

Entwicklung und Demonstration eines integrierten Systems zur Zustandsüberwachung von Gasturbinen

Von der Fakultät Luft- und Raumfahrttechnik und Geodäsie
der Universität Stuttgart zur Erlangung der Würde eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.) genehmigte Abhandlung

Vorgelegt von

Holger Lipowsky

aus Stuttgart

Hauptberichter: Prof. Dr.-Ing. Stephan Staudacher

Mitberichter: Prof. Dr.-Ing. Walter Fichter

Tag der mündlichen Prüfung: 13. Januar 2010

Institut für Luftfahrtantriebe der Universität Stuttgart

2010

Inhaltsverzeichnis

INHALTSVERZEICHNIS	I
BILDVERZEICHNIS	V
TABELLENVERZEICHNIS	XI
NOMENKLATUR	XIII
ZUSAMMENFASSUNG	XIX
ABSTRACT	XXI
KAPITEL 1: EINFÜHRUNG	1
1.1 Allgemeine Einführung	1
1.2 Entwicklung des EHM Marktes	4
1.3 Allgemeine Architektur von EHM Systemen	6
1.4 Begriffsdefinitionen	8
1.5 Zielsetzung der Arbeit	11
KAPITEL 2: STAND DER TECHNIK	13
2.1 Übersicht über ECM Verfahren	13
2.2 Modellbasierte ECM Verfahren	14
2.2.1 Grundlagen der Leistungsrechnung	14
2.2.2 Grundlagen der Gas-Pfad-Analyse	15
2.2.3 Die lineare Gas-Pfad-Analyse	17
2.2.4 Zustandsschätzverfahren	18
2.2.5 Der Kalman Filter	21
2.2.6 Kombinatorische Ansätze	22
2.2.7 Die nichtlineare Gas-Pfad-Analyse	23

2.2.8	Nichtlineare Optimierung	25
2.2.9	Mehrpunkt-Verfahren	27
2.2.10	Evolutionäre Algorithmen	28
2.3	Datenbasierte ECM Verfahren	29
2.3.1	Neuronale Netze	29
2.3.2	Fuzzy Logic	34
2.3.3	Pattern Recognition	37
2.4	Hybride ECM Verfahren	39
2.5	Verfahren zur Prognose	40
2.5.1	Regressionsverfahren	41
2.5.2	Verfahren der Zeitreihenanalyse	41
2.6	Entwicklung Grafischer Benutzeroberflächen	42
2.7	EHM Systeme im industriellen Einsatz	42
KAPITEL 3: KONZEPTENTWICKLUNG		45
3.1	Erkenntnisse aus dem Stand der Technik	45
3.2	Ableitung des umgesetzten Konzeptes	46
KAPITEL 4: DETEKTION VON EINZELEREIGNISSEN		49
4.1	Einfache Filterverfahren	50
4.1.1	Gleitender Mittelwert	50
4.1.2	Exponentielles Glätten	52
4.1.3	Detektion mit Hilfe einfacher Filterverfahren	53
4.2	Kalman Filter für Zeitreihen	55
4.3	Bayesische Vorhersage mit Dynamischen Linearen Modellen	58
4.3.1	Die Methode der Bayesischen Vorhersage	59
4.3.2	Anwendung auf das Detektionsproblem	61
4.3.3	Ausreißerererkennung	63
4.3.4	Detektion sprunghafter Veränderungen	66
4.3.5	Prognose der Residuenverläufe	70
4.3.6	Statistische Bewertung	72
4.4	Radial-Basisfunktions-Netzwerke	75
4.5	Fazit	76
KAPITEL 5: DIAGNOSE VON EINZELEREIGNISSEN		77
5.1	Generisches Triebwerksmodell	77

5.1.1	Konfiguration und Instrumentierung	77
5.1.2	Nichtlineares Ersatzmodell	79
5.2	Zustandsschätzverfahren.....	83
5.2.1	REWLS-Schätzer und Kalman Filter	84
5.2.2	Kombinatorischer Kalman Filter	85
5.2.3	Limitierung der Zustandsschätzverfahren	87
5.3	Kombinatorische Fuzzy Logic.....	88
5.3.1	Kombinatorische Analyse	89
5.3.2	Fuzzy Logic Auswertung	92
5.3.3	Nichtlineare Diagnose	97
5.3.4	Statistische Bewertung	98
5.4	Fazit	100
KAPITEL 6: DIAGNOSE GRADUELLER VERSCHLECHTERUNGEN		101
6.1	Generierung eines Alterungsbeispiels	101
6.2	Nichtlineare Optimierung	102
6.2.1	Unbeschränkte Optimierung	102
6.2.2	Optimierung mit Nebenbedingungen	103
6.2.3	Fazit	107
6.3	Einfache Beobachtbarkeitsanalyse	108
KAPITEL 7: UMSETZUNG DES KONZEPTES		111
7.1	Diagnosesoftware HealthGT [®]	111
7.2	Ausgewählte Ergebnisse.....	114
7.2.1	Diagnose der OBIDICOTE Testfälle	114
7.2.2	Diagnose eines Einzelereignisses mit überlagerter gradueller Verschlechterung	116
KAPITEL 8: BEWERTUNG DES KONZEPTES		119
8.1	Integrierte Sensitivitätsanalyse	119
8.1.1	Bestimmung der Diagnoseschwelle.....	119
8.1.2	Bestimmung der korrespondierenden Residuen.....	121
8.1.3	Bestimmung der Diagnoseschwelle des integrierten Systems	122
8.2	Diagnose stark unterbestimmter Systeme.....	123
8.3	Zusammenfassung.....	125

ANHANG	127
LITERATURVERZEICHNIS	137
LEBENS LAUF DES VERFASSERS	151

Bildverzeichnis

Bild 1.1:	Triebwerksinstandhaltungskosten als Teil der direkten Betriebskosten (DOC) eines Flugzeuges nach Rupp ^[102]	1
Bild 1.2:	Rentabilität eines EHM Systems als Funktion seiner Komplexität nach Bechini ^[7]	4
Bild 1.3:	Aufteilung und Entwicklung des EHM Marktes bei Herstellern von Fluggasturbinen ^[6]	4
Bild 1.4:	Allgemeine Architektur eines EHM Systems	7
Bild 1.5:	Einfluss von Einzelereignissen und gradueller Verschlechterung auf die Leistungsfähigkeit (angelehnt an Volponi ^[130])	9
Bild 2.1:	Grundlegende Zusammenhänge der Gas-Pfad-Analyse (adaptiert von Urban ^[120])	16
Bild 2.2:	Ablauf der nichtlinearen Gas-Pfad-Analyse mit Hilfe von Leistungsrechnungsprogrammen	24
Bild 2.3:	Prinzipieller Ablauf eines evolutionären Algorithmus	28
Bild 2.4:	Aufbau eines dreischichtigen Neuronalen Netzes (links) und Details eines künstlichen Neurons (rechts)	30
Bild 2.5:	Flussdiagramm eines Systems mehrerer Neuronaler Netze zur Diagnose von Einzelfehlern (in Anlehnung an ^[50])	33
Bild 2.6:	Elemente eines Fuzzy Logic Systems	34
Bild 2.7:	Fuzzy-Inferenz-Diagramm eines einfachen Systems	35
Bild 2.8:	Entwicklungsstand der EHM Systeme bei Fluggasturbinenherstellern bezogen auf den Marktführer GE.....	43
Bild 3.1:	Konzept des Systems zur Gasturbinenüberwachung.....	46
Bild 4.1:	Beispieldatensatz für die Detektion von Einzelereignissen	50
Bild 4.2:	Einfluss des Parameters α_1 auf den Grad der Glättung.....	51
Bild 4.3:	Auswahl des optimalen Parameters α_1 für $\Delta\mu=-3$	52
Bild 4.4:	Auswahl des optimalen Parameters α_2 für $\Delta\mu=-3$	53
Bild 4.5:	Beispiel einer einfachen Detektionslogik auf Basis der Methode des gleitenden Mittelwertes	54

Bild 4.6:	Prozessmodellierung bestehend aus Wert und Gradient sowie Prozess- und Messwertvarianzen	55
Bild 4.7:	Beeinflussung des Verhaltens des Kalman Filters durch die Wahl der Varianzparameter	57
Bild 4.8:	Optimale Wahl der Varianzparameter für $\Delta\mu=-3$ und Definition eines Schwellwertes zur Sprungdetektion.....	58
Bild 4.9:	Veranschaulichung des Satz von Bayes anhand eines Entscheidungsbaumes.....	61
Bild 4.10:	Anwendung der Bayesischen Vorhersage auf einen Beispieldatensatz mit Sprunghöhe $\Delta\mu=-3$	62
Bild 4.11:	Ableitung des Bayes Faktors H und der Erwartungsbereichsbreite ucl vom Parameter h	64
Bild 4.12:	Abhängigkeit der Parameter ucl und cdf vom Parameter h	65
Bild 4.13:	Ausreißererkenung auf Basis von Bayes Faktoren (Messwerte mit $H>10$ werden als Ausreißer bewertet).....	66
Bild 4.14:	Verlauf der Bayes Faktoren H , der maximalen kumulativen Bayes Faktoren L und der Lauflängen l über der Zeit t	67
Bild 4.15:	Logik zur Detektion sprunghafter Veränderungen.....	68
Bild 4.16:	Anwendung der Detektionslogik auf Beispieldaten mit einer Sprunghöhe von $\Delta\mu=-3\sigma$	69
Bild 4.17:	Anwendung der Detektionslogik auf Beispieldaten mit einer Sprunghöhe von $\Delta\mu=-1,5\sigma$	69
Bild 4.18:	Beispiel der Prognose mit konstantem Gradienten.....	70
Bild 4.19:	Ableitung der Dichtefunktion und der Verteilungsfunktion für die Über- bzw. Unterschreitung eines Grenzwertes.....	71
Bild 4.20:	Matrix zur Definition der verschiedenen Gütegrade zur Bewertung der Detektion	72
Bild 4.21:	Definition des Zeitraumes korrekter Detektionen	73
Bild 4.22:	Detektionsrate als Funktion von Erwartungsbereichsbreite und Sprunghöhe.....	73
Bild 4.23:	Fehldetektionsrate (fp) als Funktion von Erwartungsbereichsbreite und Sprunghöhe.....	74
Bild 5.1:	Verwendete Konfiguration und Ebenenbezeichnung.....	77
Bild 5.2:	Superposition der Einzeleinflüsse im Ersatzmodell	80
Bild 5.3:	Vergleich der Ergebnisse des Leistungsrechnungsmodells und des nichtlinearen Ersatzmodells für Variation in LP1-8	81

Bild 5.4:	Mittlere absolute Abweichung für Variation der Leistungsparameter LP1 bis LP8.....	82
Bild 5.5:	Mittlere absolute Abweichungen für Leistungsparameter von jeweils -3% als Funktion der Kombinationsnummer	82
Bild 5.6:	Mittlere absolute Abweichungen und Mittelwerte der Kategorien für Leistungsparameter von jeweils -3% als Funktion der Anzahl veränderter Leistungsparameter.....	83
Bild 5.7:	Diagnoseergebnisse von EWLS-Schätzer, REWLS-Schätzer und Kalman Filter bei einem vorgegebenen Einzelfehler von $\Delta LP8 = -1,5\%$	84
Bild 5.8:	RMS des EWLS-Schätzers und Konvergenzvergleich des REWLS-Schätzers und des Kalman Filters	85
Bild 5.9:	Diagnostische Indizes für die Leistungsparameter des in Abschnitt 5.2.1 diskutierten Beispiels.....	86
Bild 5.10:	RMS des EWLS-Schätzers und Konvergenzvergleich des REWLS-Schätzers, des Kalman Filters und des Kalman Filters mit verbesserter Startwertwahl (DI).....	86
Bild 5.11:	Diagnoseergebnisse von Kalman Filter und Kalman Filter mit verbesserter Startwertwahl (DI) bei einem vorgegebenen Einzelfehler von $\Delta LP8 = -1,5\%$	87
Bild 5.12:	Diagnoseergebnis des Kalman Filters mit verbesserter Startwertwahl (DI) bei einem vorgegebenen Einzelfehler von $\Delta LP1 = -1,0\%$, $\Delta LP2 = -1,5\%$ und $\Delta LP3 = -1,8\%$	88
Bild 5.13:	Diagnostische Indizes für die Leistungsparameter des in Bild 5.12 dargestellten Diagnosebeispiels.....	88
Bild 5.14:	Flussdiagramm des entwickelten Diagnoseverfahrens	89
Bild 5.15:	Grafische Darstellung der Analysensets.....	90
Bild 5.16:	Diagnoseergebnis des Analysensets Nr.2 mit mittleren Abweichungen und relativen Häufigkeiten für $\Delta LP1 = -1,0\%$, $\Delta LP2 = -1,5\%$ und $\Delta LP3 = -1,8\%$	92
Bild 5.17:	Flussdiagramm zur Berechnung der Fuzzy Indizes für jedes Analysenset (FLS1)	93
Bild 5.18:	Zugehörigkeitsfunktionen der Eingänge des FLS1	94
Bild 5.19:	Zugehörigkeitsfunktionen des Ausgangs des FLS1	94
Bild 5.20:	Visualisierung des FLS1 mit Hilfe einer Antwortfläche	95
Bild 5.21:	Zugehörigkeitsfunktionen des Eingangs »Abweichung« des FLS1b (zur Berücksichtigung positiver Abweichungen)	95

Bild 5.22:	Flussdiagramm zur Berechnung der kumulierten Fuzzy Indizes über alle Analysensets (FLS2)	96
Bild 5.23:	Verlauf des Fuzzy Index über die Kumulationsschritte für den Fehler $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$	96
Bild 5.24:	Kumulierter Fuzzy Index und Diagnoseergebnis der kombinatorischen Analysen für den Fehlerfall $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$	97
Bild 5.25:	Diagnoseergebnis der kombinatorischen Analyse und der nichtlinearen GPA für einen vorgegebenen Einzelfehler mit $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$	98
Bild 5.26:	Matrix zur Definition der verschiedenen Gütegrade zur Bewertung von Identifikation und Diagnose.....	99
Bild 5.27:	Identifikationsrate als Funktion der Anzahl der betroffenen Leistungsparameter	99
Bild 5.28:	Diagnoserate als Funktion der Anzahl der betroffenen Leistungsparameter mit Variation des Diagnoselimits.....	100
Bild 6.1:	Diagnoseergebnis der Alterung und Verlauf der Zielfunktion ohne Definition von Nebenbedingungen	103
Bild 6.2:	Diagnoseergebnis der Alterung und Verlauf der Zielfunktion mit Nebenbedingungen Version 1.....	104
Bild 6.3:	Diagnoseergebnis der Alterung und Verlauf der Zielfunktion mit Nebenbedingungen Version 2.....	105
Bild 6.4:	Diagnoseergebnis der Alterung und Verlauf der Zielfunktion mit Nebenbedingungen Version 3.....	106
Bild 6.5:	Darstellung der Eigenwerte des betrachteten Systems	108
Bild 6.6:	Zusammenhang zwischen Eigenwerten und Eigenvektoren des Systems	109
Bild 6.7:	Sortierung der Leistungsparameter bezüglich ihrer relativen Beobachtbarkeit	110
Bild 7.1:	Startbildschirm der Diagnosesoftware HealthGT [®]	111
Bild 7.2:	Hauptprogramm der Diagnosesoftware HealthGT [®]	112
Bild 7.3:	Diagnoseergebnis des OBIDICOTE Testfalls Nr.1	115
Bild 7.4:	Diagnoseergebnis der Alterung mit überlagertem Einzelfehler und Verlauf der Zielfunktion	117
Bild 8.1:	Diagnoseschwellen der Leistungsparameter	120

Bild 8.2:	Diagnoseschwellen der Leistungsparameter unter der Forderung, dass mindestens ein Messwertresiduum die Detektionsschwelle von $1,5\sigma$ überschreitet	123
Bild 8.3:	Diagnoseergebnis des OBIDICOTE Testfalls Nr.7 mit einem 6-fach unterbestimmten System.....	124
Bild A.1:	Visualisierung des FLS1b mit Hilfe einer Antwortfläche	127
Bild A.2:	Oberfläche zur Definition der Parameter (1)	130
Bild A.3:	Oberfläche zur Definition der Parameter (2)	130
Bild A.4:	Oberfläche zur Definition der Parameter (3)	131
Bild A.5:	Oberfläche zur Beobachtbarkeitsanalyse.....	131
Bild A.6:	Oberfläche zum Laden der Daten	132
Bild A.7:	Definition der Detektions- und Diagnoseparameter	132
Bild A.8:	Diagnoseergebnis eines Einzelereignisses.....	133
Bild A.9:	Verlauf der Diagnoseergebnisse für ein Alterungsbeispiel	133
Bild A.10:	Verlauf der Zielfunktion des Alterungsbeispiels	134
Bild A.11:	Diagnoseergebnis und wahre Leistungsparameter für das Alterungsbeispiel zum Zeitpunkt $t=400$	134
Bild A.12:	Prognose der Messwertresiduen für das Alterungsbeispiel	135
Bild A.13:	Verlauf der Dichtefunktionen und der Verteilungsfunktionen für das Alterungsbeispiel	135

Tabellenverzeichnis

Tabelle 1.1:	Richtwerte für Folgekosten von Verspätungen und Ausfällen von Flügen laut EUROCONTROL ^[32]	3
Tabelle 1.2:	Entwicklung der Instandhaltungsphilosophien über der Zeit (angelehnt an Rupp ^[103] und Bauer ^[6])	6
Tabelle 2.1:	Übersicht über mathematische Verfahren zur Zustandsüberwachung von Gasturbinen	14
Tabelle 2.2:	Übersicht über veröffentlichte Leistungsrechnungsprogramme	15
Tabelle 2.3:	Übersicht über bestehende Systeme zur Zustandsüberwachung von Gasturbinen	43
Tabelle 4.1:	Detektions- und Fehldetektionsraten abhängig von Sprunghöhe und Erwartungsbereichsbreite (Detektionslimit=3)	75
Tabelle 4.2:	Detektions- und Fehldetektionsraten abhängig von Sprunghöhe und Erwartungsbereichsbreite (Detektionslimit=1)	75
Tabelle 5.1:	Übersicht über die zu bestimmenden Leistungsparameter	78
Tabelle 5.2:	Übersicht über die gewählte Instrumentierung des Triebwerks	79
Tabelle 5.3:	Übersicht über die Kombinatorik für n=11 und m=9	90
Tabelle 5.4:	Auswahl der Ergebnisse des Analysensets Nr.2	91
Tabelle 5.5:	Klassifizierung der Ein- und Ausgänge des FLS1.....	93
Tabelle 5.6:	Übersicht über die Regeln des FLS1	93
Tabelle 6.1:	Intervalle der Leistungsparameter des Alterungsbeispiels	101
Tabelle 6.2:	Übersicht über die RMS-Werte der Alterungsdiagnosen.....	107
Tabelle 7.1:	Übersicht über die im EU-Projekt OBIDICOTE definierten Testfälle ^[20] und die entsprechenden Diagnoseergebnisse	114
Tabelle 8.1:	Korrelationskoeffizienten der Leistungsparameter	121
Tabelle 8.2:	Übersicht über die korrespondierenden Messwertresiduen	122
Tabelle A.1:	Klassifizierung der Ein- und Ausgänge des FLS1b.....	127
Tabelle A.2:	Übersicht über die Regeln des FLS1b.....	127

Tabelle A.3: Klassifizierung der Ein- und Ausgänge des FLS2	128
Tabelle A.4: Übersicht über die Regeln des FLS2.....	128
Tabelle A.5: Klassifizierung der Ein- und Ausgänge des FLS2b	128
Tabelle A.6: Übersicht über die Regeln des FLS2b.....	129
Tabelle A.7: Leistungsparameter-Kovarianz-Matrix	136

Nomenklatur

Lateinische Formelzeichen

<i>Symbol</i>	<i>Beschreibung</i>
a, b	Start- und Endwert der Leistungsparameterveränderung
a, f, m	Mittelwerte der Dynamischen Linearen Modelle
c	Exponent der Leistungsparameterveränderung
cdf	Wert der Verteilungsfunktion (<i>cumulative density function</i>)
eg	Schätzwert des Verfahrens des exponentiellen Glättens
g	Nebenbedingungsfunktion
gm	Schätzwert des Verfahrens des gleitenden Mittels
gr	Gradient des Kalman-Filters
h	Versatz zwischen Modell 0 und Modell +h bzw. Modell -h
kf	Schätzwert des Kalman-Filters
l	Lauflänge
lb, ub	untere und obere Grenze der Leistungsparameterveränderung
m	Anzahl der vorhandenen Messwerte
n	Anzahl der zu bestimmenden Leistungsparameter
net	effektiver Eingang eines Neuronalen Netzes
p	Druck
$p(A B)$	bedingte Wahrscheinlichkeit, dass Ereignis A eintritt unter der Voraussetzung, dass Ereignis B eingetreten ist
pdf	Wahrscheinlichkeitsdichtefunktion (<i>probability density function</i>)
r	Messwertresiduen
rms	Wurzel der quadratischen Abweichung (<i>root mean square</i>)
t	Zyklus, Zeitschritt
ucl	Breite des Erwartungsbereichs (<i>uncertainty limit</i>)
w	Gewichtungsfaktoren eines Neuronalen Netzes
w, Δw	Massendurchfluss und daraus gebildeter Leistungsparameter
x	Zufallsgröße
A	Dynamikmatrix des Zustandsraummodells
A	Matrix bei der Prädiktorkorrektur der Bayesischen Vorhersage

A	Ereignis erkrankt zu sein
A^C	Umkehrung des Ereignisses A, d.h. nicht erkrankt zu sein
A, ΔA	Querschnittsfläche und daraus gebildeter Leistungsparameter
B	Steuermatrix des Zustandsraummodells
B	Ereignis eines positiven Testergebnisses
B^C	Umkehrung des Ereignisses B, d.h. negatives Testergebnis
C_1, C_2, C_3, C_4	Gewichtungsfaktoren
DI	Wert des Diagnostischen Index
F	Aktivierungsfunktion eines Neuronalen Netzes
FI	Wert des Fuzzy Index
G	Kalman-Verstärkungs-Matrix (<i>Kalman Gain</i>)
G	Propagierungsfunktion eines Neuronalen Netzes
G, F	systemspezifische Matrizen des Dynamischen Linearen Modells
G_X	Verstärkungsmatrix der Zustandsschätzverfahren
G_Y	Gewichtungsmatrix der Zustandsschätzverfahren
H_1, H_2	Bayes Faktoren
I	Einheitsmatrix
J	Einfluss-Koeffizienten-Matrix, Steuermatrix
L	Likelihood-Funktion
L_1, L_2	maximale kumulative Bayes Faktoren
$N(\mu, \nu)$	Normalverteilung des vorstehenden Parameters mit dem Mittelwert μ und der Varianz ν
P	Wahrscheinlichkeit
P	Fehler-Kovarianz-Matrix des Kalman Filters
S	Summe der Fehlerquadrate
T	Temperatur
U	Vektor der Betriebsbedingungen
V, R	Varianzmatrix und Varianzwert der Messwerte
W, Q	Varianzmatrix und Varianzwert der DLM Parameter
X	Vektor der Leistungsparameter
Y	Vektor der Messwerte
ZF	Zielfunktion

Griechische Formelzeichen

Symbol *Beschreibung*

α_1	Anzahl der zu mittelnden Werte bei der Methode des gleitenden Mittelwertes
------------	--

α_2	Gewichtungsfaktor bei der Methode des exponentiellen Glättens
β	Schätzwert für den Gradienten des DLM
δ	Schrittweite bei der Optimierung
ε	Iterationsschranke
$\eta, \Delta\eta$	Wirkungsgrad und daraus abgeleiteter Leistungsparameter
λ	Eigenwert
μ	Mittelwert, Schätzwert für den Prozesswert des DLM
$\Delta\mu$	Sprunghöhe einer Messwertveränderung bzw. deren Residuum in Folge eines Einzelereignisses
σ	Standardabweichung
ω_1	Varianz des Prozesswertes
ω_2	Varianz des Prozessgradienten
v	Varianz der Messwertresiduen
Δ	relative Veränderung des nachstehenden Parameters
Θ	Systemvektor des DLM bestehend aus kf and gr

Indizes

<i>Symbol</i>	<i>Beschreibung</i>
diag	diagnostizierter Wert
i	Laufvariable
i, j, k	Elemente eines Vektors
max	maximaler Wert
ref	Referenzbedingungen
soll	Sollwert
BF	Wert aus der Methode der Bayesischen Vorhersage
E	erwarteter Wert, Wert im gesunden Zustand
M	gemessener Wert
Opt	Optimierungsergebnis

Triebwerkskomponenten

<i>Symbol</i>	<i>Beschreibung</i>
FAN	Bläser
LPC	Niederdruckverdichter (<i>low pressure compressor</i>)
HPC	Hochdruckverdichter (<i>high pressure compressor</i>)
HPT	Hochdruckturbine (<i>high pressure turbine</i>)
LPT	Niederdruckturbine (<i>low pressure turbine</i>)
NC	Düse (<i>core nozzle</i>)

Leistungsparameter

<i>Symbol</i>	<i>Einheit</i>	<i>Beschreibung</i>
$\Delta\eta_{\text{FAN}}$	%	Abweichung des FAN Wirkungsgrades
Δw_{FAN}	%	Abweichung der FAN Kapazität
$\Delta\eta_{\text{LPC}}$	%	Abweichung des LPC Wirkungsgrades
Δw_{LPC}	%	Abweichung der LPC Kapazität
$\Delta\eta_{\text{HPC}}$	%	Abweichung des HPC Wirkungsgrades
Δw_{HPC}	%	Abweichung der HPC Kapazität
$\Delta\eta_{\text{HPT}}$	%	Abweichung des HPT Wirkungsgrades
Δw_{HPT}	%	Abweichung der HPT Kapazität
$\Delta\eta_{\text{LPT}}$	%	Abweichung des LPT Wirkungsgrades
Δw_{LPT}	%	Abweichung der LPT Kapazität
ΔA_8	%	Abweichung der Düsenaustrittsfläche

Messwerte

<i>Symbol</i>	<i>Einheit</i>	<i>Beschreibung</i>
N1	1/min	Niederdruckwellendrehzahl
N2	1/min	Hochdruckwellendrehzahl
WF	kg/s	Brennstoffmassenstrom
Pt13	kPa	Totaldruck am Austritt des FAN
Pt25	kPa	Totaldruck am Austritt des LPC
Tt25	K	Totaltemperatur am Austritt des LPC
Pt3	kPa	Totaldruck am Austritt des HPC
Tt3	K	Totaldruck am Austritt des HPC
Tt5	K	Totaltemperatur am Austritt der LPT

Akronyme

<i>Symbol</i>	<i>Beschreibung</i>
ANFIS	Adaptives Neuro-Fuzzy-Inferenz-System
ANSYN	Analyse durch Synthese
ARIMA	Autoregressive Integrated Moving Average
BBN	Bayesian-Belief-Netzwerk
CBM	Condition Based Maintenance
CCBM	Component Condition Based Maintenance
CDF	Cumulative Distribution Function
CG	Conjugated Gradients
CoG	Center of Gravity

DLM	Dynamisches Lineares Modell
DOC	Direct Operating Costs
ECM	Engine Condition Monitoring
EHM	Engine Health Management
EKM	Einfluss-Koeffizienten-Matrix
EMS	Emission Monitoring System
EPR	Engine Pressure Ratio
ETM	Engine Trend Monitoring
EWLS	Extended-Weighted-Least-Squares
FDI	Fault Detection and Isolation
FLS	Fuzzy Logic System
GA	Genetischer Algorithmus
GPA	Gas-Pfad-Analyse
GUI	Graphical User Interface
KIR	Komponentenidentifikationsrate
KK	Korrelationskoeffizient
KNN	Künstliches Neuronales Netz
LKM	Leistungsparameter-Kovarianz-Matrix
LLP	Life Limited Parts
LP	Leistungsparameter
LS	Least-Squares
LUM	Life Usage Monitoring
MLP	Multi-Layer-Perceptron
MW	Messwert
OBIDICOTE	On Board Identification, Diagnosis and Control of Gas Turbine Engines
PDF	Probability Density Function
PMS	Performance Monitoring System
RBFN	Radial-Basis-Funktions-Netzwerk
REWLS	Recursive Extended-Weighted-Least-Squares
RMS	Root Mean Square
SQP	Sequentielle Quadratische Programmierung
TBO	Time Between Overhaul
TOW	Time-on-Wing
VMS	Vibration Monitoring System
WLS	Weighted-Least-Squares

Zusammenfassung

Die Leistungsfähigkeit von Gasturbinen nimmt im Laufe der Betriebsdauer aufgrund von Alterungsmechanismen und in Folge von Einzelereignissen ab. Das Ziel der Zustandsüberwachung ist es, die Leistungsfähigkeit der Gasturbine zu jedem Zeitpunkt möglichst exakt zu bestimmen und eine Prognose für den zukünftigen Zustandsverlauf zu erstellen. Dabei müssen auftretende Ereignisse zeitnah erkannt (Detektion), die betroffenen Komponenten der Gasturbine bestimmt (Identifikation) und die Leistungsparameter der jeweiligen Komponente berechnet werden (Diagnose). Während sich Alterungsmechanismen in gradueller Weise auf alle Komponenten der Gasturbine auswirken, sind Einzelereignisse dadurch charakterisiert, zeitlich diskret aufzutreten und nur einige wenige Komponenten der Gasturbine zu betreffen. Da die Charakteristiken dieser beiden Mechanismen sehr unterschiedlich sind, gestaltet sich die Durchführung der Zustandsüberwachung mit einem einzelnen Algorithmus sehr schwierig.

In der vorliegenden Arbeit wurde daher ein Konzept zur Zustandsüberwachung von Gasturbinen entwickelt, welches mehrere Algorithmen miteinander verbindet, um die Anforderungen der verschiedenen Aspekte der Zustandsüberwachung zu erfüllen. Der entscheidende Vorteil dieses integrierten Konzeptes gegenüber bisher in der Literatur dokumentierten Systemen besteht in der funktionalen Trennung von Alterungs- und Einzelereignisdiagnose. Durch die anschließende Zusammenführung der Ergebnisse ist es möglich, Einzelereignisse und alterungsbedingte Verschlechterungen auch dann zu analysieren, wenn sie in überlagerter Form auftreten.

Für die automatisierte Erkennung von Einzelereignissen wurde ein neuartiger Detektionsalgorithmus entwickelt, der durch die Anwendung einer speziellen Logik die gegensätzlichen Anforderungen einer schnellen Reaktion und eines hohen Glättungsgrades gleichzeitig erfüllt. Aufgrund der Kombination verschiedener Elemente zur Detektion (Bayes Faktoren, kumulative Bayes Faktoren, Lauflängen) ermöglicht der entwickelte Algorithmus die Detektion von Ereignis-

sen, deren Auswirkungen auf die Messwerte kleiner als das Dreifache ihrer Standardabweichungen sind.

Das entwickelte Verfahren zur Diagnose von Einzelereignissen basiert auf kombinatorischen Least-Squares-Lösungen, die mit Hilfe von Fuzzy-Logik-Regeln ausgewertet werden. Durch die spezielle Auswertelogik bedarf es keiner a-priori Informationen über die betroffenen Leistungsparameter, weder über ihre Anzahl noch über ihre Kombination. Darüber hinaus werden keinerlei Annahmen über die Beziehungen zwischen den Leistungsparametern getroffen. Es können beliebige Kombinationen an betroffenen Leistungsparametern diagnostiziert werden, wobei die maximal diagnostizierbare Anzahl an Leistungsparametern der Anzahl der vorhandenen Messwerte entspricht. Die Diagnose ist auf der Basis einzelner Messzeitpunkte durchführbar, d.h. es ist keine zeitliche Beobachtung der Messwerte notwendig. Das Diagnoseergebnis der Methode besteht nicht nur in der Berechnung der Abweichungen der Leistungsparameter, sondern auch aus der Berechnung des Fuzzy Index jedes Parameters. Der Fuzzy Index kann als Wahrscheinlichkeit interpretiert werden, mit der der entsprechende Leistungsparameter vom Fehler betroffen ist.

Die Diagnose gradueller Verschlechterungen wurde mit bereits bekannten Verfahren der Nichtlinearen Optimierung durchgeführt. Dabei wurden verschiedene Definitionen von Nebenbedingungen und eine Startwertsuche mittels eines Genetischen Algorithmus untersucht. Es konnte gezeigt werden, dass beide Maßnahmen insbesondere für schlecht beobachtbare Leistungsparameter zu deutlichen Verbesserungen des Optimierungsergebnisses führen.

Das entwickelte Konzept wurde mit Hilfe von 31680 generischen Testzyklen statistisch bewertet. Dabei wurden Detektionsraten von bis zu 99%, Identifikationsraten von bis zu 96% und Diagnoseraten von bis zu 99% erreicht.

Abschließend wurde das Konzept im Rahmen der Entwicklung einer Diagnosesoftware mit dem Namen HealthGT[®] umgesetzt. Durch die Verwendung einer grafischen Benutzeroberfläche verfügt HealthGT[®] über eine einfache Bedienbarkeit. Darüber hinaus gestattet die modulare Programmierweise von HealthGT[®] eine einfache Erweiterung um zukünftige Funktionalitäten.

Abstract

The performance of a gas turbine degrades over time due to deterioration mechanisms and single fault events. The aim of Engine Condition Monitoring (ECM) is to assess the performance of the gas turbine at any time and to give a prognosis of its future development. In that process, occurring changes have to be detected, the changes have to be assigned to individual gas turbine components (identification) and the performance parameters of the affected components have to be calculated (diagnosis). While deterioration mechanisms affect several components of a gas turbine, single fault events are characterised by influencing only a small number of components and by occurring accidentally. An ECM system has to be capable of dealing with these two different mechanisms. As the characteristics of these two mechanisms are very different, it is difficult for a single diagnostic technique to be able to deal with both mechanisms.

Hence, an ECM concept has been developed that combines several algorithms in order to meet the requirements of the different ECM aspects. The advantage of the this integrated approach compared to systems documented in the literature lies in the functional split between deterioration and single fault diagnosis. By combining the results, it is possible to analyse both mechanisms occurring at the same time.

In order to detect single fault events, a novel detection algorithm has been developed, that is able to meet the contradictory requirements of a fast response while providing a high degree of smoothing. By combining several mathematical elements like Bayes Factors, cumulative Bayes Factors and run lengths the detection algorithm enables the detection of events that lead to changes in the measurements smaller than three times the measurements' standard deviations.

The developed method for single fault event diagnosis is based on combinatorial Least-Squares solutions that are subsequently assessed with Fuzzy-Logic systems. The special assessment logic enables a diagnosis that need no a-priori information about the affected performance parameters, neither their number nor their combination. Furthermore, no assumptions have to be made that specific perform-

ance parameters hold fixed relationships with each other. Any combinations of affected performance parameters can be diagnosed. The maximum number of diagnosable performance parameters equals the number of available measurements. The diagnosis is not based on the observation of a time series of measurements but on single snapshots. The diagnostic results not only comprises the performance parameter deviations, but also the Fuzzy Index, which can be interpreted as the probability of a performance parameter to be actually affected by the fault.

For the diagnosis of gradual degradation (deterioration) state-of-the-art techniques for constrained non-linear optimisation are applied. Several definitions for the constraints as well as the calculation of an initial value for the non-linear optimisation with a Genetic Algorithm have been investigated. It could be shown, that both measures yield improvements of the non-linear optimisation, especially for performance parameters with a low observability.

The developed system was statistically assessed by the use of 31680 generic test cycles and yielded detection rates of up to 99%, identification rates of up to 96% and diagnosis rates of up to 99%.

Finally, the concept was implemented in the framework of the development of a ECM software called HealthGT[®] including a graphical user interface. HealthGT[®] is programmed in a modular fashion, which enables an easy implementation of future additional functions.

Kapitel 1: Einführung

1.1 Allgemeine Einführung

Die Leistungsfähigkeit einer Gasturbine ist ein Schlüsselkriterium für deren wirtschaftlichen Betrieb, sowohl aus Sicht des Herstellers als auch des Betreibers. Sie besteht in der Bereitstellung einer Wellenleistung (stationäre Gasturbine) bzw. eines Schubes (Fluggasturbine) bei gegebenen Betriebskosten sowie gegebenen Werten für Gewicht, Durchmesser, Emissionen und Lebensdauer ^[134]. Bei Fluggasturbinen verteilen sich die direkten Betriebskosten (DOC, *Direct Operating Costs*) etwa gleichmäßig auf Treibstoffverbrauch, Wartung & Überholung sowie Finanzierung und machen in der Summe ein Viertel der direkten Betriebskosten des Flugzeuges aus ^[102] (siehe Bild 1.1).




Bild 1.1: Triebwerksinstandhaltungskosten als Teil der direkten Betriebskosten (DOC) eines Flugzeuges nach Rupp ^[102]

Um die Leistungsfähigkeit einer Gasturbine bei gegebener Wellenleistungs- bzw. Schubforderung zu erhöhen, müssen die Betriebskosten gesenkt werden. Ein Schwerpunkt der technologischen Weiterentwicklung von Gasturbinen liegt demzufolge auf einer Reduzierung des Treibstoffverbrauches einerseits und möglichst ökonomischer Wartung & Überholung andererseits. Darüber hinaus ist eine Re-

duzierung der Betriebskosten vor dem Hintergrund der Intensivierung des Wettbewerbs und steigenden Kostendrucks notwendig ^[36]. Beispielsweise beziffert Steffens ^[116] die Zielvorgaben der MTU Aero Engines GmbH für den Zeitraum zwischen 2003 und 2020 mit einer Reduktion des spezifischen Treibstoffverbrauchs um 15-20% und einer Verringerung der Wartungskosten um 40%.

