermöglicht eine Nutzung für industrielle Anwendungsfälle.

Der Degradationsverlauf des Ölfilter-Datensatzes ist ein Beispiel für einen industriellen Anwendungsfall, der bei konstantem Betrieb ohne eine Modellierung weiterer Eingangssignale auskommt. Im Gegensatz dazu können schwerwiegende Anomalien im Signal S nicht durch das ETM kompensiert werden. Dies gilt insbesondere für die Detektion und Bewertung der Anomalien anhand der R^2_{Adj} Metrik.

Viele große Maschinen besitzen ein ähnliches Ölsystem und das Konzept ist auf andere einfache Anwendungsfälle übertragbar. Das zeigt die Möglichkeit zur Skalierung des ETM auf, die eine wesentliche Motivation für der Entwicklung dieses Überwachungskonzeptes darstellt. Weiterhin ist die Schätzung des zukünftigen Signalverlaufs auf Basis des aktuellen Verhaltens für nahezu alle Anwender nachvollziehbar. Somit ist eine einfache Interpretation sowie die Grundlage für einen Wertbeitrag im Rahmen von PresM möglich.

Im Kontext einer übergeordneten Überwachungsstruktur ist das ETM ein wichtiger Baustein des ganzheitlichen Überwachungskonzeptes zur modellbasierten Überwachung. Vor dem Hintergrund der vollautomatischen CP Detektion ist die Grundlage für eine großflächige Überwachung von Einzelsignalen gegeben.

8.2. Ergebnisse des Partikelfiltermoduls

Im folgenden Unterkapitel wird das PFM auf reale Daten angewendet. Dazu wird in Unterkapitel 8.2.1 zunächst die Einstellungen sowie die zu Grunde gelegten Funktionen beschrieben. Die Leistungsfähigkeit des PFM wird anhand von zwei unbekanntem Degradationszyklen in Unterkapitel 8.2.2 und 8.2.3 analysiert. Abschließend werden die wesentlichen Erkenntnisse in Unterkapitel 8.2.4 zusammengefasst.

8.2.1. Datenübersicht und Einstellungen

Während des Onlinebetriebs des PFM werden die Szenarien *Bestcase* und *Worstcase* für die Ableitung von Handlungsempfehlungen berechnet. Da im Rahmen der Evaluierung die historischen Daten verfügbar sind, kann das Szenario *realRul* ebenfalls ausgewertet werden und ist der Fokus der Evaluierung.




Abbildung 8.23.: Grafische Darstellung eines langsamen Degradationsverlaufs des Robertverdampfers für die Evaluierung des Partikelfiltermoduls im Rahmen einer Onlinesimulation.

In Abbildung 8.23 und 8.24 werden zwei Degradationszyklen anhand der Verläufe des Dampfdrucks ϕ vorgestellt, die in Unterkapitel 6.2.8 zur Validierung eingesetzt werden. Die beiden Zyklen zeichnen sich durch den niedrigsten bzw. den höchsten Degradationsgradienten innerhalb der verfügbaren Daten aus. Beide Zyklen entstammen




Abbildung 8.24.: Grafische Darstellung eines schnellen Degradationsverlaufs des Robertverdampfers für die Evaluierung des Partikelfiltermoduls im Rahmen einer Onlinesimulation.

aus unterschiedlichen Zeitbereichen und es werden lediglich die Zeitbereiche dargestellt,

in der die Anlage in Betrieb ist.

Die beiden Zyklen werden weder für das Training noch den Test zur Modellierung verwendet und sind somit dem in Unterkapitel 6.2 entwickelten Modell vollständig unbekannt. Auf Basis von Abbildung 6.4 und weiteren Erläuterungen aus Unterkapitel 6.2.8 folgt, dass die zwei Zyklen durch sehr unterschiedliche Degradationsgeschwindigkeiten gekennzeichnet sind. Diese sind nicht nur unterschiedlich im Vergleich zueinander, sondern auch im Vergleich zu den für das Training verwendeten Zyklen, wodurch die Onlinesimulation sehr anspruchsvoll ist.

Beide Zyklen zeigen trotz ihrer unterschiedlichen Degradationsgeschwindigkeiten Gemeinsamkeiten auf. Dazu gehören ein lokales Maximum zu Beginn des Zyklus sowie im zeitlichen Verlauf folgend ein lokales Minimum. Anschließend steigt der Dampfdruck phi im Wesentlichen stetig bis zum Erreichen des Grenzwerts ω an. Die Sprünge innerhalb des Dampfdrucks phi sowie die abrupte Änderung der Steigung sind auf die Eingänge des Systems und Störungen zurückzuführen.

Die ZG beschreibt den Übergang der beiden Zustände R bzw. T und wird in Unterkapitel 6.2.7 auf Basis der Features in Tabelle 6.1 eingeführt. Für die Onlinesimulation wird eine lineare ZG gewählt, wobei das dynamische Verhalten durch spezifische Features abgebildet wird. Dazu zählen auch die Eigenschaften des Dampfes auf Basis der WDT. Neben der Abbildung der Transition der Zustände durch die ZG wird der gemessene Ausgangsvektor Ψ durch die AG in den Zustandsvektor Φ überführt. Für weitere Details wird auf die Vorstellung der AG in Unterkapitel 6.2.7 verwiesen.

Für die Onlinesimulation des PFM auf Basis der zwei ausgewählten Zyklen werden der in Tabelle C.2 vorgestellte untere- $\Theta_{U.Grenz.}$ und obere Parametergrenzvektor $\Theta_{O.Grenz.}$ zur Definition des PR genutzt. Der Wärmewiderstand R sowie die Dampftemperatur T sind charakteristisch für das verfahrenstechnische System und werden als Zustand des RV mit $\Phi = [R \ T]$ zusammengefasst. Korrespondierend wird für das PFM der Toleranzvektor $T_{Tol.} = [0.6e-6 \ 0.25e0]$ sowie die Partikelanzahl $n_\phi = 500$ definiert. Das Importance Resampling wird durch die Grenzwertunterschreitung der ESS von $\omega_{ESS} = 80\%$ ausgeführt und mit einem normalverteilten Roughening von 1% kombiniert. Weiterhin wird die Partikelloptimierung aktiviert und eine Abbruchtoleranz von $3e-6$ definiert. Die Optimierung basiert auf bis zu $h_{Opt.} = 168$ und die Berechnung des kumulierten Gewichtsvektors $W_{Kum.}$ auf $h_{Smo.} = 48$ vergangenen Ausgangsvektoren Ψ . Ab dem Einschaltzeitpunkt bis zum Erreichen von 48 vergangenen Ausgangsvektoren Ψ wird das Resampling ausgesetzt, um eine valide Basis für die Bewertung der Partikel zu erhalten.

Üblicherweise wird der Einschaltzeitpunkt im Betrieb über den Zeitpunkt bestimmt, an dem die Entwicklung der Zustände eine ausreichende Monotonie aufweist. Um eine möglichst lange Onlinesimulation zu erzwingen und das Einlaufverhalten auszuschließen, wird der Einschaltzeitpunkt auf Betriebszeit $t = 200h$ festgelegt. Die Eingangssignale werden mit Median-Filter der Fenstergröße $h_{Filt.} = 5$ vorverarbeitet, um starke Messfehler auszuschließen.

8.2.2. Onlinesimulation eines langsamen Robertverdampfer Zyklus

Der erste in Abbildung 8.23 vorgestellte Zyklus des Validierungsdatensatzes beschreibt eine im Vergleich zu den Trainingszyklen sehr langsame Degradation. Die Ergebnisse der RUL Schätzung werden in Abbildung 8.25 dargestellt.




Abbildung 8.25.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis eines unbekannt und langsamen Degradationszyklus des Robertverdampfers.

Die obere Darstellung in Abbildung 8.25 zeigt die Schätzung im Vergleich zum Verlauf der RUL. Durch die Initialisierung ist das Partikelset zu Beginn sehr variationsreich, wie das Konfidenzintervall von $t_{\text{Konf.}} = 35.04d$ anzeigt. Durch die erste Verarbeitung des PFM werden die hohe Heterogenität des Partikelsets reduziert sowie das Konfidenzintervall auf $t_{\text{Konf.}} = 20.27d$ verringert. Die Anpassung des Partikelsets ist jedoch kein Resampling, sondern eine Überprüfung der Monotonie des geschätzten Zustandstensors $\hat{\Phi}$. Die Schätzungen von Partikeln, die eine falsche Monotonie abbilden, werden zufällig durch valide Partikel ersetzt.

Innerhalb der nächsten 48 Berechnungen wird das Resampling trotz einer geringen ESS von $q_{\text{ESS}} = 92.15$ Partikeln blockiert, um einem vorzeitigen Verlust der Partikelvariation entgegenzuwirken. Im Anschluss folgen mehrere Resampling Vorgänge, in denen das PFM die RUL Schätzung sukzessive in diskreten Sprüngen korrigiert. Die sprunghaften Änderungen sind auf das Importance Resampling zurückzuführen und bilden sich auch im Konfidenzintervall ab. Durch das Resampling wird das Konfidenzintervall zumeist verkleinert. Im Gegensatz dazu wird das Konfidenzintervall beim Wechsel zwischen Betriebszeit $t = 288h$ und $t = 289h$ von $t_{\text{Konf.}} = 9.13d$ auf $t_{\text{Konf.}} = 16.21d$ vergrößert. Zur Betriebszeit $t = 528h$ konvergiert die Schätzung mit einem Residuum der RUL

von $res_{RUL} = 0.3d$ gegen die RUL. Das Konfidenzintervall umschließt die Schätzung von $t_{RUL} = 17.38d$ mit einer unteren Grenze von $t_{Konf. \min} = 14.04d$ sowie einer oberen Grenze von $t_{Konf. \max} = 17.46d$. Das nächste Resampling erfolgt zur Betriebszeit $t = 829h$ und entfernt vorwiegend zu flache Degradationsverläufe aus dem Partikelset, das die Verminderung des Konfidenzintervalls im Mittel auf $t_{Konf.} < 0.1d$ anzeigt. Die lange Betriebszeit ohne Resampling verdeutlicht, dass das Partikelset im Wesentlichen die reale Degradation abbildet und somit auch die Schätzung vertrauenswürdig ist. Insgesamt schätzt das PFM präzise die verbleibende RUL und ermöglicht somit die Ableitung und Planung von konkreten Maßnahmen, um die Betriebsphase zu verlängern. In diesem Zusammenhang dienen das Konfidenzintervall und die Häufigkeit der Resampling Vorgänge als Qualitätsindikatoren.




Abbildung 8.26.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 201h$ auf Basis eines unbekanntes und langsamen Degradationszyklus des Robertverdampfers.

Die Initialisierung des PFM wird anhand der Schätzung des Zustands T in Abbildung 8.26 dargestellt. Neben der Heterogenität der Zustandsschätzungen der einzelnen Partikel, fallen vor allem die monoton fallenden Trajektorien auf. Ein monoton fallendes Verhalten wird bei der zugrundeliegenden Degradation nicht erwartet und folglich werden im Rahmen der ersten Monotonieprüfung alle Partikel mit einer fallenden Monotonie der Zustandsschätzung entfernt. Der Vergleich des Zustandsverlaufs und dessen Schätzungen durch die Partikel zeigt, dass keine Parameterkombination den Zustandsverlauf wiedergibt. Dies ist durch die $n_{\Theta} = 15$ Dimensionen des Parametervektors Θ bedingt, der mit einer begrenzten Partikelzahl von $n_{\varphi} = 500$ Stück nicht jede mögliche Kombination abbilden kann.

Durch weitere Resampling Vorgänge wird die Schätzung schrittweise optimiert. Zur Betriebszeit $t = 280h$ sind Partikel, die zur Überschätzung der RUL führen, nicht mehr im Partikelset vorhanden. Abbildung 8.27 zeigt die Schätzung der zukünftigen Entwicklung des Zustands T zur Betriebszeit $t = 280h$. Durch die aktive Partikeloptimierung geben vereinzelte Partikel den zukünftigen Zustandsverlauf qualitativ wieder, jedoch




Abbildung 8.27.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 280h$ auf Basis eines unbekannt und langsamen Degradationszyklus des Robertverdampfers.

ist das Partikelset zu diesem Zeitpunkt von einer Vielzahl Partikel dominiert, die eine schnellere Degradation abbilden und somit die RUL unterschätzen. In dieser frühen Phase der RUL Schätzung und aufgrund der ähnlichen Initialisierung des Zustands, überlappen sich die geschätzten Zustandsverläufe anteilig und haben zu wenig Differenzierungsmerkmale.




Abbildung 8.28.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 280h$ auf Basis eines unbekannt und langsamen Degradationszyklus des Robertverdampfers.

Die Ähnlichkeit der geschätzten Zustandsverläufe der Partikel wird auch anhand von Abbildung 8.28 verdeutlicht, die das Smoothing des Zustands T zur Betriebszeit

$t = 280h$ zeigt. Die einzelnen Zustandstrajektorien der in die Vergangenheit gerichteten Schätzung divergieren über das Zeitfenster h_{smoo} , in Abhängigkeit der unterschiedlichen Startpunktwahl ist jedoch das Kreuzen des vergangenen Zustandsverlaufs möglich. Die geschätzten kreuzenden Zustandsverläufe weichen durch diese Eigenschaft erst später ausreichend von dem Zustand ab, wodurch die korrespondierenden Partikel potenziell länger im Partikelset verbleiben. Da zu Beginn die Unterschiede zwischen den Partikeln geringe Auswirkungen auf das Smoothing besitzen, ist ein längerer Zeitraum zur Differenzierung notwendig.




Abbildung 8.29.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 479h$ auf Basis eines unbekanntes und langsamen Degradationszyklus des Robertverdampfers.

Über die Zeit divergieren die Trajektorien der Partikel immer mehr und eine effektive Auswahl der Partikel, die den Zustand abbilden, wird ermöglicht. Abbildung 8.29 zeigt das Smoothing des Zustands T zur Betriebszeit $t = 479h$. Die Partikel, deren Rückberechnungen in der oberen Hälfte der Abbildung zu sehen sind, zeigen im Vergleich zu den anderen Trajektorien eine deutliche Abweichung zum Zustand auf. Die Trajektorien im oberen Bereich bilden einen zu schnellen Degradationsverlauf ab, der mit dem Zustand nicht übereinstimmt.

Das Ergebnis des nachfolgenden Resamplings wird anhand des Smoothings zur Betriebszeit $t = 480h$ in Abbildung G.1 dargestellt. Die Trajektorien, die zum vorherigen Zeitpunkt einen deutlichen Abstand zum Zustand T ausweisen, sind nicht mehr vorhanden, da die korrespondierenden Partikel aus dem Partikelset entfernt werden.

Das Verwerfen der Partikel im Rahmen des Resamplings kann durch ein Herabsetzen der Toleranz bestärkt werden. Wie jedoch in Abbildung 8.29 zu sehen ist, enthält der Zustand T rauschbedingte Anteile und unter Umständen auch nicht abbildbare Strukturen. Das Wählen einer zu geringen Toleranz würde in diesem Zusammenhang zu einem zu schnellen Ausschluss von einer Vielzahl der Partikel führen, ohne die Degradation besser abzubilden.




Abbildung 8.30.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 500h$ auf Basis eines unbekannt und langsamen Degradationszyklus des Robertverdampfers.

Im weiteren zeitlichen Verlauf ist die Schätzung des Zustandsvektors $\hat{\Phi}$ im Vergleich zu den vorangegangenen Schätzungen deutlich präziser. Exemplarisch stellt Abbildung 8.30 die Schätzung des Zustands T zur Betriebszeit $t = 500h$ dar. Vereinzelt Trajektorien geben den Zustandsverlauf wieder. Innerhalb des Partikelsets sind auch Partikel vorhanden, deren geschätzte Zustandstrajektorien zur Unterschätzung der RUL führen. Diese Partikel werden erst zu einem späteren Zeitpunkt aus dem Partikelset verworfen, wie Abbildung G.2 zeigt.

Die Wechselwirkungen mit dem Eingangsvektor Γ , zum Beispiel der Sprung in Abbildung 8.30 zur Betriebszeit $t = 130h$, werden sehr gut durch das PFM abgebildet. Aufgrund einer ausreichenden Menge an vergangenen Ausgangsvektoren Ψ kann die Partikeloptimierung den Zustandsverlauf nahezu vollständig wiedergeben. Dies ist die Basis für das Konvergieren der Schätzung gegen die RUL. Mit jedem Resampling werden sowohl der aktuell optimierte Partikel $\mathcal{P}_{\text{Opt.}}$, als auch die auf Basis der zuvor durch Roughening weiterentwickelten optimierten Partikel verstärkt. Somit wird durch das kontinuierliche Explorieren des direkten Umfelds erfolgreicher Partikel die Schätzung immer präziser.

Die Schätzung des Degradationszyklus und das Konvergieren gegen die RUL kann anhand der zeitlichen Entwicklung einzelner Parameter des geschätzten Parametertensors $\hat{\Theta}$ verdeutlicht werden. Abbildung 8.31 zeigt die Veränderung des Parameters $sumt$ in den von dem unteren- $\Theta_{U.Grenz.}$ und oberen Parametergrenzvektor $\Theta_{O.Grenz.}$ eingeschlossenen Bereich des PR. Direkt nach der Initialisierung zur Betriebszeit $t = 200h$ ist die uniforme Verteilung zu erkennen. Im weiteren Verlauf konzentrieren sich die Partikel zunächst zur Betriebszeit $t = 320h$ um den Wert $1.0e - 1$, um im Anschluss weiter an den Rand des PR verschoben zu werden. Im zeitlichen Verlauf, nach der Entstehung des Maximums am Rande des PR, bilden sich keine weiteren lokalen Maxima aus. Dies deckt sich mit der Schätzung in Abbildung 8.25.

Abbildung G.3 zeigt die zeitliche Entwicklung der Schätzung des Parametertensors $\hat{\Theta}$




Abbildung 8.31.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = sumt$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.

anhand des Parameters $r_dfci_div_fhi_dt$, der nicht auf Basis eines erweiterten unteren- $\Theta_{U.Grenz.}$ bzw. oberen Parametergrenzvektors $\Theta_{O.Grenz.}$ initialisiert wird, sondern auf Grundlage des Mittelwertes der Parametergrenzvektoren $\Theta_{U.Grenz.}$ und $\Theta_{O.Grenz.}$. Ab dem Zeitpunkt der Initialisierung expandiert die Verteilung, die sich am Anfang mit jedem Resampling vergrößert. Am Ende des Degradationszyklus wird die Verteilung nicht mehr maßgeblich durch das Resampling verändert und die Verteilung der Partikel im PR weist das Muster der beim Roughening eingesetzten Normalverteilung auf.

Insgesamt verdeutlicht die Schätzung des PFM anhand des langsamen Zyklus, dass das Überwachungskonzept sich adaptiv an die RUL annähert. Mit zunehmender Anzahl an verfügbaren Ausgangsvektoren Ψ wird die Gewichtung der Partikel durch divergierende Zustandsverläufe effektiver und das Einbringen von neuen Partikeln durch die Partikelloptimierung präziser. Während des Betriebs helfen das Konfidenzintervall sowie die Frequenz der Resampling Vorgänge die Erwartungswertschätzung der RUL zu bewerten und Handlungen daraus abzuleiten.

8.2.3. Onlinesimulation eines schnellen Robertverdampfer Zyklus

Nachfolgend wird das PFM anhand des in Abbildung 8.24 vorgestellten schnellen Degradationsverlaufs des RV evaluiert. Abbildung 8.32 zeigt die Ergebnisse der RUL Schätzung über die Betriebszeit.




Abbildung 8.32.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis eines unbekanntes und schnellen Degradationszyklus des Robertverdampfers.

Die oberste Darstellung zeigt, dass der Median der geschätzten RUL direkt nach der Initialisierung von $t_{RUL} = 11.54d$ auf $t_{RUL} = 9.18d$ abfällt. Auch das Konfidenzintervall wird von $t_{Konf.} = 75.96d$ auf $t_{Konf.} = 26.49d$ angepasst. Innerhalb der nachfolgenden $48h$ wird das Resampling blockiert, um PI am Anfang der Überwachung zu verhindern. Die Schätzung der RUL wird durch das erste Resampling zur Betriebszeit $t = 250h$ sprunghaft in Richtung der RUL verbessert. Das Residuum der RUL Schätzung wird von $res_{RUL} = -8.73d$ auf $res_{RUL} = -2.23d$ reduziert und während der nächsten Schätzung zur Betriebszeit $t = 251h$ auf $res_{RUL} = -0.25d$ abgesenkt. Zu diesem Zeitpunkt wird auch das Konfidenzintervall auf $t_{Konf.} = 10.71d$ verringert.

Im mittleren Teil des Degradationsverlaufs weicht die Schätzung von der gemessenen RUL ab. Exemplarisch wird die RUL zur Betriebszeit $t = 400h$ mit $res_{RUL} = -0.96d$ unterschätzt. Das Konfidenzintervall schließt die RUL während dieser Zeit nicht mit ein und wird zur Betriebszeit $t = 360h$ temporär zu kürzeren RUL ausgeweitet.

Mit einem weiteren Resampling Vorgang zur Betriebszeit $t = 426h$ konvergiert die Schätzung vollständig gegen die gemessene RUL. Der Großteil der Partikel verhält sich sehr ähnlich, sodass das Konfidenzintervall $t_{Konf.} < 0.3d$ ist. Bis zum Ende des Degradationszyklus wird die RUL sehr präzise geschätzt.

Die zweite Darstellung von Abbildung 8.32 zeigt das Blockieren des Resamplings innerhalb der ersten $t = 48h$. Optisch erscheint der erste Resampling Vorgang zur Betriebszeit

$t = 250h$ als ein einzelner deutlicher Sprung, wobei zwei Resampling Vorgänge in direkter Abfolge ausgeführt werden. Dies zeigt auf, dass nach dem ersten Resampling Partikel mit geringen Gewichten w im Partikelset verbleiben, die nicht in einem Vorgang vollständig verworfen werden.

Im Anschluss an die ersten gruppierten Resampling Vorgänge finden weitere Resampling Vorgänge statt, die, wie zur Betriebszeit $t = 424h, 425h, 426h$ und $427h$, ebenfalls sequentiell ausgeführt werden und gruppiert sind. Mit fortschreitender Betriebszeit werden die Abstände zwischen den Resampling Vorgängen stetig größer und zeigen, dass das PFM die reale Degradation abbildet.




Abbildung 8.33.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 201h$ auf Basis eines unbekannt und schnellen Degradationszyklus des Robertverdampfers.

Abbildung 8.33 zeigt Schätzung des Zustands T zur Betriebszeit $t = 201h$. Das Entfernen der Partikel, die monoton fallende Zustandstrajektorien abbilden, resultiert insgesamt in einer Verschiebung der Schätzung zu kürzeren RUL. Im Rahmen der Monotonieprüfung nach der Schätzung der einzelnen Partikel werden alle nicht monoton steigenden Trajektorien zufällig durch andere valide Partikel ersetzt. Der sehr lange und monoton steigende Verlauf, der etwa bei Messwert 1900 den Grenzwert ω überschreitet, bestimmt die Beschreibung des oberen Konfidenzintervalls mit $t_{\text{Konf. max}} = 81.42d$. Durch die Entfernung der korrespondierenden Partikel der nicht monotonen Trajektorien verschiebt sich die Verteilung der RUL Schätzung. Folglich wird auch das Konfidenzintervall angepasst.

Bedingt durch das Resampling werden die verbliebenen Trajektorien weiter eingeschränkt und die Schätzung des Zustands T zur Betriebszeit $t = 250h$ in Abbildung 8.34 dargestellt. Die geschätzten Zustandsverläufe der Partikel ähneln dem Zustandsverlauf und führen aufgrund der großen Streuung zum deutlichen Über- und Unterschätzen der RUL, wobei das Unterschätzen überwiegt und daraus das Residuum der RUL mit $res_{\text{RUL}} = -2.23d$ folgt. Basierend auf den ersten 50 Ausgangsvektoren Ψ parametrisiert die Partikeloptimierung das Modell erstmals. Bei der Modellierung konkurrieren die




Abbildung 8.34.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 250h$ auf Basis eines unbekannt und schnellen Degradationszyklus des Robertverdampfers.

Parameter *intercept* und *sumt* und es zeigt sich, dass die Abbildung des Parameters *intercept* zu gering sowie die des Parameters *sumt* zu groß ist. Aus diesem Grund ist der geschätzte zukünftige Zustandsverlauf des optimierten Partikels $\mathcal{P}_{\text{Opt.}}$ anfangs zu flach und am Ende zu steil.




Abbildung 8.35.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 318h$ auf Basis eines unbekannt und schnellen Degradationszyklus des Robertverdampfers.

Exemplarisch wird eine Schätzung aus dem Zeitbereich der unterschätzen RUL in Abbildung 8.35 vorgestellt. Zur Betriebszeit $t = 318h$ beschreiben vereinzelte Partikel zu stark steigende Verläufe, die etwa bei Messwert 150 den Grenzwertvektor Ω_{Φ} des

Zustands Φ schneiden. Aufgrund der starken Überlagerung des Verlaufs von Zustand T differenzieren sich diese Partikel erst nach weiteren 50 bis 100 Schätzungen von dem Zustandsverlauf. Die späte Differenzierung wird durch das überlagerte Muster verursacht, das der Reduzierung des Toleranzvektors T_{Tol} entgegenwirkt.

Die geschätzten Zustandstrajektorien der anderen Partikel bilden den Verlauf des Zustands qualitativ sehr gut ab, wobei der Zustandsverlauf den Rand der Trajektoriengruppe beschreibt. Diese Abweichung deckt sich mit den Abweichungen der RUL Schätzung in Abbildung 8.32.

Durch das mäßige Auffächern der geschätzten Zustandsverläufe in Kombination mit deren geringeren Steigungen folgt eine Streuung beim Überschreiten des Grenzwerts Ω_{Φ} und somit auch der geschätzten RUL. Anhand dieses Beispiels wird das Spannungsfeld einer Vergrößerung der Einträge im Toleranzvektor T_{Tol} mit einem flachen Zustandsverlauf herausgearbeitet und zeigt die damit einhergehende Sensitivität der RUL Schätzung.




Abbildung 8.36.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 319h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.

Abbildung 8.36 zeigt das Smoothing des Zustands T zur Betriebszeit $t = 319h$. Der Zustandsverlauf zeigt neben überlagernden Strukturen auch Sprünge, die durch die Eingänge hervorgerufen werden. Die Intensität der Sprünge ist in den gemessenen Daten zum Teil größer im direkten Vergleich mit den geschätzten Sprüngen. Dies wird auch durch die Schätzung in Abbildung 8.35 gezeigt. Die Sprünge können anteilig durch die Partikeloptimierung und der damit verbundenen Änderung der Parameter *intercept* und *sumt* innerhalb des optimierten Parametervektors Θ_{Opt} kompensiert werden. Die optimierten Partikel \mathcal{P}_{Opt} führen zu steileren geschätzten Zustandsverläufen im Vergleich zum Zustandsverlauf von T und infolgedessen zu einer Unterschätzung der RUL.

Im zeitlichen Verlauf wird die Schätzung der RUL iterativ optimiert. In Abbildungen 8.37 wird die Schätzung des Zustands T zur Betriebszeit $t = 450h$ dargestellt. Der Zustandsverlauf wird durch eine Variation aus verschiedenen Partikeln wiedergegeben. Weniger als 25 Trajektorien weisen eine stärkere Steigung als der Zustandsverlauf auf




Abbildung 8.37.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 450h$ auf Basis eines unbekannt und schnellen Degradationszyklus des Robertverdampfers.

oder verlaufen parallel zum eigentlichen Signal. Dies kann ein Ergebnis des Roughenings sein, das den geschätzten Zustand zufällig verändert hat und gleichzeitig den korrespondierenden Parametervektor Θ nicht wesentlich beeinflusst hat. Liegen diese parallelen Zustandsverläufe innerhalb des Toleranzvektors $T_{\text{Tol.}}$, können diese Partikel kaum aus dem Partikelset entfernt werden.

Bedingt durch das überlagerte Muster, überschreitet der Zustand T erstmals den zugehörigen Grenzwert des Vektors Ω_{Φ} bei Messwert 165. Im Gegensatz dazu überschreiten die geschätzten Zustandsverläufe der Partikel den Grenzwert bei Messwert 180. Dies erklärt, dass das Residuum der RUL Schätzung in Abbildung 8.32 nicht auf $res_{\text{RUL}} = 0d$ abfällt. Dennoch wird der Erwartungswert des Zustands T effektiv durch die Schätzung des PFM wiedergegeben.

Abbildung G.4 zeigt die zeitliche Entwicklung des Parameters *intercept* auf Basis des geschätzten Parametertensors $\hat{\Theta}$. Durch das erste Resampling zur Betriebszeit $t = 250h$ werden wesentliche Teile des Wertebereichs entfernt. Sowohl negative als auch große positive Wertebereiche werden nicht mehr durch die Partikel wiedergegeben. Im zeitlichen Verlauf sind zur Betriebszeit $t = 317h$ zwei größere Segmente in der Mitte der ursprünglichen Verteilung stark ausgeprägt. Durch das Resampling zur Betriebszeit $t = 323h$ wird die Variation weiter reduziert. Dies ist auch der Betriebsbereich, in dem die Schätzung von der RUL abweicht. Die Korrektur der Abbildung durch das PFM findet zur Betriebszeit $t = 424h$ statt und wirkt sich positiv auf das Residuum der RUL Schätzung aus. Bestimmte Bereiche innerhalb der Partikeldichteverteilung sind über längere Zeiträume vertreten und wechseln sich teilweise in der Anzahl der Partikel ab.

Abbildung 8.38 zeigt die Dichteverteilung des Parameters *sumt* über die Betriebszeit t als Ausschnitt aus dem geschätzten Parametertensor $\hat{\Theta}$. Zu Beginn der Degradation ist die Charakteristik des Zustandsverlaufs noch nicht vollständig bekannt. Einige Partikel konzentrieren sich in der Mitte des Wertebereichs. Im weiteren zeitlichen Verlauf




Abbildung 8.38.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = sumt$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.

verdichteten sich die Partikel. Zur Betriebszeit $t = 424h$ findet ein Wechsel statt zu geringeren Werten. Das Verhalten ist in der zweiten Hälfte der Betriebszeit damit genau gegensätzlich zu Abbildung G.4.

Im Rahmen des Resamplings zur Betriebszeit $t = 424h$ identifiziert das PFM, dass ein konstanter Zuwachs anhand des Parameters *intercept* die Kurvenform nicht beschreiben kann und der Parameter *sumt* infolgedessen gestärkt wird. Da beide Parameter den Zuwachs beeinflussen und zu Beginn des Degradationsverlaufs somit wechselseitig zu einem ähnlichen Ergebnis kommen, ist eine weitere Eingrenzung der Freiheitsgrade sinnvoll. In diesem Zusammenhang liefert die Installation von weiteren Sensoren zusätzliche Informationen, ohne die sich das PFM bestmöglich an den Zustand anpasst.

Basierend auf dem schnellen Degradationsverlauf des RV wird gezeigt, dass das PFM trotz überlagerter Strukturen die RUL effektiv schätzt. Die adaptiven Eigenschaften des PFM sind die Basis, um mögliche Abweichung der Schätzung während des Betriebs zu korrigieren und gegen die RUL zu konvergieren. Damit erfüllt es die Erwartungen der Robustheit und trägt zu einer effektiven Planung der Instandhaltung bei.

8.2.4. Diskussion des Partikelfiltermoduls auf realen Daten

In Unterkapitel 8.2.2 und 8.2.3 wird die Onlineüberwachung durch das PFM auf Basis von realen Betriebsdaten simuliert. Dazu wird die RUL eines RV aus Unterkapitel 3.2.3 geschätzt.

Im Rahmen von Unterkapitel 8.2.2 wird die Schätzung eines sehr langsamen Degradationsverhaltens abgebildet. Die Schätzung des PFM nähert sich iterativ der RUL an, um den Verlauf ab diesem Zeitpunkt mit großer Genauigkeit abzubilden. Der Prozess des Konvergierens sollte so kurz wie nötig sein, um möglichst schnell verlässliche Ergebnisse zu bekommen. In den vorangegangenen Ausführungen wird bei der Initialisierung bewusst auf eine uniforme Initialisierung zurückgegriffen, um eine vordefinierte Prägung des

Partikelsets im Rahmen der Onlinesimulation auszuschließen. Damit ist die Wahrscheinlichkeit sehr gering, dass exakt die reale Parameterkombination im Partikelset enthalten ist. Dieser Aspekt unterstreicht die Wirksamkeit des PFM, jedoch kann im Onlinebetrieb ein schnelleres Konvergieren gegen die RUL unterstützt werden. Für die Initialisierung können dazu Varianten auf Basis von erfolgreichen Partikeln vergangener Zyklen oder einem globalen Modell mit einer parameterspezifischen normalverteilten Streuung erzeugt werden. Dies reduziert die Partikelvariation von Beginn an und ermöglicht eine gezieltere Auswahl systembeschreibender Partikel.

Im Gegensatz dazu verdeutlicht der schnelle Degradationszyklus des RV, dass trotz der Robustheit des PFM gegen Rauschen, starke Muster und Strukturen die Schätzung erschweren. Dies ist eng gekoppelt an die Wahl des Toleranzvektors $T_{\text{Tol.}}$, da dieser für eine präzise Schätzung auf kleinstmögliche Einträge begrenzt werden sollte. Aufgrund der stark ausgeprägten Strukturen in den Ausgangsvektoren Ψ ist die Schätzung insgesamt sehr gut, wobei besonders das letzte Drittel der Betriebszeit hervorgehoben wird. Die Größe des PR wirkt sich auf die Schätzung aus, da gegensätzliche Eigenschaften sich unter Umständen kompensieren können oder zu Beginn einen ähnlichen Einfluss besitzen. Im Betriebsverlauf werden sich diese Kombinationen ab einem gewissen Punkt vom Zustandsvektor Φ entfernen und können somit über längere Zeit vermieden werden. Die Einschränkung des Parameterbereichs ist dennoch im Sinne des frühen Konvergierens sinnvoll.

Vor dem Hintergrund der Evaluierung sind beide Zyklen, aufgrund der sehr unterschiedlichen Eigenschaften von den Trainingsdaten, eine sehr anspruchsvolle Validierung für das PFM. Aufgrund der selbst-überwachenden Eigenschaften des PFM und dessen Abschaltung, falls alle Partikel den Zustand Φ nicht repräsentieren, ist es eine sehr gute Basis für industrielle RUL Schätzung, da es ein einfaches, aber robustes Überwachungskonzept ist, das performant und sukzessive weiterentwickelt werden kann.

9. Zusammenfassung und Ausblick

Abschließend werden die Ergebnisse dieser Arbeit anhand von Unterkapitel 9.1 zusammengeführt. Basierend auf den gewonnenen Erkenntnissen werden in Unterkapitel 9.2 mögliche Weiterentwicklungen vorgestellt und in den Gesamtzusammenhang eingebettet.

9.1. Zusammenfassung

In dieser Arbeit wird der Einsatz von adaptiven Methoden zur RUL Schätzung innerhalb der chemischen Industrie anhand von drei unterschiedlichen Equipments diskutiert. Neben einer HDMP und einem ÖF wird ein RV als Spezialbauform eines Wärmeübertragers vorgestellt.