Eine Möglichkeit, die Wartungskosten signifikant zu senken und darüber hinaus die Leistungsfähigkeit der Gasturbine über ihren gesamten Lebenszyklus bestmöglich zu erhalten, besteht im Einsatz fortschrittlicher Systeme zur Zustandsüberwachung (ECM, *Engine Condition Monitoring*) ^[88]. Das Ziel derartiger Systeme besteht darin, auf der Basis von Messwerten eine Aussage über den Zustand der einzelnen Komponenten der Gasturbine zu treffen. Ihr volles Potential zur Wartungskostensparnis können ECM Systeme allerdings nur in Verbindung mit Systemen zur Wartungsplanung und zum Flottenmanagement entfalten. Nur durch die konsequente und zeitnahe Umsetzung der detaillierten Kenntnis über den Zustand jeder Gasturbine einer Flotte in eine Optimierung des individuellen Wartungsplanes können die mit Hilfe von ECM Systemen gewonnen Informationen wertschöpfend eingesetzt werden. Derartige Systeme, die neben den Aufgaben der Zustandsüberwachung und der Zustandsvorhersage auch die Lebensdauerüberwachung von lebensdauerbegrenzten Bauteilen (LLP, *Life Limited Parts*) und die Optimierung der Wartungsplanung und des Flottenmanagements beinhaltet, werden als EHM Systeme (EHM, *Engine Health Management*) bezeichnet ^[70]. Bei Fluggasturbinen bieten derartige Systeme folgende Vorteile ^[139]:

- » Erhöhung der Flugsicherheit durch frühzeitiges Erkennen von Triebwerksfehlfunktionen,
- » Vermeidung kostspieliger Triebwerksschäden und der damit möglicherweise verbundenen Gefährdung von Menschenleben,
- » Reduzierung der Wartungsdauer und damit der Wartungskosten durch Bereitstellung von Informationen über Ort und Schwere der Fehlerursache,
- » Verkürzung von Verspätungen und Vermeidung von Stornierungen von Flügen durch die Erweiterung der Reparaturmöglichkeiten am Flügel,
- » Erhöhung der Einsatzdauer von Triebwerken (TOW, *Time-On-Wing*) durch Minimierung von geplanten und ungeplanten Demontagen.

EHM Systeme bieten durch die Verkürzung von Verspätungen und die Vermeidung von Stornierungen von Flügen unmittelbares Potential zur Kostenersparnis. Die europäische Flugsicherheitsbehörde EUROCONTROL beziffert für Verspätungen und Ausfälle von Flügen die folgenden durchschnittlichen Kosten ^[32],

wobei die direkten Kosten nur den Umsatzausfall und eventuell zu zahlende Entschädigungen beinhalten, während mit Hilfe der indirekten Kosten versucht wird, den potentiellen Verlust zukünftiger Umsätze durch Imageverlust zu quantifizieren:

Beschreibung	Kosten
Direkte Kosten einer Verspätung	39 – 54 €/min
Direkte und indirekte Kosten einer Verspätung	78 – 93 €/min
Direkte und indirekte Kosten durch Ausfall eines Kurzstreckenfluges (120 Passagiere)	15.000 €
Direkte und indirekte Kosten durch Ausfall eines Langstreckenfluges (400 Passagiere)	70.000 €

Tabelle 1.1: Richtwerte für Folgekosten von Verspätungen und Ausfällen von Flügen laut EUROCONTROL ^[32]

Neben der Weiterentwicklung der Algorithmen derartiger Systeme darf der benötigte Aufwand für die Datenverwaltung und -verarbeitung nicht unterschätzt werden. Rolls-Royce gibt an, dass jedes ihrer derzeit im Einsatz befindlichen zivilen Triebwerke in der Lage ist, pro Flug eine Datenmenge von über einem Gigabyte aufzuzeichnen ^[87]. Die maximal mögliche Datenmenge der zivilen Flotte von derzeit rund 11700 Triebwerken liegt demnach in der Größenordnung einiger Terabyte pro Tag. Die enormen Anforderungen an das Datenmanagement werden vor dem Hintergrund von Visionen für zukünftige EHM Systeme noch verdeutlicht. Während heutige EHM Systeme zum Großteil mit Offline-Daten versorgt werden, sollen zukünftige Systeme vermehrt auf Online-Daten zurückgreifen ^[118]. Diese in Echtzeit während des Fluges gesammelten Daten sollen per Satellit an den Betreiber des EHM Systems zur Analyse übermittelt werden ^[87]. Die Ergebnisse können dem Kunden bzw. dessen Wartungsbetrieb in Form von Schadensberichten, Zustandsvorhersagen und Wartungsanweisungen elektronisch zugesendet oder über eine verschlüsselte Website zur Verfügung gestellt werden.

Tumer und Bajwa ^[118] identifizieren als Folge dieser Entwicklung drei Hauptpunkte für die Anforderungen an zukünftige EHM Systeme:

- » verlässliche Fehlererkennung, d.h. minimale Rate an Fehlalarmen
- » verlässliche Ursachenfindung, d.h. bestmögliche Integrierung aller zur Verfügung stehenden Informationen in den Prozess der Ursachenfindung
- » ausreichende Fähigkeiten zur Datenübermittlung und Datenspeicherung

Diese Anforderungen sollen selbstverständlich bei minimalen Kosten erreicht werden ^[118]. Allerdings sind die Kosten für das EHM System als Bewertungskrite-

rium nicht zweckmäßig, vielmehr ist die Rentabilität derartiger Systeme zu betrachten. Das Ziel liegt dabei in der Erreichung maximaler Rentabilität, die ein Optimum zwischen dem Aufwand in Form von Investitionen in das System und dem Nutzen in Form einer Reduktion der Lebenszykluskosten darstellt ^[7] (siehe Bild 1.2)




Bild 1.2: Rentabilität eines EHM Systems als Funktion seiner Komplexität nach Bechini ^[7]

1.2 Entwicklung des EHM Marktes

Ein deutliches Zeichen dafür, dass EHM Systeme seitens der Hersteller als entscheidendes Mittel zur Erhaltung bzw. Steigerung der Wettbewerbsfähigkeit angesehen werden, liefert die Betrachtung des EHM Marktes.

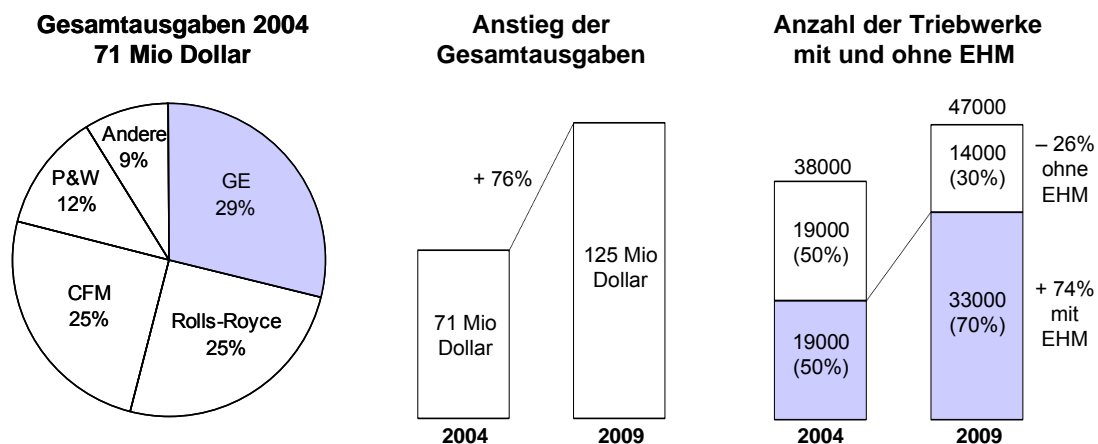


Bild 1.3: Aufteilung und Entwicklung des EHM Marktes bei Herstellern von Fluggasturbinen ^[6]

Im Bereich der Fluggasturbinen wurden im Jahr 2004 seitens der Hersteller 71 Millionen Dollar in die Entwicklung von EHM Systemen investiert. Die Firmen General Electrics, Rolls-Royce und CFM stellen dabei knapp 80% dieses Budgets (siehe Bild 1.3). Bis zum Jahr 2009 wird mit einem Anstieg der jährlichen Gesamtausgaben auf 125 Millionen Dollar gerechnet, was einem Gesamtzuwachs von 76% bzw. einem jährlichen Wachstum von knapp 12% entspricht. Die Anzahl der mit einem EHM System ausgestatteten Triebwerke wird von 2004 bis 2009 von ca. 19000 auf erwartete 33000 ansteigen, was einem Zuwachs von 74% entspricht.

Die Ursache, dass seitens der Hersteller von Fluggasturbinen ein derartiger Anstieg der Investitionen in die Entwicklung von EHM Systemen zu verzeichnen ist, liegt in einem Wandel der Instandhaltungsphilosophien und damit verbundenen neuen Vertragsformen begründet. Bis in die 1980er Jahre wurden Fluggasturbinen überwiegend einer durch definierte Zyklen festgelegten Wartung unterzogen (TBO, *Time Between Overhaul*). Seit den Anfängen der 1980er Jahre wurde diese Methode durch die Überwachung einzelner Messwerte, wie z.B. der Turbinenaustrittstemperatur, erweitert, um auf den Zustand der jeweiligen Gasturbine reagieren zu können. Bei dieser als CBM (*Condition Based Maintenance*) bekannten Methode kamen vorwiegend so genannte *Time-and-Material*^[103] Verträge zum Einsatz. Dabei zahlt der Betreiber der Fluggasturbine, i.d.R. die Fluglinie, Wartungsgebühren in Höhe der vertraglich vereinbarten Lohn- und Materialkosten. Diese Vertragsart bietet für den Betreiber jedoch nur geringe Planungssicherheit in Bezug auf die anfallenden Wartungsgebühren. Um diese Planungssicherheit zu erhöhen besteht seitens der Fluglinien seit Mitte der 1990er Jahre eine steigende Tendenz, Wartungsverträge auf einer *Fly-by-Hour*^[103] Basis abzuschließen¹. Bei derartigen Verträgen zahlt der Betreiber der Fluggasturbine pro Betriebsstunde einen festen Betrag an den Wartungsanbieter, der mit der so kumulierten Summe die Kosten für alle nötigen Wartungsarbeiten seinerseits decken muss. Darüber hinaus ist oft die Bereitstellung von Ersatztriebwerken während der Überholung vertraglich zugesichert^[103]. Daher liegt eine Optimierung der Zustandsüberwachung mit integrierter Wartungsplanung, also die Entwicklung fortschrittlicher EHM Systeme, im Interesse des Wartungsanbieters.

¹ Von den derzeit rund 11700 im zivilen Einsatz befindlichen Rolls-Royce Triebwerken werden im Jahr 2010 mehr als die Hälfte unter TotalCare[®] Verträgen betrieben werden. Bei den Neuverträgen beläuft sich der Anteil bereits auf 80%^[17]. TotalCare[®] ist ein eingetragener Markenname der Firma Rolls-Royce plc.

Diese Art der Instandhaltungsphilosophie wird als Wartung auf Basis von komponentenbasierter Diagnose bezeichnet (CCBM, *Component Condition Based Maintenance*), da nicht nur der Gesamtzustand der Gasturbine, sondern der Zustand jeder Komponente beobachtet wird.

Diese Zusammenhänge sind in Tabelle 1.2 zusammengefasst. Darüber hinaus ist die Entwicklung grundlegender EHM Funktionen zeitlich eingeordnet.

Jahr	Instandhaltungsphilosophie	EHM Funktionen
Bis 1980	Wartung durch definierte Zyklen festgelegt (TBO, Time Between Overhaul)	keine
Seit 1980	Überwachung einzelner Messwerte, z.B. der Turbinenaustrittstemperatur (CBM, Condition Based Maintenance)	Erkennen von Trends
Seit 1995	Wandel in den Vertragsformen von Time-and-Material Verträgen zu Fly-by-Hour Verträgen	automatisierte Datenverarbeitung
Seit 2000	Gasturbinenhersteller und Wartungsanbieter liefern EHM als zusätzlichen Service	einfache Diagnosefähigkeiten
Ab 2010	Wartung aufgrund komponentenbasierter Diagnose (CCBM, Component CBM), EHM wird als wertschöpfend erachtet	verbesserte Diagnosefähigkeiten, Prognosefähigkeiten, integrierte Wartungsplanung

Tabelle 1.2: Entwicklung der Instandhaltungsphilosophien über der Zeit (angelehnt an Rupp^[103] und Bauer^[6])

1.3 Allgemeine Architektur von EHM Systemen

Die Grundlage für alle EHM Systeme stellen die Messwerte einer Gasturbine dar. Dabei kann zwischen Gas-Pfad-Messwerten und Messwerten außerhalb des Gas-Pfades unterschieden werden. Unter Gas-Pfad-Messwerten werden folgende Parameter verstanden^[132]:

- » Drücke und Temperaturen im Gas-Pfad
- » Drehzahlen der Wellen
- » Brennstoffmassenstrom

Die übrigen Messwerte können nach Systemen oder Funktionen zusammengefasst werden, wobei die folgende Liste keinen Anspruch auf Vollständigkeit erhebt:

- » Ölsystem: Öltemperatur, Öldruck, Partikel im Ölsystem
- » Vibrationsmesswerte: Frequenzen und Amplituden der Wellenschwingungen

» Strukturelle Messwerte: Partikel im Einlauf und im Abgasstrom, chemische Abgaszusammensetzung, akustische Messwerte, Spaltsensoren, etc.

Alle Messwerte durchlaufen die vier folgenden Hauptprozesse des EHM Systems (siehe Bild 1.4):

- (1) Detektion: Erkennung von Anomalien in den Messwerten,
- (2) Identifikation & Diagnose: Zuordnung der Veränderung zu den betroffenen Komponenten der Gasturbine (Identifikation) sowie die quantitative Bestimmung der Veränderung (Diagnose),
- (3) Prognose: Vorhersage des zukünftigen Zustandes der Gasturbine,
- (4) Logistik: Umsetzung des detaillierten Wissens über den Zustand der Gasturbine in Wartungsanweisungen, Wartungspläne und optimiertes Flottenmanagement.

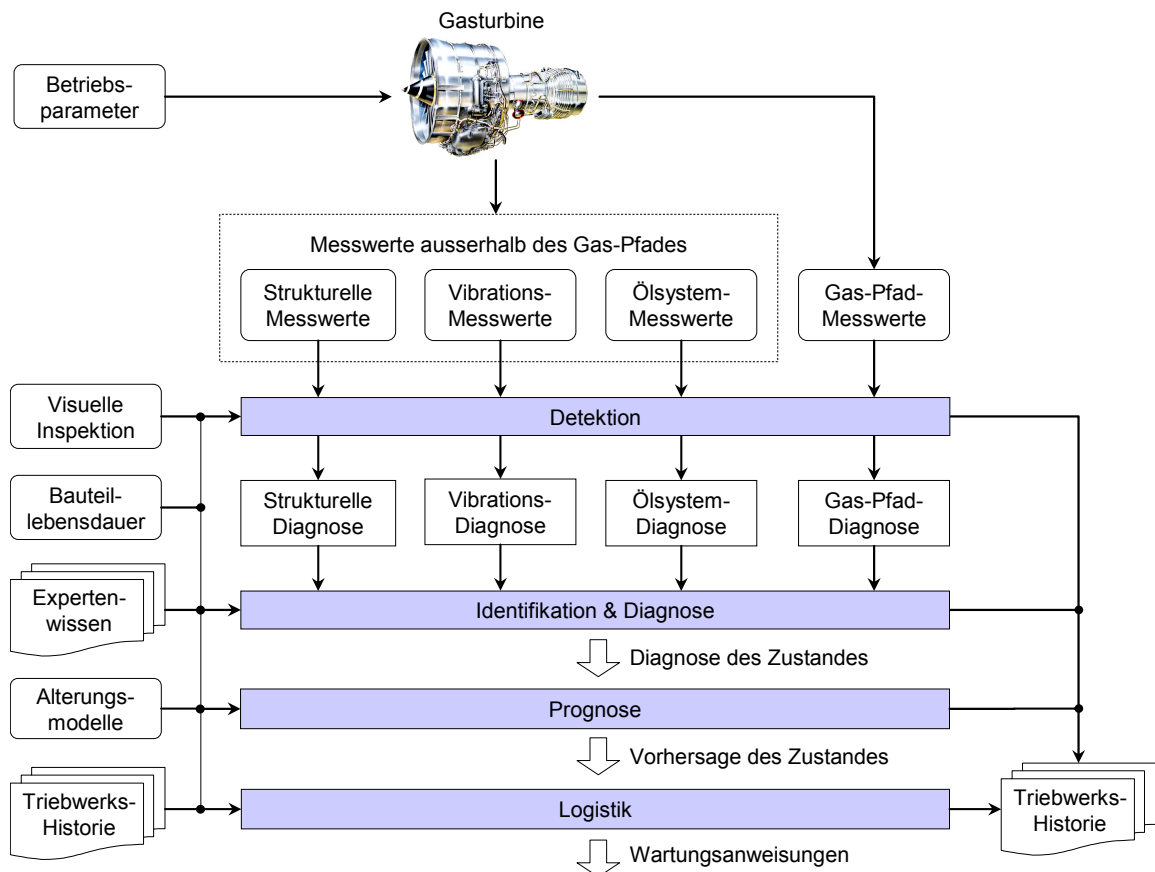


Bild 1.4: Allgemeine Architektur eines EHM Systems

Dabei können die Analysen dieser Prozesse jeweils nach Art der Messwerte getrennt und/oder in fusionierter Form durchgeführt werden. Eine fusionierte Analyse greift im Unterschied zur getrennten Analyse auf alle vorhandenen Messwer-

te zu, wodurch Güte und Zuverlässigkeit der Analyse verbessert werden kann^[131]. Dies muss jedoch mit einer erhöhten Systemkomplexität erkaufte werden. In Bild 1.4 ist beispielhaft eine getrennte Detektion, eine getrennte und anschließend fusionierte Identifikation & Diagnose, sowie eine fusionierte Prognose und eine fusionierte Wartungsplanung dargestellt.

Zusätzlich zu den Datenströmen der Messwerte können in jeden der vier Hauptprozesse Informationen aus weiteren Quellen einfließen, z.B. aus visuellen Inspektionen, Modellen zur Bauteillebensdauer, Alterungsmodellen, der Triebwerkshistorie oder in Form von Expertenwissen. Abschließend werden alle Ergebnisse als Grundlage zukünftiger Analysen in der Triebwerkshistorie abgelegt.

1.4 Begriffsdefinitionen

Obwohl in der entsprechenden Fachliteratur bereits mehrere Vorschläge für eine einheitliche Begriffsdefinition veröffentlicht wurden, konnte sich bisher keine Nomenklatur als allgemein anerkannt durchsetzen. Beispiele für entsprechende Nomenklaturvorschläge sind bei Jaw^[48], Palade et al.^[88] und Litt et al.^[70] sowie in VDI Berichten^[122] und VDMA Richtlinien^[123] zu finden. Um Mehrdeutigkeiten zu vermeiden, wird dieser Arbeit eine Zusammenstellung der verwendeten Begriffe und Abkürzungen in erläuterter Form vorangestellt. Eine Erläuterung der einzelnen Begriffe ist nachfolgend aufgeführt.

Einzelereignisse, Fehler

Ereignisse, die zeitlich diskret auftreten, werden als Einzelereignisse oder Fehler bezeichnet. Derartige Ereignisse werden z.B. durch Fremdkörperbeschädigung, Bauteilverlust durch Ermüdung, defekte Dichtungen oder defekte Leitgitterverstellungen ausgelöst und betreffen nur eine geringe Anzahl der Komponenten der Gasturbine, d.h. sie sind lokal begrenzt^[130]. In der Literatur werden die Begriffe Defekte (*Defects*), Schäden (*Failures*) und Fehler (*Faults*) verwendet. Jaw^[48] unterscheidet zusätzlich zwischen Fehlern und Schäden, wobei sich Schäden durch eine Verminderung der Leistungsfähigkeit der Gasturbine auszeichnen, deren Grad den weiteren Betrieb unmöglich macht. Eine derartige Unterscheidung ist in der vorliegende Arbeit nicht erforderlich.

Graduelle Verschlechterung, Alterung

Eine langsame und zeitlich kontinuierliche Verringerung der Leistungsfähigkeit der Gasturbine wird als graduelle Verschlechterung bezeichnet. Sie wird durch

Alterungsmechanismen wie z.B. Erosion, Korrosion oder Ablagerungen (*Fouling*) verursacht und tritt im Gegensatz zu Einzelereignissen kontinuierlich und in allen Komponenten der Gasturbine auf. Die Ausprägung kann dabei in den verschiedenen Komponenten unterschiedliche Grade erreichen.

Die Abgrenzung zwischen Einzelereignissen und gradueller Verschlechterung erfolgt durch den Grad der Leistungsver schlechterung. Bei gradueller Verschlechterung handelt es sich streng genommen um die Summe vieler Einzelereignisse mit jeweils geringer Ausprägung^[31]. So stellt z.B. Erosion nichts anderes als den durch das Auftreffen vieler kleiner Partikel hervorgerufenen Materialabtrag dar, während ein Fremdkörperereignis das Auftreffen eines einzigen oder einiger weniger, größeren Objekte bezeichnet. Die beiden Arten von Einzelereignissen unterscheiden sich jedoch beträchtlich in der Schwere ihrer Auswirkung auf die Leistungsfähigkeit der Gasturbine. Der Einfluss von gradueller Verschlechterung und Einzelereignissen auf die Leistungsfähigkeit der Gasturbine ist in Bild 1.5 qualitativ dargestellt.




Bild 1.5: Einfluss von Einzelereignissen und gradueller Verschlechterung auf die Leistungsfähigkeit (angelehnt an Volponi^[130])

Detektion

Das Erkennen von Einzelereignissen wird als Detektion bezeichnet. Die Detektion wird auf der Basis von Messwerten durchgeführt, wobei alle zur Verfügung stehenden Größen herangezogen werden können, z.B. Drücke, Temperaturen, Drehzahlen, Brennstoffmassenstrom, Öltemperatur, Partikel im Ölsystem und im Abgas, Abgaszusammensetzung, Schwingungen, etc. Damit Einzelereignisse detektiert werden können, muss deren Einfluss auf die Messwerte die Detektions-sensitivität des verwendeten Detektionsverfahrens überschreiten.

Identifikation

Die Zuordnung von Einzelereignissen zu den betroffenen Komponenten wird als Identifikation bezeichnet. Die Identifikation stellt demnach die Lokalisierung des Fehlers dar. In der Literatur wird gleichbedeutend der Begriff Fehlerisolierung (*Isolation*) verwendet. Darüber hinaus werden die Funktionen Detektion und Identifikation unter dem Akronym FDI (*Fault Detection and Isolation*) zusammengefasst ^[88].

Diagnose

Die Bestimmung der Ausprägung des Fehlers wird als Diagnose bezeichnet. Für die quantitative Bestimmung des Komponentenzustandes werden relative Abweichungen leistungsrelevanter Gütwerte (z.B. Wirkungsgrade und Kapazitäten von Verdichtern und Turbinen) von Referenzwerten im gesunden Triebwerkszustand betrachtet. Diese relativen Abweichungen der Gütwerte werden als Leistungsparameter bezeichnet. Die Aufgabe der Diagnose ist demnach die Berechnung der Leistungsparameterwerte der Gasturbine. In der Literatur wird diese Funktion auch als Identifikation bezeichnet ^[88], nicht zu verwechseln mit der oben getroffenen Definition.

Prognose

Als Prognose wird die Vorhersage von Leistungsparametern und Messwerten verstanden. Mit Hilfe der Prognose können Zeitpunkte bestimmt werden, zu denen eine Über- oder Unterschreitung festgelegter Grenzwerte erwartet wird. Diese Information kann für eine Optimierung der Wartungsplanung verwendet werden.

Engine Trend Monitoring (ETM)

Systeme zur Trendüberwachung von Messwerten werden als ETM Systeme bezeichnet. Sie stellen die einfachste Form der Zustandsüberwachungssysteme dar. Mit Hilfe von ETM Systemen können die Funktionen Detektion sowie Prognose durchgeführt werden, wobei eine Prognose nur für die Messwerte, nicht jedoch für die Leistungsparameter möglich ist. ETM Systeme beinhalten keine Identifikations- und Diagnosefähigkeiten.

Engine Condition Monitoring (ECM)

ECM Systeme beinhalten die Funktionen Detektion, Identifikation, Diagnose und Prognose und verfügen damit über alle Eigenschaften der Zustandsüberwachung und -vorhersage. In der Literatur wird je nach verwendeten Messgrößen z.B. zwischen Leistungsüberwachung (PMS, *Performance Monitoring Systems*), Vibrationsüberwachung (VMS, *Vibration Monitoring Systems*) und Emissionsüber-

wachung (EMS, *Emission Monitoring Systems*) unterschieden ^[123]. In der vorliegenden Arbeit wird eine derartige Unterscheidung nicht getroffen. ECM wird als Oberbegriff für Zustandsüberwachungssysteme verstanden, unabhängig von der Art der verwendeten Messgrößen.

Engine Health Management (EHM)

Systeme, die neben den Aufgaben der Zustandsüberwachung und deren Vorhersage auch über Funktionen der Lebensdauerüberwachung von lebensdauerbegrenzten Bauteilen verfügen (LUM, *Life Usage Monitoring*) und diese mit den logistischen Aufgaben der Wartungsplanung und des Flottenmanagements verknüpfen, werden als EHM Systeme bezeichnet ^[70]. EHM Systeme setzen die mit Hilfe von ECM Systemen gewonnenen Informationen über den detaillierten Zustand einer Gasturbine wertschöpfend um, indem optimierte Wartungsanweisungen abgeleitet werden. Dabei kommt der Automatisierung eine entscheidende Rolle zu, da die anfallenden Datenmengen bei der Überwachung einer Flotte von Gasturbinen einen beträchtlichen Umfang erreichen können (siehe Abschnitt 1.1).

Es bleibt festzuhalten, dass in der Literatur oft nicht ausreichend zwischen den Begriffen *Engine Condition Monitoring* und *Engine Health Management* unterschieden wird. Beim Studium der Literatur ist es daher nötig, im Einzelfall zu untersuchen, welche Funktionen ein beschriebenes System unabhängig von seiner Bezeichnung beinhaltet.

1.5 Zielsetzung der Arbeit

Zielsetzung der vorliegenden Arbeit ist die Entwicklung eines integrierten Systems zur Gasturbinenüberwachung, d.h. die Entwicklung eines ECM Systems im Sinne der Definition nach Abschnitt 1.4. Der Begriff *integriertes System* soll verdeutlichen, dass die Behandlung von Einzelereignissen und gradueller Verschlechterung in einem Konzept vereint werden soll. Daraus ergeben sich folgende Anforderungen an das zu entwickelnde System:

- » Das System muss in der Lage sein, Einzelereignisse zuverlässig und mit möglichst kleiner zeitlicher Verzögerung zu erkennen (Detektion).
- » Die von Einzelereignissen betroffenen Komponenten der Gastrubine müssen korrekt identifiziert werden (Identifikation). Anschließend muss die Größe

der Abweichung der entsprechenden Leistungsparameter bestimmt werden können (Diagnose von Einzelereignissen).

- » Die durch Alterungsmechanismen verursachten Abweichungen aller Leistungsparameter müssen ebenfalls bestimmt werden können (Diagnose gradueller Verschlechterung).
- » Die Ergebnisse beider Diagnosen müssen zusammengeführt werden, um eine ganzheitliche Betrachtung des Leistungszustandes der Gasturbine über der Zeit zu ermöglichen.
- » Das System sollte in der Lage sein, die zeitlichen Verläufe der Messgrößen vorherzusagen, um Zeitpunkte bestimmen zu können, zu denen festgelegte Grenzwerte über- oder unterschritten werden (Messwertprognose).

Diese Anforderungen müssen ins Besondere vor dem Hintergrund einer eingeschränkten Instrumentierung der Gasturbine erfüllt werden, wie sie im Serienbetrieb vorliegt. Der Zweck der Serieninstrumentierung von Gasturbinen ist lediglich die Gewährleistung ihres zuverlässigen Betriebs, nicht jedoch die Bereitstellung optimaler Messwerte für ECM Systeme. Dieser Umstand führt dazu, dass die Anzahl der zur Verfügung stehenden Messwerte üblicherweise geringer ist als die Anzahl der zu bestimmenden Leistungsparameter (Beispiele für übliche Serieninstrumentierungen sind bei Grönstedt ^[45], Mathioudakis ^[77,80], Romessis ^[99], Roth ^[101] und Visser ^[126] zu finden). Es liegt demnach ein unterbestimmtes System vor, dessen Lösung den Kern der Diagnoseaufgabe darstellt.

Die Leistungsfähigkeit des entwickelten Systems soll anhand generischer Daten demonstriert werden. Hierbei werden mit Hilfe eines aero-thermodynamischen Modells Messdaten erzeugt, die sich an realen, der Literatur zu entnehmenden Fehlerfällen und Alterungsverläufen orientieren. Durch diese Methodik ist es möglich eine Vielzahl an Einzelereignissen zu untersuchen, die in dieser Ausprägung nicht durch reale Daten zur Verfügung gestellt werden könnten. Es kann eine statistische Aussage über die Güte des Identifikationsprozesses und der anschließenden Diagnose der Einzelereignisse getroffen werden.

Kapitel 2: Stand der Technik

2.1 Übersicht über ECM Verfahren

Nach Donat et al. ^[30] lassen sich alle Verfahren zur Zustandsüberwachung in eine der drei folgenden Kategorien einteilen:

- » modellbasiert,
- » datenbasiert,
- » wissensbasiert (auch als regelbasiert bezeichnet).

Bei modellbasierten Ansätzen kommen Leistungsrechnungsprogramme zum Einsatz, die das aero-thermodynamische Betriebsverhalten der zu betrachtenden Gasturbine modellieren. Zu den modellbasierten Ansätzen zählen die lineare und nichtlineare Gas-Pfad-Analyse, Verfahren zur Zustandsschätzung, Verfahren der nichtlinearen Optimierung und evolutionäre (genetische) Algorithmen. Aber auch Neuronale Netze sowie Verfahren der Fuzzy Logic können modellbasiert eingesetzt werden.

Datenbasierte Verfahren verzichten auf den Einsatz aero-thermodynamischer Modelle und basieren ausschließlich auf der Analyse von Messwerten. In diese Kategorie fallen insbesondere Neuronale Netze, Fuzzy Logic und Verfahren zur Mustererkennung (*Pattern Recognition*). Allerdings können auch die Lineare Gas-Pfad-Analyse und Verfahren zur Zustandsschätzung datenbasiert durchgeführt werden.

Wissensbasierte Ansätze benötigen ebenfalls kein Modell der zu untersuchenden Gasturbine. Sie basieren auf Regeln und Zusammenhängen, die aus Erfahrungen abgeleitet werden und mit deren Hilfe die Messwerte der Gasturbine interpretiert werden können. Derartige Systeme werden als Expertensysteme bezeichnet und können sich z.B. Verfahren der Fuzzy Logic oder der Mustererkennung zur Anwendung der Regeln zu Nutze machen. Wissensbasierte Ansätze sind nicht Gegenstand der vorliegenden Arbeit und werden daher nicht weiter betrachtet.

In Tabelle 2.1 sind Verfahren zusammengefasst, die in ECM Systemen zum Einsatz kommen. Dabei ist zu beachten, dass einige Verfahren in verschiedenen Formen zum Einsatz kommen können, d.h. sowohl in modellbasierter, datenbasierter oder wissensbasierter Form. Die Markierung »x« steht für den primären Einsatz der Verfahren, während »(x)« weitere Anwendungsmöglichkeiten anzeigt.

Name des Verfahrens	modellbasiert	datenbasiert	wissensbasiert
Lineare Gas-Pfad-Analyse	x	(x)	
Zustandsschätzverfahren	x	(x)	
Kalman Filter	x	(x)	
Nichtlineare Gas-Pfad-Analyse	x		
Nichtlineare Optimierung	x		
Genetische Algorithmen	x		
Neuronale Netze	(x)	x	
Fuzzy Logic	(x)	x	(x)
Pattern Recognition		x	(x)

Tabelle 2.1: Übersicht über mathematische Verfahren zur Zustandsüberwachung von Gasturbinen

In den Abschnitten 2.2 und 2.3 werden die in Tabelle 2.1 aufgelisteten Verfahren kurz erläutert und ihre Anwendungsgebiete anhand von Literaturangaben dargelegt. Weitere Übersichten über ECM Verfahren sind bei Singh ^[110], Jaw ^[48] und Marinai et al. ^[75] zu finden.

2.2 Modellbasierte ECM Verfahren

Wie bereits erwähnt kommen bei den modellbasierten Ansätzen aerothermodynamische Modelle zur Anwendung, mit deren Hilfe das Betriebsverhalten der Gasturbine simuliert wird. In diesem Abschnitt wird daher kurz auf die Grundlagen der Leistungsrechnung eingegangen, bevor eine Übersicht über modellbasierte Verfahren zur Zustandsüberwachung von Gasturbinen gegeben wird.

2.2.1 Grundlagen der Leistungsrechnung

Die Leistungsrechnung hat ihren Ursprung 1972 mit den Arbeiten von Koenig und Fishbach ^[56,57], die ein Programm für die Berechnung des stationären Be-

triebsverhaltens einer Gasturbine vorstellten. Seitdem haben sich eine Reihe von Programmen etabliert, die alle auf dem Prinzip der modularen Synthese basieren. Dabei wird das Betriebsverhalten der Gasturbine aus den Charakteristiken² ihrer Komponenten unter Einhaltung der Erhaltungsgleichungen für Masse, Energie und Impuls synthetisiert. Daher werden Leistungsrechnungsprogramme auch als Leistungssyntheseprogramme bezeichnet. Beispiele für derartige Programme sind Tabelle 2.2 zu entnehmen. Für weiterführende Informationen sei auf die jeweiligen Referenzen und die Arbeit von Grönstedt^[43] verwiesen, der einen umfassenden Überblick über die Entwicklung der Leistungsrechnung liefert.

Name des Programms	Jahr	Institution	Referenzen
GENENG / GENENG II	1972	NASA	Koenig und Fishbach ^[56,57]
HYDES	1974	NASA	Szuch ^[117]
TURBOMATCH	1974	Cranfield University	MacMillan ^[73]
DYNGEN	1975	NASA	Sellers und Daniels ^[108]
NNEP	1975	NASA	Fishbach und Caddy ^[35]
GasTurb [®]	1995	GasTurb [®]	Kurzke ^[62]
GSP	1995	TU Delft	Visser ^[124-127]
NCP (NPSS)	1998	NASA	Evans et. al. ^[34]
PROOSIS	2007	EU-Projekt VIVACE	Bala et al. ^[4]

Tabelle 2.2: Übersicht über veröffentlichte Leistungsrechnungsprogramme

Darüber hinaus verfügen viele Hersteller von Gasturbinen über eigene Leistungsrechnungsprogramme, die ebenfalls das Prinzip der modularen Synthese einsetzen. Eine Beschreibung der Grundlagen der modularen Synthese ist bei Bauer^[5] zu finden. Details der Modellierung, wie z.B. die Berücksichtigung von Kühllufteffekten, Einlaufverlusten, Reynoldszahleinflüssen, Strömungsstörungen und Spalteffekten werden von Kurzke^[61] beschrieben.

2.2.2 Grundlagen der Gas-Pfad-Analyse

Die Grundlage für heutige ECM Systeme wurde bereits 1972 von L.A. Urban mit der Entwicklung der Gas-Pfad-Analyse (GPA) gelegt^[119]. Er beschreibt die Zusammenhänge zwischen mechanischen Veränderungen, Leistungsparametern und

² Kennfelder der Turbokomponenten, Durchsatzcharakteristiken der Düsen, Druckverluste der Brennkammer und der Strömungskanäle, Leistungsverluste der Wellen, etc.

Messwerten von Gasturbinen. Die Gas-Pfad-Analyse basiert auf den folgenden Zusammenhängen, die in Bild 2.1 dargestellt sind:

- (a) Mechanische Veränderungen führen zu Veränderungen der Leistungsparameter der Gasturbine. Als Leistungsparameter können Wirkungsgrade und Durchflussvermögen (Kapazitäten) der Turbokomponenten sowie Druckverluste herangezogen werden. Bei Fluggasturbinen kann zusätzlich der Zustand der Schubdüsen durch die effektiv durchströmten Querschnittsflächen beschrieben werden. Eine Übersicht über weitere geeignete Leistungsparameter ist bei Volponi ^[128] zu finden.
- (b) Die Veränderungen der Leistungsparameter verursachen ihrerseits eine Veränderung messbarer Größen. Hier wird zwischen thermodynamischen und mechanischen Größen unterschieden.
- (c) Die Grundidee der GPA besteht in der Invertierung dieser Zusammenhänge, d.h. dass mit Hilfe der Messwertveränderungen auf die Veränderungen der Leistungsparameter geschlossen wird.
- (d) Sind die Veränderungen der Leistungsparameter bestimmt, lassen diese Rückschlüsse auf die mechanische Ursache der Veränderung zu.