Grundlegend für die Entwicklung der Überwachungskonzepte ist die Evaluierung der RUL Methoden aus unterschiedlichen Perspektiven. Neben einer methodischen Klassifizierung werden auch die Anwendungsfälle zu Gruppen zusammengeführt. Gemessen an der Zahl der Veröffentlichungen liegt ein Schwerpunkt der Forschung von Methoden zur RUL Schätzung im Bereich Deep Learning. Oft werden die Methoden anhand von bekannten Standarddatensätzen, zum Beispiel der PHM Data Challenge, evaluiert, wobei die Datensätze häufig sehr umfangreich sind. Innerhalb der Industrie sind die bekannten Fehlerdatenmengen stark begrenzt und somit ist auch die Auswahl der Methoden limitiert.

Auf Grundlage des Stands der Technik werden einige Methoden für die Vorbereitung und Vorhersage im Detail beschrieben. Basierend auf einer geringen Datengrundlage sowie weiteren industriellen Limitierungen, wird unter anderem der PF als Basismethode ausgewählt, da dieser wenige Annahmen erfordert und somit für eine Vielzahl industrieller Anwendungsfälle geeignet ist.

Innerhalb dieser Arbeit werden zwei unterschiedliche Überwachungskonzepte zur RUL Schätzung entwickelt. Das ETM Überwachungskonzept umfasst die vollautomatische Vorhersage von Einzelsignalen. Für komplexere Modelle wird das PFM Überwachungskonzept vorgestellt, das auf den grundlegenden Funktionalitäten des PF basiert und für die Anwendung zur RUL Schätzung im industriellen Umfeld erweitert wird.

Im Hinblick auf die Modellierung ist das Vorgehen zwischen den zwei Überwachungskonzepten zu differenzieren. Die Modellierung des ETM ist ein Teil der Onlineüberwachung, wodurch lediglich die generellen Funktionen im Rahmen der Modellierung festgelegt werden. Im Gegensatz dazu wird ein konkretes Modell für den Betrieb des PFM benötigt. Die umfangreiche Modellbildung kombiniert sowohl bekannte physikalische Zusammenhänge als auch Methoden des ML. Bedingt durch die unvollständige Systembeschreibung und nicht vorhandenen Sensoren, werden während der Modellierung gezielt Freiheitsgrade eröffnet, um eine adaptive Schätzung im Onlinebetrieb zu ermöglichen.

Beide Überwachungskonzepte werden auf Grundlage von synthetischen Daten bewertet. Dazu wird für das ETM ein Sägezahn- sowie ein Kurven-Datensatz entwickelt.

Der Sägezahn-Datensatz zeigt vor allem, die grundlegenden adaptiven Eigenschaften auf sowie den Einfluss von überlagerten Strukturen. Die Erkenntnisse werden durch den Kurven-Datensatz im Hinblick auf eine mögliche Verzögerung des CP erweitert. Insbesondere die automatisierte Identifikation des CP sowie die Auswahl einer geeigneten Funktion sind ein essentieller Bestandteil für die Skalierung der Überwachung durch das ETM. Anhand der synthetischen Datensätze erfolgt eine zumeist korrekte Auswahl des CP sowie die geeignete Zuordnung einer Funktion zur Abbildung des Signals. Insgesamt ist die Schätzung der RUL durch das ETM erfolgreich, sodass die Anwendung im industriellen Kontext möglich ist.

Das PFM wird anhand eines synthetischen Datensatzes evaluiert. Der Datensatz weist exponentielles Verhalten auf und ähnelt allgemein Degradationsvorgängen in der chemischen Industrie. Für die Evaluierung werden Referenzeinstellungen vorgenommen, die auf Basis der Erkenntnisse immer weiter präzisiert werden. Dabei werden insbesondere die Aspekte der PD und PI diskutiert. Selbst moderne Partikelfiltermethoden besitzen die Herausforderung, dass das Partikelset irreversibel reduziert wird. Die entwickelte Funktionalität der Partikeloptimierung ermöglicht diese Irreversibilität aufzuheben und das Partikelset mit neuen Partikeln zu versorgen. Das erspart besonders in Phasen ohne Resampling die Wiederholung des Roughening Prozesses und ebenfalls die unnötige Ausdehnung der Partikelanzahl. Somit leistet die Partikeloptimierung einen wichtigen Beitrag für eine robuste Onlineüberwachung.

Zur Veranschaulichung der Vorhersageeigenschaften wird für beide Überwachungskonzepte ein Onlinebetrieb auf realen Betriebsdaten simuliert und im Anschluss diskutiert. Das ETM wird anhand von zwei Anwendungsfällen evaluiert. Anhand des Membranpumpen-Datensatzes wird die generelle Fähigkeit einer adaptiven Vorhersage verdeutlicht. Überlagerte Strukturen erschweren die Vorhersagefähigkeit, die im Betriebsverlauf durch zusätzliche Messwerte sukzessive verbessert wird. Die Anwendung des ETM auf den Ölfilter-Datensatz verdeutlicht, dass massive Anomalien nicht durch das Überwachungskonzept abgebildet werden können. Auf der anderen Seite zeigt es auch, dass ein Großteil der Verläufe ohne weitere Eingangssignale modelliert werden kann und somit die Grundlage für eine Skalierbarkeit des Ansatzes innerhalb der chemischen Industrie gegeben ist.

Das PFM wird auf Basis eines RV evaluiert. Die Herausforderungen sind sehr vielfältig, da der Massenstrom auf der Produktseite bauartbedingt und die Degradation als solches nicht gemessen werden. Im Sinne der Modellierung ist dieser Aspekt mit besonderem Anspruch verbunden, wobei erst die adaptiven Eigenschaften des PFM eine Onlineüberwachung ermöglichen. Die Simulation findet anhand von zwei extremen Betriebszyklen statt, die eine sehr geringe sowie sehr starke Degradation aufweisen. In beiden Fällen nähert sich die Schätzung des PFM nach der Initialisierung iterativ an die RUL an. Die Ergebnisse sind in weiten Bereichen sehr präzise und unterstützen die Handlungsempfehlungen im täglichen Betrieb. Das Konfidenzintervall sowie die Frequenz des Resamplings zeigen die Qualität der Vorhersage an und unterstützen die Interpretation der Ergebnisse. Das PFM passt sich an die herausfordernden Randbedingungen in der chemischen Industrie an und ist die Basis für eine effektive Entscheidungsfindung.

Die Entwicklung des ETM und PFM zur Vorhersage der RUL im Kontext der chemischen Industrie zeigt den Mehrwert und die Herausforderungen für die Einführung von PresM auf. Durch die Detektion von spezifischen Fehlern in Kombination mit

einer Aussage über die verbleibende Zeit und möglichen Handlungsoptionen ist die Grundlage für eine optimierte Instandhaltung gegeben. In diesem Zusammenhang wird deutlich, dass sowohl hochautomatisierte und skalierbare Ansätze, wie das ETM für den flächendeckenden Einsatz, als auch spezifische Ansätze zur Beschreibung von komplexeren Zusammenhängen, wie das PFM, im industriellen Kontext benötigt werden.

9.2. Ausblick

Sowohl das ETM als auch das PFM bilden die Basis für eine effektive Onlineüberwachung von heterogenen Anwendungsfällen in der chemischen Industrie. Im Rahmen der Entwicklung werden die wesentlichen Anforderungen bereits in diesem Stadium erfüllt, wobei weitere Verbesserungen zukünftig möglich sind.

Das ETM ermöglicht die Schätzung und Prädiktion von einfachen Signalverläufen auf Basis von unterschiedlichen Funktionen. Durch die Erweiterung des Funktionsumfangs ist das Erschließen weiterer Anwendungsfälle möglich.

Ferner besteht die Möglichkeit die Einflussnahme durch den Anwender auszuweiten. Demnach könnten beispielsweise auch bestimmte Eigenschaften des Signals, wie ein konvexer bzw. konkaver Verlauf, eingeschränkt werden. Besonders in den Übergangsbereichen ermöglicht dies eine frühere Vorhersage.

Im Rahmen der Evaluierung hat das PFM durch die Präzision der Schätzung überzeugt. Zukünftig könnten im Rahmen der Modellierung auch andere Modelltypen überwacht und optimiert werden. Generell wäre es in diesem Zusammenhang möglich ein Modell auf Basis eines NN im PFM zu überwachen.

Zur besseren Skalierung könnte das PFM im Hinblick auf die Effizienz optimiert werden. Ein möglicher Schritt ist die Beschleunigung des Partikeloptimierungsalgorithmus sowie eine mögliche Überführung der Berechnung von Python in C.

Beide Überwachungskonzepte stellen Extreme innerhalb der möglichen Modelle zur RUL Schätzung dar. Zum einen gibt es die einfachen Vorhersagen, die durch das hochautomatisierte ETM umgesetzt werden können. Zum anderen ermöglicht das PFM die Vorhersage auf Basis von komplexeren Modellen, aus denen eine konkrete Handlung abgeleitet werden kann. Zwischen diesen beiden Überwachungskonzepten gibt es viele Übergangsstufen, die wertschöpfend in industriellen Anwendungen eingesetzt werden könnten.

A. Eigene Veröffentlichungen

Konferenz:

K. Kasten und C. Zhu, “Die topologische Facette des digitalen Zwillings als Basis zur automatisierten Kontextualisierung von Prozessdaten,” in *Automation 2020: Shaping Automation for our Future*, V. D. I. W. GmbH, Hrsg., 1. Aufl. Düsseldorf: VDI Verlag, 2020, S. 255–268, isbn: 978-3-18-102375-4. doi: 10 . 51202 / 9783181023754-255. Adresse: <https://doi.org/10.51202/9783181023754-255>.

Veröffentlichung:

K. Kasten, C. C. Zhu, J. Birk und S. X. Ding, “An integral monitoring concept for data-driven detection and localization of incipient leakages by fusion of process and environment data,” *Journal of Advanced Manufacturing and Processing*, Jg. 4,Nr. 3, e10133, 2022. doi: <https://doi.org/10.1002/amp2.10133>. Adresse: <https://aiche.onlinelibrary.wiley.com/doi/abs/10.1002/amp2.10133>.

B. Informationen zur BASF SE

Zum besseren Verständnis erfolgt im Folgenden eine kurze Einleitung zur BASF SE. Diese startet mit der Geschichte und dem Produktportfolio in Unterkapitel B.1. Um die Größenordnung der Prozesse sowie die Dimensionen des Standorts Ludwigshafen zu verdeutlichen, erfolgt eine zahlenbasierte Beschreibung in Unterkapitel B.2.

B.1. Geschichte und Produktportfolio der BASF SE

Am 6. April 1865 gründete Friedrich Engelhorn die BASF SE in Mannheim. Das Portfolio war zu dieser Zeit besonders auf Farbstoffe ausgerichtet, wobei besonders die Herstellung von „Indigo rein“ zu nennen ist. Anfang des zwanzigsten Jahrhunderts entwickelte Fritz Haber die Ammoniak Synthese, die von Carl Bosch als großtechnisches Verfahren entwickelt wurde. Neben der innovativen Synthese ist auch der verfahrenstechnische Prozess aufgrund von hohen Drücken und Temperaturen eine große Herausforderung und setzt Maßstäbe. Im Lauf der Zeit wurde das Produktportfolio stetig erweitert und neue Produktionsstandorte in vielen Regionen der Welt eröffnet. In den Folgejahren wurde das Kerngeschäft stetig optimiert, wobei sowohl die Automatisierung als auch Nachhaltigkeit immer stärker in den Fokus rückten [162].

Heute verfügt die BASF SE über insgesamt sechs Geschäftssegmente [163]:

- **Chemicals:** Umfasst die Unternehmensbereiche Petrochemicals und Intermediates und stellt im Wesentlichen Basischemikalien und Zwischenprodukte her, wie Ethylen oder verschiedenste Säuren.
- **Materials:** Fokussiert auf die Herstellung von Produkten für die Kunststoff- und kunststoffverarbeitende Industrie. Neben Schaumstoffspezialitäten umfasst das Produktportfolio auch Innovationen, wie biologisch abbaubare Kunststoffe.
- **Industrial Solutions:** Auf Basis der Unternehmensbereiche Dispersions und Resins sowie Performance Chemicals werden Zusätze und Produkte für industrielle Anwendungen hergestellt. Beispielhaft werden auch Lichtschutzmittel für Kunststoffe hergestellt zur Verbesserung der Produkteigenschaften.
- **Surface Technologies:** Die Unternehmensbereiche Catalysts und Coating bieten maßgeschneiderte Lösungen zur chemischen Optimierung von Oberflächen an. In diesem Segment werden beispielsweise Lacke für automobiler Anwendungen aber auch Batteriematerialien für die Elektroautos der Zukunft hergestellt.
- **Nutrition and Care:** Dieses Segment entwickelt Lösungen für eine wachsende Nachfrage an schnelllebigem Konsumgütern. Besonders die Nahrungshersteller und die Pharmaindustrie nutzen die Produkte, wie Reinigungsmittel oder verschiedene Vitamine.

- **Agricultural Solutions:** Das Saatgut sowie der Schutz der Pflanze stehen im Zentrum des Segments. Darüber hinaus werden auch die Kundenbedürfnisse in Bezug auf gesellschaftliche Verantwortung und Verringerung der Umweltauswirkung stetig vorangetrieben.

B.2. BASF SE in Zahlen und Entwicklungsfelder

Auf Basis der sechs Segmente hat die BASF SE im Wirtschaftsjahr 2021 insgesamt 78.6Mrd.€ umgesetzt und ein EBIT vor Sondereinflüssen von 7.8Mrd.€ Erlöst [164]. Zu diesem Ergebnis haben 111,047 Mitarbeiter beigetragen.

Ein Teil des wirtschaftlichen Erfolges ist auch auf die hohe Verflechtung und Integration verschiedener Prozesse zurückzuführen. Dieses Konzept wird als „Verbund“ bezeichnet und an mehreren Standorten der BASF SE eingesetzt [165]. Die Verbundstandorte sind überall in der Welt vertreten und umfassen Geismar und Freeport in den USA, Kuantan und Nanjing in Asien sowie Antwerpen und Ludwigshafen in Europa.

Der Standort in Ludwigshafen ist dabei in mehreren Hinsichten besonders. Es ist der älteste Standort der BASF SE und wurde bereits 1865 gegründet [166]. Die etwa 125 Produktionsbetriebe stellen verschiedenste Produkte auf einer Fläche von rund 10km² her. Dazu werden jährlich rund 5.9TWh Strom, 17.8TWh fossile Brennstoffe und 19.5Tonnen Dampf eingesetzt. Werksintern sind die Betriebe durch 106km Straßen, 230km Bahnschienen und 2,850km Rohrleitungen miteinander verbunden. Um die Edukte zu beziehen und Produkte zum Kunden zu bringen, werden jeden Tag etwa 15 Schiffe, 400 Eisenbahnwaggons und 1,900 Lastkraftwagen abgefertigt.

Um auch zukünftig erfolgreich zu sein, steht der Kunde in der BASF SE Strategie im Zentrum. Darüber hinaus werden sechs Schwerpunkte definiert, die die Weiterentwicklung beschreiben [4]. Die Mitarbeiter sind ein wesentlicher Anteil, um zukünftig das Geschäft voranzutreiben und Vielfalt und Kreativität in die Arbeitswelt zu integrieren. Das Portfolio ist ein weiterer Aspekt und Abbild der Kundennachfrage. Den Marktbedürfnissen entsprechend wird das Portfolio stetig angepasst und hat sich über die Bestehensgeschichte der BASF SE stetig weiterentwickelt. Die Grundlage dafür wird durch den Schwerpunkt Innovation gelegt, der die Basis für neue Produkte darstellt. Neben dem Einsatz von 2.2Mrd.€ pro Jahr für Forschung und Entwicklung wird eine enge Zusammenarbeit mit dem Kunden sowie vielfältige Kooperationen mit Hochschulen und anderen Forschungseinrichtungen unterstützt. Der Schwerpunkt Produktion ist Grundlage für die gesamte Wertschöpfungskette. Durch das Verbund-Konzept wird die Produktion gestärkt und produktionsbezogene Vorteile ermöglicht.

Als weiterer Hebel wird die Nachhaltigkeit zukünftig weiter intensiviert und im Sinne des Leitbilds der Nachhaltigkeit aus dem Jahr 1994 weiter ausgeweitet. Für die BASF SE umfasst Nachhaltigkeit die gesamte Wertschöpfungskette - vom Einkauf bis zum Kunden, um die CO₂-Emission stetig weiter zu reduzieren bei gleichzeitigem Ausbau der Produktmenge. Mit dem Schwerpunkt Digitalisierung wird ein Aspekt benannt, der nahezu alle Einheiten der BASF SE tangiert. Diese umfasst neben der Digitalisierung von Dokumentationsprozessen auch die Integration von digitalen Technologien in das Tagesgeschäft. Einen wesentlichen Beitrag zur Erhöhung der Verfügbarkeit sowie der optimierten Steuerung der Anlagen liefern PredM Lösungen, die zukünftig weiter ausgebaut werden.

C. Grundlagen & Modellierung

C.1. Notwendige Python Pakete

Tabelle C.1.: Tabellarische Auflistung der notwendigen Pakete zur Ausführung des Einzeltrendmoduls bzw. des Partikelfiltermoduls in Python 3.8.1.