Bild 2.1: Grundlegende Zusammenhänge der Gas-Pfad-Analyse (adaptiert von Urban ^[120])

Der Zusammenhang zwischen den Betriebsparametern U , den Leistungsparametern X und den Messwerten Y lautet in allgemeiner Form

$$Y = f(X, U). \quad (2.1)$$

Hierbei umfasst der Betriebsparametervektor U die Umgebungsbedingungen sowie den Lastparameter. Für gegebene Betriebsparameter sind die Messwerte Y eine reine Funktion der Leistungsparameter X :

$$Y = f(X). \quad (2.2)$$

Die Funktion f ist gegeben durch die Charakteristiken der Komponenten (Kennfelder, Druckverluste, Durchsatzcharakteristiken) sowie durch die Erhaltungsgleichungen, die das Zusammenwirken der Komponenten bestimmen (Massenerhaltung, Energieerhaltung, Leistungsgleichgewicht) ^[63,119].

2.2.3 Die lineare Gas-Pfad-Analyse

Eine Taylorreihenentwicklung für die Komponenten des Messwertvektors Y unter Vernachlässigung der Terme höherer Ordnung liefert die Beziehung

$$Y_i = Y_i^{\text{ref}} + \sum_{j=1}^n \frac{\partial f_i}{\partial X_j} \cdot (X_j - X_j^{\text{ref}}) \quad (2.3)$$

wobei X^{ref} und Y^{ref} den unverschlechterten Zustand der Gasturbine darstellen. Durch Differenzbildung und Beziehen auf die Referenzwerte ergibt sich:

$$\frac{(Y_i - Y_i^{\text{ref}})}{Y_i^{\text{ref}}} = \sum_{j=1}^n \frac{\partial f_i}{\partial X_j} \cdot \frac{X_j^{\text{ref}}}{Y_i^{\text{ref}}} \cdot \frac{(X_j - X_j^{\text{ref}})}{X_j^{\text{ref}}}. \quad (2.4)$$

Durch Anwendung der Definitionen

$$\Delta Y_i = \frac{(Y_i - Y_i^{\text{ref}})}{Y_i^{\text{ref}}}, \quad \Delta X_j = \frac{(X_j - X_j^{\text{ref}})}{X_j^{\text{ref}}} \quad \text{und} \quad a_{ij} = \frac{\partial f_i}{\partial X_j} \cdot \frac{X_j^{\text{ref}}}{Y_i^{\text{ref}}} \quad (2.5)$$

folgt die verkürzte Schreibweise:

$$\Delta Y_i = \sum_{j=1}^n a_{ij} \cdot \Delta X_j. \quad (2.6)$$

Die Koeffizienten a beschreiben die Verhältnisse der relativen Veränderungen der Leistungsparameter zu den relativen Veränderungen der Messwerte und werden als Sensitivitäten oder Einflusskoeffizienten bezeichnet. Die aus diesen Koeffizienten bestehende Matrix wird daher Einfluss-Koeffizienten-Matrix (EKM) genannt. Sie kann aus umfangreichen Messungen abgeleitet oder durch Leistungsrechnungsprogramme, die das Betriebsverhalten der jeweiligen Gasturbine modellieren, zur Verfügung gestellt werden. Gleichung (2.6) beschreibt das Betriebsverhalten der Gasturbine in linearisierter Form und lautet in Matrixdarstellung

$$\Delta Y = \mathbf{J} \cdot \Delta X, \quad (2.7)$$

wobei \mathbf{J} die EKM darstellt. Die Vektoren ΔX und ΔY werden als Leistungsparameter- bzw. Messwertresiduen bezeichnet, da sie relative Abweichungen zu Referenzwerten darstellen. Wie bereits oben beschrieben, stellt die Gas-Pfad-Analyse eine Invertierung der Zusammenhänge aus Gleichung (2.2) bzw. (2.7) dar, d.h. die Abweichungen der Leistungsparameter sollen mit Hilfe der Abweichungen der Messwerte berechnet werden. In der linearisierten Form kann dies durch die Invertierung der EKM dargestellt werden,

$$\Delta X = \mathbf{J}^{-1} \cdot \Delta Y. \quad (2.8)$$

Dabei sind jedoch folgende Punkte zu beachten:

- » Die Inverse der EKM existiert nur, falls die EKM quadratisch ist und vollen Rang besitzt ^[82], d.h. falls die Anzahl der zur Verfügung stehenden Messgrößen (m) gleich der Anzahl der zu bestimmenden Leistungsparameter (n) ist und keine linearen Abhängigkeiten in den Zeilen der EKM vorliegen. Dies wird durch das Kriterium der Beobachtbarkeit beschrieben ^[98].
- » Gleichung (2.8) liefert keine exakte Lösung für das zugrunde liegende Problem, da sie auf einer Linearisierung beruht und damit Linearisierungsfehlern unterliegt.
- » Aufgrund der Unvollkommenheit der Messeinrichtungen sind die Messwerte fehlerbehaftet ^[60]. Darüber hinaus stellt eine Messung an einer diskreten Stelle im Ringraum nicht den Mittelwert dieser thermodynamischen Ebene dar, der für die Berechnung der Leistungsparameter herangezogen werden müsste. Hierdurch entstehen weitere Abweichungen.
- » Wird die EKM mit Hilfe eines Leistungsrechnungsprogramms bestimmt, so kommt es durch unvollkommene Modellierung der Gasturbine zu weiteren Ungenauigkeiten in der Analyse ^[88].

2.2.4 Zustandsschätzverfahren

Eine Zufallsgröße x lässt sich im Falle einer Normalverteilung durch die Gauß'sche Wahrscheinlichkeitsdichtefunktion (pdf, *probability density function*)

$$\text{pdf}(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot \exp\left(-\frac{1}{2} \cdot \left(\frac{x - \mu}{\sigma}\right)^2\right) \quad (2.9)$$

beschreiben, wobei μ den Mittelwert und σ die Standardabweichung darstellt. Werden m voneinander unabhängige Messungen y_i zur Bestimmung von m tat-

sächlichen Größen μ_i durchgeführt, so beträgt nach dem Multiplikationsgesetz der Wahrscheinlichkeitsrechnung die Wahrscheinlichkeit, dass die gesuchten Größen μ_i innerhalb der differentiellen Intervalle der Breite dy_i um y_i liegen

$$P = \frac{1}{(\sqrt{2\pi})^m} \cdot \sum_{i=1}^m \frac{1}{\sigma_i} \exp\left(-\frac{1}{2} \cdot \sum_{i=1}^m \left(\frac{y_i - \mu_i}{\sigma_i}\right)^2\right) \cdot \prod_{i=1}^m dy_i . \quad (2.10)$$

Dabei wird

$$L = \frac{1}{(\sqrt{2\pi})^m} \cdot \sum_{i=1}^m \frac{1}{\sigma_i} \exp\left(-\frac{1}{2} \cdot S\right) \quad \text{mit} \quad S = \sum_{i=1}^m \left(\frac{y_i - \mu_i}{\sigma_i}\right)^2 \quad (2.11)$$

als Likelihood-Funktion und S als Summe der Fehlerquadrate bezeichnet. Die wahrscheinlichsten Werte μ_i für die gesuchten Größen ergeben sich, wenn die Wahrscheinlichkeit P maximal wird. Dafür muss die Likelihood-Funktion maximal und damit die Summe der Fehlerquadrate minimal werden, d.h.

$$S = \sum_{i=1}^m \left(\frac{y_i - \mu_i}{\sigma_i}\right)^2 \rightarrow \min \quad (2.12)$$

Die Anwendung dieser statistischen Zusammenhänge auf die lineare Gas-Pfad-Analyse führt auf die folgenden Zustandsschätzer:

Least-Squares-Schätzer (LS-Schätzer):

$$\Delta X = (\mathbf{J}^T \mathbf{J})^{-1} \mathbf{J}^T \cdot \Delta Y \quad (2.13)$$

Weighted-Least-Squares-Schätzer (WLS-Schätzer):

$$\Delta X = (\mathbf{J}^T \mathbf{G}_Y \mathbf{J})^{-1} \cdot \mathbf{J}^T \mathbf{G}_Y \cdot \Delta Y \quad (2.14)$$

Extended-Weighted-Least-Squares-Schätzer (EWLS-Schätzer):

$$\Delta X = \Delta X_0 + (\mathbf{J}^T \mathbf{G}_Y \mathbf{J} + \mathbf{G}_X)^{-1} \cdot \mathbf{J}^T \mathbf{G}_Y \cdot (\Delta Y - \mathbf{J} \cdot \Delta X_0) \quad (2.15)$$

Liegen über einen zu beobachtenden stationären Zustand mehrere Messungen vor, so kann der EWLS-Schätzer rekursiv angewendet werden um die Schätzung zu verbessern. Dies geschieht durch die Filterung des Messrauschens durch Mittelwertbildung und durch die rekursive Startwertverwendung. Für den rekursiven Extended-Weighted-Least-Squares-Schätzer (REWLS-Schätzer) gilt:

$$\Delta X_k = \Delta X_{k-1} + (\mathbf{J}^T \mathbf{G}_Y \mathbf{J} + \mathbf{G}_X)^{-1} \cdot \mathbf{J}^T \mathbf{G}_Y \cdot \left(\frac{1}{k} \sum_{j=1}^k \Delta Y_j - \mathbf{J} \cdot \Delta X_{k-1} \right) \quad (2.16)$$

Eine vollständige Übersicht einschließlich einer ausführlichen Herleitung ist bei Roesnick ^[98] sowie bei Köhli und Lipowsky ^[58] zu finden.

Der LS-Schätzer ist nur für den überbestimmten Fall ($m > n$) anwendbar, da im unterbestimmten Fall ($m < n$) die Inverse $(\mathbf{J}^T \mathbf{J})^{-1}$ nicht existiert ^[98]. Im bestimmten Fall ($m = n$) geht Gleichung (2.13) in Gleichung (2.8) über. Der WLS-Schätzer stellt eine Erweiterung des LS-Schätzers dar. Durch die Einführung einer Gewichtungsmatrix \mathbf{G}_Y ist es möglich, unterschiedliche Messwertstreuungen zu berücksichtigen. Wird als Gewichtungsmatrix die Inverse der Kovarianzmatrix der Messwerte verwendet, spricht man vom Gauß-Markov-Schätzer. Sind die Messwertstreuungen normalverteilt und voneinander unabhängig, so lässt sich die Kovarianzmatrix der Messwerte darstellen als

$$\mathbf{R}_Y = \text{cov}(\Delta Y, \Delta Y) = \begin{pmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & & \vdots \\ \vdots & & \ddots & 0 \\ 0 & \dots & 0 & \sigma_m^2 \end{pmatrix} = \mathbf{G}_Y^{-1}, \quad (2.17)$$

wobei σ_1 bis σ_m die Standardabweichungen der Messwerte bezeichnen. Je höher die Standardabweichung eines Messwertes ist, desto geringer ist demnach seine Gewichtung. Der WLS-Schätzer ist, wie der LS-Schätzer, nur auf überbestimmte Systeme ($m > n$) anwendbar.

Der EWLS-Schätzer erweitert den WLS-Schätzer um einen Schätzwert ΔX_0 für den Zustand der Gasturbine und eine Verstärkungsmatrix \mathbf{G}_X , die im Fall von unkorrelierten Leistungsparametern gleich einem Vielfachen der Einheitsmatrix gesetzt werden kann:

$$\mathbf{G}_X = C_1 \cdot \mathbf{I} \quad (2.18)$$

Der entsprechend zu wählende Faktor C_1 bestimmt das Maß des dämpfenden bzw. verstärkenden Einflusses von \mathbf{G}_X . Der EWLS-Schätzer wird dadurch für unterbestimmte Systeme anwendbar, falls der Ausdruck $(\mathbf{J}^T \mathbf{G}_Y \mathbf{J})$ durch die Addition der a priori Information über den Zustand regulär wird, d.h. falls der Ausdruck $(\mathbf{J}^T \mathbf{G}_Y \mathbf{J} + \mathbf{G}_X)$ den Rang n besitzt und damit invertierbar wird ^[98].

Abschließend bleibt festzuhalten, dass alle Zustandsschätzverfahren dem so genannten Verschmiereffekt unterliegen, d.h. sie verteilen die vorhandene Abweichung auf mehrere Leistungsparameter. Die Ursache hierfür liegt in der Minimierung der Fehlerquadrate. Durch diese Minimierung werden Lösungen begünstigt, bei denen möglichst viele Leistungsparameter von ihrem Referenzwert abweichen (siehe Doel ^[28]). Obwohl dies bei alterungsbedingten Verschlechterungen zu sinn-

vollen Lösungen führt, entstehen im Fall eines Einzelfehlers, bei dem nur wenige Leistungsparameter einer Veränderung unterworfen sind, erhebliche Abweichungen zwischen der gefundenen und der wahren Lösung.

2.2.5 Der Kalman Filter

Der Kalman Filter geht auf eine Veröffentlichung von R.E. Kalman ^[51] aus dem Jahr 1960 zurück und wurde seitdem in einer Vielzahl von Veröffentlichungen beschrieben. Eine Einführung über die Idee des Kalman Filters ist bei Welch und Bishop ^[136] zu finden. Der Kalman Filter ist ein rekursiver Algorithmus zur Zustandsschätzung dynamischer (und damit auch stationärer) Systeme. Er liefert in Bezug auf die Minimierung der Varianz des geschätzten Fehlers optimale Schätzwerte für den Systemzustand.

Das zu beobachtende System wird durch folgende Gleichungen beschrieben:

$$\Delta X_k = \mathbf{A} \cdot \Delta X_{k-1} + \mathbf{B} \cdot U_{k-1} + W_{k-1} \quad \text{mit} \quad p(W) \sim N(0, \mathbf{Q}) \quad (2.19)$$

$$\Delta Y_k = \mathbf{J} \cdot \Delta X_k + V_k \quad \text{mit} \quad p(V) \sim N(0, \mathbf{R}) \quad (2.20)$$

Dabei bezeichnet ΔX den Zustandsvektor, ΔY den Messwertvektor, U den Vektor der Betriebsparameter, W den Vektor der Messunsicherheit mit der Varianz \mathbf{Q} und V den Vektor der Prozessunsicherheit mit der Varianz \mathbf{R} . Die Indizes k und $k-1$ beziehen sich auf den aktuellen sowie den vorhergehenden Zeitpunkt. Die Matrix \mathbf{A} wird als Dynamikmatrix, \mathbf{B} als Steuermatrix und \mathbf{J} als Systemmatrix bezeichnet.

Mit Hilfe des Kalman Filters erfolgt in einem ersten Schritt die Schätzung des Zustandes zum Zeitpunkt k auf Basis der Informationen zum Zeitpunkt $k-1$. Dieser Schritt wird Prediktor oder auch Zeit-Update genannt. Die Schätzung wird anschließend mit Hilfe der Messungen des Zeitpunkts k korrigiert. Dieser Schritt wird Korrektor oder Messwert-Update genannt. Die Gleichungen des diskreten Kalman Filters lauten:

Zeit-Update (Prediktor):

$$\Delta X_k^* = \mathbf{A} \cdot \Delta X_{k-1} + \mathbf{B} \cdot U_{k-1} \quad (2.21)$$

$$\mathbf{P}_k^* = \mathbf{A} \cdot \mathbf{P}_{k-1} \cdot \mathbf{A} + \mathbf{G}_x \quad (2.22)$$

Messwert-Update (Korrektor):

$$\mathbf{G}_k = \mathbf{P}_k^* \mathbf{J}^T \cdot \left(\mathbf{J} \mathbf{P}_k^* \mathbf{J}^T + \mathbf{G}_y^{-1} \right)^{-1} \quad (2.23)$$

$$\Delta \mathbf{X}_k = \Delta \mathbf{X}_k^* + \mathbf{G}_k \cdot \left(\Delta Y_k - \mathbf{J} \cdot \Delta \mathbf{X}_k^* \right) \quad (2.24)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{G}_k \mathbf{J}) \cdot \mathbf{P}_k^* \quad (2.25)$$

Die Matrix \mathbf{P} stellt die Kovarianz dar, die Matrix \mathbf{G} wird als Kalman-Verstärkungsmatrix (engl. Kalman Gain) bezeichnet. Im Falle eines stationären Systems ist die Dynamikmatrix \mathbf{A} gleich der Einheitsmatrix und die Steuermatrix \mathbf{B} gleich 0, so dass die Prediktor-Gleichung (2.21) entfällt. Der Kalman Filter entspricht in diesem Fall dem REWLS-Schätzer (siehe Roesnick ^[98]). Vereinfacht ausgedrückt sind der Kalman Filter und der REWLS-Schätzer in der Lage, einen Schätzwert für den stationären Zustand eines Systems durch die rekursive Auswertung einer Messreihe zu verbessern.

Der erweiterte Kalman Filter ermöglicht die Anwendung des Kalman Filters auf nichtlineare Probleme, die durch Gleichungen der Form

$$\mathbf{X}_k = f_1(\mathbf{X}_{k-1}, \mathbf{U}_{k-1}, \mathbf{W}_{k-1}) \quad (2.26)$$

$$\mathbf{Y}_k = f_2(\mathbf{X}_k, \mathbf{V}_{k-1}) \quad (2.27)$$

beschrieben werden. Dabei wird eine lokale Linearisierung des Problems zu jedem Zeitschritt durchgeführt. Die Gleichungen des erweiterten Kalman Filters entsprechen in ihrem Aufbau den Gleichungen (2.21) bis (2.25) und sind bei Welch und Bishop ^[136] zu finden. Es sei erwähnt, dass auch der Kalman Filter dem Verschmiereffekt unterliegt (siehe Abschnitt 2.2.4).

Kobayashi und Simon ^[55] wenden eine Reihe von mehreren Kalman Filtern für die Erkennung von Sensorfehlfunktionen an. Hierbei sind die verschiedenen Filter auf unterschiedliche Fehlerhypothesen ausgelegt, wobei im Falle einer Sensorfehlfunktion jeweils nur der entsprechend für diesen Fall ausgelegte Kalman Filter die nominalen Werte der Leistungsparameter produziert. Wird keine Sensorfehlfunktion erkannt, so wird ein weiterer Kalman Filter für die Aufgabe der Diagnose eingesetzt.

2.2.6 Kombinatorische Ansätze

Die Problematik des Verschmiereffektes, der bei den Zustandsschätzverfahren und dem Kalman Filter zum Tragen kommt, kann bei der Betrachtung von Ein-

zelereignissen durch die folgenden Überlegungen überwunden werden. Es kann angenommen werden, dass Einzelereignisse nur wenige Komponenten betreffen. Basierend auf dieser Annahme können aus dem unterbestimmten System bestimmte oder überbestimmte Systeme abgeleitet werden. Die Idee der kombinatorischen Ansätze besteht darin, alle möglichen Kombinationen von bestimmten oder überbestimmten Systemen zu betrachten, da i.d.R. keine Informationen darüber vorliegen, welche Leistungsparameter von dem Ereignis betroffen sind. Die Ergebnisse werden anschließend mit Hilfe eines geeigneten Kriteriums bewertet, um aus der Vielzahl der möglichen Ergebnisse die wahrscheinlichste Lösung zu ermitteln. Ein derartiges Kriterium stellt der von Aretakis et al. ^[2] eingeführte Diagnostische Index dar:

$$DI_i = \frac{|\overline{\Delta X_i}|}{\sigma_{\Delta X_i}} \quad \text{mit} \quad \overline{\Delta X_i} = \frac{1}{k} \sum_{j=1}^k \Delta X_i^j. \quad (2.28)$$

Dabei bezeichnet $\overline{\Delta X_i}$ den Mittelwert der i-ten Leistungsparameterabweichung über alle k relevanten Kombinationen und $\sigma_{\Delta X_i}$ dessen Standardabweichung. Ist ein Leistungsparameter von dem Fehler betroffen, so wird seine Abweichung über eine Vielzahl von Kombinationen mit $\Delta X_i^k \neq 0$ diagnostiziert werden. Parameter, die eine geringe Standardabweichung aufweisen, werden zusätzlich höher bewertet. Parameter, die einen hohen DI aufweisen, werden als fehlerbehaftet identifiziert. Aretakis et al. ^[2] zeigen anhand mehrerer Beispiele, dass ins Besondere der Leistungsparameter mit der größten Abweichung korrekt identifiziert werden kann. Nagy ^[84] wendet die von Aretakis et al. ^[2] vorgeschlagene Methode an und erlangt vergleichbare Ergebnisse.

2.2.7 Die nichtlineare Gas-Pfad-Analyse

Alle bisher betrachteten Verfahren basieren auf Linearisierungen des Triebwerksverhaltens und unterliegen dadurch Linearisierungsfehlern. Um Linearisierungsfehler zu vermeiden, kann Gleichung (2.1) bei gegebenen Betriebsbedingungen U und gegebenen Messwerten Y iterativ nach X gelöst werden. Um diese nichtlineare Art der Gas-Pfad-Analyse durchführen zu können, muss die Funktion f in Form eines numerischen Zusammenhangs vorliegen. Der Ablauf der Iteration ist in Bild 2.2 dargestellt.




Bild 2.2: Ablauf der nichtlinearen Gas-Pfad-Analyse mit Hilfe von Leistungsrechnungsprogrammen

Die Leistungsparameter X werden solange in entsprechender Weise verändert, bis die vom Leistungsrechnungsprogramm berechneten Erwartungswerte Y_E mit den Messwerten Y_M übereinstimmen bzw. die Differenz unter einer geforderten Iterationsgenauigkeit liegt. Dabei kommen numerische Iterationsverfahren, wie z.B. das Newton-Raphson-Verfahren zum Einsatz, um die Differenz zwischen den Erwartungswerten und den Messwerten zu minimieren^[83]. Die zu minimierende Zielfunktion lautet in diesem Fall

$$ZF_1 = \sum_{i=1}^m \left(\frac{\Delta Y_i}{a_i} \right)^2 \quad \text{mit} \quad \Delta Y_i = \frac{Y_{E,i} - Y_{M,i}}{Y_{M,i}} \quad (2.29)$$

wobei die Faktoren a_i eine Gewichtung der Messwerte zulassen. Eine detaillierte Beschreibung dieses als ANSYN (Analyse durch Synthese) bezeichneten Verfahrens ist bei Bauer^[5,6] zu finden. Visser et al.^[126] beschreiben die Implementierung dieses Verfahrens in das Leistungsrechnungsprogramm GSP. Zur Minimierung der Zielfunktion kommt ein Newton-Raphson-Verfahren zum Einsatz.

Inan et al.^[47] beschreiben ebenfalls ein System, das nach dem in Bild 2.2 dargestellten Konzept arbeitet und eine Zielfunktion in der Form von ZF_1 minimiert. Als Optimierungsalgorithmus wird allerdings kein Newton-Verfahren, sondern das Simplex-Verfahren nach Nelder und Mead^[86] angewendet. Das beschriebene System berücksichtigt Mess- und Modellierungsfehler durch die Anwendung von entsprechenden Referenzwerten für das jeweilige individuelle Triebwerk.

In der oben beschriebenen Form ist dieses Verfahren allerdings nur für bestimmte und beobachtbare Systeme anwendbar, d.h. die Anzahl der Messwerte (m) muss

mit der Anzahl der Leistungsparameter (n) übereinstimmen und das Kriterium der Beobachtbarkeit muss erfüllt sein.

2.2.8 Nichtlineare Optimierung

Im unterbestimmten Fall besitzt Gleichung (2.29) unendlich viele Lösungen. Um die nichtlineare Gas-Pfad-Analyse auch in diesem Fall anwenden zu können, bedarf es einer Erweiterung der Zielfunktion, die auf zusätzlichen Informationen und Zusammenhängen, Erfahrungen oder begründeten Annahmen basieren kann. Beispiele hierfür sind ^[78]:

- » Die Wirkungsgrade aller Komponenten, sowie die Durchsätze der Verdichter können sich nur verschlechtern, nicht verbessern.
- » Die Veränderungen der Leistungsparameter sind auf bestimmte Bereiche begrenzt, die durch den Betriebsbereich der Gasturbine festgelegt sind.
- » Die relative Abhängigkeit der Parameter einer Komponente ist bekannt, oder zumindest auf einen gewissen Bereich einzugrenzen.
- » Im Falle von alterungsbedingter Verschlechterung sind die Inkremente der Leistungsparameterveränderungen minimal oder zumindest auf einen bestimmten Bereich beschränkt.
- » Im Falle von Einzelereignissen ist die Anzahl der betroffenen Komponenten beschränkt, d.h. nicht alle Komponenten weisen in diesem Fall veränderte Leistungsparameter auf.
- » Aufgrund weiterer zur Verfügung stehender Informationen (z.B. visuelle Inspektionen) kann für bestimmte Komponenten eine Veränderung der Leistungsparameter ausgeschlossen werden.

Eine allgemeingültige Form der erweiterten Zielfunktion lautet

$$ZF_2 = \sum_{i=1}^m \left(\frac{\Delta Y_i}{a_i} \right)^2 + C_1 \cdot \sum_{i=1}^n \left(\frac{\Delta X_i^k - \Delta X_i^{k-1}}{b_i \cdot \Delta X_i^{k-1}} \right)^2 + C_2 \cdot \sum_{i=1}^n \left| \frac{\Delta X_i^k - \Delta X_i^{k-1}}{c_i \cdot \Delta X_i^{k-1}} \right| \quad (2.30)$$

mit den Definitionen

$$\Delta X_i = \frac{X_i - X_{\text{ref},i}}{X_{\text{ref},i}} \quad \text{und} \quad \Delta Y_i = \frac{Y_{E,i} - Y_{M,i}}{Y_{M,i}}. \quad (2.31)$$

Der Index k bezeichnet den betrachteten Zeitschritt, während die Parameter a_i , b_i , c_i , C_1 und C_2 zur Gewichtung der jeweiligen Elemente dienen. Der letzte Term

der Gleichung (2.30) dient der Erhöhung der numerischen Robustheit, was von Grodent und Navez ^[42] gezeigt wurde. Unter Berücksichtigung der oben genannten Zusatzinformationen können folgende Nebenbedingungen definiert werden, die bei der Minimierung der Zielfunktion ZF_2 eingehalten werden müssen:

$$lb_i < \Delta X_i < 0 \quad \text{für die Wirkungsgrade } \Delta\eta \text{ aller Komponenten} \quad (2.32)$$

$$lb_i < \Delta X_i < 0 \quad \text{für die Durchsätze } \Delta w \text{ aller Verdichter} \quad (2.33)$$

$$lb_i < \Delta X_i < ub_i \quad \text{für alle übrigen Leistungsparameter} \quad (2.34)$$

$$\Delta X_i^{k-1} - \varepsilon_i < \Delta X_i^k < \Delta X_i^{k-1} + \varepsilon_i \quad \text{für alle Leistungsparameter} \quad (2.35)$$

Um die Zielfunktion ZF_2 unter der Berücksichtigung derartiger Nebenbedingungen zu minimieren, bedarf es dem Einsatz von Verfahren der nichtlinearen Optimierung. Da es sich bei den Nebenbedingungen aus Gleichung (2.32) bis (2.35) um Ungleichungsnebenbedingungen handelt, kommen für diese Aufgabe nur Verfahren in Betracht, die in der Lage sind, die folgende Aufgabe zu lösen:

$$\begin{aligned} &\text{Minimiere die Zielfunktion } ZF(x) \text{ bzgl. } x \\ &\text{unter den Nebenbedingungen} \\ &g_i(x) = 0 \quad \text{für } 1 \leq i \leq m_e \\ &g_i(x) \geq 0 \quad \text{für } m_e \leq i \leq m \end{aligned} \quad (2.36)$$

Diese Aufgabenstellung wird als nichtlineares Parameteroptimierungsproblem bezeichnet. Als eines der wichtigsten und verbreitetsten Verfahren für die Lösung dieser Aufgabe nennen Grimm und Well ^[41] die Sequentielle Quadratische Programmierung (SQP), die das ursprüngliche Problem (2.36) in jedem Schritt der Optimierung durch ein quadratisches Problem ersetzt, dessen Lösung die Suchrichtung darstellt. Damit stellt das SQP-Verfahren eine Verallgemeinerung des Newton-Verfahrens für nichtlineare Gleichungssysteme dar. Weiterführende Informationen sind bei Grimm und Well ^[41] zu finden.

Mathioudakis et al. ^[77] beschreiben ein Verfahren zur Minimierung einer erweiterten Zielfunktion der Form (2.30) zur Lösung unterbestimmter Probleme ($m < n$). Es werden jedoch keine Zahlen für die Gewichtungsfaktoren C_1 und C_2 genannt, von denen die Lösung maßgeblich abhängt. Darüber hinaus ist nicht erwähnt, welcher Optimierungsalgorithmus zur Minimierung verwendet wird.

Kamboukos et al. ^[52] vergleichen die Konvergenzgeschwindigkeiten verschiedener Algorithmen, darunter der Simplex Algorithmus, das CG-Verfahren, die Levenberg-Marquardt-Methode und das SQP-Verfahren. Die schnellste Konvergenz erreichen das SQP-Verfahren und die Levenberg-Marquardt-Methode, das CG-

Verfahren und der Simplex Algorithmus liegen weniger als eine Größenordnung dahinter.

Roth et al. ^[100] vergleichen zwei weitere Zielfunktionen mit der Zielfunktion der kleinsten Fehlerquadrate (ZF_1). Dies sind die Min-Max-Funktion, die nur den besten und den schlechtesten Fall abdeckt, und die Summe der Fehlerbeträge. Um unterbestimmte Systeme betrachten zu können, führen sie entsprechend Gleichung (2.30) zusätzliche Terme in die Zielfunktion ein. In einer späteren Veröffentlichung erläutern sie die Einbindung der entwickelten Methode in das Leistungsrechnungsprogramm NPSS ^[101].

Es ist anzumerken, dass Verfahren der nichtlinearen Optimierung lediglich in der Lage sind, lokale Minima zu finden, d.h. Punkte, die nur in einer bestimmten Umgebung ein Minimum darstellen. Die Lösung dieser Verfahren hängt demnach vom gewählten Startpunkt ab. Bei alterungsbedingten Verschlechterung stellt jeweils die Lösung des vorherigen Zeitschrittes einen sinnvollen Startwert dar.

2.2.9 Mehrpunkt-Verfahren

Eine weitere Möglichkeit unterbestimmte Systeme zu lösen liegt in der Analyse mehrerer Betriebspunkte. Hierbei wird die Nichtlinearität des Betriebverhaltens ausgenutzt. Liegen die betrachteten Betriebspunkte ausreichend weit voneinander entfernt, so sind die Abhängigkeiten zwischen den Leistungsparametern und den Messwerten der Gasturbine (Einflusskoeffizienten) in den verschiedenen Betriebspunkten unterschiedlich. Durch diese zusätzlichen Informationen kann es gelingen, die Beobachtbarkeit des Systems herzustellen (Grönstedt ^[45]). In der Literatur sind Mehrpunkt-Verfahren bei Stamatis et al. ^[114], Grönstedt ^[44], Gulati et al. ^[46], Skölde et al. ^[111] und Loboda et al. ^[71] zu finden.

Ein Kritikpunkt ist, dass die Mehrpunkt-Analyse auf der Annahme basiert, dass die relativen Veränderungen der Leistungsparameter in verschiedenen Betriebspunkten identisch sind (Roesnick ^[98]). Dies muss aufgrund der Nichtlinearität des Betriebverhaltens nicht gewährleistet sein. Wird die Variation des Betriebspunktes auf einen Bereich beschränkt, in dem diese Annahme gerechtfertigt ist, so sinkt der Gewinn an Beobachtbarkeit, da auch die nichtlinearen Einflüsse auf die Einflusskoeffizienten geringer ausfallen.

2.2.10 Evolutionäre Algorithmen

Die Startpunktabhängigkeit der (deterministischen) Verfahren der Nichtlinearen Optimierung und damit die Einschränkung, nur lokale Minima zu finden, kann mit evolutionären Algorithmen überwunden werden. Evolutionäre Algorithmen orientieren sich am Vorbild der natürlichen Evolution, die ins Besondere durch die Arbeiten von Charles Darwin bekannt wurde. Grundlage sind die folgenden drei Prinzipien ^[69]:

- » Selektion
- » Rekombination
- » Mutation

Die Selektion beschreibt die Auswahl der besten Individuen einer Generation. Die »Güte« eines Individuums wird durch die so genannte Fitnessfunktion definiert. Bezüglich der Anwendung zur Gasturbinendiagnose stellt eine allgemeine Zielfunktion der Form ZF_2 eine derartige Fitnessfunktion dar. Ein Individuum entspricht in diesem Fall einem Leistungsparametervektor ΔX . Die Rekombination beschreibt den Austausch von Eigenschaften zwischen Individuen einer Generation. Dieser Austausch findet zufällig statt und stellt ein ungerichtetes Element des Algorithmus dar. Die Mutation schließlich sorgt durch zufällige Generierung neuer Eigenschaften für ein weiteres ungerichtetes Element. Diese ungerichteten Elemente befähigen evolutionäre Algorithmen globale Minima zu finden und nicht in lokalen Minima zu verharren. Der grundlegende Ablauf eines evolutionären Algorithmus bestehend aus Selektion, Rekombination und Mutation ist in Bild 2.3 dargestellt.




Bild 2.3: Prinzipieller Ablauf eines evolutionären Algorithmus

Neben der Fähigkeit, globale Minima aufzufinden, sind evolutionäre Algorithmen deterministischen Algorithmen überlegen falls die Zielfunktion nicht stetig, nicht

differenzierbar, stochastisch oder hochgradig nichtlinear ist. Ihr Nachteil liegt dagegen in der Zeitaufwändigkeit ihrer Durchführung. Die am häufigsten angewendete Variante der evolutionären Algorithmen stellt der Genetische Algorithmus (GA) dar. Weiterführende Informationen zur programmtechnischen Umsetzung genetischer Algorithmen sowie zu weiteren Varianten evolutionärer Algorithmen sind bei Lippe ^[69] zu finden.

Kamboukos et al. ^[52] führen einen Vergleich der Konvergenzgeschwindigkeiten verschiedener Algorithmen durch, in dem der Nachteil der Genetischen Algorithmen gegenüber den deterministischen Verfahren deutlich wird. Die Konvergenzgeschwindigkeit des Genetischen Algorithmus liegt bei den Untersuchungen mehr als vier Größenordnungen über der des SQP-Verfahrens.

Zedda und Singh ^[143] beschreiben die Anwendung eines Genetischen Algorithmus zur Diagnose überbestimmter Systeme, wie sie im Fall von Triebwerkstests in der Entwicklungsphase vorhanden sind. Aufgrund der hohen Messwertredundanz ist eine Diagnose auch bei einem Ausfall mehrerer Messsensoren möglich.

Eine häufige Einsatzweise Genetischer Algorithmen ist ihre Anwendung in Verbindung mit deterministischen Optimierverfahren. Hierbei wird der GA zur Startwertsuche für das nachgeschaltete deterministische Optimierverfahren verwendet. Dadurch soll erreicht werden, dass der Startwert für die deterministische Optimierung bereits in der Umgebung des globalen Minimums liegt. Die eigentliche Zielwertsuche kann anschließend mit dem deterministischen Optimierverfahren schneller durchgeführt werden als mit dem Genetischen Algorithmus. Beispiele zu dieser Art der Anwendung sind in Abschnitt 2.4 zu finden.

2.3 Datenbasierte ECM Verfahren

2.3.1 Neuronale Netze

Künstliche Neuronale Netze (KNN) basieren auf der Informationsverarbeitung biologischer neuronaler Netze, wie z.B. dem menschlichen Gehirn. Wie ihre biologischen Vorbilder sind KNN in der Lage, aus der Präsentation von Beispieldaten zu lernen und das gelernte Wissen auf unbekannte Daten anzuwenden. Die Informationsverarbeitung geschieht mit Hilfe von Neuronen (modellierten Nervenzellen). Die erste mathematische Beschreibung eines künstlichen Neurons wurde

1943 von McCulloch und Pitts ^[81] gegeben. Sie definieren ein Neuron als logisches Schwellwertelement mit zwei möglichen Zuständen, aktiv und inaktiv. Der allgemeine Aufbau eines künstlichen Neurons ist in Bild 2.4 (rechts) dargestellt. Die Werte der Eingänge werden mit Gewichtungsfaktoren versehen und der Propagierungsfunktion G zugeführt. Die Propagierungsfunktion berechnet daraus einen effektiven Eingangswert net . In der einfachsten Form gilt für die Propagierungsfunktion

$$net = \sum_{i=1}^k w_i e_i . \quad (2.37)$$

Aus dem effektiven Eingang wird mit Hilfe der Aktivierungsfunktion F der Ausgabewert des Neurons berechnet. Bei McCulloch und Pitts ist die Aktivierungsfunktion eine binäre Sprungfunktion der Form

$$a = 1 \text{ für } net > \theta, \text{ sonst } a = 0, \quad (2.38)$$

wobei θ den Schwellwert darstellt. Weitere gängige Aktivierungsfunktionen sind die Identität, die hyperbolische Tangensfunktion sowie die Sigmoidfunktion ^[69].




Bild 2.4: Aufbau eines dreischichtigen Neuronales Netzes (links) und Details eines künstlichen Neurons (rechts)

Ein KNN besteht aus einer Vielzahl künstlicher Neuronen, die auf unterschiedliche Weise miteinander verbunden sind. Es wird zwischen Feedforward-Netzen und Feedback-Netzen unterschieden. Bei Feedforward-Netzen verlaufen die Verbindungen zwischen Neuronen ausschließlich in Richtung der Ausgangsschicht, bei Feedback-Netzen gibt es auch rückkoppelnde Verbindungen in Richtung der Eingangsschicht. In Bild 2.4 (links) ist exemplarisch ein dreischichtiges KNN mit zwei Rückkopplungen dargestellt. Netze, die aus mehreren Schichten aufgebaut sind werden als MLP bezeichnet (*Multi Layer Perceptron*). Laut Sampath und

Singh ^[107] verwenden 85% der Anwendungen im Bereich der Gasturbinendiagnose Netze dieser Topologie. Eine Übersicht über weitere Netztopologien ist bei Lippe ^[69] zu finden.

Eine entscheidende Eigenschaft von Neuronalen Netzen ist ihre Lernfähigkeit. Bei KNN besteht der Lernvorgang in der Anpassung der Gewichte der Neuronen. Ein optimal trainiertes KNN erzeugt für alle Beispielausgaben Ausgaben, deren Abweichungen zu den Beispielausgaben minimal ist. Eine Übersicht über wichtige Lernalgorithmen liefert Joos ^[50]. Die mathematischen Herleitung der Algorithmen ist bei Rigoll ^[96] sowie bei Rittel et al. ^[97] zu finden. Neben der Lernfähigkeit verfügen KNN über folgende weitere Vorteile:

- » Schnelligkeit der Rechenoperationen durch hohe Parallelisierung
- » Adaptivität durch die Möglichkeit des ständigen Lernens
- » Hohe Robustheit gegenüber fehlerhaften Daten
- » Klassifizierungsfähigkeit durch entsprechendes Training
- » Generalisierungsfähigkeit durch entsprechendes Training

Allerdings birgt ein KNN auch folgende Gefahren, bzw. Nachteile:

- » Black-Box-Charakter: Es ist nicht möglich, analytisch nachzuvollziehen, wie ein KNN aus einer Eingabe eine entsprechende Ausgabe generiert. Diese Information ist lediglich in Form der Gewichte gespeichert.
- » Trainingsaufwand: Ein KNN ist nur dann in der Lage, korrekte Ausgaben zu generieren, wenn die Eingabedaten innerhalb des trainierten Bereichs liegen. Der in Frage kommende Bereich muss daher möglichst vollständig während der Lernphase abgedeckt werden. Dabei muss berücksichtigt werden, dass eine zu hohe Auflösung des Trainingsgebietes die Fähigkeit der Generalisierung negativ beeinflusst, d.h. das KNN »lernt die Trainingsdaten auswendig« anstatt die Zusammenhänge zwischen Eingaben und Ausgaben zu generalisieren. Für die Auswahl der Trainingsdaten muss ein Optimum zwischen den Anforderungen Genauigkeit und Generalisierung gefunden werden.
- » Vorfilter: Bei der Verwendung eines MLP ist im Besonderen darauf zu achten, dass Ausgaben auch dann generiert werden, wenn die Eingangsdaten nicht im Bereich der Trainingsdaten liegen. Es bedarf eines vorgeschalteten Systems, um die Eingangsdaten auf Plausibilität zu überprüfen.

Eine besondere Form eines KNN stellt das so genannte Radial-Basisfunktions-Netzwerk (RBFN) dar. Die Topologie entspricht derjenigen aus Bild 2.4 (links). Die Neuronen der Eingangsschicht verfügen jedoch über radialsymmetrische

Aktivierungsfunktionen, z.B. Gauß'sche Wahrscheinlichkeitsdichtefunktionen nach Gleichung (2.9). Dadurch wird erreicht, dass der Wert des Ausgabe mit steigendem Abstand der Eingabe vom Trainingsbereich gegen Null geht. Eingabemuster, die nicht im Bereich der Trainingsdaten liegen, werden dadurch erkannt. Anwendungen von RBFN im Bereich der Gasturbinendiagnose sind bei Brotherton und Johnson ^[14] sowie bei Gansel ^[40] und Ganguli ^[39] zu finden. Brotherton und Johnson verwenden ein RBFN zur Erkennung von Anomalien, während Gansel und Ganguli RBFN für die Detektion von Einzelereignissen anwenden.

Mathioudakis und Romessis ^[79] beschreiben die Anwendung eines MLP zur Erkennung von Sensorfehlern. Das Netz wird dabei mit Hilfe eines Leistungsrechnungsprogramms trainiert und anschließend an einer Vielzahl von generischen Testfällen validiert. Romessis und Mathioudakis ^[99] präsentieren des Weiteren ein System, das ein Bayesian-Belief-Netzwerk (BBN) anwendet. Bei einem BBN handelt es sich um eine probabilistische Form eines KNN, das in der Lage ist Fehlerwahrscheinlichkeiten anzugeben. Es wird ebenfalls mit Hilfe eines Leistungsrechnungsprogramms trainiert und wird für die Identifikation von Einzelfehlern eingesetzt.

Qiu et al. ^[95] wenden ein MLP zur Überwachung von Alterung an. Dabei treffen sie die Annahme, dass sich die relative Alterung der Komponenten in bestimmten (festen) Verhältnissen vollzieht. Zum Training des Neuronalen Netzes kommt ebenfalls ein Leistungsrechnungsprogramm zum Einsatz. Zukünftige Versionen des Systems sollen mit variablen Verhältnissen der Komponentenveränderungen arbeiten.

Joos ^[50] führt umfangreiche Untersuchungen zur Erstellung eines aus KNN bestehenden Diagnosesystems durch. Eines der wichtigsten Ergebnisse von Joos ist die Erkenntnis, dass die Diagnoseaufgabe nicht mit Hilfe eines einzigen allgemein trainierten KNN durchgeführt werden kann ^[50]. Vielmehr muss die Aufgabenstellung in Teilprobleme zerlegt werden, die von jeweils speziell trainierten KNN gelöst werden können. Joos schlägt hierfür den in Bild 2.5 dargestellten Berechnungsablauf vor. In einer ersten Ebene werden die Messdaten auf Sensorfehler überprüft und gegebenenfalls durch berechnete Werte ersetzt. Anschließend prüft ein weiteres KNN, ob das vorliegende Messwertmuster auf eine Abweichung $>1\%$ in mindestens einem Leistungsparameter hinweist. Bei positivem Ergebnis führt ein weiteres KNN die Identifikation der betroffenen Baugruppe durch, wobei die Komponenten der Gasturbine in die in Bild 2.5 dargestellten 4 Baugruppen zu-

sammengefasst werden. Die KNN der letzten Ebene führen dann die Berechnung der Abweichungen der identifizierten Leistungsparameter durch.

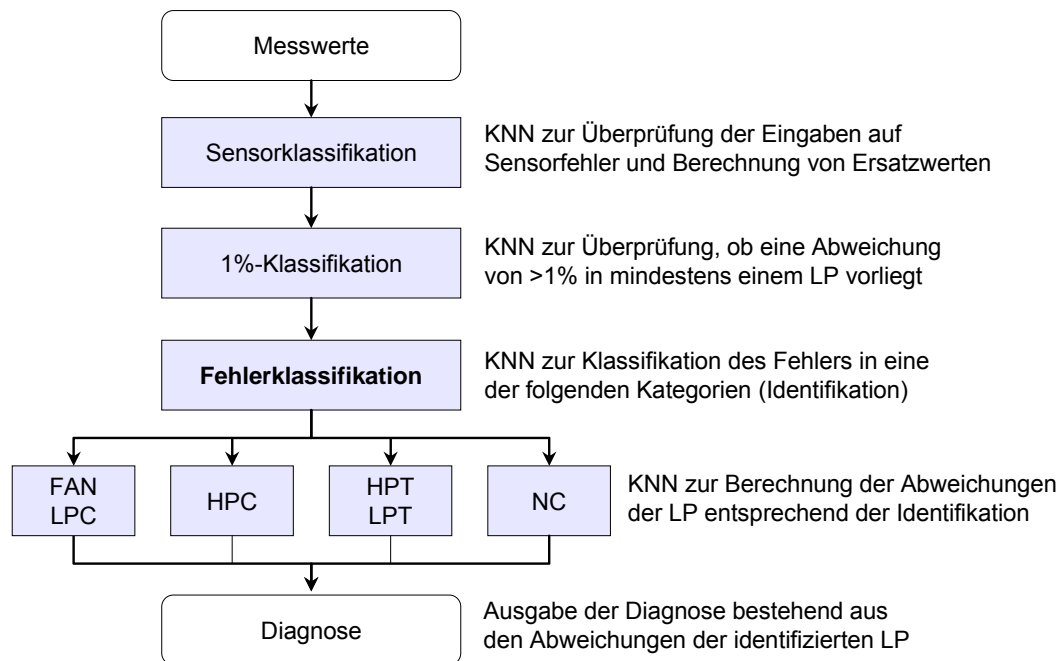


Bild 2.5: Flussdiagramm eines Systems mehrerer Neuronaler Netze zur Diagnose von Einzelfehlern (in Anlehnung an ^[50])

Das KNN »Fehlerklassifikation« übernimmt die Aufgabe der Identifikation und liefert damit ein Ergebnis, das dem Fuzzy Index des in Abschnitt 5.3 entwickelten Verfahrens entspricht. Es werden Identifikationsraten >98,6% erreicht, falls die zu untersuchenden Fehlerfälle die folgenden Bedingungen erfüllen:

- » Sie weisen eine Abweichung von mindestens 1% in mindestens einem LP auf.
- » Die Abweichungen sind jeweils auf eine der 4 definierten Baugruppen beschränkt.

Für den Fall dass die vorhandenen Abweichungen nicht auf eine der 4 Baugruppen beschränkt sind (Kombinationsfehler von Baugruppen), so ist mit dem entwickelten KNN System keine zuverlässige Identifikation und damit keine Diagnose möglich. Bereits für den Fall, dass Abweichungen von maximal 0,2% in weiteren Baugruppen auftreten, sinkt die Identifikationsrate auf unter 50%.

Darüber hinaus ist das Verhalten des Systems bei Fehlerfällen, die nicht im Bereich der Trainingsdaten liegen, nicht vorhersehbar. Die verwendeten Neuronalen Netze (Multi-Layer-Perceptronen-Netze) sind nicht in der Lage, das Auftreten derartiger Fehlerfälle zu erkennen und liefern eine fehlerhafte Diagnose ohne eine entsprechende Warnung auszugeben. Abhilfe für dieses Problems könnte der

Einsatz von RBF Netzen schaffen, die bei derartigen Fehlerfällen eine »Nullausgabe« generieren und damit das Auftreten von Eingabedaten außerhalb des Trainingsbereichs anzeigen.

2.3.2 Fuzzy Logic

Die Fuzzy Logic (unscharfe Logik) stellt eine Erweiterung der binären Logik dar. Im Gegensatz zur binären Logik, die nur die scharfen Wahrheitswerte *wahr* und *falsch* beinhaltet, bietet die Fuzzy Logic die Möglichkeit, unscharfe Mengen zu beschreiben. Ihre Ursprünge stammen aus dem Jahr 1965. Zadeh ^[142] beschreibt erstmals die mathematische Darstellung von linguistisch (somit unscharf) vorgegebenen Werten und liefert die Regeln für deren Verknüpfung. Ein berühmtes Zitat von Zadeh besagt, dass »die Fuzzy Logic die programmtechnische Umsetzung des gesunden Menschenverstandes darstellt.« Der grundlegende Aufbau eines Fuzzy Logic Systems (FLS) ist in Bild 2.6 dargestellt:




Bild 2.6: Elemente eines Fuzzy Logic Systems

Bei den Eingängen eines FLS handelt es sich um scharfe Werte verschiedener Parameter. Durch Regeln, die in einer Wenn-Dann-Form gegeben sind, wird eine Beziehung zwischen den Eingängen und den Ausgängen des Systems hergestellt. Die Eingangsdaten werden mit Hilfe von so genannten Zugehörigkeitsfunktionen, die die Eingangs- und Ausgangswerte kategorisieren, in unscharfe Werte umgewandelt (Fuzzifizierung). Häufig verwendete Zugehörigkeitsfunktionen sind Dreiecks-, Trapez-, Gauß- und Sigmoidfunktionen ^[9]. Anschließend werden die Regeln des FLS entsprechend der unscharfen Logik ausgewertet (Implikation). Die Ergebnisse der einzelnen Regelauswertungen werden anschließend zu einer Ergebnisfunktion zusammengefasst (Aggregation), aus der ein scharfer Ausgangswert abgeleitet wird (Defuzzifizierung).

Die Details dieses Ablaufes lassen sich übersichtlich in einem Fuzzy-Inferenz-Diagramm darstellen (siehe Bild 2.7). Jede Zeile des Diagramms stellt eine Regel des FLS dar. Die ersten beiden Spalten beschreiben die Fuzzifizierungen der

beiden Eingänge des Systems, die dritte Spalte beschreibt die Fuzzifizierung des Systemausganges. Die letzte Spalte beschreibt die Implikation, aus der durch Aggregation und Defuzzifizierung der Ausgangswert berechnet wird. Die Regeln des in Bild 2.7 dargestellten Systems lauten:

- » **Regel 1:** Wenn beide Eingänge niedrig sind, dann ist der Ausgang niedrig.
- » **Regel 2:** Wenn der Eingang 1 mittel ist, dann ist der Ausgang mittel.
- » **Regel 3:** Wenn beide Eingänge hoch sind, dann ist der Ausgang hoch.

Die in diesem Beispiel verwendete Implikationsmethode ist die Maximum-Methode, d.h. der größte in der Regel auftretende Wert wird an die Zugehörigkeitsfunktion des Ausgangs übergeben. Für die Aggregation wurde ebenfalls die Maximum-Methode verwendet, was einer Addition der implizierten Zugehörigkeitsfunktionen entspricht. Die Defuzzifizierung wird mit Hilfe der Schwerpunktmethode (CoG, *Center of Gravity*) durchgeführt, d.h. der Schwerpunkt der sich ergebenden Fläche gibt den scharfen Ausgangswert des FLS an.

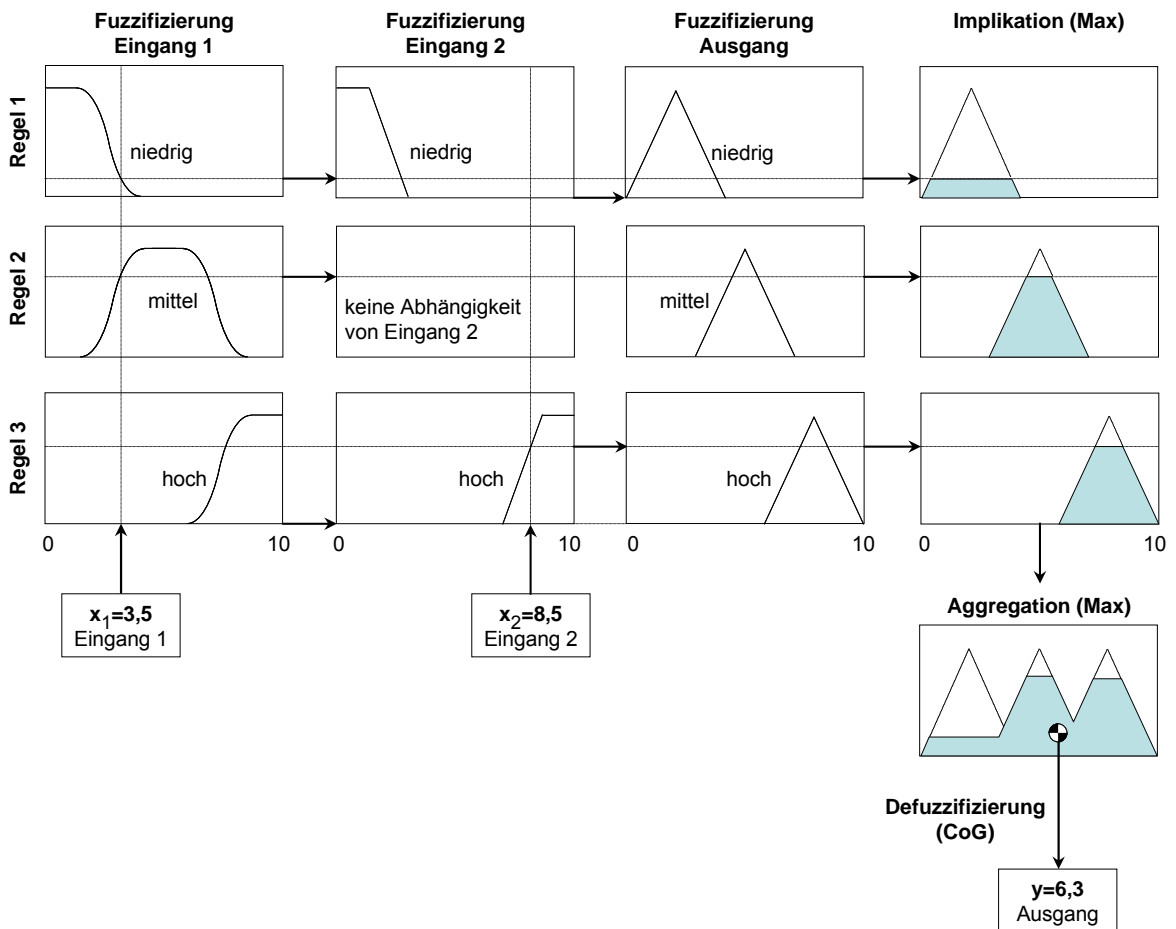


Bild 2.7: Fuzzy-Inferenz-Diagramm eines einfachen Systems

Im dargestellten Beispiel ist die Besonderheit zu beachten, dass Regel 2 keine Abhängigkeit von Eingang 2 ausweist. Der Eingang 2 wird daher nur mit den beiden Zugehörigkeitsfunktionen für die Klassen »niedrig« und »hoch« beschrieben. Das Fuzzy-Inferenz-Diagramm ist für die Eingangswerte $x_1=3,5$ und $x_2=8,5$ dargestellt. Es ergibt sich ein defuzzifizierter Ausgangswert von $y=6,3$.

Fuzzy Logic Systeme bieten folgende Vorteile:

- » Die Methode ist intuitiv verständlich, da sie auf der menschlichen Ausdrucksweise basiert.
- » Die Fuzzy Logic bindet Ungenauigkeiten direkt in den Berechnungsprozess ein und ist daher prädestiniert für den Umgang mit ungenauen oder fehlerhaften Daten.
- » Es können Funktionen beliebiger Komplexität abgebildet werden.
- » Im Gegensatz zu Neuronalen Netzen stellt ein FLS keine »Black-Box« dar. Der Berechnungsablauf kann mit Hilfe von Fuzzy-Inferenz-Diagrammen visualisiert werden. Daraus kann abgeleitet werden, wie sich der Einfluss der Eingangsparameter auf die Lösungsfindung verteilt.
- » Fuzzy Logic kann Expertenwissen (prinzipiell jede Art von zusätzlichem Wissen) in Form von Regeln einbinden.
- » Fuzzy Logic Systeme können problemlos mit anderen Verfahren kombiniert werden und verringern oftmals die Komplexität des Gesamtsystems.

Bezüglich der Schwierigkeiten bzw. Nachteile, die sich bei der Verwendung von Fuzzy Logic Systemen ergeben, sind folgende Punkte zu nennen:

- » Die Aufstellung der geeigneten Regeln kann sich schwierig gestalten.
- » Fuzzy Logic Systeme sind nicht adaptiv, d.h. jedes nicht akzeptierte Fehlverhalten des Systems muss vom Entwickler analysiert und entsprechend korrigiert werden.
- » Neben der Auswahl der geeigneten Regeln gibt es eine Vielzahl weiterer Freiheitsgrade in der Modellierung, z.B. die Definition der Zugehörigkeitsfunktionen, sowie der Implikations-, Aggregations- und Defuzzifizierungsmethoden.

Aufgrund ihrer überlegenen Handhabung von unscharfem Wissen genießen Fuzzy Logic Systeme in der Gasturbinendiagnose seit einiger Zeit wachsende Aufmerksamkeit. Marinai und Singh ^[76] präsentieren ein auf Fuzzy Logic basierendes Verfahren, das in der Lage ist, Fehler in maximal einer Komponente einer Gasturbine zu identifizieren und zu diagnostizieren, wobei zusätzlich maximal ein

Sensor einen fehlerhaften Messwert liefern darf. Priya und Singh ^[91] führen für ein vergleichbares System eine Variation der Zugehörigkeitsfunktionen durch.

Diao und Passino ^[24] verwenden eine Reihe von Fuzzy Logic Systemen zur Diagnose, wobei mit Hilfe von zusätzlichen Regeln eine Auswahl der jeweils passenden Systeme getroffen wird, um den Rechenaufwand zu verringern.

Ganguli ^[38] beschreibt die Anwendung von Fuzzy Logic für die Identifikation von Einzelfehlern auf Komponentenebene. Neben Fehlern in den Verdichtern und Turbinen können auch Fehler im Kühlluftsystem und in der Leitschaufelverstellung des Hochdruckverdichters betrachtet werden. Für ein einfach unterbestimmtes System ($n=9$, $m=8$) wird eine durchschnittliche Identifikationsrate von 98% erreicht, im Falle eines fünffach unterbestimmten Systems ($n=9$, $m=4$) sinkt die Identifikationsrate auf 89%.

Yu et al. ^[140] präsentieren ein Verfahren, bei dem bekannte Fehlerfälle mit Hilfe von Fuzzy Logic beschrieben werden. Unbekannte Daten können dann mit diesen bekannten Fehlerfällen verglichen werden. Das Ergebnis besteht in einem Index für jeden bekannten Fehlerfall, der angibt, mit welcher Wahrscheinlichkeit der entsprechende Fehlerfall in den vorliegenden Daten vorhanden ist. In einer späteren Veröffentlichung erweitern Yu et al. ^[141] dieses Verfahren um Methoden der Entscheidungsfindung in Bezug auf Fehlerursache und Wartungsanweisungen.

2.3.3 Pattern Recognition

Das Gebiet der Mustererkennung (*Pattern Recognition*) ist nicht scharf von anderen Verfahren wie z.B. den Neuronalen Netzen oder der Fuzzy Logic zu trennen, da diese auch zum Zwecke der Mustererkennung eingesetzt werden können. Darüber hinaus werden unter dem Oberbegriff der Mustererkennung verschiedenste Verfahren zusammengefasst. Der folgende Abschnitt gibt lediglich eine Übersicht über in der Triebwerksdiagnose eingesetzte Verfahren.

Aretakis et al. ^[3] verwenden Methoden der Mustererkennung für die Erkennung von Sensorfehlern, die auf dem Vergleich von Vektoren beruhen. Die mit Hilfe eines ANSYN Verfahrens ermittelten Vektoren der Leistungsparameter werden mit einer Reihe von Referenzvektoren verglichen, die jeweils eine fehlerhafte Messung eines der Messsensoren repräsentieren. Bei dem Vergleich der Vektoren kommen verschiedene Arten von Diskriminanten zum Einsatz:

- » Geometrische Diskriminante: Der Abstand der Vektoren wird durch Vektornormen, z.B. die Euklidische Norm, oder durch Cross-Korrelationskoeffizienten beschrieben.
- » Statistische Diskriminante: Mit Kovarianz-Matrizen werden die Wahrscheinlichkeiten berechnet, mit denen der Testvektor zu den Referenzfehlerfällen gehört. Der Fehlerfall mit der höchsten Wahrscheinlichkeit wird als erkannt angesehen.
- » Statistisch optimale Diskriminante: Es wird eine Vorauswahl der in Frage kommenden Fehlerfälle getroffen. Anschließend folgt wie oben beschrieben die Berechnung von Wahrscheinlichkeiten mit Hilfe von Kovarianz-Matrizen.

Loukis et al. ^[72] beschreiben ebenfalls die Anwendung dieser drei Diskriminanten, allerdings für die Erkennung von Verdichterfehlern.

Das System eCM der Firma Smart Signal ^[112] basiert auf einem aus Trainingsdaten erstellten empirischen Modell der Gasturbine. Dieses Modell besteht aus ausgewählten Messvektoren, die den gesamten Betriebsparameterraum der Gasturbine beschreiben. Liegt ein zu untersuchender Messvektor außerhalb dieses Betriebsparameterraums, so liegt entweder ein abnormales Betriebsverhalten vor oder der Betriebsparameterraum war unzureichend definiert. Mit Hilfe von statistischen Test werden relevante Messvektoren mit einer Musterdatenbank von Fehlerfällen verglichen, um abnormales Betriebsverhalten zu erkennen.

Davison und Birk ^[21] stellen eine andere Art der Mustererkennung vor, die auf der Darstellung so genannter Fehlerkennfelder basiert. Druck- und Temperaturverhältnisse der Komponenten werden in zweidimensionaler Form dargestellt, wobei der Betriebspunkt im Falle von alterungsbedingter Verschlechterung in diesen Fehlerkennfeldern einen bestimmten Pfad beschreibt. Aus der Form der Pfade können Rückschlüsse auf die veränderten Komponenten getroffen werden.

Varma et al. ^[121] wenden neben Verfahren des Vektorvergleiches weitere Verfahren der Mustererkennung an, z.B. selbstorganisierende Netze und Entscheidungsbäume. Im Gegensatz zu allen bisher aufgeführten Referenzen werden die Verfahren jedoch nicht auf Sensormesswerte sondern auf so genannte nicht-parametrische Daten angewendet, d.h. auf textbasierte Protokolldateien oder Ergebnisse von Selbsttests. Die Fusion der verschiedenen Verfahren wird ebenfalls diskutiert.

2.4 Hybride ECM Verfahren

Aufgrund der Gegensätzlichkeit der Anforderungen an ein ECM System, ist keines der vorgestellten Verfahren in der Lage, alle Aufgaben der Zustandsüberwachung zufrieden stellend zu erfüllen. Mit dem Ziel, die Vorteile der einzelnen Verfahren zu verbinden und ihre Nachteile zu eliminieren, wurden daher eine Reihe von Konzepten entwickelt, die verschiedene Verfahren miteinander verbinden.

Der Nachteil der fehlenden Adaptivität von Fuzzy Logic Systemen kann durch die Verbindung mit neuronalen Komponenten behoben werden. So genannte Adaptive Neuro Fuzzy Inferenz Systeme (ANFIS) bieten die Möglichkeit, Regeln und Zugehörigkeitsfunktionen durch einen Lernprozess an vorhandene Daten anzupassen. Für die Details von ANFIS sei an die entsprechende Literatur verwiesen (z.B. Bothe ^[10]). Eine Anwendung von ANFIS in der Gasturbinendiagnose ist bei Karvounis und Frith ^[53] zu finden. Sie beschreiben den Einsatz eines ANFIS zur Reduzierung der Ungenauigkeiten eines Leistungsrechnungsmodells.

Grönstedt ^[44] beschreibt eine Optimierungstechnik, die die Vorteile eines Genetischen Algorithmus (globale Minimumsuche) und eines SQP-Verfahrens (schnelle Konvergenz) vereint. Der GA wird zur groben Gebietssuche verwendet und liefert den Startpunkt für die Bestimmung des Minimums mit Hilfe des SQP-Verfahrens.

Sampath und Singh ^[107] schlagen die Verbindung eines Künstlichen Neuronalen Netzes mit einem Genetischen Algorithmus vor. Das Neuronale Netz fungiert dabei als Klassifikator, um den Suchraum für den nachgeschalteten Genetischen Algorithmus zu verkleinern. Kobayashi und Simon ^[54] wenden ebenfalls eine Fusion aus KNN und GA an, wobei sie den GA für die Erkennung von Messfehlern und das KNN für Diagnosezwecke einsetzen.

Brotherton et al. ^[16] stellen ein System vor, das die Verwendung eines Kalman Filters und eines Neuronalen Netzes verbindet. Das Modell der Gasturbine vernachlässigt eine Reihe physikalischer Effekte, wie z.B. Spalteinflüsse, Reynoldszahleinflüsse und Einflüsse durch Schaufelentwindung. Das Neuronale Netz wurde darauf trainiert, diese Einflüsse zu modellieren und damit die berechneten Erwartungswerte des Modells zu verbessern. Der Kalman Filter wird anschließend wie in Abschnitt 2.2.5 beschrieben zur Berechnung der Leistungsparameter verwendet. Es wird gezeigt, dass die Modellierungsverbesserung durch die Verwendung des Neuronalen Netzes die Sensitivität des Systems deutlich erhöht.

Dewallef et al. ^[23] präsentieren ebenfalls ein System, dass die Anwendung eines Kalman Filters und eines Neuronalen Netzes verbindet. Allerdings wird das Neuronale Netz nicht zur Verbesserung der Modellierung verwendet, sondern als Klassifikator, dessen Ergebnis als Eingabe für den Kalman Filter dient.

Brotherton et al. ^[13] verbinden die Anwendung Neuronaler Netze mit Algorithmen zur Regelextraktion, die Regeln in Form von Entscheidungsbäumen darstellen. Dadurch soll der Black-Box-Charakter der Neuronalen Netze überwunden werden. Obwohl der Ansatz viel versprechend ist, konnte der Nutzen bisher nicht ausreichend dargelegt werden.

Eustace ^[33] beschreibt ein System zur Identifikation und Diagnose, das auf der Anwendung von Fuzzy Logic beruht, deren Ergebnisse kombinatorisch ausgewertet werden. Das System liefert neben der diagnostischen Aussage eine Wahrscheinlichkeit, mit der die identifizierten Parameter tatsächlich verändert sind. Von 17 Testfällen werden 12 korrekt identifiziert. Bei diesen liegt die Wahrscheinlichkeit für die Betroffenheit der Parameter bei knapp 85%.

Borguet und Léonard ^[8] verbinden einen Kalman Filter mit einem vorgeschalteten quadratischen Optimierverfahren, das Sensorfehler ausfiltert. Dabei können sowohl einmalige (*impulsive noise*), als auch dauerhafte Sensorabweichungen (*sensor bias*) betrachtet werden. Graduelle Sensorabweichungen (*sensor drifts*) können mit der Methode nicht erkannt werden.

2.5 Verfahren zur Prognose

Während die verschiedenen Verfahren zur Detektion, Identifikation und Diagnose in ihrer Entwicklung weit fortgeschritten und in der Literatur entsprechend dokumentiert sind, finden sich in Bezug auf Prognoseverfahren deutlich weniger Ansätze. Da der Fokus der vorliegenden Arbeit auf den Funktionen Detektion, Identifikation und Diagnose liegt, werden die Verfahren zur Prognose im Folgenden nur kurz vorgestellt. Hauptsächlich werden einfache Regressionsverfahren beschrieben, bei denen der zeitliche Verlauf des zu betrachtenden Parameters durch eine Regressionsgleichung dargestellt wird. Komplexere Verfahren der Zeitreihenanalyse, deren ursprüngliche Anwendung im Bereich der Wirtschafts- und Finanzmathematik liegt, bilden die zweite Gruppe der beschriebenen Verfahren.

2.5.1 Regressionsverfahren

Für den alterungsbedingten Verlauf der Leistungsparameter einer Fluggastturbine schlagen Spieler et al. ^[113] die folgende allgemeine Regressionsgleichung vor:

$$\Delta X = a + b \cdot t^c \quad (2.39)$$

Dabei stellen a, b und c an den jeweiligen Fall anzupassende Koeffizienten dar, während t den Flugzyklus bezeichnet. Nagy ^[84] wendet diese Form der Regression auf die mit Hilfe eines SQP-Verfahrens diagnostizierten Leistungsparameter an. Li und Nilkitsaranont ^[64] verwenden ebenfalls Regressionsgleichungen für die Prognose von Leistungsparametern, allerdings ohne variablen Exponenten, d.h. sie beschränken sich auf lineare (c=1) und quadratische Modelle (c=2). Marinai et al. ^[74] beschreiben den alterungsbedingten Verlauf von Leistungsparametern mit den Exponenten c=0,5 für die Einlaufphase, c=1 für den Rest der Auslebensdauer und c=2 für die Versagensphase.

2.5.2 Verfahren der Zeitreihenanalyse

Marinai et al. ^[74] verwenden die oben beschriebenen Regressionsmodelle für mittel- und langfristige Prognosen. Für kurzfristige Prognosen schlagen sie die von Box und Jenkins ^[11] entwickelte ARIMA Methode vor (*Autoregressive Integrated Moving Average*). Die ARIMA Methode enthält drei Komponenten:

- » Autoregression (AR): Sie beschreibt die gemittelte Summe der vorhergehenden Werte der Zeitreihe und berücksichtigt somit die Abhängigkeit des aktuellen Wertes von seinen Vorgängerwerten.
- » Integration (I): Um Trends und Nicht-Stationarität zu eliminieren können bereits vor der Modellierung Differenzen aufeinander folgender Punkte gebildet werden. Die Zeitreihe wird »integrativ« betrachtet.
- » Gleitender Mittelwert (MA): Sie beschreibt die gemittelte Fehlersumme der vorhergehenden Werte der Zeitreihe und bezieht somit die Varianz der vorhergehenden Werte in die Modellierung ein.

Wang et al. ^[135] wenden ebenfalls die ARIMA Methode auf die Prognose des Betriebsverhaltens einer Gasturbine an, im Gegensatz zu Marinai et al. ^[74] jedoch für Langzeitprognosen. Sowohl Marinai et al. ^[74] als auch Wang et al. ^[135] erzielen viel versprechende Resultate, die allerdings gegenüber den einfachen Regressionsverfahren mit einer erhöhte Komplexität der Modellierung erkauft werden.

2.6 Entwicklung Grafischer Benutzeroberflächen

Die Vielfalt der in den vorigen Kapiteln beschriebenen Verfahren zur Zustandsüberwachung von Gasturbinen dokumentiert den erheblichen Aufwand, der in Bezug auf die Entwicklung und Verbesserung derartiger Verfahren betrieben wurde. Um diese Verfahren in kommerziellen EHM Systemen einsetzen zu können, muss jedoch eine gewisse Anwenderfreundlichkeit gewährleistet sein. Neben der Weiterentwicklung der Verfahren wird daher verstärkt in die Entwicklung grafischer Benutzeroberflächen (GUI, *Graphical User Interface*) investiert.

Sampath et al. ^[105] beschreiben die Entwicklung eines EHM Systems mit grafischer Benutzeroberfläche, das neben der linearen GPA auch Genetische Algorithmen und Neuronale Netze zur Diagnose einsetzt. Darüber hinaus werden Algorithmen zur Lebenskostenberechnung eingebunden. Zukünftige Versionen sollen Prognosefähigkeiten besitzen. In einer weiteren Veröffentlichung ^[106] beschreiben Sampath et al. die Erweiterung auf die nichtlineare GPA in Verbindung mit Kombinatorik und präsentieren diverse Testfälle.

Ein weiteres Beispiel für die Entwicklung eines EHM Systems mit grafischer Benutzeroberfläche ist die Arbeit von Alexiou und Mathioudakis ^[1]. Zur Modellierung der Gasturbine kommt die kommerzielle Software EcosimPro ³ zum Einsatz. Zur Diagnose wird das Verfahren der nichtlinearen GPA angewendet.

2.7 EHM Systeme im industriellen Einsatz

Die meisten Gasturbinenhersteller verfügen mittlerweile über EHM Systeme verschiedenster Ausprägung. Eine Übersicht über bestehende EHM Systeme ist in Tabelle 2.3 dargestellt. Eine Kurzbeschreibung der Funktionalitäten der einzelnen Systeme ist bei Köhli und Lipowsky ^[58] zu finden. Für Details sei an die in Tabelle 2.3 angegebenen Referenzen verwiesen. Die mit * gekennzeichneten Systeme verfügen über eine grafische Benutzeroberfläche.

³ Das im Rahmen des EU Projektes VIVACE entwickelte Leistungsrechnungsprogramm PROOSIS basiert ebenfalls auf der kommerziellen Simulationssoftware EcosimPro.

Name des Systems	Jahr	Institution	Referenzen
OLMOS (RB199)	1987	MTU Aero Engines	Pfoertner ^[89]
TEMPER	1990	General Electric	Doel ^[25-27]
COMPASS	1990	Rolls-Royce	Provost ^[92]
OLMOS (EJ200)	1995	MTU Aero Engines	Broede et al. ^[12]
iMDS	2000	Intelligent Automation Corp.	Brotherton et al. ^[15]
STORM	2000	Pratt & Whitney	Volponi ^[133]
ICEMS *	2001	Scientific Monitoring Inc.	www.icems.net
ProDAPS *	2002	US Air Force	Friend ^[37]
COMPASS Navigator *	2002	Data Systems & Solutions	www.ds-s.com
QUICK Technology *	2002	Oxford BioSignals	www.oxford-biosignals.com
DHMS *	2002	Intelligent Automation Corp.	Brotherton et al. ^[15]
eCM	2002	Smart Signal	Smart Signal ^[112]
eSTORM	2003	Pratt & Whitney	Brotherton et al. ^[16]
AMODIS *	2005	ALSTOM Ltd.	Decoussemaeker ^[22]

Tabelle 2.3: Übersicht über bestehende Systeme zur Zustandsüberwachung von Gasturbinen

Mit dem Augenmerk auf die Hersteller von Fluggasturbinen wurde versucht, den Entwicklungsstand der Systeme der verschiedenen Hersteller zu vergleichen. Dabei wurde zwischen den vier Kategorien Detektion, Identifikation & Diagnose, Prognose und Logistik unterschieden. Das Ergebnis basiert auf den Erkenntnissen aus Köhli und Lipowsky ^[58] und ist in Bild 2.8 dargestellt.