Einzeltrendmodul & Partikelfiltermodul			
Paket	Version	Paket	Version
adjustText	0.8	contourpy	1.0.7
cycler	0.11.0	fonttools	4.39.0
importlib-resources	5.12.0	joblib	1.2.0
kiwisolver	1.4.4	matplotlib	3.7.1
numpy	1.24.2	packaging	23.0
pandas	1.5.3	Pillow	9.4.0
pymannkendall	1.4.3	pyparsing	3.0.9
python-dateutil	2.8.2	pytz	2022.7.1
scikit-learn	1.2.2	scipy	1.10.1
seaborn	0.12.2	six	1.16.0
threadpoolctl	3.1.0	tikzplotlib	0.10.1
tk	0.1.0	webcolors	1.12
zip	3.15.0		

Einzeltrendmodul		Partikelfiltermodul	
Paket	Version	Paket	Version
MoTOSSingleTagPrediction	2.0	MoTOSParticleFilterPackage	0.2
MoTOSUtilityPackage	1.0	MoTOSUtilityPackage	1.0
DateTime	5.0	et-xmlfile	1.1.0
pytictoc	1.5.2	openpyxl	3.1.1
ruptures	1.1.7	plotly	5.13.1
zope.interface	5.5.2	pytimeparse	1.1.8
		pyXSteam	0.4.9
		tenacity	8.2.2

C.2. Literaturübersicht Restlebenszeit Schätzung

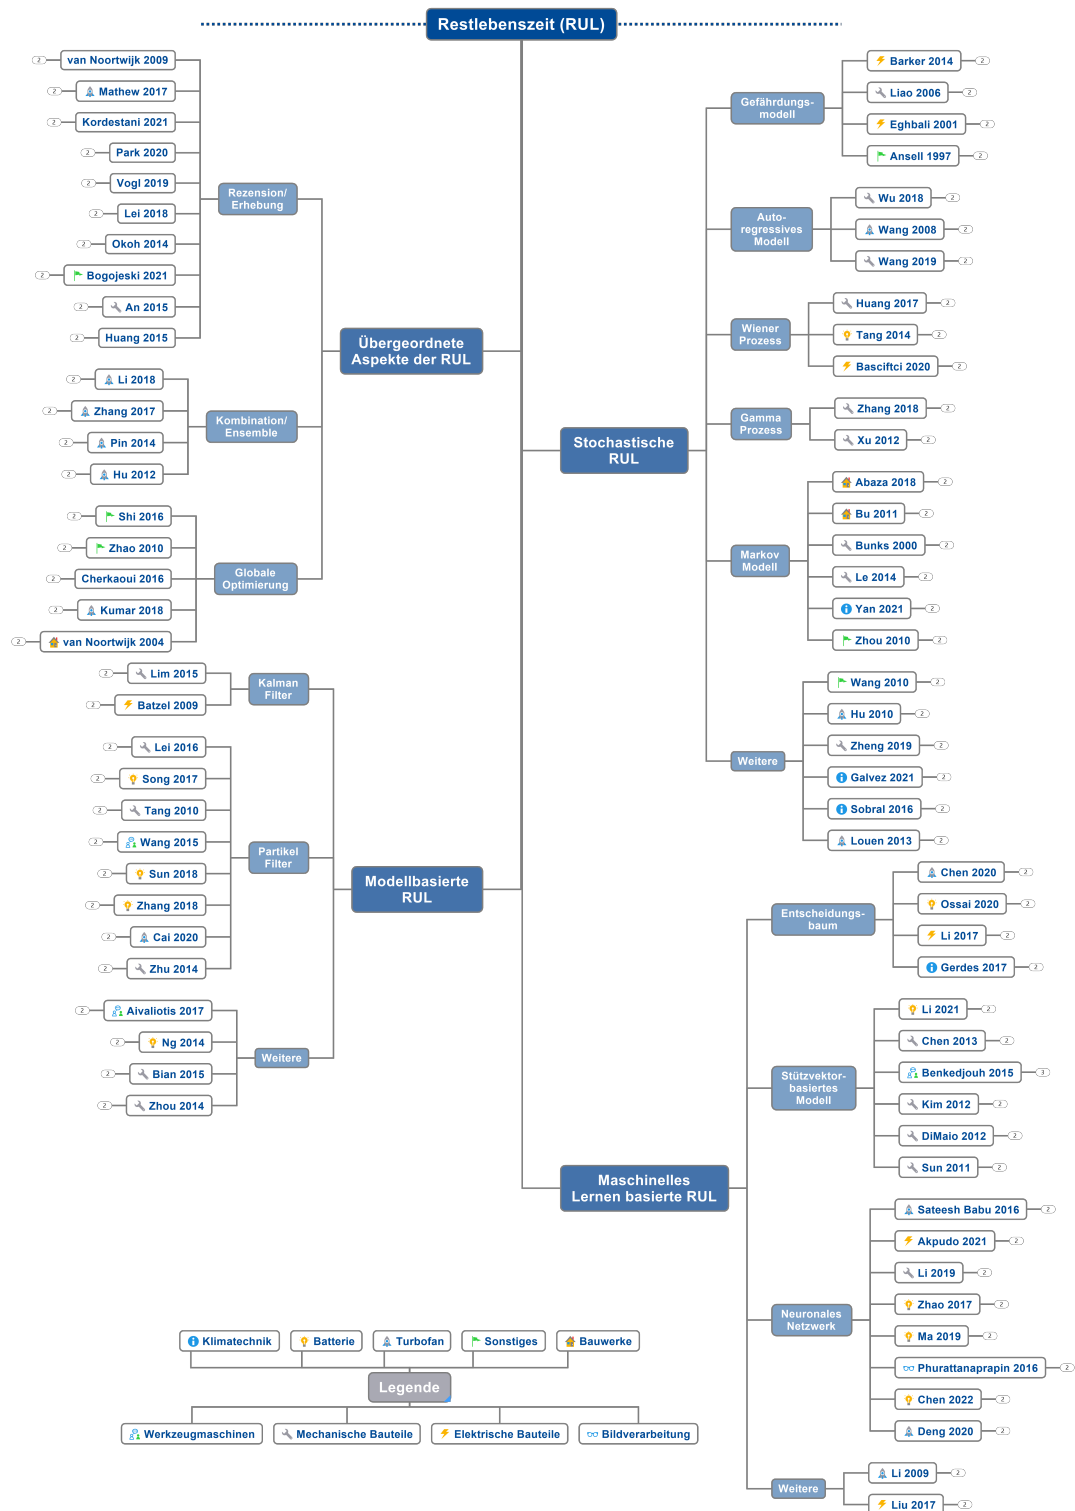


Abbildung C.1.: Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle.

C.3. Startwerte des Einzeltrendmodul-Optimierers

Im Rahmen des ETM wird ein Onlineoptimierungsproblem gelöst. Für die Abbildung des Signals werden die Parameter einer vordefinierten Gleichung bestimmt. Besonders für Exponentialfunktionen ist die Vorgabe von geeigneten Startwerten für die Optimierung von zentraler Bedeutung. Nachfolgend wird skizziert, wie die Startwerte der Funktion C.1 bestimmt werden.

$$y = c_1 + c_2 \left(1 + \exp(c_3 x) \right) \quad (\text{C.1})$$

Zu diesem Zweck werden drei Wertepaare ausgewählt, die den Datensatz möglichst gut beschreiben, die im Folgenden als x_1, y_1, x_2, y_2 und x_3, y_3 bezeichnet werden. Für die Abstände der Eingangsgröße gilt: $x_2 - x_1 = x_3 - x_2 = 0.5(x_3 - x_1) = \Delta x$. Grundlegend werden alle Wertepaare in Gleichung C.1 eingesetzt. Daraus folgt:

$$y_1 = c_1 + c_2 \left(1 + \exp(c_3 x_1) \right) \quad (\text{C.2})$$

$$y_2 = c_1 + c_2 \left(1 + \exp(c_3 x_2) \right) \quad (\text{C.3})$$

$$y_3 = c_1 + c_2 \left(1 + \exp(c_3 x_3) \right) \quad (\text{C.4})$$

Mit der Differenz aus Gleichung C.2 und Gleichung C.3 bzw. Gleichung C.2 und Gleichung C.4 folgt:

$$y_1 - y_2 = c_2 \left(\exp(c_3 x_1) - \exp(c_3 x_2) \right) \quad (\text{C.5})$$

$$y_1 - y_3 = c_2 \left(\exp(c_3 x_1) - \exp(c_3 x_3) \right) \quad (\text{C.6})$$

Durch den Quotienten aus Gleichung C.5 und C.6 folgt nach dem Umstellen Parameter c_3 :

$$\frac{y_1 - y_2}{y_1 - y_3} = \frac{\exp(c_3 x_1) - \exp(c_3 x_2)}{\exp(c_3 x_1) - \exp(c_3 x_3)} \quad (\text{C.7})$$

$$\Leftrightarrow \frac{y_1 - y_2}{y_1 - y_3} = \frac{1 - \exp\left(c_3(x_1 - x_2)\right)}{1 - \exp\left(c_3(x_1 - x_3)\right)} \quad (\text{C.8})$$

$$\Leftrightarrow \frac{y_1 - y_2}{y_1 - y_3} = \frac{1 - \exp(\Delta x)}{\left(1 - \exp(\Delta x)\right) \left(1 + \exp(\Delta x)\right)} \quad (\text{C.9})$$

$$\Leftrightarrow c_3 = \frac{\log(y_2 - y_3) - \log(y_1 - y_2)}{x_2 - x_1} \quad (\text{C.10})$$

Anhand von Gleichung C.5 wird durch Umformen Parameter c_2 abgeleitet. Abschließend wird durch Einsetzen in Gleichung C.2 der Parameter c_1 berechnet:

$$c_2 = \frac{y_1 - y_3}{\exp(c_3 x_1) - \exp(c_3 x_3)} \quad (\text{C.11})$$

$$c_1 = y_1 - c_2 \left(1 + \exp(c_3 x_1) \right) \quad (\text{C.12})$$

C.4. Modellierung des Robertverdampfers

Tabelle C.2.: Tabellarische Auflistung der Grenzen des Parameterraums als Basis für die Onlineüberwachung des Robertverdampfers durch das Partikelfiltermodul.

Position	Feature	untere Grenze	obere Grenze
Θ		$\Theta_{U.Grenz.}$	$\Theta_{O.Grenz.}$
1	<i>intercept</i>	-0.12613728	0.76599308
2	<i>dfci_dt</i>	-0.02248849	-0.02248814
3	<i>dinv_fhi_dt</i>	-0.17693833	-0.17693809
4	<i>dtei_dt</i>	-0.28104809	-0.28104773
5	<i>expdeltat</i>	0.00410228	0.004103
6	<i>fci_div_fhi</i>	0.00686957	0.00687444
7	<i>inv_fhi</i>	0.00750448	0.00750959
8	<i>r_dfci_div_fhi_dt</i>	0.38838797	0.38838826
9	<i>r_dfci_dt</i>	-0.23940802	-0.23940772
10	<i>r_dfhi_div_fci_dt</i>	0.08682054	0.08682082
11	<i>r_dfhi_dt</i>	-0.74923329	-0.74923308
12	<i>r_dinv_fhi_dt</i>	-0.13838639	-0.13838616
13	<i>r_fci</i>	0.00416795	0.00417037
14	<i>sumt</i>	0.00321768	0.50280297
15	<i>tci</i>	0.02058784	0.02059459




Abbildung C.2.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{Kum.}$ und dessen Residuum $res_{\Delta r_{Kum.}}$ anhand von Zyklus 17.




Abbildung C.3.: Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Zyklus 4.

D. Anhang zur synthetischen
Evaluation des
Einzeltrendmoduls

Tabelle D.1.: Tabellarische Auflistung der Einstellung zur Erzeugung synthetischer Daten für die Evaluierung durch das Partikelfiltermodul.

Einstellung	Wert
Anzahl Messwerte $n_{\text{Mess.}}$	200
Anzahl Ausgänge $n_{\text{Var.,Aus.}}$	2
Anzahl Zustände n_{Φ}	2
Anzahl Eingänge $n_{\text{Var.,Ein.}}$	4
Anzahl Sprünge pro Eingang n_{Sprung}	10
Initialer Zustand $State_{t=0}$	$[+10.1 \quad -1.56]$
Versatz Eingangssignale $c_{\text{Vers.}}$	1.0
Faktor Eingangssignale $c_{\text{Skal.}}$	2.5
ZG Parametervektor $\Theta_{\text{Synth.}}$	$[4.1e-3 \quad 6.7e-3 \quad 3.9e-3 \quad 5.8e-3]$
AG Parametervektor C	$[1.6 \quad 1.2 \quad 3.1 \quad 9.3]$
Rauschenvektor K_{Input} (für alle Eingänge)	$\mathcal{N}(0, 0.012)$
Rauschen Ausgänge K_{Measure}	$[\mathcal{N}(0, 4.83) \quad \mathcal{N}(0, 0.38)]$




Abbildung D.1.: Grafische Darstellung eines linearen, quadratischen und exponentiellen Signals S mit Rauschfaktor 0.005 sowie Wechsellpunkt bei 20%.




Abbildung D.2.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 451h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.




Abbildung D.3.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 571h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.




Abbildung D.4.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 581h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.




Abbildung D.5.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 761h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.

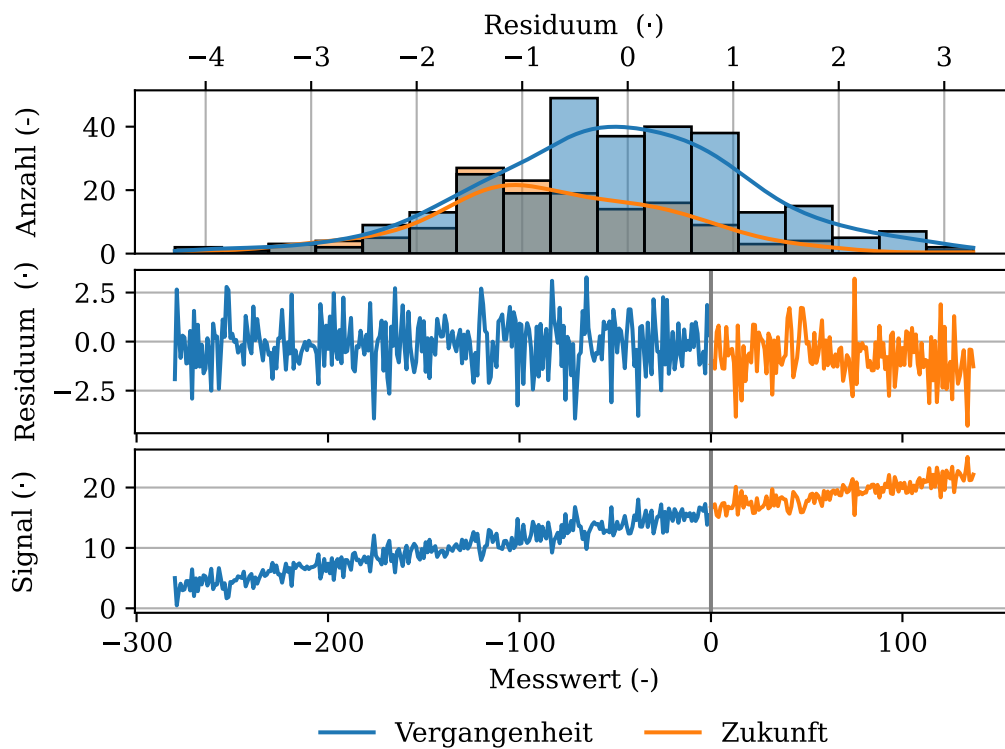


Abbildung D.6.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 761h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekannt Monotonie.




Abbildung D.7.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.




Abbildung D.8.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.




Abbildung D.9.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 941h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.




Abbildung D.10.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 571h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.




Abbildung D.11.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 0%.




Abbildung D.12.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 0%.




Abbildung D.13.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 901h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.




Abbildung D.14.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2041h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

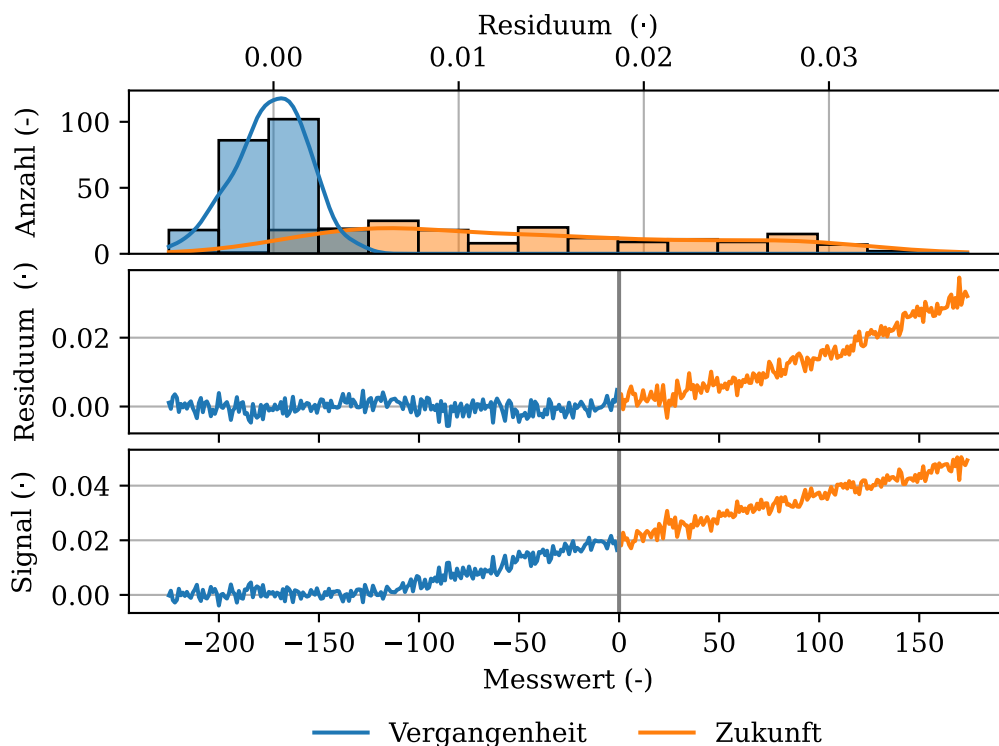


Abbildung D.15.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.