Bild 2.8: Entwicklungsstand der EHM Systeme bei Fluggasturbinenherstellern bezogen auf den Marktführer GE

General Electric hat sich als Marktführer hervorheben können, dicht gefolgt von Rolls-Royce. Die Firma CFM International verfügt nicht über eine Eigenentwicklung, sondern verwendet eine auf dem GE-System basierende Anwendung. Die Firma Pratt & Whitney wendet dagegen ein selbst entwickeltes System an, welches im Vergleich zum EHM System des Marktführers GE jedoch noch erhebliches Entwicklungspotential aufweist. Dieses funktionale Benchmarking ist konsistent mit der in Kapitel 1.2 diskutierten Betrachtung der EHM Entwicklungsbudgets der jeweiligen Firmen (siehe Bild 1.3).

Kapitel 3: Konzeptentwicklung

Im folgenden Kapitel werden die wichtigsten Erkenntnisse aus dem Stand der Technik kurz zusammengefasst. Anschließend wird daraus das Gesamtkonzept eines »integrierten Systems zur Zustandsüberwachung« abgeleitet, das die Basis der vorliegenden Arbeit darstellt. Darüber hinaus werden die Anforderungen an die Einzelprozesse erläutert.

3.1 Erkenntnisse aus dem Stand der Technik

In Abschnitt 1.5 wurden die Anforderungen an das zu entwickelnde System erläutert. In Bezug auf diese Anforderungen werden aus dem Stand der Technik folgende Beobachtungen abgeleitet:

- » Es existiert kein Verfahren, das in seiner alleinigen Anwendung in der Lage ist, alle Anforderungen an das zu entwickelnde System zu erfüllen. Die funktionale Trennung zwischen der Diagnose von Einzelereignissen und von gradueller Verschlechterung ist daher notwendig.
- » In der Literatur ist bisher kein System dokumentiert, das die beiden Diagnosearten funktional trennt und die Ergebnisse anschließend wieder zusammenführt. Ein derartiges integriertes System stellt eine grundlegende Erweiterung des Stands der Technik dar.
- » Um in automatisierter Form zwischen den beiden Diagnosearten unterscheiden zu können, empfiehlt sich die Entwicklung eines speziellen Detektionsalgorithmus. In bestehenden Systemen wird die Aufgabe der Erkennung von Einzelereignissen, falls überhaupt vorgesehen, durch einfache Verfahren wie z.B. der Überprüfung fester Grenzwerte bewerkstelligt. Ein speziell für diese Aufgabe entwickelter Algorithmus ist in der Lage, Einzelereignisse deutlich sensitiver zu erkennen und stellt somit ebenfalls eine Erweiterung des Stands der Technik dar.

3.2 Ableitung des umgesetzten Konzeptes

Um diesen Anforderungen gerecht zu werden, wird ein dreistufiges Konzept eines ECM Systems abgeleitet, dessen Ablaufdiagramm in Bild 3.1 dargestellt ist.

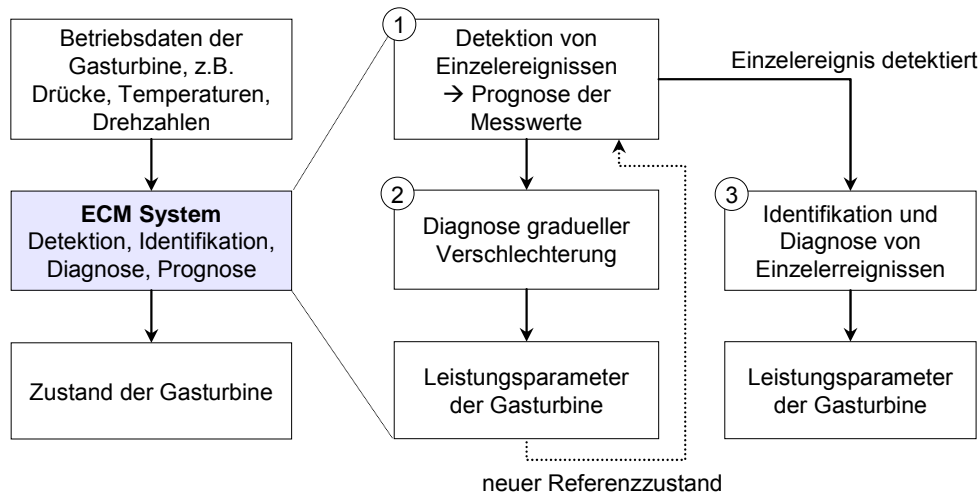


Bild 3.1: Konzept des Systems zur Gasturbinenüberwachung

Das entwickelte ECM System besteht aus den folgenden drei Prozessen, deren Charakteristika in den folgenden Abschnitten kurz erläutert werden:

- » Detektion von Einzelereignissen,
- » Diagnose gradueller Verschlechterung,
- » Identifikation und Diagnose von Einzelereignissen.

(1) Detektion von Einzelereignissen

In einem Detektionsprozess werden die Messwerte der Gasturbine auf Einzelereignisse überprüft. Dafür ist ein Detektionsalgorithmus zu entwickeln, der Einzelereignisse zuverlässig und mit möglichst kurzer zeitlicher Verzögerung erkennt und dabei eine möglichst geringe Fehlalarmrate aufweist. Im Falle der positiven Detektion schließt sich die Identifikation und Diagnose des Einzelereignisses an, anderenfalls folgt die Diagnose gradueller Verschlechterung. Bei Bedarf kann eine Prognose der Messwertverläufe vorgenommen werden, um den zukünftigen Zeitpunkt der Über- oder Unterschreitung festgelegter Grenzwerte zu bestimmen.

(2) Diagnose gradueller Verschlechterung

Bei der Diagnose gradueller Verschlechterung kann genutzt werden, dass der Einfluss von Alterungsmechanismen auf die Leistungsfähigkeit der Gasturbine gradueller Natur ist und alle Komponenten betrifft (siehe Abschnitt 1.4). Die für diesen Prozess gewählte Methode ist derart zu gestalten, dass bekannte Nebenbe-

dingungen integriert werden können, z.B. die Tatsache, dass die Änderungsrate der Leistungsparameter einen bestimmten Wert nicht überschreitet oder dass sich bestimmte Leistungsparameter nur einseitig verändern (i.d.R. verschlechtern). Das Ergebnis dieses Prozesses ist die Berechnung der Leistungsparameter der Gasturbine, welches den Referenzzustand des nächsten Zeitschrittes darstellt. Dieses »Feedback« ermöglicht die integrierte Betrachtung von gradueller Verschlechterung und Einzelereignissen.

(3) Identifikation und Diagnose von Einzelereignissen

In diesem Prozess erfolgt zuerst die Identifikation der vom Fehler betroffenen Komponenten der Gasturbine. Hierbei wird die Annahme getroffen, dass nicht alle Komponenten von einem Einzelfehler betroffen sind (siehe Abschnitt 1.4). Anschließend wird auf der Basis der erzielten Identifikation die Diagnose durchgeführt. Die Schwierigkeit bei diesem Prozess liegt in der korrekten Identifikation der betroffenen Komponenten. Ist die Identifikation durchgeführt, so besteht die Aufgabe der Diagnose lediglich in der Lösung eines bestimmten oder sogar überbestimmten Systems. Entscheidend ist die Güte des zu entwickelnden Identifikationsalgorithmus. Durch das oben erwähnte »Feedback« dient nicht der gesunde Triebwerkszustand als Referenz, sondern des Ergebnis der vorherigen Alterungsdiagnose. Der Prozess der Identifikation und Diagnose von Einzelereignissen bezieht sich demnach zu jedem Zeitpunkt auf den aktuellen Triebwerkszustand, was die Integration von Alterungs- und Einzelereignisdiagnose ermöglicht.

In den folgenden Kapiteln werden die Überlegungen und Untersuchungen dargelegt, die zur Auswahl der in den oben beschriebenen drei Prozessen verwendeten Verfahren geführt haben. Um eine direkte Vergleichbarkeit verschiedener Verfahren zu gewährleisten wurden mehrere relevante Verfahren umgesetzt. In einigen Fällen wurde ein Vergleich gegenüber in der Literatur beschriebenen Ergebnissen durchgeführt.

Kapitel 4: Detektion von Einzelereignissen

Um Betriebspunkteinflüsse zu eliminieren werden bei der Detektion nicht die absoluten Messwerte betrachtet, sondern deren relative Abweichungen von ihren jeweiligen betriebspunktabhängigen Erwartungswerten. Wie bereits in Abschnitt 2.2.3 beschrieben, werden diese relativen Abweichungen als Messwertresiduen bezeichnet und berechnen sich aus:

$$\Delta Y_i = r_i = \frac{Y_i - Y_i^{\text{ref}}}{Y_i^{\text{ref}}}, \quad (4.1)$$

wobei Y_i die Messwerte und Y_i^{ref} die jeweiligen betriebspunktabhängigen Erwartungswerte bezeichnen, die z.B. von einem Leistungsrechnungsprogramm zur Verfügung gestellt werden können. Soll eine Detektion von Parametern durchgeführt werden, deren Erwartungswerte nicht durch ein Leistungsrechnungsprogramm berechnet werden können (z.B. Schwingungs- oder Ölparameter) so empfiehlt sich die Bestimmung entsprechender Referenzwerte aus Abnahmeläufen oder ähnlichen Quellen.

Im Rahmen der vorliegenden Arbeit wurden verschiedene Detektionsverfahren anhand generischer Daten untersucht. Hierzu wurden normalverteilte Residuen mit einer Standardabweichung von $\sigma=1$ generiert. Der Verlauf des Mittelwertes μ wurde den gewünschten Prozessverläufen entsprechend modelliert. Bei der Beschreibung der Datensätze sind folgende Parameter von Relevanz:

- » Standardabweichung σ des Prozesses
- » Mittelwert μ des Prozesses und dessen sprunghafte Veränderungen
- » Gradient des Prozesses

In Bild 4.1 ist ein Datensatz dargestellt, dessen Mittelwert μ_t für die Zyklen 1–50 den Wert 0 hat, für die Zyklen 51–100 den Wert -3 und für die Zyklen 101–150 mit einem konstanten Gradienten von -0,02 pro Zyklus von -3 auf -4 abfällt.

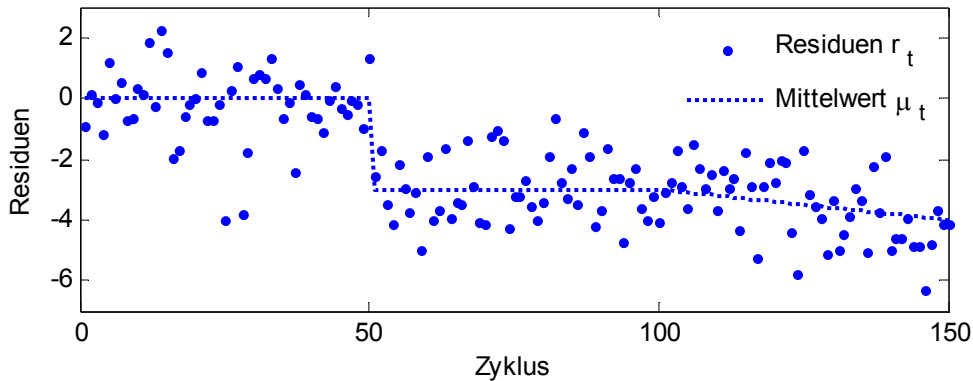


Bild 4.1: Beispieldatensatz für die Detektion von Einzelereignissen

In den folgenden Untersuchungen werden Datensätze der oben diskutierten Form verwendet, wobei eine Variation der Sprunghöhe vorgenommen wird, um die Sensitivitäten der Verfahren zu bewerten. Die Sprunghöhe wird jeweils in Vielfachen der Standardabweichung angegeben. Da die Standardabweichung stets mit $\sigma=1$ gewählt wurde, entspricht der Absolutwert der Sprunghöhe gleichzeitig dem Vielfachen der Standardabweichung.

4.1 Einfache Filterverfahren

4.1.1 Gleitender Mittelwert

Der gleitende Mittelwert ist ein einfaches Filterverfahren zur Trendverfolgung. Der Wert des gleitenden Mittels berechnet sich aus dem ungewichteten Mittelwert der letzten Residuen, wobei der Parameter α_1 die Anzahl der für die Mittelung zu verwendenden Werte angibt:

$$gm_t = \frac{1}{\alpha_1} \sum_{i=k}^t r_i \quad \text{für } t \geq \alpha_1 \quad \text{mit } k = t - \alpha_1 + 1. \quad (4.2)$$

Bei dieser Definition ist zu beachten, dass sie für $t < \alpha_1$ nicht anwendbar ist, da $k < 1$ folgt. Um dennoch gemittelte Werte für diesen Bereich angeben zu können, lässt sich folgende Erweiterung definieren:

$$gm_t = \frac{1}{t} \sum_{i=1}^t r_i \quad \text{für } t < \alpha_1. \quad (4.3)$$

Der Parameter α_1 beeinflusst den Grad der Glättung. In Bild 4.2 sind die gleitenden Mittelwerte für $\alpha_1=3$ und $\alpha_1=30$ dargestellt. Es ist zu erkennen, dass der Grad der Glättung für $\alpha_1=3$ gering ist. Die Reaktion auf Veränderungen in der Zeitreihe erfolgt dagegen zeitnah. Problematisch ist bei dieser Situation, dass aufgrund der geringen Glättung die im Prozessverlauf vorliegende Veränderung (Zyklus 51) nur schwer von den Schwankungen des gleitenden Mittelwertes unterschieden werden kann. Für $\alpha_1=30$ ergibt sich ein hoher Glättungsgrad, der mit einer langsamen Reaktion auf sprunghafte Veränderungen erkaufte wird. Es gilt, ein Optimum zwischen diesen beiden Anforderungen zu finden.




Bild 4.2: Einfluss des Parameters α_1 auf den Grad der Glättung

Eine Möglichkeit dieses Optimum zu definieren besteht in der Minimierung des mittleren quadratischen Fehlers (RMS, *Root-Mean-Square*), der sich aus den Abweichungen zwischen dem wahren Prozessverlauf und dem gleitenden Mittelwert berechnet. Um diese Art der Bewertung durchführen zu können, muss der wahre Prozessverlauf (repräsentiert durch die Mittelwerte μ_t) bekannt sein, was bei generierten Daten der Fall ist.

$$\text{rms}_t = \sqrt{\frac{1}{j} \cdot \sum_{i=1}^j (\text{gm}_t - \mu_t)^2} \quad \text{mit } j = \text{Anzahl der Zyklen} \quad (4.4)$$

Für den Fall einer Sprunghöhe von $\Delta\mu=-3$ ergibt sich der in Bild 4.3 dargestellte Verlauf des mittleren quadratischen Fehlers über dem Parameter α_1 mit einem

Minimum bei $\alpha_1=6$. Der sich daraus ergebende gleitende Mittelwert ist ebenfalls in Bild 4.3 dargestellt. Er liefert ein Optimum zwischen Glättungsgrad und schneller Reaktion auf sprunghafte Prozessänderungen.




Bild 4.3: Auswahl des optimalen Parameters α_1 für $\Delta\mu=-3$

4.1.2 Exponentielles Glätten

Das exponentielle Glätten stellt einen Sonderfall des gleitenden Mittelwertes dar, bei dem alle vorherigen Punkte der Zeitreihe in exponentiell gewichteter Weise in den Filterwert des aktuellen Zeitpunktes einfließen. Es gilt:

$$eg_t = (1 - \alpha_2) \cdot \sum_{j=0}^{\infty} \alpha_2^j \cdot r_{t-j} \quad \text{mit} \quad 0 < \alpha_2 < 1 \quad (4.5)$$

Formal müssen unendlich viele Beobachtungen der Vergangenheit vorhanden sein. Die unendliche Reihe kann jedoch nach Kreiß ^[59] umgeformt werden in:

$$eg_t = (1 - \alpha_2) \cdot r_t + \alpha_2 \cdot eg_{t-1} \quad \text{mit} \quad 0 < \alpha_2 < 1 \quad (4.6)$$

Diese rekursive Definition verdeutlicht, dass sich der Filterwert des aktuellen Zeitpunktes aus dem aktuellen Wert der Zeitreihe und dem vorherigen Filterwert zusammensetzt. Der Parameter α_2 bestimmt das Verhältnis der Gewichtung der beiden Anteile. Entsprechend der Diskussion in Abschnitt 4.1.1 lässt sich durch

Minimierung des RMS ein Parameter α_2 finden, der ein Optimum zwischen Glättungsgrad und Reaktionsgeschwindigkeit darstellt. In Bild 4.4 ist für eine Sprunghöhe $\Delta\mu=-3$ der Verlauf des RMS über α_2 und der sich für das Minimum $\alpha_2=0,22139$ ergebende exponentiell geglättete Filterwert dargestellt.




Bild 4.4: Auswahl des optimalen Parameters α_2 für $\Delta\mu=-3$

Der Verlauf des exponentiellen Glättens ist sowohl qualitativ als auch quantitativ mit dem Verlauf des gleitenden Mittelwertes vergleichbar. Die Methode des exponentiellen Glättens bietet somit keinen ersichtlichen Vorteil gegenüber der Methode des gleitenden Mittelwertes.

4.1.3 Detektion mit Hilfe einfacher Filterverfahren

Um auf der Basis einfacher Filterverfahren einen Detektionsalgorithmus zu entwickeln, ist die Definition eines Erwartungsbereiches notwendig, mit dem die Residuen oder deren entsprechend gefilterten Werte verglichen werden können. Neben der Definition eines festen Schwellwertes ist die Berechnung der Differenz zweier Filterreihen mit unterschiedlichen α -Werten sinnvoll. Diese Differenz kann anschließend auf die Überschreitung eines Schwellwertes überprüft werden. Dadurch werden alterungsbedingte Trends eliminiert und die Sensitivität gegenüber Einzelereignissen erhöht. In Bild 4.5 ist ein Beispiel einer derartigen einfachen

Detektionslogik auf der Basis der Methode des gleitenden Mittelwertes dargestellt.

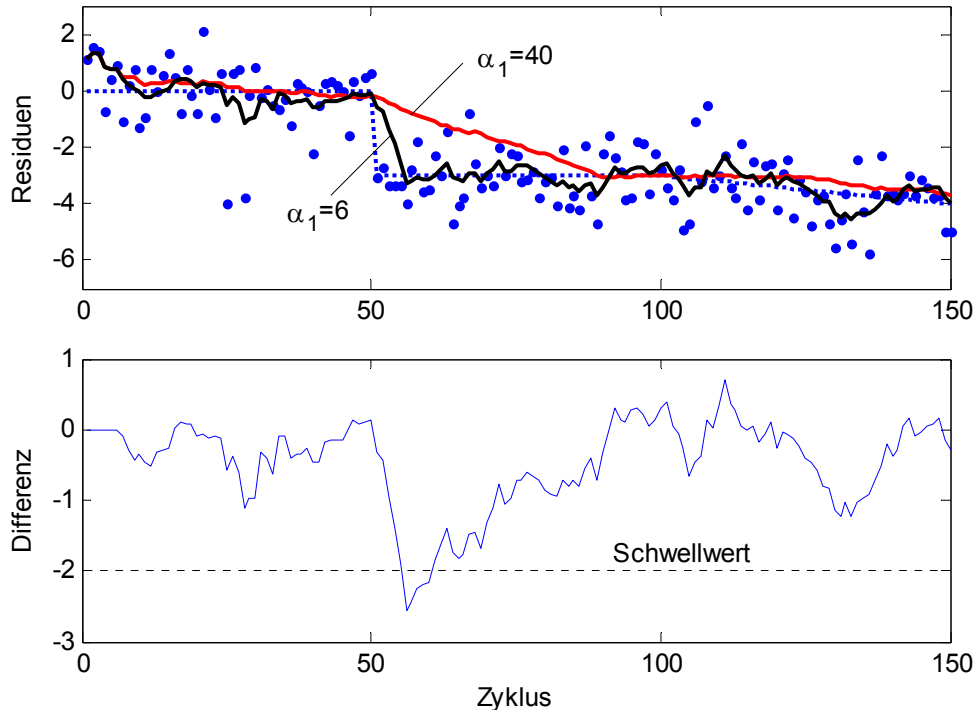


Bild 4.5: Beispiel einer einfachen Detektionslogik auf Basis der Methode des gleitenden Mittelwertes

Folgende weitere Punkte sind bei der detaillierten Entwicklung eines entsprechenden Detektionsalgorithmus zu beachten:

- » Die optimalen Werte für die Parameter α sind abhängig von der zu detektierenden Sprunghöhe $\Delta\mu$ und wären demnach der kleinsten detektierbaren Sprunghöhe entsprechend zu wählen.
- » Das System ist nicht robust gegenüber Ausreißern. Bild 4.5 ist zu entnehmen, dass zwei Ausreißer bei $t=25$ und $t=28$ zu einem Wert der Differenz führen, der den Wert -1 unterschreitet. Um zu verhindern, dass durch Ausreißer eine Detektion ausgelöst wird, ist eine Vorfilterung der Ausreißer nötig.

Diese beiden Aspekte sind bei allen Detektionsalgorithmen zu beachten, unabhängig von den zugrunde liegenden Filterverfahren. Bei den einfachen Filterverfahren sind darüber hinaus die folgenden Punkte zu beachten, die gegen eine detaillierte Entwicklung eines derartigen Detektionsalgorithmus sprechen:

- » Sie liefern keine Information über die Dynamik des Prozesses, z.B. in Form einer Gradientenbetrachtung. Sie eignen sich daher nicht zur Trendverfolgung, d.h. zur Prognose der Messwerte.
- » Sie verfügen lediglich über einen Parameter, der zur Anpassung an bestimmte Probleme variiert werden kann. Die mit derartigen Verfahren erreichbare Detektionssensitivität wird daher geringer eingestuft als die komplexerer Verfahren.

Die Verwendung einfacher Filterverfahren für die Entwicklung eines leistungsfähigen Detektionsalgorithmus ist vor dem Hintergrund genannten Defizite nicht sinnvoll. In den folgenden Abschnitten werden daher komplexere Verfahren vorgestellt, auf deren Basis Detektionsalgorithmen entwickelt werden können, die die in Abschnitt 3.1 definierten Anforderungen erfüllen.

4.2 Kalman Filter für Zeitreihen

Auf Basis des Kalman Filters kann neben der in Abschnitt 2.2.5 beschriebenen Zustandsschätzung dynamischer Systeme auch eine Zeitreihenanalyse durchgeführt werden. Der Kalman Filter eignet sich dadurch auch zur Detektion. Provost und Nevell^[93] ließen sich diese Anwendung des Kalman Filters im Jahr 1992 patentieren.

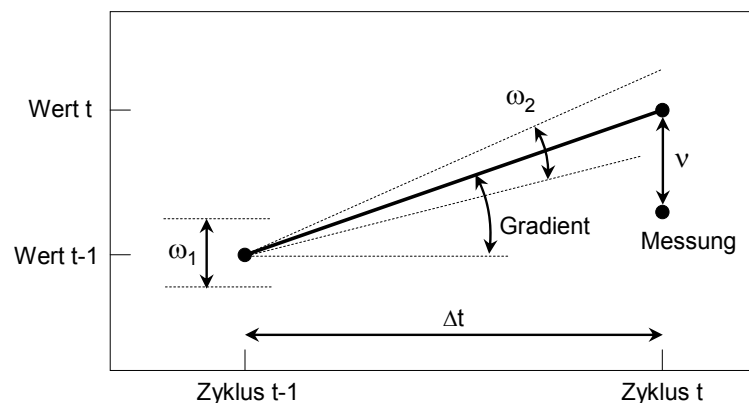


Bild 4.6: Prozessmodellierung bestehend aus Wert und Gradient sowie Prozess- und Messwertvarianzen

Der Prozess wird dabei wie in Bild 4.6 dargestellt durch zwei Komponenten modelliert, Prozesswert und Prozessgradient. Hinzu kommen die Varianzen dieser

beiden Komponenten sowie die Messwertvarianz. Es gelten die folgenden Beziehungen ^[94]:

$$\text{Wert}_t = (\text{Wert}_{t-1} + \omega_{1,t-1}) + \Delta t \cdot (\text{Gradient}_{t-1} + \omega_{2,t-1}) \quad (4.7)$$

$$\text{Gradient}_t = \text{Gradient}_{t-1} + \omega_{2,t-1} \quad (4.8)$$

$$\text{Messwert}_t = \text{Wert}_t + v_t \quad (4.9)$$

Diese Art der Prozessmodellierung wird als Dynamisches Lineares Modell (DLM) bezeichnet und stellt die Basis vieler Methoden der Zeitreihenanalyse dar ^[90]. Da der Prozess in der oben erwähnten Form durch zwei Komponenten (Wert und Gradient) modelliert wird, spricht man von einem DLM zweiter Ordnung. In Matrixschreibweise ergibt sich:

$$\begin{pmatrix} \text{kf} \\ \text{gr} \end{pmatrix}_t = \begin{pmatrix} 1 & \Delta t \\ 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} \text{kf} \\ \text{gr} \end{pmatrix}_{t-1} + \begin{pmatrix} 1 & \Delta t \\ 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} \omega_1 \\ \omega_2 \end{pmatrix}_{t-1} \quad (4.10)$$

$$\Delta Y_t = (1 \ 0) \cdot \begin{pmatrix} \text{kf} \\ \text{gr} \end{pmatrix}_t + v_t \quad (4.11)$$

Da ω_1 und ω_2 unkorreliert sind, müssen keine Kovarianzen betrachtet werden. Es werden die folgenden Normalverteilungen angenommen:

$$\omega_1 \sim N(0, q_1), \omega_2 \sim N(0, q_2) \text{ und } v \sim N(0, \sigma^2) \quad (4.12)$$

Nun können die in Abschnitt 2.2.5 erläuterten Kalman Filter Gleichungen (2.21) bis (2.25) mit folgenden Definitionen angewendet werden:

$$\Delta X = \begin{pmatrix} \text{kf} \\ \text{gr} \end{pmatrix}, A = \begin{pmatrix} 1 & \Delta t \\ 0 & 1 \end{pmatrix}, J = (1 \ 0), Q = \begin{pmatrix} q_1 & 0 \\ 0 & q_2 \end{pmatrix} \text{ und } R = \sigma^2 \quad (4.13)$$

Eine über den Inhalt des Patents hinausgehende Beschreibung des Algorithmus ins Besondere in Bezug auf die programmtechnische Umsetzung sowie ein Vergleich mit einfachen Filterverfahren (gleitender Mittelwert und exponentielles Glätten) ist bei Provost ^[94] zu finden.

Die Parameter q_1 und q_2 bestimmen das Verhalten des Kalman Filters in Bezug auf Glättungsgrad und Reaktionsgeschwindigkeit. Für die Aufgabe der Detektion ist eine Variante mit hoher Reaktionsgeschwindigkeit zu wählen, für die Aufgabe der Trendverfolgung (Prognose) eine Variante mit hohem Glättungsgrad. In Bild 4.7 ist dieser Zusammenhang anhand zweier Beispiele dargestellt. Es ist zu erkennen, dass die Variante mit hohem Glättungsgrad ($q=1e-7$) den konstanten Gradienten nach 150 Zyklen deutlich besser wiedergibt, als die reaktionsschnelle Variante ($q=1e-4$). Die reaktionsschnelle Variante kann dagegen zur Entwicklung

einer entsprechenden Detektionslogik eingesetzt werden. Hierbei gilt es wiederum ein Optimum zwischen Reaktionsgeschwindigkeit und Glättungsgrad zu finden.

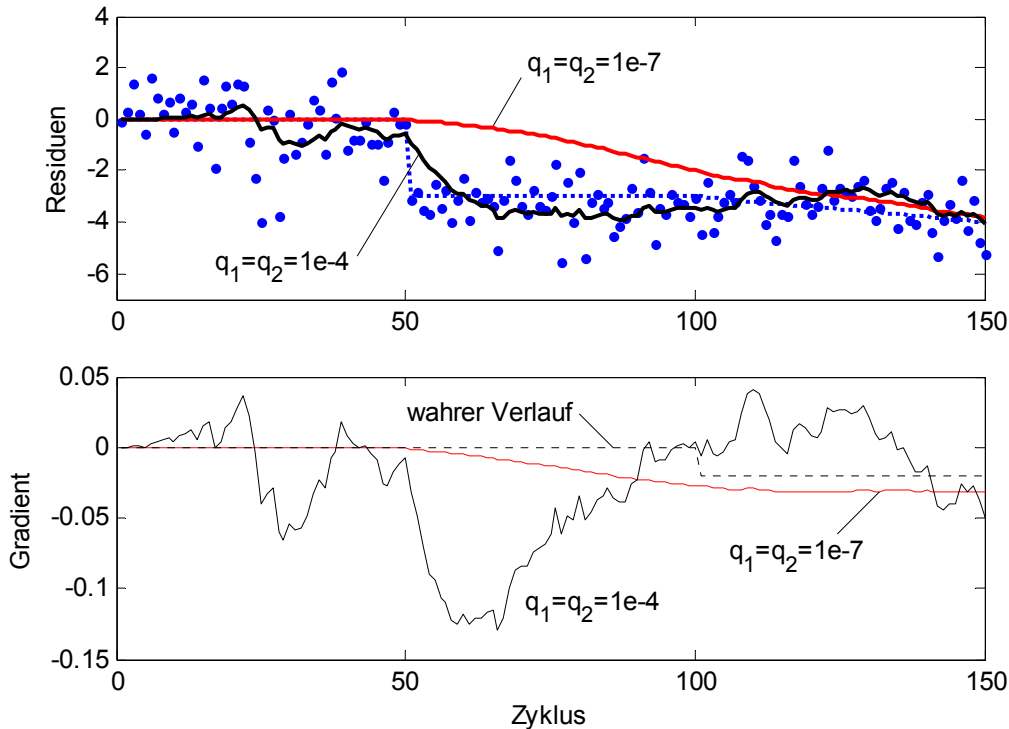


Bild 4.7: Beeinflussung des Verhaltens des Kalman Filters durch die Wahl der Varianzparameter

Dieses Optimum kann entsprechend Abschnitt 4.1.1 durch die Minimierung des mittleren quadratischen Fehlers zwischen Filterwert und wahrem Prozessverlauf bestimmt werden:

$$rms_t = \sqrt{\frac{1}{j} \cdot \sum_{i=1}^j (kf_t - \mu_t)^2} \quad \text{mit } j = \text{Anzahl der Zyklen} \quad (4.14)$$

Für die Sprunghöhe $\Delta\mu=-3$ ergibt sich der in Bild 4.8 dargestellte Verlauf des Filterwertes mit den angegebenen Varianzparametern. Darüber hinaus ist in Bild 4.8 eine mögliche Detektionslogik basierend auf dem Kalman Filter dargestellt. Falls der Gradient einen gesetzten Schwellwert über- bzw. unterschreitet, wird eine Detektion ausgelöst. In diesem Beispiel unterschreitet der Gradient den Schwellwert bei Zyklus 57, d.h. 6 Zeitschritte nach dem Auftreten der sprunghaften Veränderung. Diese Verzögerung wird als Retrospektivität der Detektion bezeichnet. Sie ist abhängig von der Sprunghöhe, von den Varianzparametern und vom gewählten Schwellwert.

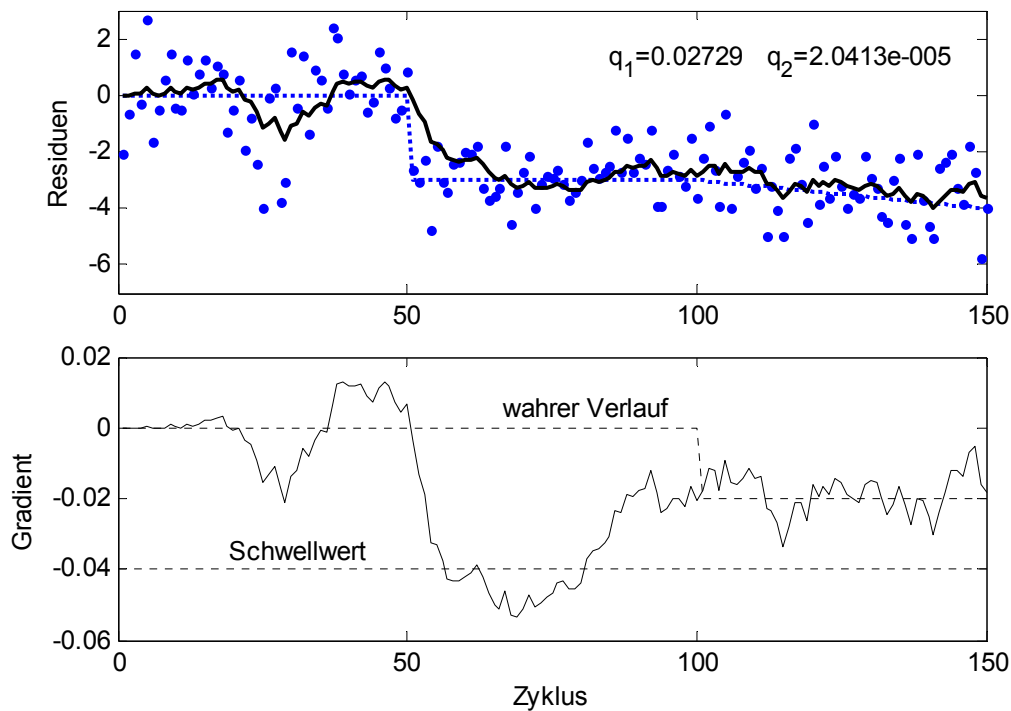


Bild 4.8: Optimale Wahl der Varianzparameter für $\Delta\mu = -3$ und Definition eines Schwellwertes zur Sprungdetektion

Der Kalman Filter bietet als Basis für einen Detektionsalgorithmus gegenüber den einfachen Filterverfahren den Vorteil, nicht nur eine Schätzung für den Prozesswert sondern auch für den Prozessgradienten zu ermöglichen. Einerseits eröffnen sich dadurch mehr Möglichkeiten bei der Auslegung eines Detektionsalgorithmus, andererseits kann durch die Fortsetzung dieses Gradienten eine lineare Prognose getroffen werden.

Das folgende Verfahren besitzt diesen Vorteil ebenfalls, erweitert die Modellierung jedoch noch um die Berechnung eines Erwartungswertes für den nächsten Zeitschritt inklusive einer Wahrscheinlichkeitsverteilung. Es bietet gegenüber dem Kalman Filter Vorteile, die im folgenden Abschnitt erläutert werden.

4.3 Bayesische Vorhersage mit Dynamischen Linearen Modellen

Für das in diesem Abschnitt vorgestellte Verfahren wird ein DLM zweiter Ordnung verwendet, wobei die Zeitdifferenz zwischen zwei Zyklen vereinfachend als

$\Delta t=1$ angenommen wird (zeitlich äquidistante Messwerte). Für die allgemeinen DLM Gleichungen ^[90]

$$\Theta_t = G_t \cdot \Theta_{t-1} + \omega_t \quad \text{mit} \quad \omega_t \sim N(0, W_t) \quad (4.15)$$

$$Y_t = F_t^T \cdot \Theta_t + v_t \quad \text{mit} \quad v_t \sim N(0, V_t) \quad (4.16)$$

gelten die folgenden Parameter:

$$\Theta = \Delta X = \begin{pmatrix} \mu \\ \beta \end{pmatrix}, F = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, G = \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix}, W = \begin{pmatrix} w_1 & 0 \\ 0 & w_2 \end{pmatrix} \text{ und } V = \sigma^2. \quad (4.17)$$

4.3.1 Die Methode der Bayesischen Vorhersage

Der grundlegende Unterschied zwischen der Methode der Bayesischen Vorhersage und den bisher vorgestellten Verfahren besteht in der Modellierung der Prozessparameter durch Wahrscheinlichkeitsdichtefunktionen. Die Schreibweise

$$(\Theta_t | D_t) \sim N(m_t, C_t) \quad \text{mit} \quad D_t = Y_1, Y_2, \dots, Y_t \quad (4.18)$$

bedeutet, dass die Wahrscheinlichkeitsdichtefunktion des Parameters Θ zum Zeitpunkt t bei Kenntnis der Messwerte D normalverteilt ist mit dem Mittelwert m und der Varianz C . Die Methode der Bayesischen Vorhersage ähnelt dem Kalman Filter in der Hinsicht, dass ebenfalls eine Vorhersage (Prediktor) generiert wird, die mit Berücksichtigung des neuen Messwertes korrigiert wird (Korrektor). Ist der Zustand zum Zeitpunkt $t-1$ bekannt, dann gilt

$$(\Theta_{t-1} | D_{t-1}) \sim N(m_{t-1}, C_{t-1}). \quad (4.19)$$

Die Vorhersagegleichungen (1-Schritt Prognosegleichungen) lauten dann:

$$(\Theta_t | D_{t-1}) \sim N(a_t, R_t) \quad (4.20)$$

$$(Y_t | D_{t-1}) \sim N(f_t, Q_t) \quad (4.21)$$

wobei sich Mittelwerte und Varianzen wie folgt berechnen:

$$a_t = G_t \cdot m_{t-1}, \quad f_t = F_t^T \cdot a_t \quad (4.22)$$

$$R_t = G_t C_{t-1} G_t^T + W_t, \quad Q_t = F_t^T R_t F_t + V_t \quad (4.23)$$

Unter Berücksichtigung des Messwertes zum Zeitpunkt t ergibt sich die Korrekturgleichung (Update Gleichung) und damit der neuen Systemzustand

$$(\Theta_t | D_t) \sim N(m_t, C_t) \quad (4.24)$$

mit den Parametern

$$m_t = a_t + A_t e_t \quad \text{mit} \quad A_t = R_t F_t / Q_t, \quad e_t = Y_t - f_t \quad (4.25)$$

$$C_t = R_t - A_t A_t^T Q_t. \quad (4.26)$$

Die Anwendung der erweiterten Vorhersagegleichungen (k-Schritt Prognosegleichungen) zum Zeitpunkt t führt zur Vorhersage der nächsten k Zeitschritte:

$$(\Theta_{t+k} | D_t) \sim N(a_t(k), R_t(k)) \quad (4.27)$$

$$(Y_{t+k} | D_t) \sim N(f_t(k), Q_t(k)) \quad (4.28)$$

wobei für die Mittelwerte und Varianzen gilt:

$$a_t(k) = G_{t+k} \cdot a_t(k-1), \quad f_t(k) = F_{t+k}^T \cdot a_t(k) \quad (4.29)$$

$$R_t(k) = G_{t+k} R_t(k-1) G_{t+k}^T + W_{t+k}, \quad Q_t = F_{t+k}^T R_t(k) F_{t+k} + V_{t+k} \quad (4.30)$$

Die Herleitung der Gleichungen ist bei West und Harrison ^[137] zu finden. Es sollte jedoch erwähnt werden, dass sie auf dem Theorem von Bayes beruht (daher der Name Bayesische Vorhersage). Das Theorem von Bayes ermöglicht die Berechnung bedingter Wahrscheinlichkeiten und lautet in allgemeiner Form:

$$p(A | B) = \frac{p(B | A) \cdot p(A)}{p(B)}. \quad (4.31)$$

Dabei bezeichnet $p(A|B)$ die Wahrscheinlichkeit, dass das Ereignis A eintritt unter der Voraussetzung, dass das Ereignis B eingetreten ist. Ein weit verbreitetes Beispiel zur Veranschaulichung des Satz von Bayes lautet wie folgt: Die Wahrscheinlichkeit, an einer bestimmten Krankheit zu leiden, sei $p(A)=0,01\%$. Für den Nachweis der Krankheit existiert ein medizinischer Test, der über eine Genauigkeit von $p(B|A)=99\%$ verfügt (das Ereignis B bezeichnet dabei den Erhalt eines positiven Testergebnisses). Bei einem positiven Testergebnis liegt die Wahrscheinlichkeit, tatsächlich an der Krankheit zu leiden jedoch nur bei $p(A|B)=0,98\%$, d.h. die Wahrscheinlichkeit, trotz positivem Testergebnis gesund zu sein, liegt bei $p(A^C|B)=99,02\%$. Dabei bezeichnet A^C die Umkehrung des Ereignisses A, d.h. die Tatsache nicht erkrankt zu sein. Dieses Ergebnis ist auf den ersten Blick verblüffend, liegt aber darin begründet, dass die Wahrscheinlichkeit erkrankt zu sein mit $p(A)=0,01\%$ um das hundertfache geringer ist, als die Wahrscheinlichkeit eines falschen Testergebnisses $p(B^C|A)+p(B|A^C)=1\%$. In Bild 4.9 ist die Berechnung der Wahrscheinlichkeiten mit Hilfe eines Entscheidungsbaumes veranschaulicht. Vereinfachend wird eine absolute Population von einer Million Personen angenommen. Die Wahrscheinlichkeit $p(A|B)=0,98\%$ stellt

dabei das Verhältnis der korrekt positiv getesteten zu den insgesamt positiv getesteten Personen dar.

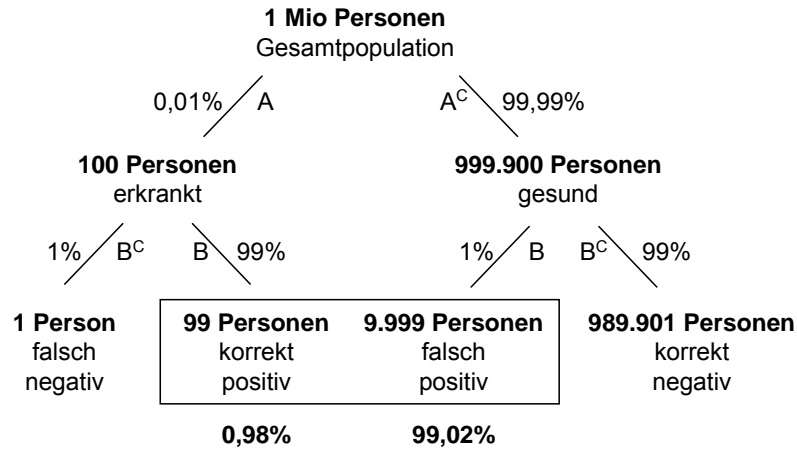


Bild 4.9: Veranschaulichung des Satz von Bayes anhand eines Entscheidungsbaumes

4.3.2 Anwendung auf das Detektionsproblem

Die Methode der Bayesischen Vorhersage wird mit Hilfe der in den vorangegangenen Abschnitten erläuterten Gleichungen auf einen Beispieldatensatz von Residuen angewendet. Die Berechnungen legen die Varianzwerte $\omega_1 = \omega_2 = 1e-6$ zugrunde und sind in Bild 4.10 dargestellt.

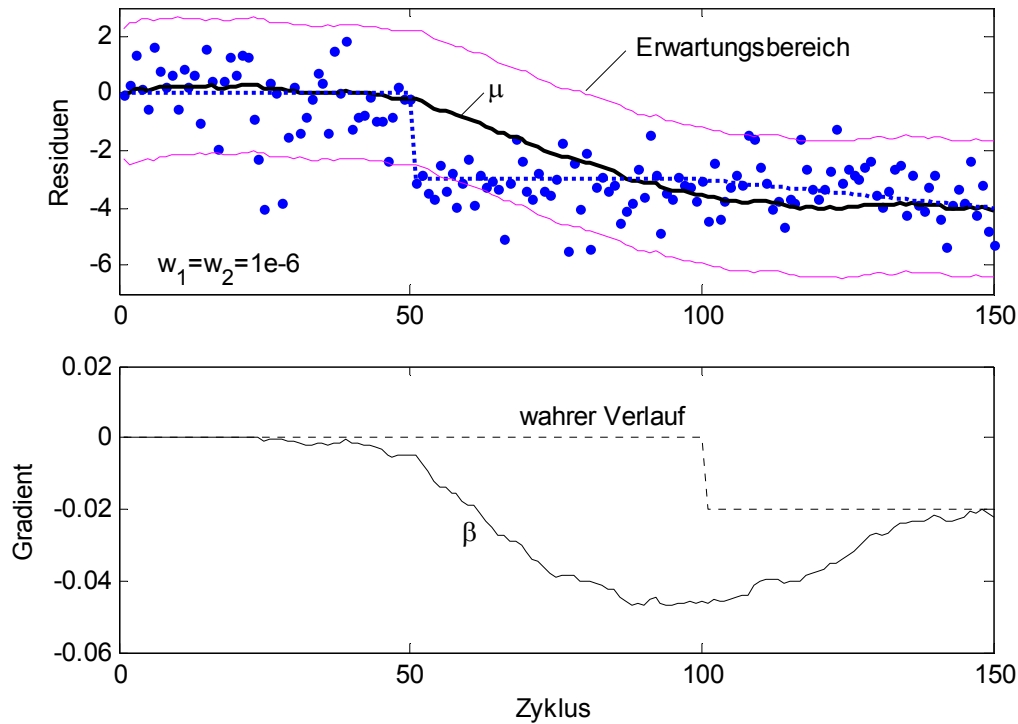


Bild 4.10: Anwendung der Bayesianischen Vorhersage auf einen Beispieldatensatz mit Sprunghöhe $\Delta\mu=-3$

Im oberen Diagramm ist der Verlauf des Prozessschätzwertes (μ) zu erkennen, der aufgrund der gewählten Varianzen einen hohen Glättungsgrad aufweist. Darüber hinaus ist die Ober- und Untergrenze eines Erwartungsbereichs dargestellt, der über die Breite $\pm 2,22\sigma$ verfügt (wie dieser Wert der Erwartungsbreite zustande kommt wird zu einem späteren Zeitpunkt erläutert werden). Im unteren Diagramm ist der Verlauf des Gradientenschätzwertes (β) zu sehen. Es ist zu erkennen, dass die sprunghafte Veränderung des Prozesswertes zum Zeitpunkt $t=51$ teilweise durch eine Anpassung des Gradienten aufgefangen wird. Erst bei Zyklus 150 gibt der Gradientenschätzwert den wahren Wert des Gradienten korrekt wieder.

Die Methode der Bayesianischen Vorhersage wird um eine Detektionslogik erweitert, um auf sprunghafte Veränderungen des Prozesswertes reagieren zu können ohne dabei den Glättungsgrad verringern zu müssen. Die entwickelte Detektionslogik ist Gegenstand eines vom Autor der vorliegenden Arbeit in Zusammenarbeit mit der MTU AeroEngines GmbH angemeldeten Patentes ^[65]. Die Detektionslogik besteht aus einer Ausreißererkennung und einer Erkennung sprunghafter Veränderungen. In den folgenden Abschnitten wird die Entwicklung dieser beiden Funktionalitäten näher erläutert.

4.3.3 Ausreißererkennung

Die Ausreißererkennung basiert auf der Berechnung von Bayes Faktoren, die das Verhältnis zweier Wahrscheinlichkeitsdichtefunktionen darstellen. Zu jedem Zeitpunkt liefert die Bayesische Vorhersage eine Wahrscheinlichkeitsdichtefunktion für den nächsten erwarteten Messwert, die im Weiteren als »Modell 0« bezeichnet wird. Ein alternatives Modell, dessen Mittelwert gegenüber dem Modell 0 um den Wert h verschoben ist, wird als »Modell + h « eingeführt. Der aktuelle Messwert wird bezüglich beider Modelle ausgewertet, wobei das Verhältnis der beiden Wahrscheinlichkeiten den Bayes Faktor wiedergibt ^[90]:

$$H_{1,t} = \frac{p(Y_t | D_{t-1}, M_h)}{p(Y_t | D_{t-1}, M_0)} = \frac{\text{Wert der Dichtefunktion des Modells } h}{\text{Wert der Dichtefunktion des Modells } 0} \quad (4.32)$$

Im Falle von Gauß'schen Normalverteilungen ergibt sich der Bayes Faktor zu:

$$H_{1,t} = \exp\left(\frac{2h \cdot (Y_t - f_t) - h^2}{2Q_t^2}\right). \quad (4.33)$$

In Bild 4.11 ist die Ableitung des Bayes Faktors aus den beiden Wahrscheinlichkeitsdichtefunktionen beispielhaft für den Fall $h=1,645\sigma$ dargestellt. Es ist zu erkennen, dass der Bayes Faktor in der logarithmischen Darstellung eine monoton steigende Gerade beschreibt. Für den Bayes Faktor $H=1$ ist die Wahrscheinlichkeit, dass der aktuelle Messwert aus der Verteilung des Modells 0 stammt gleich der Wahrscheinlichkeit, dass er aus der Verteilung des Modells + h stammt. Für die Entscheidung, ab welchem Bayes Faktor der Messwert der Verteilung + h zuzurechnen ist, schlägt Jeffreys ^[49] den Wert $H_{\min}=10$ vor. Mit $h=1,645\sigma$ ergibt sich als Breite des Erwartungsbereiches $ucl=2,22\sigma$ (*uncertainty limit*), d.h. dass der aktuelle Messwert als potentieller Ausreißer bewertet wird, falls er mehr als $2,22\sigma$ vom Erwartungswert des Modells 0 abweicht.




Bild 4.11: Ableitung des Bayes Faktors H und der Erwartungsbereichsbreite ucl vom Parameter h

Die Breite des Erwartungsbereiches (ucl) lässt sich nach Gleichung (4.34) aus dem Parameter h berechnen. Es gilt:

$$ucl = \frac{\ln(H_{\min})}{h} + \frac{h}{2}. \quad (4.34)$$

Die Integration der Gauß'schen Wahrscheinlichkeitsdichtefunktion über den Erwartungsbereich liefert die Verteilungsfunktion (cdf, *cumulative distribution function*). Sie gibt die Wahrscheinlichkeit an, mit der ein Messwert innerhalb des definierten Erwartungsbereiches liegt und berechnet sich zu

$$cdf(x) = 2 \cdot \int_0^x pdf(t) dt = \frac{2}{\sigma\sqrt{2\pi}} \cdot \int_0^x \exp\left(-\frac{t^2}{2\sigma^2}\right) dt \quad \text{mit} \quad x = ucl. \quad (4.35)$$

Das Integral der Gauß'schen Wahrscheinlichkeitsdichtefunktion ist nicht geschlossen analytisch darstellbar und muss numerisch bestimmt werden. Es kann jedoch mit Hilfe der Errorfunktion (erf) beschrieben werden:

$$cdf(\tilde{x}) = \frac{2}{\sqrt{\pi}} \cdot \int_0^{\tilde{x}} \exp(-t^2) dt = erf(\tilde{x}) \quad \text{mit} \quad \tilde{x} = \frac{x}{\sigma\sqrt{2}} \quad (4.36)$$

In Verbindung mit Gleichung (4.34) liefert Gleichung (4.36) den Zusammenhang $\text{cdf}(ucl)$ und damit $\text{cdf}(h)$. In Bild 4.12 sind die Zusammenhänge zwischen den Parametern h , ucl und $\text{cdf}(ucl)$ dargestellt. Es ist zu erkennen, dass bei $h=2,15\sigma$ ein Minimum vorliegt. Um monoton steigende Zusammenhänge zu gewährleisten sollten daher nur Werte $h>2,15\sigma$ gewählt werden.




Bild 4.12: Abhängigkeit der Parameter ucl und cdf vom Parameter h

Im folgenden Beispiel (Bild 4.13) wurde die oben beschriebene Logik zur Ausreißerererkennung angewendet. Mit $h=3\sigma$ wurde ein Wert größer als $2,15\sigma$ gewählt. Messwerte außerhalb des Erwartungsbereiches, d.h. Messwerte mit einem Bayes Faktor $H>10$, werden als Ausreißer bewertet und sind entsprechend markiert. Es ist zu beachten, dass mit dem in Bild 4.11 dargestellten »Modell +h« lediglich Ausreißer mit positiver Abweichung zum Erwartungswert detektiert werden können. Um Ausreißer mit negativer Abweichung erfassen zu können wird ein zweites alternatives Modell mit einem Versatz des Erwartungswertes um den Wert $-h$ definiert (»Modell -h«). Es gilt:

$$H_{2,t} = \exp\left(\frac{-2h \cdot (Y_t - f_t) - h^2}{2Q_t^2}\right). \quad (4.37)$$

Der Verlauf beider Bayes Faktoren ist in Bild 4.13 überlagert dargestellt.




Bild 4.13: Ausreißerererkennung auf Basis von Bayes Faktoren
(Messwerte mit $H > 10$ werden als Ausreißer bewertet)

4.3.4 Detektion sprunghafter Veränderungen

Um sprunghafte Veränderungen von einmaligen Ausreißern zu unterscheiden wird eine spezielle Logik eingeführt, die auf der Berechnung kumulativer Bayes Faktoren und Lauflängen basiert. Als kumulativer Bayes Faktor $H(k)$ wird das Produkt der letzten k Bayes Faktoren^[90] bezeichnet. Es gilt:

$$H_t(k) = \prod_{t-k+1}^t H_t \quad \text{mit} \quad k = 1, 2, \dots, l_{\max}, \quad (4.38)$$

wobei l_{\max} die maximale Anzahl der zu berücksichtigenden Faktoren angibt. Aus dieser Menge ergibt sich der maximale kumulative Bayes Faktor L zu

$$L_t = H_t(l) = \max_{1 \leq k \leq l} (H_t(k)). \quad (4.39)$$

Der Parameter l wird als Lauflänge bezeichnet und liefert die Information über den Zeitpunkt einer sprunghaften Veränderung. Wird eine derartige Veränderung zum Zeitpunkt t erkannt (Ereigniszeitpunkt), so liegt ihre Ursache bereits $l+1$ Zeitschritte zurück, d.h. das Ereignis hat zum Zeitpunkt $t-l+1$ stattgefunden (Ereigniszeitpunkt). Die Differenz zwischen diesen Zeitpunkten wird als Retropektivität der Detektion bezeichnet. Der Erkennungszeitpunkt liegt mindestens einen Zeitschritt nach dem Ereigniszeitpunkt, da der erste Punkt einer sprunghaften Veränderung in erster Instanz als Ausreißer bewertet wird. Es bedarf

mindestens eines weiteren Punktes zur Bestätigung des Ereignisses. Je kleiner die Sprunghöhe des Ereignisses ist, desto größer wird die Differenz zwischen Erkennung und Ereignis. Die maximale Retrospektivität beträgt l_{\max} . Es sei erwähnt, dass die kumulativen Bayes Faktoren entsprechend den Gleichungen (4.33) und (4.37) für positive und negative Abweichungen zu berechnen sind.




Bild 4.14: Verlauf der Bayes Faktoren H , der maximalen kumulativen Bayes Faktoren L und der Lauflängen l über der Zeit t

Eine Übersicht über die Verläufe der Bayes Faktoren, der maximalen kumulativen Bayes Faktoren und der Lauflängen für das diskutierte Beispiel ist in Bild 4.14 dargestellt. Es ist zu erkennen, dass der maximale kumulative Bayes Faktor den Schwellwert zum Zeitpunkt $t=52$ überschreitet. Aus dem Verlauf der Lauflänge wird weiterhin ersichtlich, dass der Schwellwert $l_{\min}=4$ zum Zeitpunkt $t=54$ erreicht wird. Der Ereigniszeitpunkt ergibt sich damit zu $t=51$.

Auf der Basis dieser Erkenntnisse wurde die folgende Logik zur Erkennung sprunghafter Veränderungen entwickelt:

- » Ein potentieller Ausreißer liegt vor, falls $H(t) > H_{\min}$ erfüllt ist und es sich beim vorherigen Messwert nicht ebenfalls um einen Ausreißer handelte. Der Ausreißer wird übersprungen, indem direkt mit dem nächsten Zeitschritt fortgefahren wird, ohne die Updategleichungen anzuwenden.
- » Eine sprunghafte Veränderung liegt vor, falls zwei potentielle Ausreißer aufeinander folgen, was durch $L(t) > H_{\min}^2$ überprüft wird, oder falls $L(t) > H_{\min}$ erfüllt ist und gleichzeitig die Lauflänge über dem Schwellwert l_{\min} liegt. Die erste Bedingung greift bei kleinen Sprunghöhen, letztere bei großen Sprunghöhen. Im Falle einer Detektion erfolgt eine retrospektive Anpassung des Modells, indem der Mittelwert des »Modells 0« zum Zeitpunkt des Ereignisses ($t-l+1$) auf den entsprechenden Messwert gesetzt wird. Die Analyse wird anschließend ab dem Ereigniszeitpunkt wiederholt.

Diese Logik stellt den Kern des vom Autor der vorliegenden Arbeit in Zusammenarbeit mit der MTU Aero Engines GmbH angemeldeten Patentes ^[65] dar und ist in Bild 4.15 in Form eines Flussdiagramms dargestellt.




Bild 4.15: Logik zur Detektion sprunghafter Veränderungen

Die Anwendung der entwickelten Detektionslogik auf Beispieldaten mit einer Sprunghöhe von $\Delta\mu = -3$ ist Bild 4.16 zu entnehmen. Die Retrospektivität beträgt lediglich einen Zeitschritt. Des Weiteren ist zu erkennen, dass der Gradient während der ersten 100 Zeitschritte dem wahren Verlauf folgt. Die beim Zyklus 101 einsetzende graduelle Verschlechterung mit konstantem Gradienten wird dagegen

nur verzögert wiedergegeben. Die Anpassung des Gradienten erfolgt aufgrund der gewählten Gradientenvarianz entsprechend langsam und ist zum Zeitpunkt 150 noch nicht abgeschlossen.

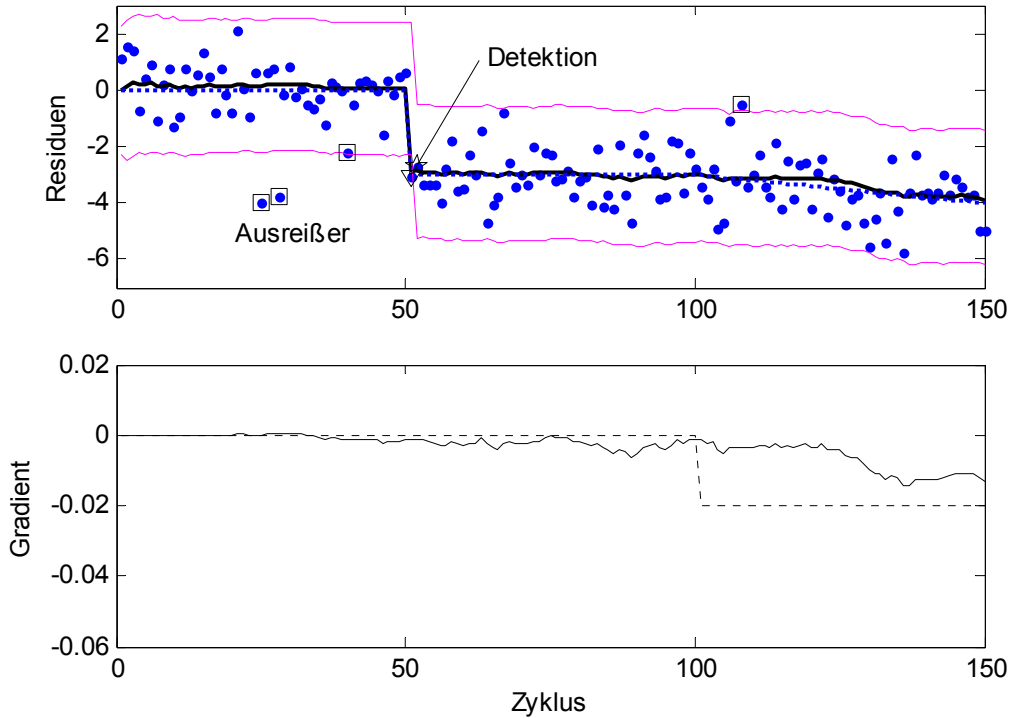


Bild 4.16: Anwendung der Detektionslogik auf Beispieldaten mit einer Sprunghöhe von $\Delta\mu = -3\sigma$

Ein abschließendes Beispiel mit einer Sprunghöhe von $\Delta\mu = -1,5\sigma$ ist in Bild 4.17 dargestellt. Das Ereignis wird zum Zeitpunkt $t=62$ mit einer Retrospektivität von 5 Zeitschritten detektiert. Es ist anzumerken, dass der detektierte Ereigniszeitpunkt ($t=57$) nicht mit dem wahren Ereigniszeitpunkt ($t=51$) übereinstimmt, so dass die wahre Retrospektivität der Detektion 11 Zeitschritte beträgt.

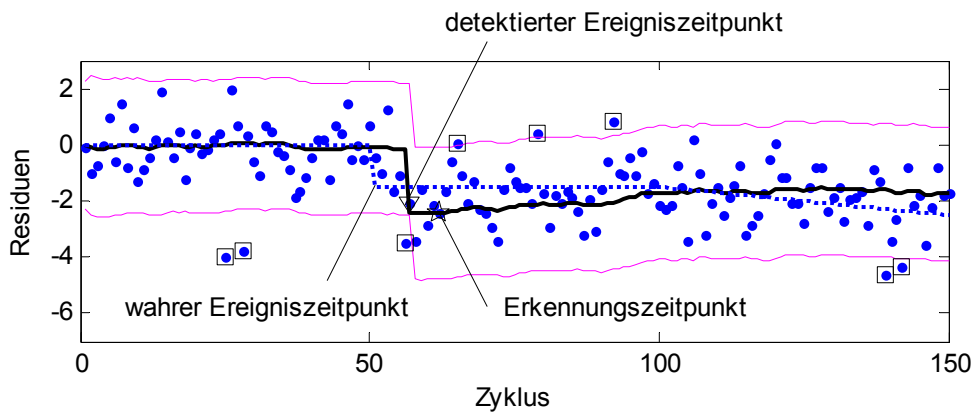


Bild 4.17: Anwendung der Detektionslogik auf Beispieldaten mit einer Sprunghöhe von $\Delta\mu = -1,5\sigma$

Dieses Verhalten des Algorithmus tritt insbesondere bei sprunghaften Veränderungen auf, deren Sprunghöhe zwar über der Detektionsschwelle von $\Delta\mu = \pm 1,5\sigma$ jedoch unterhalb von $\Delta\mu = \pm 3\sigma$ liegt. Eine ausführlichere Diskussion zu den Themen Detektionsschwelle und Detektionen mit höherwertigen Retrospektivitäten folgt in Abschnitt 4.3.6.

4.3.5 Prognose der Residuenverläufe

Da die Methode der Bayesischen Vorhersage zu jedem Zeitpunkt einen Schätzwert für den Prozess und dessen Dynamik zur Verfügung stellt, der alle bisherigen Beobachtungen beinhaltet, ist es möglich, eine prognostische Aussage über den Residuenverlauf zu treffen. Hierzu müssen lediglich die erweiterten Vorhersagegleichungen (4.27) bis (4.30) angewendet werden. Der aktuelle Wert des Gradienten wird dabei beibehalten, was zu einer linearen Vorhersage führt. Mit steigender Anzahl der prognostizierten Zeitschritte wächst die Unsicherheit der Prognose, was sich in einer Verbreiterung des Erwartungsbereiches niederschlägt (siehe Bild 4.18). Darüber hinaus ist im dargestellten Beispiel zu erkennen, dass die Anpassung des Gradienten nach dessen sprunghafter Veränderung ($t=101$) rund 90 Zeitschritte benötigt und dass der Gradient zum Beginn der Prognose überschätzt wird ($-0,0235$ statt $-0,02$).

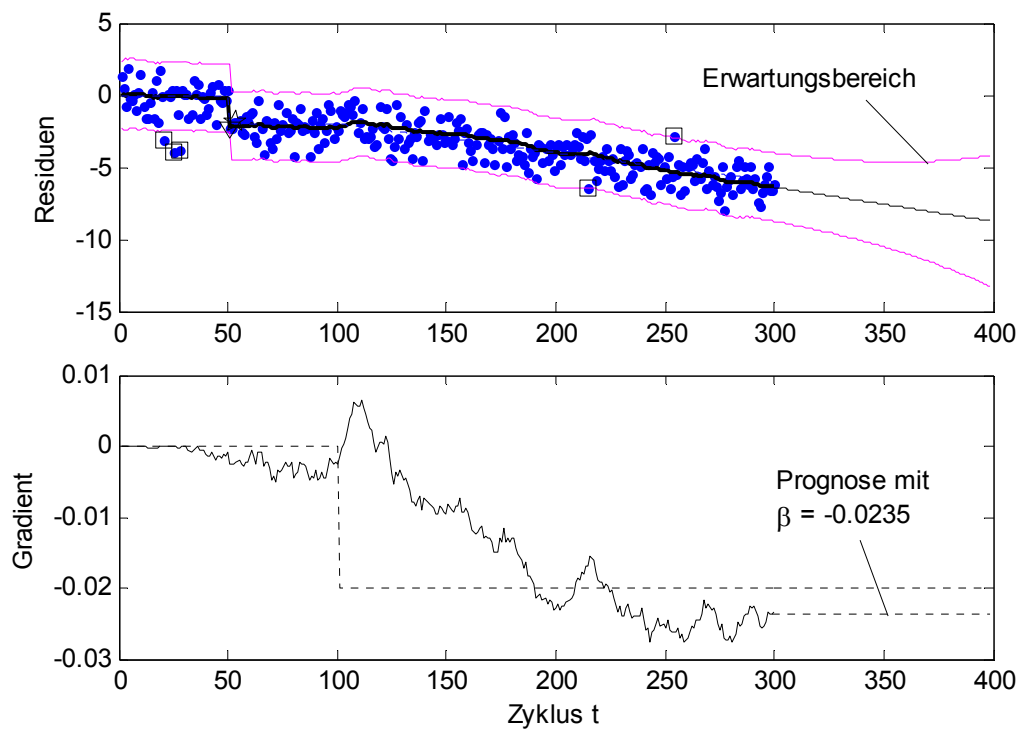


Bild 4.18: Beispiel der Prognose mit konstantem Gradienten

Aus den Ergebnissen der Prognose lassen sich in Bezug auf die Über- bzw. Unterschreitung von bestimmten Grenzwerten in den Residuenverläufen zwei wichtige Funktionen ableiten, die Dichtefunktion (PDF, *Probability Density Function*) und die Verteilungsfunktion (CDF, *Cumulative Density Function*) für die Grenzwertüberschreitung. In Bild 4.19 ist die grafische Ableitung der beiden Funktionen dargestellt. Die Dichtefunktion ergibt sich aus der Auswertung des DLM Verlaufes über der Zeit bei dem entsprechenden Grenzwert (im Beispiel beträgt der Grenzwert -5). Treten im betreffenden Zeitraum keine beeinflussenden sprunghaften Veränderungen auf, so weist die Dichtefunktion Gauß'sche Form auf. Das Integral der Dichtefunktion liefert die Verteilungsfunktion, die angibt, zu welchem Zeitpunkt der betrachtete Grenzwert mit welcher Wahrscheinlichkeit über- bzw. unterschritten wird. Um einen Wahrscheinlichkeitswert zwischen 0 und 1 zu erhalten, wird das Integral der PDF auf das Gesamtintegral bezogen:

$$\text{cdf}(t) = \int_0^t \text{pdf}(x) \, dx / \int_0^\infty \text{pdf}(x) \, dx \tag{4.40}$$

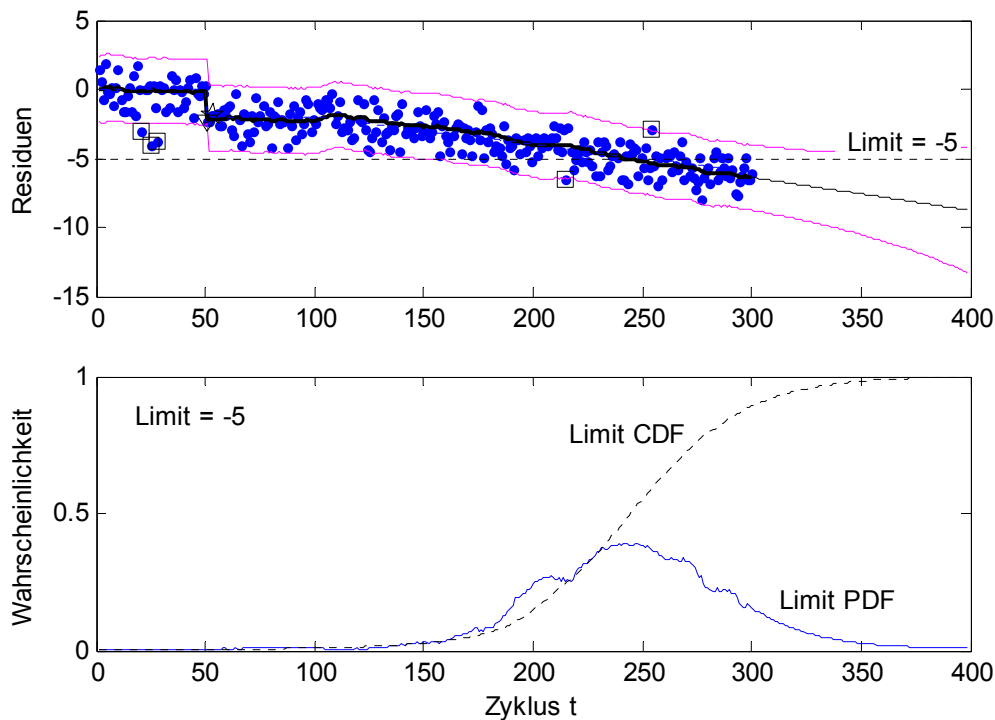


Bild 4.19: Ableitung der Dichtefunktion und der Verteilungsfunktion für die Über- bzw. Unterschreitung eines Grenzwertes

Da rechnerisch keine unendliche Anzahl an Zeitpunkten betrachtet werden kann, wird das Bezugsintegral auf die Anzahl der vorhandenen Zeitpunkte (inkl. prognostizierter Zeitpunkte) beschränkt. Dieses Verfahren liefert nur dann sinnvolle

Ergebnisse, wenn der betrachtete Zeitraum ausreichend ist. Mathematisch ausgedrückt muss die Dichtefunktion nach dem Erreichen eines Maximums bereits wieder asymptotisch gegen null gehen. Als Richtwert gilt, dass der betrachtete Zeitraum ausreichend ist, falls das Maximum der Dichtefunktion mindestens um das Dreifache ihrer Standardabweichung überschritten wurde.

4.3.6 Statistische Bewertung

Das entwickelte Verfahren wurde im Rahmen einer statistischen Bewertung einem aus 31680 Testzyklen bestehenden Versuchsprogramm unterzogen ^[68]. Zur statistischen Bewertung wurden die folgenden drei Gütegrade definiert:

$$\text{Detektionsrate} = \frac{\text{Anzahl korrekter Detektionen}}{\text{Anzahl existenter Ereignisse}} \quad (4.41)$$

$$\text{Fehldetektionsrate (fn)} = \frac{\text{Anzahl nicht erfolgter Detektionen}}{\text{Anzahl existenter Ereignisse}} \quad (4.42)$$

$$\text{Fehldetektionsrate (fp)} = \frac{\text{Anzahl inkorrekt er Detektionen}}{\text{Anzahl möglicher inkorrekt er Detektionen}} \quad (4.43)$$

Die Abkürzungen »fn« und »fp« stehen dabei für »falsch negativ« und »falsch positiv«. Die in Bild 4.20 dargestellte Bewertungsmatrix veranschaulicht die definierten Gütegrade in einfacher Weise.

		Fehler detektiert	
		Ja	Nein
Fehler existent	Ja	Detektionsrate (korrekt positiv)	Fehldetektionsrate (falsch negativ)
	Nein	Fehldetektionsrate (falsch positiv)	n/a

Bild 4.20: Matrix zur Definition der verschiedenen Gütegrade zur Bewertung der Detektion

Zur Definition einer korrekten Detektion wird ein Grenzwert (Detektionslimit) eingeführt, der den Zeitraum angibt, innerhalb dessen eine Detektion als korrekt bewertet wird. Tritt ein Ereignis beispielsweise zum Zeitpunkt $t=10$ auf, so wird dessen Detektion bei einem Detektionslimit von 3 als korrekt bewertet, falls der detektierte Ereigniszeitpunkt im Intervall $7 \leq t \leq 13$ liegt (Bild 4.21). Im Rahmen der Versuchreihe wurden die Detektionslimits 0, 1, 2 und 3 untersucht.




Bild 4.21: Definition des Zeitraumes korrekter Detektionen

Weitere in der statistischen Bewertung variierte Parameter sind die Sprunghöhe $\Delta\mu$ und die Erwartungsbereichsbreite $\text{cdf}(u_{cl})$. Die Sprunghöhe wurde zwischen $0,7\sigma$ und 9σ variiert, für die Erwartungsbereichsbreite wurden die Werte 97%, 98% und 99% untersucht. In Bild 4.22 und Bild 4.23 ist beispielhaft das Ergebnis der Parameterstudie für den Fall eines Detektionslimits von 3 Zyklen dargestellt. Aus Bild 4.22 ist abzuleiten, dass die erzielten Detektionsraten mit steigender Erwartungsbereichsbreite sinken. Bei einer Erwartungsbereichsbreite von 97% werden bis zu einer Sprunghöhe von 2σ Detektionsraten von 100% erreicht. Bei $\Delta\mu=1,5\sigma$ liegt die Detektionsrate knapp unter 93%. Mit Hilfe dieser Ergebnisse wird eine Detektionsschwelle von $\Delta\mu=1,5\sigma$ festgelegt, bis zu der Detektionen mit einer akzeptablen Detektionsrate zu erreichen sind.