Abbildung D.16.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1341h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.




Abbildung D.17.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1501h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.




Abbildung D.18.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2081h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechselpunkt bei 20%.

E. Anhang zur synthetischen
Evaluation des
Partikelfiltermoduls




Abbildung E.1.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit hoher Toleranz.




Abbildung E.2.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit reduziertem Parameterbereich.




Abbildung E.3.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 2$ auf Basis synthetischer Daten ohne Rauschen mit niedriger Toleranz.




Abbildung E.4.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 1$ auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.




Abbildung E.5.: Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit niedriger Toleranz und mit 5% normalverteiltem Roughening.




Abbildung E.6.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 75h$ auf Basis synthetischer Daten ohne Rauschen, mit 25% normalverteiltem Roughening und Importance Resampling.




Abbildung E.7.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.




Abbildung E.8.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand $State(B)$ bei $t = 127h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.




Abbildung E.9.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 76h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.

F. Anhang zur Onlinesimulation des Einzeltrendmoduls




Abbildung F.1.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.2.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5986h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen zur Verfügung stehenden Funktionen.




Abbildung F.3.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5458h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.4.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.5.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5746h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.6.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.




Abbildung F.7.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5530h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.




Abbildung F.8.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4522h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.9.: Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 5674h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.10.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5002h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.




Abbildung F.11.: Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.

G. Anhang zur Onlinesimulation des Partikelfiltermoduls




Abbildung G.1.: Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 480h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.




Abbildung G.2.: Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 550h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.




Abbildung G.3.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parameterensors $\hat{\Theta}(j)$ mit Parameter $j = r_dfci_div_fhi_dt$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.




Abbildung G.4.: Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parameterensors $\hat{\Theta}(j)$ mit Parameter $j = intercept$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.

Tabellenverzeichnis

6.1.	Tabellarische Auflistung aller Merkmale des Featurevektors $M_{\text{Feat.}}$ und deren Formeln zur Abbildung der Degradation des Robertverdampfers.	94
7.1.	Tabellarische Auflistung der Eigenschaften eines sägezahnförmigen synthetischen Signals für die Evaluierung durch das Einzeltrendmodul.	104
7.2.	Tabellarische Auflistung der Eigenschaften heterogener synthetischer Signale für die Evaluierung durch das Einzeltrendmodul.	105
7.3.	Tabellarische Auflistung der Referenzeinstellung des Partikelfiltermoduls zur Evaluierung auf Basis von synthetischen Daten.	135
7.4.	Tabellarische Auflistung der Grenzen des Parameterraums zur Evaluierung des Partikelfiltermoduls auf Basis von synthetischen Daten.	136
8.1.	Tabellarische Auflistung der Einstellungen des Einzeltrendmoduls zur Überwachung des realen Membranpumpen Anwendungsfalls.	153
8.2.	Tabellarische Auflistung der Einstellung des Einzeltrendmoduls zur Überwachung des realen Ölfilter Anwendungsfalls.	167
C.1.	Tabellarische Auflistung der notwendigen Pakete zur Ausführung des Einzeltrendmoduls bzw. des Partikelfiltermoduls in Python 3.8.1.	199
C.2.	Tabellarische Auflistung der Grenzen des Parameterraums als Basis für die Onlineüberwachung des Robertverdampfers durch das Partikelfiltermodul.	202
D.1.	Tabellarische Auflistung der Einstellung zur Erzeugung synthetischer Daten für die Evaluierung durch das Partikelfiltermodul.	206

Algorithmenverzeichnis

1.	Pseudocode der Überführung unterschiedlicher Arten von Wechselempunkten in Sprünge und deren Detektion durch das Einzeltrendmodul. . . .	65
2.	Pseudocode der Funktionsauswahl und Parametrierung für alle potenziellen Wechselempunkte durch das Einzeltrendmodul.	66
3.	Pseudocode der Schätzung des zukünftigen Signals sowie der Restlebenszeit durch das Einzeltrendmodul.	68
4.	Pseudocode der wesentlichen Bearbeitungsschritte in der Hauptfunktionen des Partikelfiltermoduls.	72
5.	Pseudocode der Vorverarbeitung von Zeitreihen durch die Funktion preprocessing des Partikelfiltermoduls.	73
6.	Pseudocode der Aktualisierungsfunktion des Partikelfiltermoduls mit Resampling, Roughening und Partikeloptimierung.	75
7.	Pseudocode der Schätzfunktion des Partikelfiltermoduls zur Prädiktion zukünftiger Zustände.	77
8.	Pseudocode der Generierung synthetischer Daten für die Evaluation durch das Partikelfiltermodul.	79

Abbildungsverzeichnis

1.1.	Grafische Darstellung des vereinfachten Ablaufschemas dieser Arbeit mit Untergliederung in das Einzeltrendmodul und das Partikelfiltermodul sowie der Aufteilung in Offlinetraining und Onlineüberwachung.	5
2.1.	Grafische Darstellung der Klassifikation verschiedener Methoden zur Restlebenszeitschätzung untergliedert in Methodengruppen.	11
2.2.	Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die stochastische Methodengruppe.	13
2.3.	Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die Methodengruppe des maschinellen Lernens.	17
2.4.	Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf die modellbasierte Methodengruppe.	21
2.5.	Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle mit dem Fokus auf übergeordnete Aspekte der Restlebenszeitschätzung.	24
3.1.	Grafische Darstellung der operativen Infrastruktur innerhalb des Überwachungszentrums (ReCe) der BASF SE, bestehend aus Betriebsdateninformationssystem (PIMS), Unternehmensressourcenplanung (ERP), Anlagenstruktur (AF), Ausführungsplattform (DP) und Anzeigetafeln (DB) zur modellbasierten Onlineüberwachung der Equipments.	30
3.2.	Grafische Darstellung eines schematischen Ölfilterkreislaufs bestehend aus einem Ölbehälter, Ölkühler und dem Ölfilter F1 als Unterstützungseinrichtung eines exemplarischen Verdichters.	34
3.3.	Grafische Darstellung eines schematischen Hochdruckmembranpumpenkopfes im Schnitt mit dem Detail einer beschädigten doppelwandigen Membran.	36
3.4.	Grafische Darstellung eines Prozesses bestehend aus drei Kolonnen zur Aufbereitung eines Produkts mit dem Fokus auf die Wärmeübertragung durch einen Robertverdampfer.	37
3.5.	Grafische Darstellung eines Robertverdampfers im Schnitt inklusive der verfügbaren Messstellen sowie der Differenzierung zwischen Produkt- und Dampfseite.	38
4.1.	Grafische Darstellung der Stichprobe einer allgemeinen Verteilung Λ mit Mittelwert μ , Median ξ sowie weiteren statistischen Kennzahlen.	41

4.2.	Grafische Darstellung unterschiedlicher Arten von möglichen Wechselpunkten in einem Signal S	47
4.3.	Grafische Darstellung der Funktionsweise eines Kalman Filters auf Basis von Eingangsvektor Γ_t , Zustandsvektor Φ_t und Ausgangsvektor Ψ_t , der Systemmatrix \mathbf{A}_{KF} , Eingangsmatrix \mathbf{B}_{KF} , Ausgangsmatrix \mathbf{C}_{KF} und Durchgangsmatrix \mathbf{D}_{KF} sowie Messrauscheinfluss K_Ψ und Prozessrauscheinfluss K_Φ	55
4.4.	Grafische Darstellung der Verknüpfung zwischen Eingangsvektor Γ_t , Zustandsvektor $\Phi_{p,t}$ und Ausgangsvektor Ψ_t durch die Zustandsgleichung f_{ZG} und Ausgangsgleichung h_{AG} für einen Partikel p zum Zeitpunkt t	56
4.5.	Grafische Darstellung eines exemplarischen Resampling Vorgangs anhand der Importance Resampling Methode für den Zustand $\Phi(1)$ im Rahmen des Partikelfiltermoduls.	60
5.1.	Exemplarische Darstellung der Ergebnisse des Einzeltrendmoduls.	70
5.2.	Exemplarische Darstellung der Prädiktion des Einzeltrendmoduls.	71
5.3.	Exemplarische Darstellung des Schätzresiduums des Einzeltrendmoduls.	71
5.4.	Exemplarische Darstellung der Ergebnisse des Partikelfiltermoduls.	80
5.5.	Exemplarische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T	81
5.6.	Exemplarische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 1$	81
6.1.	Grafische Darstellung der verfügbaren Funktionen des Einzeltrendmoduls und den dazugehörigen Parametervektoren C_{ETM}	84
6.2.	Grafische Darstellung eines schematischen Degradationsprozesses und dessen Aufgliederung in unterschiedliche Datenkategorien.	88
6.3.	Grafische Darstellung der verfügbaren Datengrundlage des Robertverdampfers anhand des Dampfdrucks phi sowie der Kennzeichnung aktiver Betriebszustände.	90
6.4.	Grafische Darstellung des Vergleichs zwischen der Differenzbetriebszeit und dem Differenzwärmedurchgangswiderstand für alle ausgewählten Zyklen des Robertverdampfers sowie deren Unterteilung in Kreuzvalidierungs- und Blindtestzyklen.	93
6.5.	Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines 100-fältig globalen Degradationsmodells des Robertverdampfers.	96
6.6.	Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines zyklusspezifischen Degradationsmodells des Robertverdampfers auf Basis der Trainingszyklen.	98
6.7.	Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands Δr_{Kum} und dessen Residuum $res_{\Delta r_{\text{Kum}}}$ anhand von Zyklus 22.	99
6.8.	Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands Δr_{Kum} und dessen Residuum $res_{\Delta r_{\text{Kum}}}$ anhand von Zyklus 19.	99

6.9.	Grafische Gegenüberstellung der R^2 -Metriken von Training- und Testdaten eines zyklusspezifischen Degradationsmodells des Robertverdampfers auf Basis der Validierungszyklen.	100
6.10.	Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Validierungszyklus 18.	101
6.11.	Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{\text{Kum.}}$ und dessen Residuum $res_{\Delta r_{\text{Kum.}}}$ anhand von Validierungszyklus 2.	101
7.1.	Grafische Darstellung eines Sägezahn-Signals S mit drei unterschiedlich ausgeprägten Steigungen und Rauschfaktor 0.01.	104
7.2.	Grafische Darstellung eines Sägezahn-Signals S mit drei unterschiedlich ausgeprägten Steigungen und Rauschfaktor 0.03.	105
7.3.	Grafische Darstellung eines linearen, quadratischen und exponentiellen Signals S mit Rauschfaktor $w_{\kappa} = 0.015$ und einem Wechsellpunkt bei $i_{\text{Proz.}} = 0\%$	106
7.4.	Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekanntem Monotonie.	107
7.5.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 711h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	108
7.6.	Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 711h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekanntem Monotonie.	109
7.7.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 461h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	110
7.8.	Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.	112
7.9.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.	113
7.10.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1061h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.	114
7.11.	Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.	115
7.12.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 921h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.	116

7.13. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 511h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.	117
7.14. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.	118
7.15. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 501h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.	119
7.16. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 511h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.	120
7.17. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und CP bei $i_{\text{Proz.}} = 0\%$	121
7.18. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1461h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 0%	122
7.19. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2081h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 0%	123
7.20. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	124
7.21. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	125
7.22. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 861h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	126
7.23. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2221h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	127
7.24. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	128
7.25. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 901h$ auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	129
7.26. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2041h$ auf Basis des Kurven-Datensatzes mit schwachem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%	130
7.27. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Kurven-Datensatzes mit schwachem Rauschen, steigender Monotonie und Wechsellpunkt bei 20%	131
7.28. Grafische Darstellung der synthetischen Eingangs-, Ausgangs- und Zustandssignale zur Evaluation des Partikelfiltermoduls mit überlagertem Rauschen.	134

7.29. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit Referenzeinstellungen.	135
7.30. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit reduziertem Wertebereich von Θ	136
7.31. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen mit hoher Toleranz.	137
7.32. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit Referenzeinstellungen.	138
7.33. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 13h$ auf Basis synthetischer Daten ohne Rauschen mit niedriger Toleranz.	139
7.34. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.	140
7.35. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 50h$ auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.	141
7.36. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen und mit 25% normalverteiltem Roughening.	142
7.37. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit 25% normalverteiltem Roughening und Importance Resampling.	143
7.38. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	144
7.39. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	145
7.40. Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand $State(A)$ bei $t = 31h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	146
7.41. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 31h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	146
7.42. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 127h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	147
7.43. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	148

7.44. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 52h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	149
7.45. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 126h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	150
7.46. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 126h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	150
8.1. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	154
8.2. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5338h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	155
8.3. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	156
8.4. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5578h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	157
8.5. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5914h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	157
8.6. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	158
8.7. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8776h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	159
8.8. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8824h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	160
8.9. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8962h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	160
8.10. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	161
8.11. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	162

8.12. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5962h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	163
8.13. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	164
8.14. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8914h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	165
8.15. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8962h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	166
8.16. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 8824h$ auf Basis der kurzen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	166
8.17. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	168
8.18. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4402h$ auf Basis der kurzen Zyklen des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	169
8.19. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5674h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	170
8.20. Grafische Darstellung der Ergebnisse des Einzeltrendmoduls auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.	171
8.21. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4858h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.	172
8.22. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5002h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.	173
8.23. Grafische Darstellung eines langsamen Degradationsverlaufs des Robertverdampfers für die Evaluierung des Partikelfiltermoduls im Rahmen einer Onlinesimulation.	175
8.24. Grafische Darstellung eines schnellen Degradationsverlaufs des Robertverdampfers für die Evaluierung des Partikelfiltermoduls im Rahmen einer Onlinesimulation.	175
8.25. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis eines unbekanntes und langsamen Degradationszyklus des Robertverdampfers.	177
8.26. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 201h$ auf Basis eines unbekanntes und langsamen Degradationszyklus des Robertverdampfers.	178
8.27. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 280h$ auf Basis eines unbekanntes und langsamen Degradationszyklus des Robertverdampfers.	179

8.28. Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 280h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	179
8.29. Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 479h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	180
8.30. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 500h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	181
8.31. Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = sumt$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	182
8.32. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	183
8.33. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 201h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	184
8.34. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 250h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	185
8.35. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 318h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	185
8.36. Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 319h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	186
8.37. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 450h$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	187
8.38. Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = sumt$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	188
C.1. Grafische Darstellung der Klassifikation verschiedener Veröffentlichungen anhand der Methoden zur Restlebenszeitschätzung und deren Anwendungsfälle.	200
C.2. Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{Kum.}$ und dessen Residuum $res_{\Delta r_{Kum.}}$ anhand von Zyklus 17.	202
C.3. Grafische Gegenüberstellung des globalen- und zyklenspezifischen Degradationsmodells des Robertverdampfers mittels der kumulierten finiten Differenzen des Wärmedurchgangswiderstands $\Delta r_{Kum.}$ und dessen Residuum $res_{\Delta r_{Kum.}}$ anhand von Zyklus 4.	203

D.1. Grafische Darstellung eines linearen, quadratischen und exponentiellen Signals S mit Rauschfaktor 0.005 sowie Wechsellpunkt bei 20%.	206
D.2. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 451h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	207
D.3. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 571h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	207
D.4. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 581h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	208
D.5. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 761h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	208
D.6. Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 761h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer unbekannt Monotonie.	209
D.7. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und unbekannter Monotonie.	209
D.8. Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 481h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, allen verfügbaren Funktionen und einer steigenden Monotonie.	210
D.9. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 941h$ auf Basis des Sägezahn-Datensatzes mit starkem Rauschen, linearer Funktion und einer steigenden Monotonie.	210
D.10. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 571h$ auf Basis des Sägezahn-Datensatzes mit schwachem Rauschen, linearer Funktion und einer steigenden Monotonie.	211
D.11. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 0%.	211
D.12. Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 0%.	212
D.13. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 901h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	212
D.14. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2041h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	213
D.15. Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 841h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	213
D.16. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1341h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	214

D.17. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 1501h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	214
D.18. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 2081h$ auf Basis des Kurven-Datensatzes mit starkem Rauschen, unbekannter Monotonie und Wechsellpunkt bei 20%.	215
E.1. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit hoher Toleranz.	218
E.2. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen mit reduziertem Parameterbereich.	218
E.3. Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 2$ auf Basis synthetischer Daten ohne Rauschen mit niedriger Toleranz.	219
E.4. Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = 1$ auf Basis synthetischer Daten ohne Rauschen und mit 5% uniformem Roughening.	219
E.5. Grafische Darstellung der Ergebnisse des Partikelfiltermoduls auf Basis synthetischer Daten ohne Rauschen, mit niedriger Toleranz und mit 5% normalverteiltem Roughening.	220
E.6. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 75h$ auf Basis synthetischer Daten ohne Rauschen, mit 25% normalverteiltem Roughening und Importance Resampling.	220
E.7. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(B)$ bei $t = 10h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	221
E.8. Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand $State(B)$ bei $t = 127h$ auf Basis synthetischer Daten ohne Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	221
E.9. Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand $State(A)$ bei $t = 76h$ auf Basis synthetischer Daten mit Rauschen, mit 5% normalverteiltem Roughening, Importance Resampling und aktiver Partikeloptimierung.	222
F.1. Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	224
F.2. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5986h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen zur Verfügung stehenden Funktionen.	224
F.3. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5458h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	225
F.4. Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	225