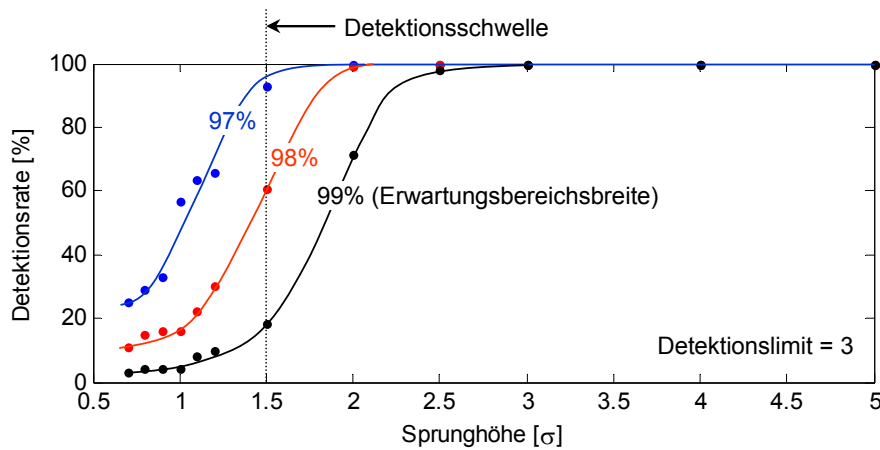


Bild 4.22: Detektionsrate als Funktion von Erwartungsbereichsbreite und Sprunghöhe




Bild 4.23: Fehldetektionsrate (fp) als Funktion von Erwartungsbereichsbreite und Sprunghöhe

Aus Bild 4.23 wird ersichtlich, dass die fp-Fehldetektionsraten mit sinkenden Erwartungsbereichsbreiten steigen. Bei einer Erwartungsbereichsbreite von 97% liegen die maximalen fp-Fehldetektionsraten in der Größenordnung von 2%. Im Anwendungsfall gilt es, ein Optimum zwischen hoher Detektionsrate und niedriger fp-Fehldetektionsrate zu finden. Die Definition dieses Optimums muss auf den jeweiligen Anwendungsfall zugeschnitten sein und obliegt dem Anwender. Die maximalen fp-Fehldetektionsraten treten im Bereich von $1,5\sigma \leq \Delta\mu \leq 3\sigma$ auf, was sich mit dem Bereich der Detektionen mit höherwertigen Retrospektivitäten deckt (Retrospektivitäten > 1). In diesem Bereich sind die Sprunghöhen nicht ausreichend hoch, so dass die erste Bedingung des Algorithmus (Bild 4.15) nicht greift und die Detektion durch die zweite Bedingung der logischen Abfrage ausgelöst werden muss. Bei Sprunghöhen von $\Delta\mu < 1,5\sigma$ greift schließlich auch diese Bedingung nicht mehr und der Algorithmus versagt.

Eine Übersicht der Ergebnisse der Parameterstudie für ein Detektionslimit von drei Zyklen ist in Tabelle 4.1 dargestellt. Als Vergleich dient der in Tabelle 4.2 aufgeführte Fall mit einem Detektionslimit von einem Zeitschritt. Erwartungsgemäß sinkt die Detektionsrate mit sinkendem Detektionslimit, während die Fehldetektionsrate steigt. Beispielsweise wird bei $\Delta\mu = 2\sigma$ bei der Forderung nach einer zeitlichen Genauigkeit des detektierten Ereigniszeitpunktes von einem Zyklus (Detektionslimit=1) nur noch eine Detektionsrate von 98,99% erreicht. Wie bereits oben erwähnt liegt der entsprechende Wert bei einer zeitlichen Toleranz von 3 Zeitschritten (Detektionslimit=3) bei 100%.

$\Delta\mu$ [σ]	Detektionsrate			fn-Fehldetektionsrate			fp-Fehldetektionsrate		
	Erwartungsbereichsbreite			Erwartungsbereichsbreite			Erwartungsbereichsbreite		
	97%	98%	99%	97%	98%	99%	97%	98%	99%
0,7	25,25	11,11	3,03	74,75	88,89	96,97	0,45	0,14	0,00
0,8	29,29	15,15	4,04	70,71	84,85	95,96	0,51	0,18	0,04
0,9	33,33	16,16	4,04	66,67	83,84	95,96	0,58	0,25	0,00
1,0	56,57	16,16	4,04	43,43	83,84	95,96	0,90	0,25	0,00
1,1	63,64	22,22	8,08	36,36	77,78	91,92	1,19	0,29	0,11
1,2	65,66	30,30	10,10	34,34	69,70	89,90	1,23	0,22	0,14
1,5	92,93	60,61	18,18	7,07	39,39	81,82	1,63	0,69	0,21
2,0	100	98,99	71,72	0	1,01	28,28	1,89	1,59	0,69
2,5	100	100	97,98	0	0	2,02	1,93	1,67	1,26
3,0	100	100	100	0	0	0	1,59	1,33	1,23
4,0	100	100	100	0	0	0	0,97	0,90	0,90
5,0	100	100	100	0	0	0	0,35	0,33	0,25

Tabelle 4.1: Detektions- und Fehldetektionsraten abhängig von Sprunghöhe und Erwartungsbereichsbreite (Detektionslimit=3)

$\Delta\mu$ [σ]	Detektionsrate			fn-Fehldetektionsrate			fp-Fehldetektionsrate		
	Erwartungsbereichsbreite			Erwartungsbereichsbreite			Erwartungsbereichsbreite		
	97%	98%	99%	97%	98%	99%	97%	98%	99%
0,7	24,24	7,07	1,01	75,76	92,93	98,99	0,57	0,16	0,03
0,8	17,17	7,07	2,02	82,83	92,93	97,98	0,55	0,25	0,08
0,9	19,19	10,10	3,03	80,81	89,90	96,97	0,57	0,27	0,03
1,0	38,38	10,10	3,03	61,62	89,90	96,97	0,93	0,27	0,03
1,1	42,42	15,15	5,05	57,58	84,85	94,95	1,20	0,36	0,13
1,2	51,52	19,19	5,05	48,48	80,81	94,95	1,19	0,32	0,16
1,5	83,84	51,52	15,15	16,16	48,48	84,85	1,96	0,66	0,14
2,0	98,99	93,94	59,60	1,01	6,06	40,40	3,07	2,02	0,81
2,5	100	100	94,95	0	0	5,05	2,91	2,26	1,90
3,0	100	100	100	0	0	0	2,07	1,83	1,88
4,0	100	100	100	0	0	0	1,77	0,95	0,92
5,0	100	100	100	0	0	0	1,68	0,46	0,27

Tabelle 4.2: Detektions- und Fehldetektionsraten abhängig von Sprunghöhe und Erwartungsbereichsbreite (Detektionslimit=1)

4.4 Radial-Basisfunktions-Netzwerke

Die von Ganguli ^[39] beschriebene Methode zur Anwendung von RBFN zur Detektion von Einzelereignissen wurde von Gansel ^[40] detailliert untersucht. Er erarbeitete ein System von RBFN und eine entsprechende Logik, die die Detektion durch eine Betrachtung von jeweils 4 Residuen ermöglicht (aktueller Wert plus drei retrospektive Werte). Es wurden Detektionsraten von 60% für Sprunghöhen

größer als 3σ bei einem Detektionslimit von 3 Zeitschritten erreicht. Die Detektionsrate für zeitlich exakte Detektionen (Detektionslimit=0) lag bei 50% (ebenefalls für $\Delta\mu > 3\sigma$). Für Sprunghöhen kleiner als 2σ konnten lediglich Detektionsraten von wenigen Prozent erreicht werden. Diese Ergebnisse wurden darüber hinaus nur unter Anwendung eines Vorfilters erreicht, was einer Reduktion der Standardabweichung des zu untersuchenden Signals entspricht. Ein weiterer entscheidender Nachteil gegenüber der in Abschnitt 4.3 entwickelten Methode besteht darin, dass für jede diskrete Sprunghöhe jeweils ein speziell trainiertes RBFN generiert werden muss, was zu einem erheblichen Aufwand führt.

4.5 Fazit

Als Grundlage für die Entwicklung eines leistungsfähigen Detektionsalgorithmus bietet die Methode der Bayesischen Vorhersage mit Hilfe Dynamischer Linearer Modelle gegenüber einfacheren Filterverfahren eine erhöhte Flexibilität. Das in Abschnitt 4.3 entwickelte Verfahren zur Detektion sprunghafter Veränderungen bietet gegenüber den bisher in der Literatur veröffentlichten Verfahren folgende Vorteile:

- » Durch die Entwicklung der speziellen Detektionslogik werden die gegensätzlichen Anforderungen der schnellen Reaktion bei hohem Glättungsgrad gleichzeitig erfüllt. Darüber hinaus werden Ausreißer eliminiert.
- » Die Dynamik des Prozesses kann durch den Einsatz Dynamischer Linearer Modelle abgebildet werden. Die Ordnung der eingesetzten Modelle kann entsprechend den Anforderungen gewählt werden.
- » Aufgrund der statistischen Grundlage können Prognosen nicht nur getroffen, sondern mit Vertrauensbereichen versehen werden.
- » Aufgrund der Kombination verschiedener Elemente zur Detektion (Bayes Faktoren, kumulative Bayes Faktoren, Lauflängen) erlaubt die Methode zuverlässige Detektionen selbst bei Sprunghöhen, die kleiner als das Dreifache der Standardabweichungen der Residuenverläufe sind.
- » Im Gegensatz zu Verfahren, die auf Neuronalen Netzen basieren, ist die entwickelte Methode auf beliebige Sprunghöhen anwendbar.

Kapitel 5: Diagnose von Einzelereignissen

5.1 Generisches Triebwerksmodell

In den Untersuchungen zur Diagnose sowohl von Einzelereignissen als auch von gradueller Verschlechterung kommt ein generisches Triebwerksmodell zum Einsatz, das mit einem modernen modularen Leistungsrechnungsprogramm erstellt wurde.

5.1.1 Konfiguration und Instrumentierung

Bei der verwendeten Triebwerkskonfiguration handelt es sich um ein Zweiwellen-Zweistrom-Turboluftstrahltriebwerk mit Strahlmischung und konvergenter Schubdüse, dessen Blockschaltbild in Bild 5.1 dargestellt ist. Bild 5.1 ist neben der Komponentenanzordnung auch die Ebenenbezeichnung zu entnehmen.




Bild 5.1: Verwendete Konfiguration und Ebenenbezeichnung

Das Triebwerk besteht aus dem Einlauf, drei Verdichtern (FAN, LPC, HPC), einer Brennkammer (BK), zwei Turbinen (HPT, LPT), einem Mischer und der

Schubdüse. Es werden die in Tabelle 5.1 gelisteten Leistungsparameter betrachtet, die entsprechend den folgenden Gleichungen definiert sind.

Wirkungsgrade:

$$\Delta\eta_i = (\eta_i - \eta_{\text{ref}}) \cdot 100\% \quad (5.1)$$

Kapazitäten:

$$\Delta w_i = \left(\frac{w_i \sqrt{T_i} / P_i}{w_{i,\text{ref}} \sqrt{T_{i,\text{ref}}} / P_{i,\text{ref}}} - 1 \right) \cdot 100\% \quad (5.2)$$

Querschnittsflächen:

$$\Delta A_i = \left(\frac{A_i}{A_{i,\text{ref}}} - 1 \right) \cdot 100\% \quad (5.3)$$

Den Gleichungen ist zu entnehmen, dass Wirkungsgrade als absolute Abweichungen und die übrigen Leistungsparameter als relative Abweichungen bezüglich eines Referenzwertes definiert sind. Die Referenzwerte sind durch die entsprechenden Werte des unverschlechterten Triebwerkes im betrachteten Betriebspunkt gegeben.

Nr.	Bezeichnung	Symbol	Einheit
ΔLP1	Abweichung des FAN Wirkungsgrades	$\Delta\eta_{\text{FAN}}$	%
ΔLP2	Abweichung der FAN Kapazität	Δw_{FAN}	%
ΔLP3	Abweichung des LPC Wirkungsgrades	$\Delta\eta_{\text{LPC}}$	%
ΔLP4	Abweichung der LPC Kapazität	Δw_{LPC}	%
ΔLP5	Abweichung des HPC Wirkungsgrades	$\Delta\eta_{\text{HPC}}$	%
ΔLP6	Abweichung der HPC Kapazität	Δw_{HPC}	%
ΔLP7	Abweichung des HPT Wirkungsgrades	$\Delta\eta_{\text{HPT}}$	%
ΔLP8	Abweichung der HPT Kapazität	Δw_{HPT}	%
ΔLP9	Abweichung des LPT Wirkungsgrades	$\Delta\eta_{\text{LPT}}$	%
ΔLP10	Abweichung der LPT Kapazität	Δw_{LPT}	%
ΔLP11	Abweichung der Düsenaustrittsfläche	ΔA_8	%

Tabelle 5.1: Übersicht über die zu bestimmenden Leistungsparameter

Als Regelparameter wurde das Triebwerksdruckverhältnis P_{t5}/P_{t2} gewählt (EPR, *Engine Pressure Ratio*), während die Umgebungsbedingungen durch die Flughöhe Alt, die Flugmachzahl Ma_0 und die Umgebungstemperatur T_0 gegeben sind. Der Auslegungspunkt des Triebwerkes ist festgelegt durch $EPR=1,4348$, $Alt=10668\text{m}$, $Ma_0=0,8$ und $T_0=218,8\text{K}$. Neben diesen vier den Betriebspunkt festlegenden Größen wurde eine aus neun Messgrößen bestehende Instrumentierung gewählt.

Eine Übersicht über die gewählte Instrumentierung inklusive Referenzwerten im Auslegungspunkt ist in Tabelle 5.2 dargestellt. Die angegebenen Unsicherheiten wurden von Aretakis ^[2] übernommen und stellen den dreifachen Wert der Standardabweichung der Messaufnehmer dar.

Nr.	Bezeichnung	Symbol	Referenz	Unsicherheit	Einheit
MW1	Niederdruckwellendrehzahl	N1	4600,5	6,0	1/min
MW2	Hochdruckwellendrehzahl	N2	12931,3	12,0	1/min
MW3	Brennstoffmassenstrom	WF	0,3815	0,002	kg/s
MW4	FAN Austrittsdruck	Pt13	61,1869	0,3	kPa
MW5	LPC Austrittsdruck	Pt25	90,5723	0,4	kPa
MW6	LPC Austrittstemperatur	Tt25	334,4	2,0	K
MW7	HPC Austrittsdruck	Pt3	1181,7	5,0	kPa
MW8	HPC Austrittstemperatur	Tt3	738,5	2,0	K
MW9	LPT Austrittstemperatur	Tt5	654,8	2,0	K

Tabelle 5.2: Übersicht über die gewählte Instrumentierung des Triebwerks

Mit dieser Wahl der Leistungsparameter und Messgrößen liegt ein zweifach unterbestimmtes System vor ($n=11$, $m=9$), was einer typischen Instrumentierungssituation einer Fluggasturbine im Serieneinsatz entspricht ^[26,27,29,128,129].

5.1.2 Nichtlineares Ersatzmodell

Da das in Abschnitt 5.1.1 beschriebene Triebwerksmodell in einem Leistungsrechnungsprogramm vorlag, das nicht mit externen Diagnosealgorithmen verbunden werden konnte, wurde folgendes Vorgehen gewählt, das für den zweidimensionalen Fall in Bild 5.2 dargestellt ist:

- » Mit Hilfe des Modells wurde eine Reihe von Syntheserechnungen mit variierenden Leistungsparametern durchgeführt. Die Leistungsparameter wurden dabei jeweils im Bereich von +1% bis -3% in Schritten von 0,5% verändert.
- » Auf Basis dieser Rechnungen wurde ein tabellarisches Ersatzmodell erstellt, bei dem die sich ergebenden Messwertresiduen durch Superposition der Einflüsse der einzelnen Leistungsparameter berechnet werden.
- » Liegen Leistungsparameter zwischen den berechneten Stützstellen vor, so wird zwischen den Stützstellen mit Hilfe eines kubischen Splines interpoliert.

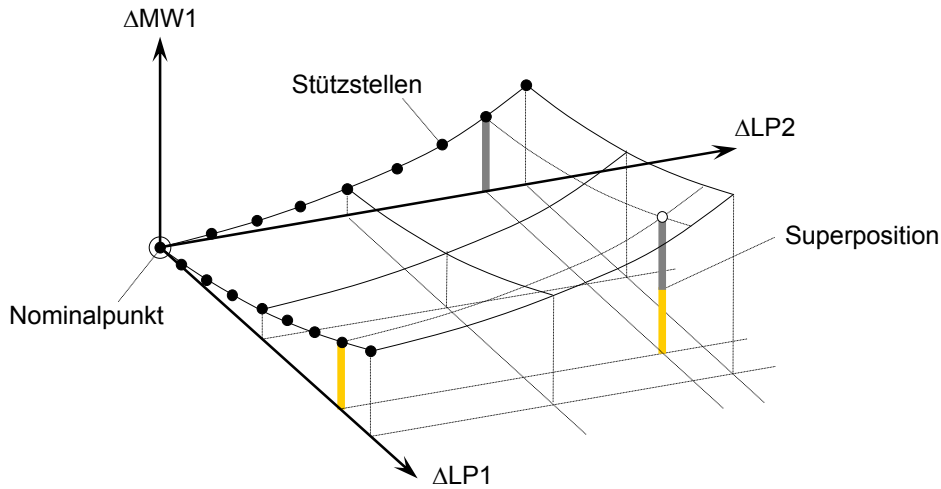


Bild 5.2: Superposition der Einzeleinflüsse im Ersatzmodell

Es ist festzuhalten, dass mit Hilfe des nichtlinearen Ersatzmodells Abweichungen gegenüber den mit dem Leistungsrechnungsmodell berechneten Messwertresiduen entstehen. Um die Güte des Ersatzmodells zu bewerten wurde eine Parameterstudie mit beiden Modellen durchgeführt. Hierbei wurden alle Leistungsparameter linear von +1% bis -3% variiert und dabei alle möglichen Kombinationen von Leistungsparametern berücksichtigt. Bei $n=11$ Leistungsparametern ergeben sich

$$11 + \binom{11}{2} + \binom{11}{3} + \dots + \binom{11}{10} + 1 = \sum_{k=1}^{11} \binom{11}{k} = 2047 \quad (5.4)$$

mögliche Kombinationen. In Bild 5.3 ist das Ergebnis der Messwertresiduen dargestellt für den Fall, dass sich die Leistungsparameter LP1 bis LP8 gleichzeitig und linear von +1% bis -3% verschlechtern.

Im dargestellten Beispiel tritt die größte Abweichung mit $\Delta R_{\max} = 2,3585\%$ bei dem Messwert P25 auf, wobei ΔR_{\max} die größte absolute Differenz der Residuen darstellt.




Bild 5.3: Vergleich der Ergebnisse des Leistungsrechnungsmodells und des nichtlinearen Ersatzmodells für Variation in LP1-8




Bild 5.4: Mittlere absolute Abweichung für Variation der Leistungsparameter LP1 bis LP8

Als Mittelwert der Beträge der Abweichungen ergibt sich der in Bild 5.4 dargestellte Verlauf über der Leistungsparameterveränderung. Diese mittlere absolute Abweichung wurde als Gütekriterium für die Bewertung der 2047 berechneten Kombinationen herangezogen und jeweils bei einem Leistungsparameterwert von -3% ausgewertet. Aufgetragen über der Kombinationsnummer ergibt sich die in Bild 5.5 dargestellte Verteilung dieses Gütekriteriums.

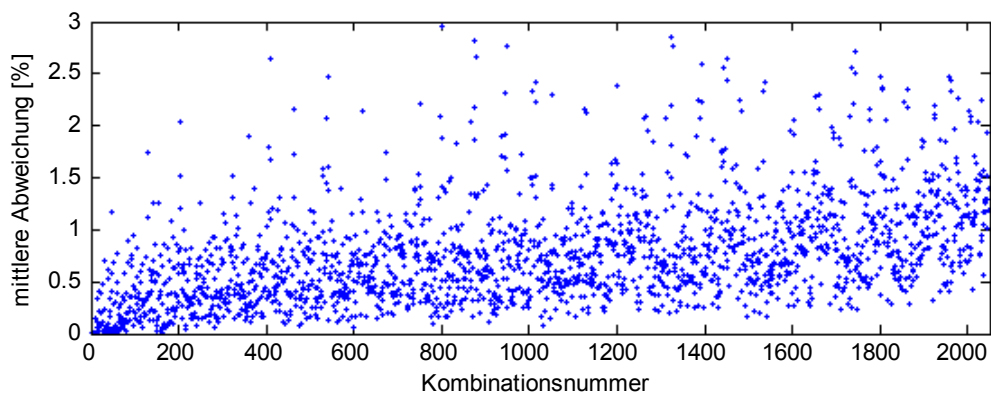


Bild 5.5: Mittlere absolute Abweichungen für Leistungsparameter von jeweils -3% als Funktion der Kombinationsnummer

Durch eine Klassifizierung der Ergebnisse nach der Anzahl der veränderten Leistungsparameter und anschließende Mittelwertbildung für jede Klasse ergibt sich der in Bild 5.6 dargestellte monoton steigende Verlauf. Im Falle der Veränderung aller 11 Leistungsparameter beträgt der Mittelwert der Abweichung $1,3\%$.




Bild 5.6: Mittlere absolute Abweichungen (•) und Mittelwerte der Kategorien (□) für Leistungsparameter von jeweils -3% als Funktion der Anzahl veränderter Leistungsparameter

Es bleibt festzuhalten, dass die mittleren absoluten Abweichungen in Bezug auf die Messwertresiduen zwischen den Ergebnissen des nichtlinearen Ersatzmodells und des Leistungsrechnungsmodells im betrachteten Leistungsparameterbereich von $+1\%$ bis -3% einen Wert von 3% nicht überschreiten. Im Hinblick auf die Diagnoseergebnisse ist zu beachten, dass die simulierten Messdaten ebenfalls mit dem Ersatzmodell generiert wurden. Daraus ergibt sich, dass durch die Verwendung des Ersatzmodells anstelle des Leistungsrechnungsmodells keinerlei Abweichungen in den Diagnoseergebnissen entstehen. Es ist lediglich in Kauf zu nehmen, dass das vom nichtlinearen Ersatzmodell wiedergegebene physikalische Betriebsverhalten des Triebwerkes nicht exakt dem Verhalten des Leistungsrechnungsmodells entspricht.

5.2 Zustandsschätzverfahren

Umfangreiche Untersuchungen der in Abschnitt 2.2.4 dargestellten linearisierten Zustandsschätzverfahren und des in Abschnitt 2.2.5 erläuterten Kalman Filters wurden von Nagy ^[84] durchgeführt. Einige über die grundlegenden Arbeiten von Nagy ^[84] hinausgehende Ergebnisse werden im folgenden Abschnitt präsentiert. Insbesondere wird die Limitierung der Zustandsschätzverfahren diskutiert.

5.2.1 REWLS-Schätzer und Kalman Filter

Im ersten Beispiel wurde ein Einzelfehler mit einer Verschlechterung des Leistungsparameters Nr. 8 vorgegeben ($\Delta LP8 = -1,5\%$). Es wurde eine Messreihe bestehend aus 50 Beobachtungen dieses verschlechterten Zustandes generiert und mit Messunsicherheiten entsprechend Tabelle 5.2 versehen. In Bild 5.7 ist das Diagnoseergebnis von EWLS-Schätzer, REWLS-Schätzer und Kalman Filter dargestellt, wobei die Diagramme von REWLS-Schätzer und Kalman Filter das Ergebnis nach 50 Zeitschritten repräsentieren. Die jeweils ersten Zeitschritte dieser beiden Verfahren sind darüber hinaus identisch mit dem Ergebnis des EWLS-Schätzers (siehe Abschnitt 2.2.5).




Bild 5.7: Diagnoseergebnisse (□) von EWLS-Schätzer, REWLS-Schätzer und Kalman Filter bei einem vorgegebenen Einzelfehler von $\Delta LP8 = -1,5\%$ (■)

Zur Bewertung der Diagnoseergebnisse wird die mittlere quadratische Abweichung (RMS, *Root Mean Square*) zwischen dem Diagnoseergebnis und dem vorgegebenen Fehler herangezogen. Es gilt:

$$\text{RMS} = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (\Delta X_{i,\text{diag}} - \Delta X_{i,\text{soll}})^2} \quad (5.5)$$

Die Ergebnisse der RMS-Werte sind direkt in den Diagrammen in Bild 5.7 angegeben. Darüber hinaus zeigt die Betrachtung des Verlaufes der RMS-Werte (siehe Bild 5.8), dass es sich beim REWLS-Schätzer und beim Kalman Filter bei der Anwendung auf stationäre Systeme um identische Verfahren handelt und dass die Ergebnisse des ersten Zeitschrittes jeweils mit dem EWLS-Schätzer übereinstimmen. Bild 5.8 ist weiterhin zu entnehmen, dass die beiden rekursiven Verfahren nach 13 Zeitschritten ein Minimum des RMS-Wertes erreicht haben.




Bild 5.8: RMS des EWLS-Schätzers und Konvergenzvergleich des REWLS-Schätzers und des Kalman Filters

5.2.2 Kombinatorischer Kalman Filter

Um die Qualität der Lösung zu erhöhen, kann die Wahl des Startwertes ΔX_0 der rekursiven Verfahren verbessert werden. Nagy ^[84] schlägt hierfür die Verwendung des nach Gleichung (2.28) definierten Diagnostischen Index (DI) vor. In der vorliegenden Arbeit wird eine davon abweichende Definition verwendet, die zur Bildung des DI den Mittelwert $\overline{\Delta X_i}$ und nicht dessen Betrag verwendet:

$$\text{DI}_i = \frac{\overline{\Delta X_i}}{\sigma_{\Delta X_i}} \quad \text{mit} \quad \overline{\Delta X_i} = \frac{1}{k} \sum_{j=1}^k \Delta X_i^j. \quad (5.6)$$

Für die 11 zu bestimmenden Leistungsparameter ($n=11$) und die gewählte Instrumentierung ($m=9$) ergeben sich für die Berechnung des DI

$$\binom{11}{9} = 55 \quad (5.7)$$

Leistungsparameterkombinationen. Das Ergebnis des in Abschnitt 5.2.1 diskutierte Beispiels ist in Bild 5.9 dargestellt.




Bild 5.9: Diagnostische Indizes für die Leistungsparameter des in Abschnitt 5.2.1 diskutierten Beispiels

Aus Bild 5.9 ist abzuleiten, dass eine Verschlechterung in LP8 vorliegt, da LP8 über den betragsmäßig größten DI verfügt. Als Startwert für den kombinatorischen Kalman Filter wird für den identifizierten Leistungsparameter

$$\Delta X_{i,0} = DI_i \quad (5.8)$$

verwendet, während alle übrigen Startwerte weiterhin zu null gesetzt werden. Es ergibt sich der folgende Konvergenzverlauf:

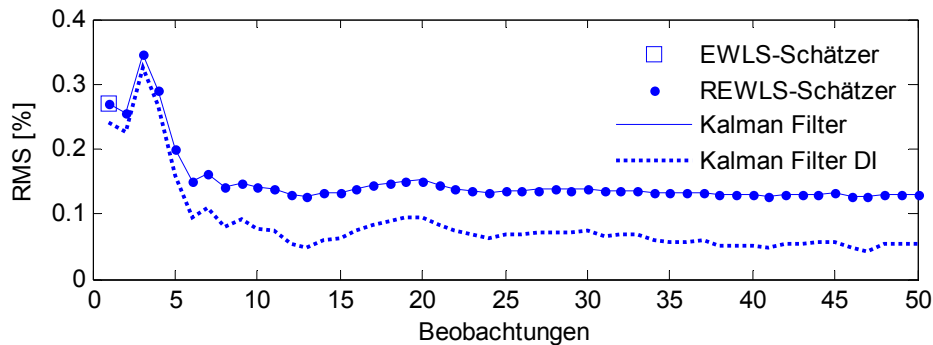


Bild 5.10: RMS des EWLS-Schätzers und Konvergenzvergleich des REWLS-Schätzers, des Kalman Filters und des Kalman Filters mit verbesserter Startwertwahl (DI)

Es ist zu erkennen, dass das Minimum des RMS-Wertes weiterhin nach 13 Zeitschritten erreicht wird und damit die Geschwindigkeit der Konvergenz identisch ist. Allerdings wird die Güte der Diagnose von $RMS=0,13\%$ auf $RMS=0,053\%$ verbessert, d.h. der Verschmiereffekt des Verfahrens wird durch die verbesserte Startwertwahl reduziert (siehe Bild 5.11).

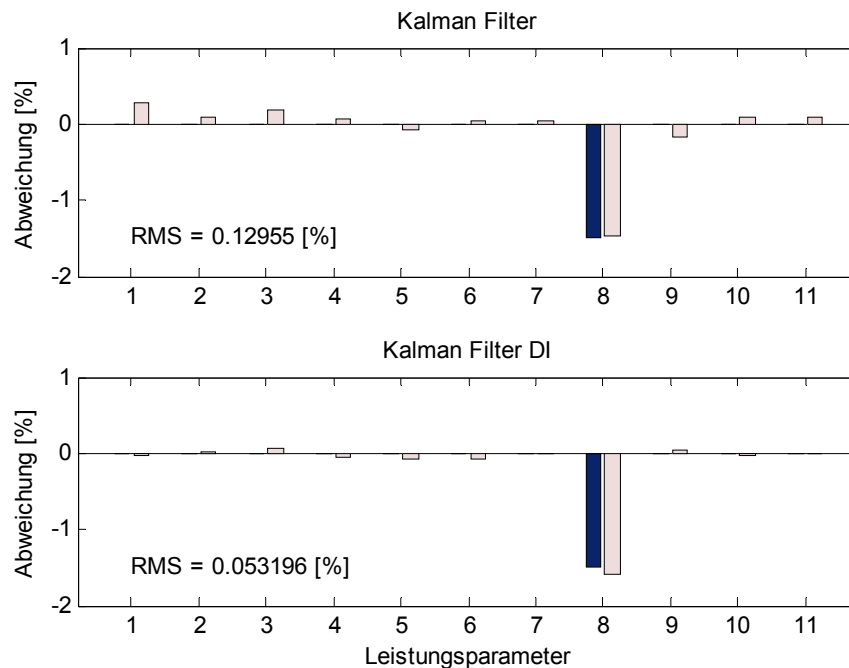


Bild 5.11: Diagnoseergebnisse (■) von Kalman Filter und Kalman Filter mit verbesserter Startwertwahl (DI) bei einem vorgegebenen Einzelfehler von $\Delta LP8 = -1,5\%$ (■)

5.2.3 Limitierung der Zustandsschätzverfahren

Um die Limitierung der Zustandsschätzverfahren zu diskutieren wird ein Fehler mit den Leistungsparametern $\Delta LP1 = -1,0\%$, $\Delta LP2 = -1,5\%$ und $\Delta LP3 = -1,8\%$ generiert. Das Diagnoseergebnis des Kalman Filters mit verbesserter Startwertwahl ist in Bild 5.12 dargestellt. LP2 und LP3 werden als fehlerhaft diagnostiziert, während die berechnete Abweichung in LP1 lediglich in der Größenordnung des Verschmiereffektes liegt. Die Limitierung, nur 1-2 fehlerbehaftete Leistungsparameter korrekt zu diagnostizieren, liegt in der Wahl des Startwertes durch die Verwendung des Diagnostischen Index begründet. Im Startwertvektor wird lediglich der Leistungsparameter mit dem größten DI mit einem Wert ungleich null vorgegeben. Die Verwendung des Diagnostische Index führt somit nicht zu einem optimalen Startwert bezüglich mehrerer fehlerbehafteter Leistungsparameter (siehe Bild 5.13).




Bild 5.12: Diagnoseergebnis (□) des Kalman Filters mit verbesserter Startwertwahl (DI) bei einem vorgegebenen Einzelfehler von $\Delta LP1 = -1,0\%$, $\Delta LP2 = -1,5\%$ und $\Delta LP3 = -1,8\%$ (■)




Bild 5.13: Diagnostische Indizes für die Leistungsparameter des in Bild 5.12 dargestellten Diagnosebeispiels

In Abschnitt 5.3 wird daher ein Verfahren entwickelt, das in der Lage ist, mehrere betroffene Leistungsparameter korrekt zu identifizieren wodurch eine bessere Diagnose erreicht wird. Darüber hinaus wird die Diagnose auf der Basis einer einzelnen Messung durchgeführt, und nicht wie bei den rekursiven Zustandsschätzverfahren auf Basis einer Messreihe.

5.3 Kombinatorische Fuzzy Logic

Das im Rahmen der vorliegenden Arbeit entwickelte Verfahren ^[66] zur Einzelfehlerdiagnose basiert auf einer kombinatorischen Analyse mit anschließender Fuzzy Logic Auswertung, deren Ergebnis in der Identifikation der fehlerbehafteten Leistungsparameter besteht (siehe Bild 5.14). Die Identifikation der Parameter ist dabei nicht scharf, sondern mit einem Wahrscheinlichkeitswert behaftet, der im Intervall $[0,1]$ liegt und als Fuzzy Index (FI) bezeichnet wird. Er stellt die Erweiterung des Diagnostischen Index (DI) aus Abschnitt 5.2.2 dar. Zusätzlich

zum Fuzzy Index liefert das Verfahren ein erstes Diagnoseergebnis, das durch Mittelwertbildung über alle relevanten kombinatorischen Analysen entsteht. Darüber hinaus lässt sich aus dem Fuzzy Index durch Einführung eines Grenzwertes (z.B. $FI > 0,5$) eine scharfe Parameteridentifikation ableiten, auf deren Basis eine nichtlineare Gas-Pfad-Analyse durchgeführt wird (siehe Abschnitt 2.2.7). Das Ergebnis dieser nichtlinearen GPA stellt das Diagnoseergebnis des entwickelten Verfahrens dar.

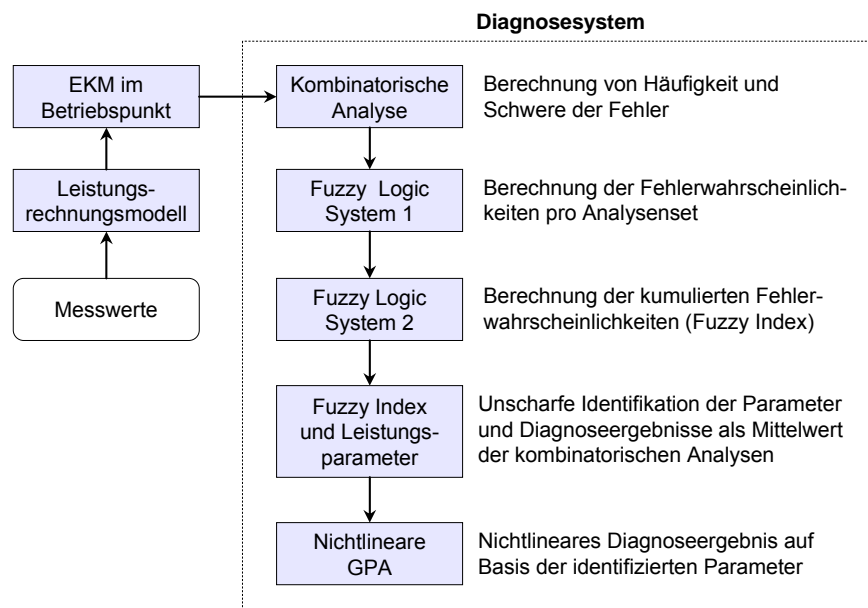


Bild 5.14: Flussdiagramm des entwickelten Diagnoseverfahrens

5.3.1 Kombinatorische Analyse

Im Gegensatz zur Bestimmung des DI werden im entwickelten Verfahren nicht nur alle bestimmten, sondern auch alle überbestimmten Systeme betrachtet. Für den gewählten Fall ($n=11, m=9$) ergeben sich

$$11 + \binom{11}{2} + \binom{11}{3} + \dots + \binom{11}{9} = \sum_{k=1}^9 \binom{11}{k} = 2035 \tag{5.9}$$

zu berechnende Kombinationen, die in 9 »Analysensets« zusammengefasst werden, die aus jeweils

$$\binom{n}{a} = \frac{n!}{(n-a)! \cdot a!}, \quad a \leq n \tag{5.10}$$

Analysen bestehen. Eine Übersicht über die Kombinatorik für den gewählten Fall ist in Tabelle 5.3 dargestellt.

Analysenset Nr.	1	2	3	4	5	6	7	8	9	Summe
Anzahl veränderter LP	1	2	3	4	5	6	7	8	9	
Anzahl Kombinationen	11	55	165	330	462	462	330	165	55	2035
Anzahl »beste 10%«	1	5	16	33	46	46	33	16	5	201

Tabelle 5.3: Übersicht über die Kombinatorik für $n=11$ und $m=9$

Die einzelnen Analysen werden wie folgt durchgeführt:

- » Zur Reduzierung der Rechendauer werden lineare Analysen durchgeführt.
- » Die überbestimmten Systeme (Anzahl der fehlerhaften Leistungsparameter kleiner als Anzahl der Messwerte) werden mit Hilfe des LS-Schätzers nach Gleichung (2.13) analysiert.
- » Die bestimmten Systeme (Anzahl der fehlerhaften Leistungsparameter gleich der Anzahl der Messwerte) werden durch Invertierung der Einflusskoeffizienten-Matrix nach Gleichung (2.8) analysiert.

Zur Bewertung der Analysen wird der mit den Abweichungen zwischen Messwerten und diagnostizierten Messwerten gebildete Güteparameter $RMSy$ verwendet:

$$RMSy = \sqrt{\frac{1}{m} \cdot \sum_{i=1}^m (\Delta Y_{i,diag} - \Delta Y_{i,mess})^2} \quad (5.11)$$

Alle Analysen werden innerhalb ihres Analysensets nach aufsteigendem $RMSy$ -Wert sortiert, wobei die Analyse mit dem geringsten $RMSy$ -Wert die beste Übereinstimmung zwischen Messwerten und diagnostizierten Messwerten aufweist.