F.5.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5746h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	226
F.6.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5410h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	226
F.7.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5530h$ auf Basis der langen Zyklen des Membranpumpen-Datensatzes, einer steigenden Monotonie und einer exponentiellen Funktion.	227
F.8.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 4522h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	227
F.9.	Grafische Darstellung des Schätzresiduums des Einzeltrendmoduls bei $t = 5674h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	228
F.10.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5002h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und allen verfügbaren Funktionen.	228
F.11.	Grafische Darstellung der Prädiktion des Einzeltrendmoduls bei $t = 5482h$ auf Basis des Ölfilter-Datensatzes, einer steigenden Monotonie und einer quadratischen Funktion.	229
G.1.	Grafische Darstellung des Smoothings durch das Partikelfiltermodul für den Zustand T bei $t = 480h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	232
G.2.	Grafische Darstellung der Prädiktion des Partikelfiltermoduls von Zustand T bei $t = 550h$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	232
G.3.	Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = r_dfci_div_fhi_dt$ auf Basis eines unbekanntem und langsamen Degradationszyklus des Robertverdampfers.	233
G.4.	Grafische Darstellung der geschätzten Partikeldichteverteilung des Partikelfiltermoduls anhand des Parametertensors $\hat{\Theta}(j)$ mit Parameter $j = intercept$ auf Basis eines unbekanntem und schnellen Degradationszyklus des Robertverdampfers.	233

Literaturverzeichnis

- [1] BPB, *Deutschlands Abhängigkeit von russischem Gas*. 2022. Adresse: <https://www.bpb.de/kurz-knapp/hintergrund-aktuell/507243/deutschlands-abhaengigkeit-von-russischem-gas/> (besucht am 19.01.2023).
- [2] UNFCCC, „Report of the Conference of the Parties on its twenty-first session, held in Paris from 30 November to 13 December 2015,“ United Nations Framework Convention on Climate Change, Report, 2016. Adresse: <https://unfccc.int/documents/9097>.
- [3] T. Schmeja, *Klimaschutzplan 2050 der Bundesregierung - Diskussionsbeitrag des Umweltbundesamtes* (Position). Umweltbundesamt, 2016, S. 67. Adresse: <https://www.umweltbundesamt.de/publikationen/klimaschutzplan-2050-der-bundesregierung>.
- [4] BASF, *Strategische Schwerpunkte und Werte*. 2022. Adresse: <https://www.basf.com/global/de/who-we-are/strategy/purpose-action-areas-values.html> (besucht am 07.06.2022).
- [5] H. H. Chin, P. S. Varbanov, J. J. Klemeš, M. F. D. Benjamin und R. R. Tan, „Asset maintenance optimisation approaches in the chemical and process industries – A review,“ *Chemical Engineering Research and Design*, Jg. 164, S. 162–194, 2020, ISSN: 0263-8762. DOI: <https://doi.org/10.1016/j.cherd.2020.09.034>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0263876220304986>.
- [6] B. Liu, J. Lin, L. Zhang und U. Kumar, „A Dynamic Prescriptive Maintenance Model Considering System Aging and Degradation,“ *IEEE Access*, Jg. 7, S. 94931–94943, 2019, ISSN: 2169-3536. DOI: 10.1109/ACCESS.2019.2928587.
- [7] X.-S. Si, W. Wang, C.-H. Hu und D.-H. Zhou, „Remaining useful life estimation – A review on the statistical data driven approaches,“ *European Journal of Operational Research*, Jg. 213, Nr. 1, S. 1–14, 2011, ISSN: 0377-2217. DOI: <https://doi.org/10.1016/j.ejor.2010.11.018>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0377221710007903>.
- [8] M. Kordestani, M. Saif, M. E. Orchard, R. Razavi-Far und K. Khorasani, „Failure Prognosis and Applications—A Survey of Recent Literature,“ *IEEE Transactions on Reliability*, Jg. 70, Nr. 2, S. 728–748, 2021, ISSN: 1558-1721. DOI: 10.1109/TR.2019.2930195.
- [9] Y. Lei, N. Li, L. Guo, N. Li, T. Yan und J. Lin, „Machinery health prognostics: A systematic review from data acquisition to RUL prediction,“ *Mechanical Systems and Signal Processing*, Jg. 104, S. 799–834, 2018, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp.2017.11.016>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0888327017305988>.

- [10] L. Tang, J. DeCastro, G. Kacprzyński, K. Goebel und G. Vachtsevanos, *Filtering and prediction techniques for model-based prognosis and uncertainty management*. 2010, S. 1–10. DOI: 10.1109/PHM.2010.5413490.
- [11] Y. Zheng, „Predicting Remaining Useful Life Based on Hilbert–Huang Entropy with Degradation Model,“ *Journal of Electrical and Computer Engineering*, Jg. 2019, S. 3203959, 2019, ISSN: 2090-0147. DOI: 10.1155/2019/3203959. Adresse: <https://doi.org/10.1155/2019/3203959>.
- [12] D. An, N. H. Kim und J.-H. Choi, „Practical options for selecting data-driven or physics-based prognostics algorithms with reviews,“ *Reliability Engineering and System Safety*, Jg. 133, S. 223–236, 2015, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.s.2014.09.014>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0951832014002245>.
- [13] X. Chen, G. Jin, S. Qiu, M. Lu und D. Yu, „Direct Remaining Useful Life Estimation Based on Random Forest Regression,“ in *2020 Global Reliability and Prognostics and Health Management (PHM-Shanghai)*, S. 1–7. DOI: 10.1109/PHM-Shanghai49105.2020.9281004.
- [14] G. Bu, J. Lee, H. Guan, M. Blumenstein und Y.-C. Loo, „Improving Reliability of Markov-based Bridge Deterioration Model using Artificial Neural Network.“
- [15] X. Chen, Z. Shen, Z. He, C. Sun und Z. Liu, „Remaining life prognostics of rolling bearing based on relative features and multivariable support vector machine,“ *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, Jg. 227, Nr. 12, S. 2849–2860, 2013, ISSN: 0954-4062. DOI: 10.1177/0954406212474395. Adresse: <https://doi.org/10.1177/0954406212474395>.
- [16] B. Wu, Y. Gao, S. Feng und T. Chanwimalueang, „Sparse Optimistic Based on Lasso-LSQR and Minimum Entropy De-Convolution with FARIMA for the Remaining Useful Life Prediction of Machinery,“ *Entropy*, Jg. 20, Nr. 10, 2018, ISSN: 1099-4300. DOI: 10.3390/e20100747.
- [17] U. E. Akpudo und J.-W. Hur, „A CEEMDAN-Assisted Deep Learning Model for the RUL Estimation of Solenoid Pumps,“ *Electronics*, Jg. 10, Nr. 17, 2021, ISSN: 2079-9292. DOI: 10.3390/electronics10172054.
- [18] H.-E. Kim, A. C. C. Tan, J. Mathew und B.-K. Choi, „Bearing fault prognosis based on health state probability estimation,“ *Expert Systems with Applications*, Jg. 39, Nr. 5, S. 5200–5213, 2012, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2011.11.019>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0957417411015491>.
- [19] X. Li, W. Zhang und Q. Ding, „Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction,“ *Reliability Engineering and System Safety*, Jg. 182, S. 208–218, 2019, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.s.2018.11.011>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0951832018308299>.

- [20] J. Li, R. J. Stones, G. Wang, X. Liu, Z. Li und M. Xu, „Hard drive failure prediction using Decision Trees,“ *Reliability Engineering and System Safety*, Jg. 164, S. 55–65, 2017, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2017.03.004>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832016301569>.
- [21] Z. Liu, W. Mei, X. Zeng, C. Yang und X. Zhou, „Remaining Useful Life Estimation of Insulated Gate Bipolar Transistors (IGBTs) Based on a Novel Volterra k-Nearest Neighbor Optimally Pruned Extreme Learning Machine (VKOPP) Model Using Degradation Data,“ *Sensors*, Jg. 17, Nr. 11, 2017, ISSN: 1424-8220. DOI: [10.3390/s17112524](https://doi.org/10.3390/s17112524).
- [22] C. I. Ossai und I. P. Egwutuoha, „Anomaly Detection and Extra Tree Regression for Assessment of the Remaining Useful Life of Lithium-Ion Battery,“ in *Advanced Information Networking and Applications*, L. Barolli, F. Amato, F. Moscato, T. Enokido und M. Takizawa, Hrsg., Springer International Publishing, S. 1474–1488, ISBN: 978-3-030-44041-1.
- [23] C. Louen, S. X. Ding und C. Kandler, „A new framework for remaining useful life estimation using Support Vector Machine classifier,“ in *2013 Conference on Control and Fault-Tolerant Systems (SysTol)*, S. 228–233. DOI: [10.1109/SysTol.2013.6693833](https://doi.org/10.1109/SysTol.2013.6693833).
- [24] G. Zhao, G. Zhang, Y. Liu, B. Zhang und C. Hu, „Lithium-ion battery remaining useful life prediction with Deep Belief Network and Relevance Vector Machine,“ in *2017 IEEE International Conference on Prognostics and Health Management (ICPHM)*, S. 7–13. DOI: [10.1109/ICPHM.2017.7998298](https://doi.org/10.1109/ICPHM.2017.7998298).
- [25] K. Phurattanaprapin und P. Horata, „Extended hierarchical extreme learning machine with multilayer perceptron,“ in *2016 13th International Joint Conference on Computer Science and Software Engineering (JCSSE)*, S. 1–5. DOI: [10.1109/JCSSE.2016.7748874](https://doi.org/10.1109/JCSSE.2016.7748874).
- [26] J. Wang, R. X. Gao, Z. Yuan, Z. Fan und L. Zhang, „A joint particle filter and expectation maximization approach to machine condition prognosis,“ *Journal of Intelligent Manufacturing*, Jg. 30, Nr. 2, S. 605–621, 2019, ISSN: 1572-8145. DOI: [10.1007/s10845-016-1268-0](https://doi.org/10.1007/s10845-016-1268-0). Adresse: <https://doi.org/10.1007/s10845-016-1268-0>.
- [27] J. Wang, P. Wang und R. X. Gao, „Enhanced particle filter for tool wear prediction,“ *Journal of Manufacturing Systems*, Jg. 36, S. 35–45, 2015, ISSN: 0278-6125. DOI: <https://doi.org/10.1016/j.jmsy.2015.03.005>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0278612515000217>.
- [28] Y. Lei, N. Li, S. Gontarz, J. Lin, S. Radkowski und J. Dybala, „A model-based method for remaining useful life prediction of machinery,“ *IEEE Transactions on Reliability*, Jg. 65, Nr. 3, S. 1314–1326, 2016, ISSN: 0018-9529.
- [29] S. X. Ding, Y. Wang, S. Yin, P. Zhang, Y. Yang und E. L. Ding, „Data-Driven Design of Fault-Tolerant Control Systems,“ *IFAC Proceedings Volumes*, Jg. 45, Nr. 20, S. 1323–1328, 2012, ISSN: 1474-6670. DOI: <https://doi.org/10.3182/20120829-3-MX-2028.00125>. Adresse: <http://www.sciencedirect.com/science/article/pii/S1474667016349382>.

- [30] C. Sun, Z. Zhang und Z. He, „Research on bearing life prediction based on support vector machine and its application,“ *Journal of Physics: Conference Series*, Jg. 305, S. 012028, 2011, ISSN: 1742-6596. DOI: 10.1088/1742-6596/305/1/012028. Adresse: <http://dx.doi.org/10.1088/1742-6596/305/1/012028>.
- [31] T. Benkedjouh, K. Medjaher, N. Zerhouni und S. Rechak, „Health assessment and life prediction of cutting tools based on support vector regression,“ *Journal of Intelligent Manufacturing*, Jg. 26, Nr. 2, S. 213–223, 2015, ISSN: 1572-8145. DOI: 10.1007/s10845-013-0774-6. Adresse: <https://doi.org/10.1007/s10845-013-0774-6>.
- [32] T. Darkow, R. Dittmar und H. Timm, „Real-time application of multivariate statistical methods for early event detection in an industrial slurry stripper,“ *IFAC Proceedings Volumes*, Jg. 47, Nr. 3, S. 8879–8884, 2014, ISSN: 1474-6670. DOI: <https://doi.org/10.3182/20140824-6-ZA-1003.00399>. Adresse: <http://www.sciencedirect.com/science/article/pii/S1474667016430144>.
- [33] Z. Shu, L. Lijuan, Y. Lijuan, Y. Shipin und Z. Tao, „Data-driven process decomposition and robust online distributed modelling for large-scale processes,“ *International Journal of Systems Science*, Jg. 49, Nr. 3, S. 449–463, 2018, ISSN: 0020-7721. DOI: 10.1080/00207721.2017.1406551. Adresse: <https://doi.org/10.1080/00207721.2017.1406551>.
- [34] F. Li, Z. Zhu, H. Liao, Y. Liu, L. Yan, Y. Wu und Z. Huang, *An AdaBoost-Support Vector Regression Method for Remaining Useful Life Prediction of Lithium-ion Batteries*. 2021. DOI: 10.46855/energy-proceedings-7154.
- [35] Z. Li, K. Goebel und D. Wu, „Degradation Modeling and Remaining Useful Life Prediction of Aircraft Engines Using Ensemble Learning,“ *Journal of Engineering for Gas Turbines and Power*, Jg. 141, Nr. 4, 2018, ISSN: 0742-4795. DOI: 10.1115/1.4041674. Adresse: <https://doi.org/10.1115/1.4041674>.
- [36] D. R. Cox, „Regression Models and Life-Tables,“ *Journal of the Royal Statistical Society: Series B (Methodological)*, Jg. 34, Nr. 2, S. 187–202, 1972, ISSN: 0035-9246. DOI: <https://doi.org/10.1111/j.2517-6161.1972.tb00899.x>. Adresse: <https://rss.onlinelibrary.wiley.com/doi/abs/10.1111/j.2517-6161.1972.tb00899.x>.
- [37] K. Barker und H. Baroud, „Proportional hazards models of infrastructure system recovery,“ *Reliability Engineering and System Safety*, Jg. 124, S. 201–206, 2014, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2013.12.004>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832013003256>.
- [38] H. Liao, W. Zhao und H. Guo, *Predicting remaining useful life of an individual unit using proportional hazards model and logistic regression model*. 2006, S. 127–132. DOI: 10.1109/RAMS.2006.1677362.
- [39] G. Eghbali und E. Elsayed, „Reliability Estimate using Degradation Data,“ 2001.
- [40] J. I. Ansell und M. J. Philipps, „Practical aspects of modelling of repairable systems data using proportional hazards models,“ *Reliability Engineering and System Safety*, Jg. 58, Nr. 2, S. 165–171, 1997, ISSN: 0951-8320. DOI: [https://doi.org/10.1016/S0951-8320\(97\)00026-4](https://doi.org/10.1016/S0951-8320(97)00026-4). Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832097000264>.

-
- [41] T. Wang, J. Yu, D. Siegel und J. Lee, „A similarity-based prognostics approach for Remaining Useful Life estimation of engineered systems,“ in *2008 International Conference on Prognostics and Health Management*, S. 1–6. DOI: 10.1109/PHM.2008.4711421.
- [42] B. Basciftci, S. Ahmed und N. Gebraeel, „Data-driven maintenance and operations scheduling in power systems under decision-dependent uncertainty,“ *IISE Transactions*, Jg. 52, Nr. 6, S. 589–602, 2020, ISSN: 2472-5854. DOI: 10.1080/24725854.2019.1660831. Adresse: <https://doi.org/10.1080/24725854.2019.1660831>.
- [43] Z. Huang, Z. Xu, X. Ke, W. Wang und Y. Sun, „Remaining useful life prediction for an adaptive skew-Wiener process model,“ *Mechanical Systems and Signal Processing*, Jg. 87, S. 294–306, 2017, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp.2016.10.027>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0888327016304423>.
- [44] S. Tang, C. Yu, X. Wang, X. Guo und X. Si, „Remaining Useful Life Prediction of Lithium-Ion Batteries Based on the Wiener Process with Measurement Error,“ *Energies*, Jg. 7, Nr. 2, S. 520–547, 2014, ISSN: 1996-1073. Adresse: <https://www.mdpi.com/1996-1073/7/2/520>.
- [45] J. Y. Zhang, „Development of a data-driven method for predicting the remaining useful life of a belt system,“ Thesis, 2018.
- [46] W. Xu und W. Wang, „An adaptive gamma process based model for residual useful life prediction,“ in *Proceedings of the IEEE 2012 Prognostics and System Health Management Conference (PHM-2012 Beijing)*, S. 1–4, ISBN: 978-1-4577-1910-3. DOI: 10.1109/PHM.2012.6228785.
- [47] Y. Yan, J. Cai, T. Li, W. Zhang und L. Sun, „Fault prognosis of HVAC air handling unit and its components using hidden-semi Markov model and statistical process control,“ *Energy and Buildings*, Jg. 240, S. 110 875, 2021, ISSN: 0378-7788. DOI: <https://doi.org/10.1016/j.enbuild.2021.110875>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0378778821001596>.
- [48] C. Bunks, D. McCarthy und T. Al-Ani, „CONDITION-BASED MAINTENANCE OF MACHINES USING HIDDEN MARKOV MODELS,“ *Mechanical Systems and Signal Processing*, Jg. 14, Nr. 4, S. 597–612, 2000, ISSN: 0888-3270. DOI: <https://doi.org/10.1006/mssp.2000.1309>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0888327000913098>.
- [49] T. Le, C. Berenguer und F. Chatelain, „Multi-Branch Hidden Semi-Markov Modeling for RUL Prognosis,“ Jg. 2015, 2014. DOI: 10.1109/RAMS.2015.7105132.
- [50] K. A. Abaza, „Empirical-Markovian model for predicting the overlay design thickness for asphalt concrete pavement,“ *Road Materials and Pavement Design*, Jg. 19, Nr. 7, S. 1617–1635, 2018, ISSN: 1468-0629. DOI: 10.1080/14680629.2017.1338188. Adresse: <https://doi.org/10.1080/14680629.2017.1338188>.

- [51] Z.-J. Zhou, C.-H. Hu, D.-L. Xu, M.-Y. Chen und D.-H. Zhou, „A model for real-time failure prognosis based on hidden Markov model and belief rule base,“ *European Journal of Operational Research*, Jg. 207, Nr. 1, S. 269–283, 2010, ISSN: 0377-2217. DOI: <https://doi.org/10.1016/j.ejor.2010.03.032>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0377221710002596>.
- [52] J. Sobral und C. Guedes Soares, „Preventive Maintenance of Critical Assets based on Degradation Mechanisms and Failure Forecast,“ *IFAC-PapersOnLine*, Jg. 49, Nr. 28, S. 97–102, 2016, ISSN: 2405-8963. DOI: <https://doi.org/10.1016/j.ifacol.2016.11.017>. Adresse: <http://www.sciencedirect.com/science/article/pii/S2405896316324417>.
- [53] A. Gálvez, A. Diez-Olivan, D. Seneviratne und D. Galar, „Fault Detection and RUL Estimation for Railway HVAC Systems Using a Hybrid Model-Based Approach,“ *Sustainability*, Jg. 13, Nr. 12, 2021, ISSN: 2071-1050. DOI: 10.3390/su13126828.
- [54] Y. Wang, Y. Dang, Y. Li und S. Liu, „An approach to increase prediction precision of GM(1,1) model based on optimization of the initial condition,“ *Expert Systems with Applications*, Jg. 37, Nr. 8, S. 5640–5644, 2010, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2010.02.048>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0957417410000874>.
- [55] D. Julong, „Introduction to grey system theory,“ *The Journal of grey system*, Jg. 1, Nr. 1, S. 1–24, 1989.
- [56] C.-H. Hu, X.-S. Si und J.-B. Yang, „System reliability prediction model based on evidential reasoning algorithm with nonlinear optimization,“ *Expert Systems with Applications*, Jg. 37, Nr. 3, S. 2550–2562, 2010, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2009.08.024>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0957417409007775>.
- [57] M. Gerdes, D. Galar und D. Scholz, „Genetic algorithms and decision trees for condition monitoring and prognosis of A320 aircraft air conditioning,“ *Insight-Non-Destructive Testing and Condition Monitoring*, Jg. 59, Nr. 8, S. 424–433, 2017, ISSN: 1354-2575.
- [58] F. Di Maio, K. L. Tsui und E. Zio, „Combining Relevance Vector Machines and exponential regression for bearing residual life estimation,“ *Mechanical Systems and Signal Processing*, Jg. 31, S. 405–427, 2012, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp.2012.03.011>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0888327012001161>.
- [59] G. Sateesh Babu, P. Zhao und X.-L. Li, „Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life,“ in *Database Systems for Advanced Applications*, S. B. Navathe, W. Wu, S. Shekhar, X. Du, X. S. Wang und H. Xiong, Hrsg., Springer International Publishing, S. 214–228, ISBN: 978-3-319-32025-0.
- [60] Y. Ma, D. Shen, L. Wu, Y. Guan und H. Zhu, „The Remaining Useful Life Estimation of Lithium-ion Batteries Based on the HKA -ML-ELM Algorithm,“ 2019. DOI: 10.20964/2019.08.44. Adresse: <http://www.electrochemsci.org/papers/vol114/140807737.pdf>.

-
- [61] Y. Deng, A. D. Bucchianico und M. Pechenizkiy, „Controlling the accuracy and uncertainty trade-off in RUL prediction with a surrogate Wiener propagation model,“ *Reliability Engineering and System Safety*, Jg. 196, S. 106 727, 2020, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2019.106727>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832019301723>.
- [62] X. Chen und Z. Liu, „A long short-term memory neural network based Wiener process model for remaining useful life prediction,“ *Reliability Engineering and System Safety*, Jg. 226, S. 108 651, 2022, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2022.108651>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832022002861>.
- [63] Y. G. Li und P. Nilkitsaranont, „Gas turbine performance prognostic for condition-based maintenance,“ *Applied Energy*, Jg. 86, Nr. 10, S. 2152–2161, 2009, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2009.02.011>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0306261909000506>.
- [64] T. D. Batzel und D. C. Swanson, „Prognostic Health Management of Aircraft Power Generators,“ *IEEE Transactions on Aerospace and Electronic Systems*, Jg. 45, Nr. 2, S. 473–482, 2009, ISSN: 1557-9603. DOI: [10.1109/TAES.2009.5089535](https://doi.org/10.1109/TAES.2009.5089535).
- [65] C. K. R. Lim und D. Mba, „Switching Kalman filter for failure prognostic,“ *Mechanical Systems and Signal Processing*, Jg. 52-53, S. 426–435, 2015, ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp.2014.08.006>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0888327014003227>.
- [66] Y. Sun, X. Hao, M. Pecht und Y. Zhou, „Remaining useful life prediction for lithium-ion batteries based on an integrated health indicator,“ *Microelectronics Reliability*, Jg. 88-90, S. 1189–1194, 2018, ISSN: 0026-2714. DOI: <https://doi.org/10.1016/j.microrel.2018.07.047>. Adresse: <https://www.sciencedirect.com/science/article/pii/S002627141830595X>.
- [67] J. Zhu, J. Yoon, D. He und E. Bechhofer, „Online particle-contaminated lubrication oil condition monitoring and remaining useful life prediction for wind turbines: Particle contamination models,“ *Wind Energy*, Jg. 18, 2014. DOI: [10.1002/we.1746](https://doi.org/10.1002/we.1746).
- [68] H. Zhang, Q. Miao, X. Zhang und Z. Liu, „An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction,“ *Microelectronics Reliability*, Jg. 81, S. 288–298, 2018, ISSN: 0026-2714. DOI: <https://doi.org/10.1016/j.microrel.2017.12.036>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0026271417306005>.
- [69] Y. Song, D. Liu, C. Yang und Y. Peng, „Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery,“ *Microelectronics Reliability*, Jg. 75, S. 142–153, 2017, ISSN: 0026-2714. DOI: <https://doi.org/10.1016/j.microrel.2017.06.045>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0026271417302330>.

- [70] H. Cai, J. Feng, W. Li, Y.-M. Hsu und J. Lee, „Similarity-based Particle Filter for Remaining Useful Life prediction with enhanced performance,“ *Applied Soft Computing*, Jg. 94, S. 106–117, 2020, ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2020.106474>. Adresse: <http://www.sciencedirect.com/science/article/pii/S1568494620304130>.
- [71] S. S. Y. Ng, Y. Xing und K. L. Tsui, „A naive Bayes model for robust remaining useful life prediction of lithium-ion battery,“ *Applied Energy*, Jg. 118, S. 114–123, 2014, ISSN: 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2013.12.020>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0306261913010192>.
- [72] L. Bian, N. Gebraeel und J. P. Kharoufeh, „Degradation modeling for real-time estimation of residual lifetimes in dynamic environments,“ *IIE Transactions*, Jg. 47, Nr. 5, S. 471–486, 2015, ISSN: 0740-817X. DOI: [10.1080/0740817X.2014.955153](https://doi.org/10.1080/0740817X.2014.955153). Adresse: <https://doi.org/10.1080/0740817X.2014.955153>.
- [73] R. R. Zhou, N. Serban, N. Gebraeel und H.-G. Müller, „A Functional Time Warping Approach to Modeling and Monitoring Truncated Degradation Signals,“ *Technometrics*, Jg. 56, Nr. 1, S. 67–77, 2014, ISSN: 0040-1706. DOI: [10.1080/00401706.2013.805661](https://doi.org/10.1080/00401706.2013.805661). Adresse: <https://doi.org/10.1080/00401706.2013.805661>.
- [74] P. Aivaliotis, K. Georgoulas und G. Chryssolouris, „A RUL calculation approach based on physical-based simulation models for predictive maintenance,“ in *2017 International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, S. 1243–1246. DOI: [10.1109/ICE.2017.8280022](https://doi.org/10.1109/ICE.2017.8280022).
- [75] C. Okoh, R. Roy, J. Mehnen und L. Redding, „Overview of Remaining Useful Life Prediction Techniques in Through-life Engineering Services,“ *Procedia CIRP*, Jg. 16, S. 158–163, 2014, ISSN: 2212-8271. DOI: <https://doi.org/10.1016/j.procir.2014.02.006>. Adresse: <http://www.sciencedirect.com/science/article/pii/S2212827114001140>.
- [76] Y.-J. Park, S.-K. S. Fan und C.-Y. Hsu, „A Review on Fault Detection and Process Diagnostics in Industrial Processes,“ *Processes*, Jg. 8, Nr. 9, S. 1123, 2020, ISSN: 2227-9717. Adresse: <https://www.mdpi.com/2227-9717/8/9/1123>.
- [77] V. Mathew, T. Toby, V. Singh, B. M. Rao und M. G. Kumar, „Prediction of Remaining Useful Lifetime (RUL) of turbofan engine using machine learning,“ in *2017 IEEE International Conference on Circuits and Systems (ICCS)*, S. 306–311. DOI: [10.1109/ICCS1.2017.8326010](https://doi.org/10.1109/ICCS1.2017.8326010).
- [78] J. M. van Noortwijk, „A survey of the application of gamma processes in maintenance,“ *Reliability Engineering and System Safety*, Jg. 94, Nr. 1, S. 2–21, 2009, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.ress.2007.03.019>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832007001111>.
- [79] H.-Z. Huang, H.-K. Wang, Y.-F. Li, L. Zhang und Z. Liu, „Support vector machine based estimation of remaining useful life: current research status and future trends,“ *Journal of Mechanical Science and Technology*, Jg. 29, Nr. 1, S. 151–163, 2015, ISSN: 1976-3824. DOI: [10.1007/s12206-014-1222-z](https://doi.org/10.1007/s12206-014-1222-z). Adresse: <https://doi.org/10.1007/s12206-014-1222-z>.

-
- [80] G. W. Vogl, B. A. Weiss und M. Helu, „A review of diagnostic and prognostic capabilities and best practices for manufacturing,“ *Journal of Intelligent Manufacturing*, Jg. 30, Nr. 1, S. 79–95, 2019, ISSN: 1572-8145.
- [81] M. Bogojeski, S. Sauer, F. Horn und K.-R. Müller, „Forecasting industrial aging processes with machine learning methods,“ *Computers and Chemical Engineering*, Jg. 144, S. 107–123, 2021, ISSN: 0098-1354. DOI: <https://doi.org/10.1016/j.compchemeng.2020.107123>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0098135420305494>.
- [82] L. Pin, C.-K. Goh, K. C. Tan und P. Dutta, „Estimation of remaining useful life based on switching Kalman Filter neural network ensemble,“ *PHM 2014 - Proceedings of the Annual Conference of the Prognostics and Health Management Society 2014*, S. 2–9, 2014.
- [83] C. Zhang, P. Lim, A. K. Qin und K. C. Tan, „Multiobjective Deep Belief Networks Ensemble for Remaining Useful Life Estimation in Prognostics,“ *IEEE Transactions on Neural Networks and Learning Systems*, Jg. 28, Nr. 10, S. 2306–2318, 2017, ISSN: 2162-2388. DOI: 10.1109/TNNLS.2016.2582798.
- [84] C. Hu, B. D. Youn, P. Wang und J. Taek Yoon, „Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life,“ *Reliability Engineering and System Safety*, Jg. 103, S. 120–135, 2012, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2012.03.008>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832012000427>.
- [85] H. Shi und J. Zeng, „Real-time prediction of remaining useful life and preventive opportunistic maintenance strategy for multi-component systems considering stochastic dependence,“ *Computers and Industrial Engineering*, Jg. 93, S. 192–204, 2016, ISSN: 0360-8352. DOI: <https://doi.org/10.1016/j.cie.2015.12.016>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0360835215004866>.
- [86] X. Zhao, M. Fouladirad, C. Bérenguer und L. Bordes, „Condition-based inspection/replacement policies for non-monotone deteriorating systems with environmental covariates,“ *Reliability Engineering and System Safety*, Jg. 95, Nr. 8, S. 921–934, 2010, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2010.04.005>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0951832010000839>.
- [87] A. Kumar, R. Shankar und L. S. Thakur, „A big data driven sustainable manufacturing framework for condition-based maintenance prediction,“ *Journal of Computational Science*, Jg. 27, S. 428–439, 2018, ISSN: 1877-7503. DOI: <https://doi.org/10.1016/j.jocs.2017.06.006>. Adresse: <http://www.sciencedirect.com/science/article/pii/S1877750316305129>.
- [88] H. Cherkaoui, K. T. Huynh und A. Grall, „On the Assessment of Performance and Robustness of Condition-Based Maintenance Strategies,“ *IFAC-PapersOnLine*, Jg. 49, Nr. 12, S. 809–814, 2016, ISSN: 2405-8963. DOI: <https://doi.org/10.1016/j.ifacol.2016.07.874>. Adresse: <http://www.sciencedirect.com/science/article/pii/S2405896316311600>.
- [89] J. M. v. Noortwijk, „Optimal Replacement Decisions for Structures under Stochastic Deterioration.“

- [90] A. Walzenbach, *Asset Monitoring Solutions and Services*. 2022. Adresse: <https://intranet.basf.com/global-engineering/leadership-team/technical-expertise-get/get-a/get-ar/get-ar-asset-monitoring-solutions-services/> (besucht am 30.12.2022).
- [91] A. Lauer, „PIMS - Plant information management system,“ Unpublished Work, 2020.
- [92] A. Lauer, „PIMS Compression,“ Unpublished Work, 2019.
- [93] A. Kunz, „Leitlinien zur Kompressionseinstellung von BDIS Tags,“ Unpublished Work, 2020.
- [94] OSIsoft, *PI Server*. 2022. Adresse: <https://www.osisoft.de/pi-system/pi-core/pi-server> (besucht am 31.12.2022).
- [95] gitHub, *Let's build from here*. 2022. Adresse: <https://github.com/> (besucht am 31.12.2022).
- [96] kubernetes, *Produktreife Container-Orchestrierung*. 2022. Adresse: <https://kubernetes.io/de/>.
- [97] R. S. Dwyer-Joyce, „Predicting the abrasive wear of ball bearings by lubricant debris,“ *Wear*, Jg. 233-235, S. 692–701, 1999, ISSN: 0043-1648. DOI: [https://doi.org/10.1016/S0043-1648\(99\)00184-2](https://doi.org/10.1016/S0043-1648(99)00184-2). Adresse: <https://www.sciencedirect.com/science/article/pii/S0043164899001842>.
- [98] J. Halme und P. Andersson, „Rolling contact fatigue and wear fundamentals for rolling bearing diagnostics - state of the art,“ *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology*, Jg. 224, Nr. 4, S. 377–393, 2010. DOI: 10.1243/13506501jet656. Adresse: <https://journals.sagepub.com/doi/abs/10.1243/13506501JET656>.
- [99] H. D. Baehr und S. Kabelac, „Der 1.Hauptsatz der Thermodynamik,“ in *Thermodynamik: Grundlagen und technische Anwendungen*, H. D. Baehr und S. Kabelac, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, S. 43–91, ISBN: 978-3-642-00556-5. DOI: 10.1007/978-3-642-00556-5_2. Adresse: https://doi.org/10.1007/978-3-642-00556-5_2.
- [100] D. Bernoulli, *Hydrodynamica: sive de viribus et motibus fluidorum commentarii*. 1738.
- [101] G. O. Brown, „The history of the Darcy-Weisbach equation for pipe flow resistance,“ in *Environmental and water resources history*. 2003, S. 34–43.
- [102] LEWA, *LEWA ecoflow Membrandosierpumpe*. 2022. Adresse: <https://www.lewa.de/de/pumpen/dosierpumpen/lewa-ecoflow-membrandosierpumpe> (besucht am 02.01.2023).
- [103] LEWA, *LEWA Pumpenkopftechnologie*. 2022. Adresse: <https://www.lewa.de/de/technologien/pumpentechnik> (besucht am 02.01.2023).
- [104] R. Wunderlich, „O1 Konstruktive Hinweise für den Bau von Wärmeübertragern,“ in *VDI-Wärmeatlas: Fachlicher Träger VDI-Gesellschaft Verfahrenstechnik und Chemieingenieurwesen*, P. Stephan, S. Kabelac, M. Kind, D. Mewes, K. Schaber und T. Wetzels, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2019, S. 2011–2039, ISBN: 978-3-662-52989-8. DOI: 10.1007/978-3-662-52989-8_114. Adresse: https://doi.org/10.1007/978-3-662-52989-8_114.

- [105] H. Müller-Steinhagen, „C4 Fouling of Heat Exchanger Surfaces,“ in *VDI Heat Atlas*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, S. 79–104, ISBN: 978-3-540-77877-6. DOI: 10.1007/978-3-540-77877-6_7. Adresse: https://doi.org/10.1007/978-3-540-77877-6_7.
- [106] L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, „Univariate Deskription und Exploration von Daten,“ in *Statistik: Der Weg zur Datenanalyse*, L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, S. 29–103, ISBN: 978-3-662-50372-0. DOI: 10.1007/978-3-662-50372-0_2. Adresse: https://doi.org/10.1007/978-3-662-50372-0_2.
- [107] L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, „Stetige Zufallsvariablen,“ in *Statistik: Der Weg zur Datenanalyse*, L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, S. 251–287, ISBN: 978-3-662-50372-0. DOI: 10.1007/978-3-662-50372-0_6. Adresse: https://doi.org/10.1007/978-3-662-50372-0_6.
- [108] L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, „Mehrdimensionale Zufallsvariablen,“ in *Statistik: Der Weg zur Datenanalyse*, L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, S. 311–335, ISBN: 978-3-662-50372-0. DOI: 10.1007/978-3-662-50372-0_8. Adresse: https://doi.org/10.1007/978-3-662-50372-0_8.
- [109] F. Galton, „I. Co-relations and their measurement, chiefly from anthropometric data,“ *Proceedings of the Royal Society of London*, Jg. 45, Nr. 273-279, S. 135–145, 1889, ISSN: 0370-1662.
- [110] M. G. Kendall, „A New Measure of Rank Correlation,“ *Biometrika*, Jg. 30, Nr. 1/2, S. 81–93, 1938, ISSN: 00063444. DOI: 10.2307/2332226. Adresse: <http://www.jstor.org/stable/2332226>.
- [111] W. W. Melek, Z. Lu, A. Kapps und W. Fraser, „Comparison of Trend Detection Algorithms in the Analysis of Physiological Time-Series Data,“ *IEEE transactions on bio-medical engineering*, Jg. 52, S. 639–51, 2005. DOI: 10.1109/TBME.2005.844029.
- [112] S. Sharma, D. A. Swayne und C. Obimbo, „Trend analysis and change point techniques: a survey,“ *Energy, Ecology and Environment*, Jg. 1, Nr. 3, S. 123–130, 2016, ISSN: 2363-7692.
- [113] L. Rabiner, M. Sambur und C. Schmidt, „Applications of a nonlinear smoothing algorithm to speech processing,“ *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Jg. 23, Nr. 6, S. 552–557, 1975, ISSN: 0096-3518. DOI: 10.1109/TASSP.1975.1162749.
- [114] G. Arce und M. McLoughlin, „Theoretical analysis of the max/Median filter,“ *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Jg. 35, Nr. 1, S. 60–69, 1987, ISSN: 0096-3518. DOI: 10.1109/TASSP.1987.1165036.
- [115] N. Gallagher und G. Wise, „A theoretical analysis of the properties of median filters,“ *IEEE Transactions on Acoustics, Speech, and Signal Processing*, Jg. 29, Nr. 6, S. 1136–1141, 1981, ISSN: 0096-3518. DOI: 10.1109/TASSP.1981.1163708.

- [116] P. J. Rousseeuw und M. Hubert, „Robust statistics for outlier detection,“ *WIREs Data Mining and Knowledge Discovery*, Jg. 1, Nr. 1, S. 73–79, 2011, ISSN: 1942-4787. DOI: <https://doi.org/10.1002/widm.2>. Adresse: <https://wires.onlinelibrary.wiley.com/doi/abs/10.1002/widm.2>.
- [117] P. C. Mahalanobis, „On the generalized distance in statistics,“ National Institute of Science of India.
- [118] C. Truong, L. Oudre und N. Vayatis, „Selective review of offline change point detection methods,“ *Signal Processing*, Jg. 167, S. 107–299, 2020, ISSN: 0165-1684.
- [119] O. Jesorsky, K. J. Kirchberg und R. W. Frischholz, „Robust face detection using the hausdorff distance,“ in *International conference on audio-and video-based biometric person authentication*, Springer, S. 90–95.
- [120] D. P. Huttenlocher, G. A. Klanderman und W. J. Rucklidge, „Comparing images using the Hausdorff distance,“ *IEEE Transactions on pattern analysis and machine intelligence*, Jg. 15, Nr. 9, S. 850–863, 1993, ISSN: 0162-8828.
- [121] L. Hubert und P. Arabie, „Comparing partitions,“ *Journal of Classification*, Jg. 2, Nr. 1, S. 193–218, 1985, ISSN: 1432-1343. DOI: 10.1007/BF01908075. Adresse: <https://doi.org/10.1007/BF01908075>.
- [122] C. Ündey, B. A. Williams und A. Çınar, „MONITORING OF BATCH PHARMACEUTICAL FERMENTATIONS: DATA SYNCHRONIZATION, LANDMARK ALIGNMENT, AND REAL-TIME MONITORING,“ *IFAC Proceedings Volumes*, Jg. 35, Nr. 1, S. 271–276, 2002, ISSN: 1474-6670. DOI: <https://doi.org/10.3182/20020721-6-ES-1901.01354>. Adresse: <https://www.sciencedirect.com/science/article/pii/S1474667015397755>.
- [123] M. Mowbray, M. Vallerio, C. Perez-Galvan, D. Zhang, A. Del Rio Chanona und F. J. Navarro-Brull, „Industrial data science – a review of machine learning applications for chemical and process industries,“ *Reaction Chemistry and Engineering*, 2022. DOI: 10.1039/D1RE00541C. Adresse: <http://dx.doi.org/10.1039/D1RE00541C>.
- [124] T. De Bie, N. Cristianini und R. Rosipal, „Eigenproblems in Pattern Recognition,“ in *Handbook of Geometric Computing: Applications in Pattern Recognition, Computer Vision, Neuralcomputing, and Robotics*, E. B. Corrochano, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005, S. 129–167, ISBN: 978-3-540-28247-1. DOI: 10.1007/3-540-28247-5_5. Adresse: https://doi.org/10.1007/3-540-28247-5_5.
- [125] S. X. Ding, *Data-driven Design of Fault Diagnosis and Fault-tolerant Control Systems* (Advances in Industrial Control). London DOI - 10.1007/978-1-4471-6410-4: Springer Nature, 2014, ISBN: 9781447164098. Adresse: <https://doi.org/10.1007/978-1-4471-6410-4>.
- [126] S. Ding, P. Zhang, E. Ding, S. Yin, A. Naik, P. Deng und W. Gui, „On the Application of PCA Technique to Fault Diagnosis,“ *Tsinghua Science and Technology*, Jg. 15, Nr. 2, S. 138–144, 2010, ISSN: 1007-0214. DOI: [https://doi.org/10.1016/S1007-0214\(10\)70043-2](https://doi.org/10.1016/S1007-0214(10)70043-2). Adresse: <http://www.sciencedirect.com/science/article/pii/S1007021410700432>.

- [127] J. F. MacGregor und T. Kourti, „Statistical process control of multivariate processes,“ *Control Engineering Practice*, Jg. 3, Nr. 3, S. 403–414, 1995, ISSN: 0967-0661.
- [128] Q. P. He und J. Wang, „Statistical process monitoring as a big data analytics tool for smart manufacturing,“ *Journal of Process Control*, Jg. 67, S. 35–43, 2018, ISSN: 0959-1524. DOI: <https://doi.org/10.1016/j.jprocont.2017.06.012>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0959152417301257>.
- [129] H. Wold, „Estimation of principal components and related models by iterative least squares,“ *Multivariate analysis*, S. 391–420, 1966.
- [130] L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, „Multivariate Deskription und Exploration,“ in *Statistik: Der Weg zur Datenanalyse*, L. Fahrmeir, C. Heumann, R. Künstler, I. Pigeot und G. Tutz, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016, S. 105–164, ISBN: 978-3-662-50372-0. DOI: 10.1007/978-3-662-50372-0_3. Adresse: https://doi.org/10.1007/978-3-662-50372-0_3.
- [131] F. J. Anscombe, „Graphs in Statistical Analysis,“ *The American Statistician*, Jg. 27, Nr. 1, S. 17–21, 1973, ISSN: 0003-1305. DOI: 10.1080/00031305.1973.10478966. Adresse: <https://www.tandfonline.com/doi/abs/10.1080/00031305.1973.10478966>.
- [132] A. Saxena, K. Goebel, D. Simon und N. Eklund, „Damage propagation modeling for aircraft engine run-to-failure simulation,“ in *2008 International Conference on Prognostics and Health Management*, S. 1–9. DOI: 10.1109/PHM.2008.4711414.
- [133] D. An, J.-H. Choi und N. H. Kim, „Prognostics 101: A tutorial for particle filter-based prognostics algorithm using Matlab,“ *Reliability Engineering and System Safety*, Jg. 115, S. 161–169, 2013, ISSN: 0951-8320. DOI: <https://doi.org/10.1016/j.res.2013.02.019>. Adresse: <http://www.sciencedirect.com/science/article/pii/S0951832013000549>.
- [134] P. Paris und F. Erdogan, „A critical analysis of crack propagation laws,“ 1963, ISSN: 0021-9223.
- [135] M. Orchard, B. Wu und G. Vachtsevanos, *A Particle Filtering Framework for Failure Prognosis*. 2005. DOI: 10.1115/WTC2005-64005.
- [136] M. E. Orchard und G. J. Vachtsevanos, „A particle-filtering approach for on-line fault diagnosis and failure prognosis,“ *Transactions of the Institute of Measurement and Control*, Jg. 31, Nr. 3-4, S. 221–246, 2009, ISSN: 0142-3312.
- [137] B. G. Sileshi, J. Oliver, R. Toledo, J. Gonçalves und P. Costa, „On the behaviour of low cost laser scanners in HW/SW particle filter SLAM applications,“ *Robotics and Autonomous Systems*, Jg. 80, S. 11–23, 2016, ISSN: 0921-8890. DOI: <https://doi.org/10.1016/j.robot.2016.03.002>. Adresse: <https://www.sciencedirect.com/science/article/pii/S0921889015303201>.
- [138] N. Bergman, „Recursive Bayesian Estimation : Navigation and Tracking Applications.“

- [139] P. C. P. M. Pardal, H. K. Kuga und R. V. de Moraes, „The Particle Filter Sample Impoverishment Problem in the Orbit Determination Application,“ *Mathematical Problems in Engineering*, Jg. 2015, S. 168045, 2015, ISSN: 1024-123X. DOI: 10.1155/2015/168045. Adresse: <https://doi.org/10.1155/2015/168045>.
- [140] R. R. Labbe, *Kalman and Bayesian Filters in Python*. gitHub, 2020, S. 506. Adresse: <https://github.com/rlabbe/Kalman-and-Bayesian-Filters-in-Python>.
- [141] B. M. S. Arifin, Z. Li und S. L. Shah, „Pipeline Leak Detection Using Particle Filters,“ *IFAC-PapersOnLine*, Jg. 48, Nr. 8, S. 76–81, 2015, ISSN: 2405-8963. DOI: <https://doi.org/10.1016/j.ifacol.2015.08.160>. Adresse: <http://www.sciencedirect.com/science/article/pii/S2405896315010277>.
- [142] M. S. Arulampalam, S. Maskell, N. Gordon und T. Clapp, „A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking,“ *IEEE Transactions on Signal Processing*, Jg. 50, Nr. 2, S. 174–188, 2002, ISSN: 1941-0476. DOI: 10.1109/78.978374.
- [143] A. Doucet und A. M. Johansen, „A tutorial on particle filtering and smoothing: Fifteen years later,“ *Handbook of nonlinear filtering*, Jg. 12, Nr. 656-704, S. 3, 2009.
- [144] R. E. Kalman, „A New Approach to Linear Filtering and Prediction Problems,“ *Journal of Basic Engineering*, Jg. 82, Nr. 1, S. 35–45, 1960, ISSN: 0021-9223. DOI: 10.1115/1.3662552. Adresse: <https://doi.org/10.1115/1.3662552>.
- [145] J. Zuo, „Dynamic resampling for alleviating sample impoverishment of particle filter,“ *Radar, Sonar and Navigation, IET*, Jg. 7, S. 968–977, 2013. DOI: 10.1049/iet-rsn.2013.0009.
- [146] T. Bayes und U. Price, „An Essay towards Solving a Problem in the Doctrine of Chances. By the Late Rev. Mr. Bayes, F. R. S. Communicated by Mr. Price, in a Letter to John Canton, A. M. F. R. S,“ *Philosophical Transactions (1683-1775)*, Jg. 53, S. 370–418, 1763, ISSN: 02607085. Adresse: <http://www.jstor.org/stable/105741>.
- [147] X. S. Ding, „System and parameter identification, and state estimation,“ Unpublished Work, 2019.
- [148] A. Kong, J. S. Liu und W. H. Wong, „Sequential imputations and Bayesian missing data problems,“ *Journal of the American statistical association*, Jg. 89, Nr. 425, S. 278–288, 1994, ISSN: 0162-1459.
- [149] R. Douc und O. Cappe, „Comparison of resampling schemes for particle filtering,“ in *ISPA 2005. Proceedings of the 4th International Symposium on Image and Signal Processing and Analysis, 2005.*, S. 64–69. DOI: 10.1109/ISPA.2005.195385.
- [150] S. A. Alam und O. Gustafsson, „Improved Particle Filter Resampling Architectures,“ *Journal of Signal Processing Systems*, Jg. 92, Nr. 6, S. 555–568, 2020, ISSN: 1939-8115. DOI: 10.1007/s11265-019-01489-y. Adresse: <https://doi.org/10.1007/s11265-019-01489-y>.

- [151] T. Ma, S. Liu und H. Xiao, „Location of natural gas leakage sources on offshore platform by a multi-robot system using particle swarm optimization algorithm,“ *Journal of Natural Gas Science and Engineering*, Jg. 84, S. 103 636, 2020. DOI: 10.1016/j.jngse.2020.103636.
- [152] L. Wu und F. Lu, „Dynamic resampling particle filter adaptive to changes in system model,“ *Journal of Control Theory and Applications*, Jg. 9, Nr. 4, S. 584–588, 2011, ISSN: 1993-0623. DOI: 10.1007/s11768-011-9314-0. Adresse: <https://doi.org/10.1007/s11768-011-9314-0>.
- [153] M. Fried, „Stabilisierung von Acrylmonomeren: Eine Übersicht über die theoretischen Grundlagen der Inhibierung,“ *Farbe+ Lack*, Jg. 100, Nr. 8, S. 604–609, 1994, ISSN: 0014-7699.
- [154] S. Schulze und H. Vogel, „Aspects of the safe storage of acrylic monomers: kinetics of the oxygen consumption,“ *Chemical Engineering and Technology: Industrial Chemistry-Plant Equipment-Process Engineering-Biotechnology*, Jg. 21, Nr. 10, S. 829–837, 1998, ISSN: 0930-7516.
- [155] W. Ebert und C. Panchal, „Analysis of Exxon crude-oil-slip stream coking data,“ Argonne National Lab., IL (United States), Report, 1995.
- [156] M. R. J. Nasr und M. M. Givi, „Modeling of crude oil fouling in preheat exchangers of refinery distillation units,“ *Applied thermal engineering*, Jg. 26, Nr. 14-15, S. 1572–1577, 2006, ISSN: 1359-4311.
- [157] G. T. Polley, D. I. Wilson, B. L. Yeap und S. J. Pugh, „Evaluation of laboratory crude oil threshold fouling data for application to refinery pre-heat trains,“ *Applied Thermal Engineering*, Jg. 22, Nr. 7, S. 777–788, 2002, ISSN: 1359-4311. DOI: [https://doi.org/10.1016/S1359-4311\(02\)00023-6](https://doi.org/10.1016/S1359-4311(02)00023-6). Adresse: <https://www.sciencedirect.com/science/article/pii/S1359431102000236>.
- [158] J. Yang, O. K. Matar, G. F. Hewitt, W. Zheng und P. Manchanda, „Modelling of fundamental transfer processes in crude-oil fouling,“ in *International Heat Transfer Conference Digital Library*, Begel House Inc.
- [159] Y. Wang, Z. Yuan, Y. Liang, Y. Xie, X. Chen und X. Li, „A review of experimental measurement and prediction models of crude oil fouling rate in crude refinery preheat trains: Measurement and Models of Crude Oil Fouling,“ *Asia-Pacific Journal of Chemical Engineering*, Jg. 10, 2015. DOI: 10.1002/apj.1895. Adresse: <https://onlinelibrary.wiley.com/doi/abs/10.1002/apj.1895>.
- [160] H. D. Baehr und S. Kabelac, „Thermodynamik des Heizens und Kühlens,“ in *Thermodynamik: Grundlagen und technische Anwendungen*, H. D. Baehr und S. Kabelac, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, S. 571–607, ISBN: 978-3-642-00556-5. DOI: 10.1007/978-3-642-00556-5_9. Adresse: https://doi.org/10.1007/978-3-642-00556-5_9.
- [161] X. Si, Z. Ren, X. Hu, C. Hu und Q. Shi, „A Novel Degradation Modeling and Prognostic Framework for Closed-Loop Systems With Degrading Actuator,“ *IEEE Transactions on Industrial Electronics*, Jg. 67, Nr. 11, S. 9635–9647, 2020, ISSN: 1557-9948. DOI: 10.1109/TIE.2019.2952828.
- [162] BASF, *BASF-Geschichte: Chemie, die verbindet 1865-2015*. 2022. Adresse: https://www.basf.com/global/images/about-us/history/BASF-Geschichte_Chemie-die-verbundet-1865-2015.pdf (besucht am 07.06.2022).

- [163] BASF, *Geschäftssegmente*. 2022. Adresse: <https://www.basf.com/global/de/investors/basf-at-a-glance/business-segments.html> (besucht am 07.06.2022).
- [164] BASF, *BASF-Bericht 2021 (BASF-Gruppe)*BASF. 2022. Adresse: <http://bericht.basf.com/2021/de/> (besucht am 07.06.2022).
- [165] BASF, *Verbundstandorte weltweit*. 2022. Adresse: <https://www.basf.com/global/de/investors/basf-at-a-glance/verbund/sites-worldwide.html> (besucht am 07.06.2022).
- [166] BASF, *Standort Ludwigshafen 2021 in Zahlen*. 2022. Adresse: https://www.basf.com/global/de/documents/Ludwigshafen/standort-in-zahlen-2022/2022_BASF_Standort%20Ludwigshafen%20in%20Zahlen_2021_de.pdf (besucht am 07.06.2022).

DuEPublico

Duisburg-Essen Publications online

UNIVERSITÄT
D U I S B U R G
E S S E N

Offen im Denken

ub | universitäts
bibliothek

Diese Dissertation wird via DuEPublico, dem Dokumenten- und Publikationsserver der Universität Duisburg-Essen, zur Verfügung gestellt und liegt auch als Print-Version vor.

DOI: 10.17185/duepublico/81445

URN: urn:nbn:de:hbz:465-20240125-142633-9

Alle Rechte vorbehalten.