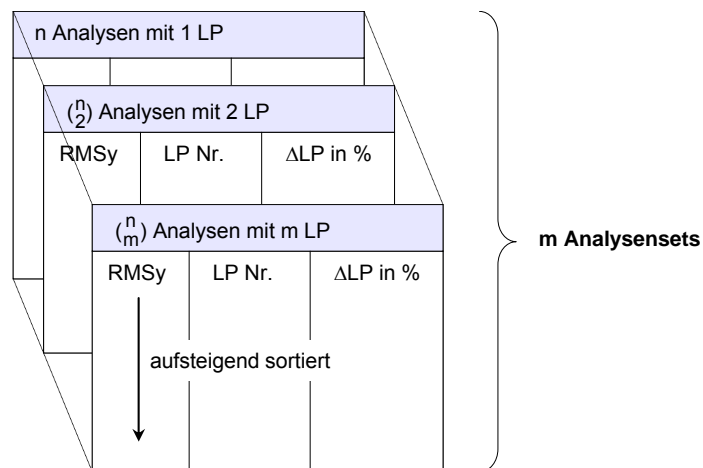


Bild 5.15: Grafische Darstellung der Analysensets

Darüber hinaus beinhaltet jedes Analysenset die Nummern der veränderten Leistungsparameter und deren Abweichungen ΔLP (siehe Bild 5.15). Zur anschließenden Fuzzy Logic Auswertung werden nur die jeweils besten 10% der Analysen jedes Analysensets herangezogen. Die entsprechende Anzahl ist in Tabelle 5.3 aufgeführt. Zu jedem Analysenset wird durch Mittelwertbildung über die besten 10% der Analysen ein Diagnoseergebnis berechnet.

Zur weiteren Erklärung der kombinatorischen Analyse wird das Beispiel aus Abschnitt 5.2.3 verwendet, das die Verschlechterungen der Leistungsparameter $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$ aufweist. Tabelle 5.4 beinhaltet eine Auswahl der Ergebnisse des Analysensets Nr.2 für dieses Beispiel.

Nr.	RMSy	veränderte LP		Abweichung in [%]	
1*	0,5545	LP3	LP11	$\Delta LP3=-1,8722$	$\Delta LP11=0,3991$
2*	0,9098	LP1	LP3	$\Delta LP1=-0,8184$	$\Delta LP3=-2,3969$
3*	1,3207	LP3	LP4	$\Delta LP3=-1,7804$	$\Delta LP4=-1,4845$
4*	1,3695	LP3	LP6	$\Delta LP3=-2,0673$	$\Delta LP6=-0,3706$
5*	1,3947	LP3	LP7	$\Delta LP3=-1,7618$	$\Delta LP7=-0,4725$
6	1,401	LP3	LP5	$\Delta LP3=-1,7985$	$\Delta LP5=-0,7255$
7	1,4327	LP2	LP3	$\Delta LP2=-0,8084$	$\Delta LP3=-1,3866$
8	1,4468	LP3	LP8	$\Delta LP3=-1,9587$	$\Delta LP8=-0,1687$
9	1,4516	LP3	LP9	$\Delta LP3=-2,0779$	$\Delta LP9=-0,4305$
10	1,4957	LP3	LP10	$\Delta LP3=-1,8077$	$\Delta LP10=0,0396$
...

Tabelle 5.4: Auswahl der Ergebnisse des Analysensets Nr.2
(beste 10% der Analysen mit * gekennzeichnet)

Das Diagnoseergebnis jedes Analysensets besteht aus zwei Komponenten:

- » Abweichung jedes LP gemittelt über die besten 10% der Analysen
- » Relative Häufigkeit jedes LP innerhalb der besten 10% der Analysen

Auffällig ist Leistungsparameter LP3, der in allen Analysen der besten 10% vertreten ist (und damit über eine relative Häufigkeit von 1,0 verfügt) und einen über diese Analysen gemittelten Wert von $\Delta LP3=-1,97572\%$ aufweist. Das vollständige Diagnoseergebnis des Analysensets Nr.2 bestehend aus den mittleren Abweichungen und den relativen Häufigkeiten der Leistungsparameter ist in Bild 5.16 dargestellt. Die Leistungsparameter LP1, LP4, LP6, LP7 und LP11 verfügen über relative Häufigkeiten von 0,2, da sie jeweils in einer der 5 besten Analysen vertreten sind.




Bild 5.16: Diagnoseergebnis des Analysensets Nr.2 mit mittleren Abweichungen (□) und relativen Häufigkeiten (■) für $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$ (■)

Der Leistungsparameter LP2 ist nicht unter den besten 10% der Analysen vertreten und ist daher nicht Teil des Diagnoseergebnisses. Diese Tatsache verdeutlicht, dass sich die kombinatorische Auswertung nicht auf eine bestimmte Anzahl betroffener Parameter beschränken kann. Die Auswertung muss auf der Basis aller Analysensets durchgeführt werden.

5.3.2 Fuzzy Logic Auswertung

Die Fuzzy Logic Auswertung der kombinatorischen Analysen wird in den folgenden zwei Schritten durchgeführt, die jeweils durch ein eigenständiges Fuzzy Logic System (FLS) abgebildet sind:

- » FLS1: Berechnung des Fuzzy Index für jedes Analysenset
- » FLS2: Kumulierung der Fuzzy Indizes über alle Analysensets

Mit Hilfe des FLS1 wird aus den relativen Häufigkeiten und den mittleren Abweichungen der besten 10% der kombinatorischen Analysen der Fuzzy Index für jedes Analysenset berechnet (siehe Bild 5.17).




Bild 5.17: Flussdiagramm zur Berechnung der Fuzzy Indizes für jedes Analysenset (FLS1)

Wie bereits in Abschnitt 2.3.2 erläutert, wird die Verknüpfung zwischen den Ein- und Ausgängen eines FLS durch Zugehörigkeitsfunktionen und Regeln bestimmt. Dazu werden die Ein- und Ausgänge des Systems in Kategorien eingeteilt (siehe Tabelle 5.5), die durch Zugehörigkeitsfunktionen beschrieben werden. Mit Hilfe der Regeln wird die Abbildung der Eingänge auf die Ausgänge definiert. In Tabelle 5.6 sind die 12 Regeln des FLS1 in verkürzter Form zusammengefasst. Die Schreibweise $A B \rightarrow C$ bedeutet, dass eine relative Häufigkeit mit dem Wert »A« und eine mittlere Abweichung mit dem Wert »B« einen Fuzzy Index mit dem Wert »C« ergeben.

relative Häufigkeit	mittlere Abweichung	Fuzzy Index
1 = low	1 = zero	1 = not existent
2 = medium	2 = low	2 = unlikely
3 = high	3 = medium	3 = likely
	4 = high	4 = very likely
		5 = existent

Tabelle 5.5: Klassifizierung der Ein- und Ausgänge des FLS1

Nr.	Regel	Nr.	Regel	Nr.	Regel
1	1 1 \rightarrow 1	5	2 1 \rightarrow 1	9	3 1 \rightarrow 1
2	1 2 \rightarrow 1	6	2 2 \rightarrow 2	10	3 2 \rightarrow 3
3	1 3 \rightarrow 1	7	2 3 \rightarrow 3	11	3 3 \rightarrow 4
4	1 4 \rightarrow 2	8	2 4 \rightarrow 4	12	3 4 \rightarrow 5

Tabelle 5.6: Übersicht über die Regeln des FLS1

Zusammen mit den in Bild 5.18 und Bild 5.19 dargestellten Zugehörigkeitsfunktionen des FLS1 ergibt sich aus den in Tabelle 5.6 definierten Regeln der Fuzzy Index in Abhängigkeit der relativen Häufigkeit und der mittleren Abweichung.




Bild 5.18: Zugehörigkeitsfunktionen der Eingänge des FLS1




Bild 5.19: Zugehörigkeitsfunktionen des Ausgangs des FLS1

Diese durch das FLS abgebildete Eingangs-Ausgangs-Beziehung lässt sich mit Hilfe einer Antwortfläche dreidimensional darstellen (siehe Bild 5.20). An der Antwortfläche lassen sich die Überlagerungen der einzelnen Regeln ablesen. So wird beispielsweise das Plateau $FI=1,0$ von Regel Nr.12 ($3\ 4 \rightarrow 5$) beeinflusst, wohingegen das Plateau $FI=0,25$ durch Regel Nr.4 ($1\ 4 \rightarrow 2$) gebildet wird. Die Flanken der Antwortfläche entstehen durch die Überlagerung der übrigen Regeln.




Bild 5.20: Visualisierung des FLS1 mit Hilfe einer Antwortfläche

Das Fuzzy Logic System FLS1 ist nur für Leistungsparameter anzuwenden, die ausschließlich negative Abweichungen (Verschlechterungen) aufweisen. Um auch positive Abweichungen berücksichtigen zu können wurde ein entsprechendes Fuzzy Logic System (FLS1b) erstellt, das sich lediglich in der Definition der Zugehörigkeitsfunktionen des Eingangs »Abweichung« von FLS1 unterscheidet. (siehe Bild 5.21). Weitere Details zum Fuzzy Logic System FLS1b sind im Anhang A.1 zu finden.

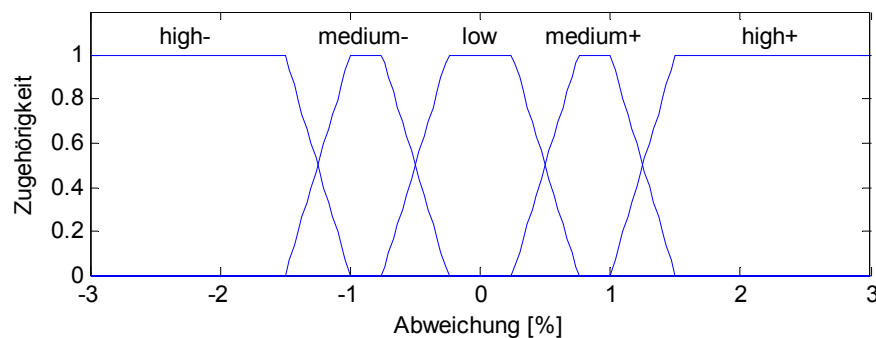


Bild 5.21: Zugehörigkeitsfunktionen des Eingangs »Abweichung« des FLS1b (zur Berücksichtigung positiver Abweichungen)

Nach der Anwendung des FLS1 bzw. FLS1b auf alle Analysensets, liegt für jeden Leistungsparameter ein Fuzzy Index pro Analysenset vor. Die Aufgabe des folgenden Fuzzy Logic Systems FLS2 ist die Kumulierung der Ergebnisse über alle Analysensets hinweg, so dass sich als Endergebnis ein einziger Fuzzy Index und eine mittlere Abweichung pro Leistungsparameter ergibt. Das erstellte FLS2 verwendet dazu drei Eingänge und einen Ausgang (siehe Bild 5.22).

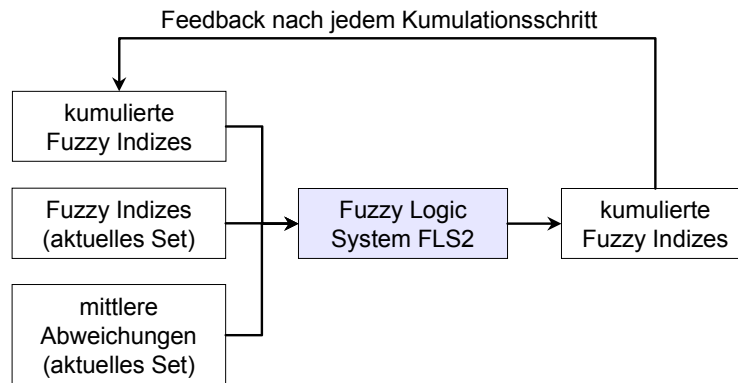


Bild 5.22: Flussdiagramm zur Berechnung der kumulierten Fuzzy Indizes über alle Analysensets (FLS2)

Das Ergebnis der kumulierten Fuzzy Indizes nach jedem Schritt stellt dabei einen Eingang des nächsten Kumulationsschrittes dar. Der Startwert des kumulierten Fuzzy Index liegt für alle Leistungsparameter bei $FI=0,5$. Dieser Wert wird nach jedem Schritt entsprechend der festgelegten Regeln im Rahmen der Klassifizierung herauf- oder herabgestuft, wodurch nach Bearbeitung aller Analysensets ein kumulierter Ergebniswert entsteht. Die Klassifizierungen der Ein- und Ausgänge sowie eine Übersicht über die Regeln des FLS2 sind im Anhang A.2 zu finden. Entsprechend der Definition von FLS1b wird auch für das FLS2 ein weiteres System für die Berücksichtigung positiver Veränderungen (Verbesserungen) von Leistungsparametern definiert. Die entsprechenden Informationen zu diesem System (FLS2b) sind im Anhang A.3 aufgeführt.




Bild 5.23: Verlauf des Fuzzy Index über die Kumulationsschritte für den Fehler $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$

Der Verlauf der Fuzzy Indizes über die Kumulationsschritte ist in Bild 5.23 für das in Abschnitt 5.3.1 diskutierte Beispiel dargestellt. Es ist zu erkennen, dass ausgehend von einem Startwert von $FI=0,5$ die Fuzzy Indizes der Leistungsparameter

parameter LP1, LP2 und LP3 zu einem Endwert von $FI=1,0$ kumulieren. Die übrigen Fuzzy Indizes bleiben dagegen unter Werten von $FI=0,25$.

Das Ergebnis der Fuzzy Logic Auswertung besteht im Ergebnis der Fuzzy Indizes nach der Kumulation (Bild 5.24 links) und den über die relevanten Analysen gemittelten Abweichungen (Bild 5.24 rechts). Unter »relevanten Analysen« werden dabei die besten 10% der kombinatorischen Analysen verstanden, die für die Fuzzy Logic Auswertung herangezogen wurden.




Bild 5.24: Kumulierter Fuzzy Index (■) und Diagnoseergebnis der kombinatorischen Analysen (□) für den Fehlerfall $\Delta LP1=-1,0\%$, $\Delta LP2=-1,5\%$ und $\Delta LP3=-1,8\%$ (■)

5.3.3 Nichtlineare Diagnose

Das in Bild 5.24 dargestellte Diagnoseergebnis weist einen RMS-Wert von 0,28384% auf. Dieses Ergebnis kann verbessert werden, indem der Fuzzy Logic Auswertung eine nichtlineare Gas-Pfad-Analyse (siehe Abschnitt 2.2.7) nachgeschaltet wird. Hierfür werden aus dem kumulierten Fuzzy Index durch Einführung eines Identifikationslimits (z.B. $FI>0,5$) die fehlerbehafteten Leistungsparameter abgeleitet. Aus den identifizierten Leistungsparametern und den Messwerten ergibt sich immer ein unterbestimmtes System, das somit durch eine nichtlineare GPA analysiert werden kann. Für das in den vorigen Abschnitten diskutierte Beispiel ergibt sich ein Diagnoseergebnis mit einem RMS-Wert von 0,052437%, was einer Reduktion des RMS-Wertes um 81,5% gegenüber dem mittleren Ergebnis der kombinatorischen Analysen entspricht (siehe Bild 5.25).




Bild 5.25: Diagnoseergebnis (□) der kombinatorischen Analyse und der nichtlinearen GPA für einen vorgegebenen Einzelfehler mit $\Delta LP1 = -1,0\%$, $\Delta LP2 = -1,5\%$ und $\Delta LP3 = -1,8\%$ (■)

5.3.4 Statistische Bewertung

Entsprechend der statistischen Bewertung des Detektionsverfahrens (siehe Abschnitt 4.3.6) wurde auch das entwickelte Diagnoseverfahren im Rahmen einer Versuchsreihe mehreren tausend Testfällen unterzogen. Zur statistischen Bewertung wurden die folgenden Gütegrade definiert:

$$\text{Identifikationsrate} = \frac{\text{Anzahl korrekt identifizierter LP}}{\text{Anzahl vorhandener LP}} \quad (5.12)$$

$$\text{Fehlidentifikationsrate} = \frac{\text{Anzahl inkorrekt identifizierter LP}}{\text{Anzahl vorhandener LP}} \quad (5.13)$$

$$\text{Diagnoserate} = \frac{\text{Anzahl korrekt diagnostizierter LP}}{\text{Anzahl vorhandener LP}} \quad (5.14)$$

$$\text{Fehldiagnoserate} = \frac{\text{Anzahl inkorrekt diagnostizierter LP}}{\text{Anzahl vorhandener LP}} \quad (5.15)$$

Die in Bild 5.26 dargestellten Bewertungsmatrizen veranschaulichen die definierten Gütegrade, wobei die farblich markierten Bereiche jeweils paarweise zu den oben definierten Raten beitragen. Im Gegensatz zur Bewertung der Detektion wird bei der Bewertung von Identifikation und Diagnose nicht zwischen »positiv« und »negativ« unterschieden. Es gilt daher, dass die Summe aus Identifikationsrate und Fehlidentifikationsrate bzw. aus Diagnoserate und Fehldiagnoserate jeweils den Wert 1 ergibt.

		Fehler identifiziert		Fehler diagnostiziert	
		Ja	Nein	Ja	Nein
Fehler existent	Ja	Identifikation (korrekt positiv)	Fehlidentifikation (falsch negativ)	Diagnose (korrekt positiv)	Fehldiagnose (falsch negativ)
	Nein	Fehlidentifikation (falsch positiv)	Identifikation (korrekt negativ)	Fehldiagnose (falsch positiv)	Diagnose (korrekt negativ)

Bild 5.26: Matrix zur Definition der verschiedenen Gütegrade zur Bewertung von Identifikation und Diagnose

Zur Definition einer korrekten Diagnose wird ein Diagnoselimit eingeführt, das die maximal zulässige Differenz zwischen der existenten und der diagnostizierten Abweichung des betrachteten Leistungsparameters darstellt. Die Ergebnisse der statistischen Bewertung sind in Bild 5.27 und Bild 5.28 dargestellt. Die Identifikationsrate (Bild 5.27) sinkt linear mit wachsender Anzahl der betroffenen Parameter, während die Diagnoserate einen parabelförmigen Verlauf zeigt (Bild 5.28). Die Diagnoserate sinkt zusätzlich mit sinkendem Diagnoselimit. Für ein Diagnoselimit von 0,5 werden Diagnoseraten von über 98% erreicht falls maximal 2 betroffene Leistungsparameter vorliegen. Für Diagnoseraten von über 88% dürfen bei einem Diagnoselimit von 0,5 maximal 5 betroffene Leistungsparameter vorliegen, bei einem Diagnoselimit von 0,3 maximal 4 betroffene Parameter und bei einem Diagnoselimit von 0,1 maximal 3 betroffene Parameter (siehe Bild 5.28).




Bild 5.27: Identifikationsrate als Funktion der Anzahl der betroffenen Leistungsparameter




Bild 5.28: Diagnoserate als Funktion der Anzahl der betroffenen Leistungsparameter mit Variation des Diagnoselimits

5.4 Fazit

Das in Abschnitt 5.3 entwickelte Verfahren zur Diagnose von Einzelfehlern bietet gegenüber bisher in der Literatur beschriebenen Verfahren folgende Vorteile:

- » Es bedarf keiner a-priori Informationen über die betroffenen Leistungsparameter, weder deren Anzahl noch deren Kombination, und es werden keinerlei Beziehungen zwischen den Leistungsparametern angenommen.
- » Es können beliebige Kombinationen an betroffenen Leistungsparametern diagnostiziert werden, wobei die maximal diagnostizierbare Anzahl an Leistungsparametern der Anzahl der vorhandenen Messwerte entspricht.
- » Die Diagnose ist auf der Basis einzelner Messzeitpunkte durchführbar. Es ist keine zeitliche Beobachtung der Messwerte notwendig.
- » Das Diagnoseergebnis der Methode besteht nicht nur in der Berechnung der Abweichungen der Leistungsparameter, sondern auch aus der Berechnung des Fuzzy Index jedes Parameters, der als Wahrscheinlichkeit interpretiert werden, mit der jeder Leistungsparameter vom Fehler betroffen ist.
- » Die Methode ist robust gegenüber Messrauschen, da sie auf einer statistischen Auswertung vieler potentieller Diagnosen beruht.
- » Im Gegensatz zu Systemen, die auf Neuronalen Netzen basieren, ist keinerlei Trainingsaufwand nötig.

Das entwickelte Verfahren stellt somit einen signifikanten Fortschritt gegenüber den bisher in der Literatur beschriebenen Verfahren dar.

Kapitel 6: Diagnose gradueller Verschlechterungen

Bei der Diagnose gradueller Verschlechterung bedarf es der Lösung eines unterbestimmten Systems. Die Schließung des unterbestimmten Systems kann dabei entweder durch die Erweiterung der Zielfunktion nach Gleichung (2.30) oder durch die Definition von Nebenbedingungen geschehen. Da bei der erweiterten Definition der Zielfunktion die Lösung maßgeblich von den gewählten Konstanten C_1 und C_2 abhängt, die keine allgemeine Gültigkeit aufweisen, wurde im Rahmen der vorliegenden Arbeit eine Optimierung mit Nebenbedingungen durchgeführt.

6.1 Generierung eines Alterungsbeispiels

Zur Demonstration des Verfahrens wurde ein Alterungsfall mit 30 Zyklen modelliert. Bezüglich des Verlaufes der Veränderung der einzelnen Leistungsparameter stehen Analysen historischer Daten zur Verfügung, die zeigen, dass Alterung zu Verringerungen von Wirkungsgraden und Verdichterkapazitäten sowie zu Steigerungen der Turbinen- und Düsenkapazitäten führt (Sallee ^[104] und Wulf ^[138]). Weitere Beispielfälle sind bei Mathioudakis et al. ^[77] sowie bei Simon et al. ^[109] zu finden, die ebenfalls die oben genannten Verläufe beschreiben. Die Start- und Endwerte der Leistungsparameterveränderungen sind in Tabelle 6.1 aufgelistet. Für das in diesem Kapitel verwendete Alterungsbeispiel wurden lineare Verläufe der Parameter vorgegeben.

LP Nr.	1	2	3	4	5	6	7	8	9	10	11
Δ LP Startwert	0	0	0	0	0	0	0	0	0	0	0
Δ LP Endwert	-3	-3	-3	-3	-3	-3	-3	+2	-3	+2	+2

Tabelle 6.1: Intervalle der Leistungsparameter des Alterungsbeispiels

6.2 Nichtlineare Optimierung

Die verwendete Zielfunktion der Form (2.29) wurde auf die ungewichteten mittleren Fehlerquadrate der Differenzen zwischen den Residuen der Bayesischen Vorhersage $\Delta Y_{\text{BF},i}$ und den mit Hilfe der Optimierung berechneten Residuen $\Delta Y_{\text{Opt},i}$ angewendet. Es gilt:

$$\text{ZF}_3 = \sqrt{\frac{1}{m} \cdot \sum_{i=1}^m (\Delta Y_{\text{BF},i} - \Delta Y_{\text{Opt},i})^2} \quad \text{mit} \quad \Delta Y_{\text{X},i} = \frac{Y_{\text{E},i} - Y_{\text{X},i}}{Y_{\text{X},i}} \quad (6.1)$$

Durch die Verwendung der Residuen der Bayesischen Vorhersage $\Delta Y_{\text{BF},i}$ anstelle der gemessenen Residuen $\Delta Y_{\text{M},i}$ wird eine Reduzierung des Einflusses des Messrauschens und damit eine Verbesserung der Optimierungsqualität erreicht.

6.2.1 Unbeschränkte Optimierung

Um die Notwendigkeit der Definition von Nebenbedingungen zu unterstreichen wurde zunächst eine Optimierung ohne Nebenbedingungen durchgeführt. Hierzu wurde eine Trust-Region-Methode verwendet, die die Zielfunktion innerhalb eines Vertrauensgebietes (*Trust Region*) approximiert und anschließend das Minimum der Näherungsfunktion bestimmt. Details zum verwendeten Algorithmus sind bei Coleman ^[18,19] zu finden.

In Bild 6.1 sind die berechneten Verläufe der Leistungsparameter (o) den vorgegebenen Verläufen (—) entgegengestellt. Zusätzlich ist zu jedem Leistungsparameter der über der Zyklenzahl gemittelte quadratische Fehler

$$\text{RMS}_i = \sqrt{\frac{1}{\text{Zyklenzahl}} \cdot \sum_{t=1}^{\text{Zyklenzahl}} (\Delta X_{i,\text{diag},t} - \Delta X_{i,\text{soll},t})^2} \quad (6.2)$$

angegeben. Der Verlauf der Zielfunktion ZF_3 vervollständigt die Darstellung. Beachtenswert ist, dass die Richtungen der Veränderungen (Verringerung bzw. Steigerung) in allen Leistungsparametern korrekt erkannt wird. Der Mittelwert der Zielfunktion beträgt 4,9614e-6, was auf eine hervorragende Übereinstimmung zwischen berechneten und geforderten Messwertresiduen schließen lässt. Allerdings ist zu erkennen, dass die Leistungsparameter LP1, LP3 und LP9 die größten RMS-Werte und damit die größten Abweichungen in den diagnostizierten Verläufen ausweisen. Die Frage, warum gerade diese Leistungsparameter die schlechtesten Diagnoseergebnisse aufweisen, wird in Abschnitt 6.3 geklärt.




Bild 6.1: Diagnoseergebnis (o) der Alterung (—) und Verlauf der Zielfunktion (ZF) ohne Definition von Nebenbedingungen

Der über alle Leistungsparameter gemittelte RMS-Wert liegt bei 0,4264%. Dieser Wert kann als allgemeines Gütekriterium der Diagnose des Alterungsverlaufes herangezogen werden. Im folgenden Abschnitt wird gezeigt, dass dieser Wert durch die Definition von Nebenbedingungen verbessert werden kann.

6.2.2 Optimierung mit Nebenbedingungen

Für die Optimierung mit Nebenbedingungen wurde die Methode der Sequentiellen Quadratischen Programmierung gewählt (SQP-Verfahren). Der Algorithmus basiert auf der Zerlegung der in Gleichung (2.36) definierten Optimierungsaufgabe in ein quadratisches Problem in jedem Schritt, dessen Lösung die Suchrichtung darstellt. In dieser Hinsicht handelt es sich beim SQP-Verfahren um eine Verallgemeinerung des Quasi-Newton-Verfahrens, bei dem die Suchrichtung in jedem Schritt durch die Minimierung einer quadratischen Modellfunktion bestimmt wird. Weitere Details zum SQP-Verfahren sind bei Grimm und Well ^[41] zu finden.

Es wurden drei verschiedene Versionen von Nebenbedingungen untersucht:

- » **Version 1:** Für alle Leistungsparameter werden allgemeine Unter- und Obergrenzen definiert. Es gilt $-3\% \leq \Delta LP \leq +3\%$ für alle Parameter.
- » **Version 2:** Für jeden Leistungsparameter werden individuelle Unter- und Obergrenzen eingeführt. Für Wirkungsgrade und Verdichterkapazitäten gilt $-3\% \leq \Delta LP \leq 0\%$. Für Turbinen- und Düsenkapazitäten wird das Intervall $0\% \leq \Delta LP \leq +3\%$ definiert.
- » **Version 3:** Zusätzlich zu den in Version 2 definierten individuellen Unter- und Obergrenzen wird eine maximale Veränderung der Leistungsparameter δ_{\max} zwischen zwei Zeitschritten definiert. Aus Gründen der numerischen Robustheit wird diese Grenze nicht einseitig, sondern zweiseitig definiert, wobei durch Einführung von Richtungsfaktoren C_3 und C_4 eine Vorzugsrichtung festgelegt werden kann. Es gilt:

$$\Delta LP_{t-1} - C_3 \cdot \delta_{\max} \leq \Delta LP_t \leq \Delta LP_{t-1} + C_4 \cdot \delta_{\max} \quad (6.3)$$




Bild 6.2: Diagnoseergebnis (o) der Alterung (—) und Verlauf der Zielfunktion (ZF) mit Nebenbedingungen Version 1

Da die absolute Größe der Terme $C_3 \cdot \delta_{\max}$ bzw. $C_4 \cdot \delta_{\max}$ durch die Wahl von δ_{\max} festgelegt werden kann, ist nur das Verhältnis der Faktoren C_3 und C_4 von Interesse. Untersuchungen haben ergeben, dass ein Verhältnis von 2:1 ein gutes Maß darstellt, um eine Vorzugsrichtung für die Leistungsparameter vorzugeben ohne dabei den Optimierungsalgorithmus zu sehr einzuschränken und damit die numerische Robustheit signifikant zu verschlechtern. Für Leistungsparameter mit fallender Tendenz (Wirkungsgrade und Verdichterkapazitäten) wurden daher die Richtungsfaktoren $C_3=1,0$ und $C_4=0,5$ gewählt, für Leistungsparameter mit steigender Tendenz (Turbinen- und Düsenkapazitäten) $C_3=0,5$ und $C_4=1,0$.




Bild 6.3: Diagnoseergebnis (o) der Alterung (—) und Verlauf der Zielfunktion (ZF) mit Nebenbedingungen Version 2

Die Ergebnisse der drei Optimierungsversionen sind in Bild 6.2 bis Bild 6.4 abgebildet. Die Darstellungsweise entspricht der in Bild 6.1. Die Ergebnisse der Version 1 (Bild 6.2) zeigen deutliche Ähnlichkeit mit den Ergebnissen der unbeschränkten Optimierung (Bild 6.1). Die Einführung der Untergrenze in LP9 führt jedoch zu einer Verbesserung des Diagnoseergebnisses, die sich auch in LP1 bemerkbar macht. Der über alle Leistungsparameter gemittelte RMS-Wert sinkt auf 0,3661%. Trotz dieser Verbesserung weisen die Parameter LP1, LP3 und LP9

weiterhin die größten Diagnoseabweichungen auf. Der mittlere Zielfunktionswert steigt um eine Größenordnung auf $4,9598e-5$.

Durch die Einführung der individuellen Ober- und Untergrenzen (Version 2, Bild 6.3) wird eine erhebliche Verbesserung erzielt. Die RMS-Werte aller Leistungsparameter sinken. In der Summe wird fast eine Halbierung des gemittelten RMS-Wertes von $0,3661\%$ auf $0,1946\%$ erzielt. Diese Verbesserung ist mit einer Erhöhung der Zielfunktion um zwei Größenordnungen auf $3,0785e-3$ verbunden.

Die Einführung einer maximalen Schrittweite δ_{\max} (Version 3, Bild 6.4) bringt eine weitere Reduktion des gemittelten RMS-Wertes auf $0,1893\%$. Dies stellt gegenüber der Verbesserung zwischen Version 1 und Version 2 lediglich eine marginale Verbesserung dar, die darüber hinaus mit einer Erhöhung des mittleren Zielfunktionswertes auf $8,02015e-2$ erkauft werden muss. Bei dieser Version hängt die Güte der Diagnose darüber hinaus von der gewählten Schrittweite δ_{\max} ab. Liegt diese in der Größenordnung des wahren Gradienten der Leistungsparameterveränderungen, so können gute Ergebnisse erzielt werden, andernfalls stellt diese Bedingung eine zu starke Einschränkung der Optimierung dar.




Bild 6.4: Diagnoseergebnis (o) der Alterung (—) und Verlauf der Zielfunktion (ZF) mit Nebenbedingungen Version 3

6.2.3 Fazit

Eine Übersicht über die RMS-Werte und die mittleren Zielfunktionswerte der diskutierten Optimierungen ist in Tabelle 6.2 abgebildet. Die jeweils größten RMS-Werte sind markiert. Es ist zu erkennen, dass die Leistungsparameter LP1, LP3, LP9 und LP10 jeweils die schlechtesten Diagnoseergebnisse aufweisen. Weiterhin ist zu erkennen, dass der Mittelwert der RMS-Werte mit der Definition der Nebenbedingungen sinkt, was eine Verbesserung der Diagnoseergebnisse anzeigt. Dem entgegen steht die Erhöhung des Mittelwertes der Zielfunktion, was auf die steigende Einschränkung der Optimierung und damit die Verschlechterung der Übereinstimmung zwischen berechneten und geforderten Messwertresiduen zurückzuführen ist.

RMS des LP Nr.	keine NB	NB Version 1	NB Version 2	NB Version 3
1	0,9620 %	0,6725 %	0,2422 %	0,1855 %
2	0,2732 %	0,2087 %	0,0993 %	0,2650 %
3	0,6919 %	0,6456 %	0,4251 %	0,4397 %
4	0,5565 %	0,4649 %	0,2463 %	0,2815 %
5	0,2107 %	0,1682 %	0,1388 %	0,0554 %
6	0,1729 %	0,1939 %	0,1228 %	0,1402 %
7	0,2822 %	0,2223 %	0,1231 %	0,0536 %
8	0,3488 %	0,2846 %	0,1795 %	0,1798 %
9	0,7933 %	0,5615 %	0,2586 %	0,0536 %
10	0,1237 %	0,3863 %	0,2021 %	0,2416 %
11	0,2753 %	0,2185 %	0,1031 %	0,1861 %
RMS-Mittelwert	0,4264 %	0,3661 %	0,1946 %	0,1893 %
ZF-Mittelwert	4,9614 e-6	4,9598 e-5	3,0785 e-3	8,02015 e-2

Tabelle 6.2: Übersicht über die RMS-Werte der Alterungsdiagnosen

Optimierungsversion 2 stellt in Bezug auf diese beiden Anforderungen den besten Kompromiss dar. Optimierungsversion 3 führt zwar gegenüber Version 2 zu einer Verbesserung des Diagnoseergebnisses, es besteht jedoch noch Verbesserungsbedarf in Bezug auf die Definition der Schrittweite δ_{\max} . Durch die Definition einer festen maximalen Schrittweite können nur lineare Veränderungen optimal abgebildet werden. Um für die Diagnose nichtlinearer Veränderungen gegenüber Optimierungsversion 2 eine Verbesserung zu erzielen, sollte die Schrittweite δ_{\max} adaptiv gestaltet werden. Die adaptive Wahl der Schrittweite könnte auf einer Modellierung der Diagnoseergebnisse basieren, die z.B. mit Regressionsverfahren (Abschnitt 2.5.1) oder Dynamischen Linearen Modellen (Abschnitt 4.3) durchgeführt werden könnte.

6.3 Einfache Beobachtbarkeitsanalyse

Die Beobachtbarkeitsanalyse liefert ein mathematisches Werkzeug zur Bestimmung derjenigen Leistungsparameter, die systematisch die schlechtesten Diagnoseergebnisse aufweisen. Ein System heißt beobachtbar, wenn sein Zustand ΔX vollständig und exakt aus den vorliegenden Messwerten ΔY bestimmt werden kann^[98]. Dies ist nur für bestimmte ($n=m$) oder überbestimmte Systeme ($n < m$) möglich. Unterbestimmte Systeme ($n > m$) sind per Definition nicht beobachtbar. Wie im vorigen Abschnitt gezeigt, lassen sie sich dennoch durch die Einführung geeigneter Nebenbedingungen näherungsweise lösen. Die Aufgabe der in diesem Abschnitt erläuterten Beobachtbarkeitsanalyse besteht in der Bewertung jedes Leistungsparameters hinsichtlich seiner Beobachtbarkeit.

Nach Roesnick^[98] basiert die Beobachtbarkeitsanalyse auf der Bestimmung der Eigenwerte und der Eigenvektoren des Ausdrucks

$$EKM^T \cdot EKM . \quad (6.4)$$

Da sich die Methode aus der linearen Algebra ableitet, wird sie auch als geometrische Beobachtbarkeitsanalyse bezeichnet. Alternativ zur Bestimmung der Eigenwerte von (6.4) können auch die Singulärwerte der EKM bestimmt werden, wobei gilt, dass die Singulärwerte σ_i die Wurzeln der Eigenwerte λ_i darstellen:

$$\sigma_i = \sqrt{\lambda_i} . \quad (6.5)$$

Da die Methode jedoch die Eigenvektoren von (6.4) benötigt, ist die Berechnung der Eigenwerte ohnehin notwendig. Die Eigenwerte des betrachteten Systems sind in Bild 6.5 dargestellt.




Bild 6.5: Darstellung der Eigenwerte des betrachteten Systems

Zu den Eigenwerten lassen sich die entsprechenden Eigenvektoren berechnen, die den Eigenraum des Systems aufspannen. Die Richtungen, in die diese Eigenvek-

toren zeigen, lassen Rückschlüsse auf die Beobachtbarkeit der Leistungsparameter zu. Dabei gilt, dass Leistungsparameter, deren Raumrichtung mit Eigenvektoren übereinstimmen, die zu kleinen Eigenwerten gehören, über eine geringere Beobachtbarkeit verfügen, als Leistungsparameter, die in Richtung von Eigenvektoren mit großen Eigenwerten zeigen. Dieses Kriterium liefert demnach keine absolute, sondern eine relative Güte der Beobachtbarkeit der Leistungsparameter untereinander. Für das betrachtete System ergeben sich die in Bild 6.6 dargestellten Absolutbeträge der Eigenvektoren.




Bild 6.6: Zusammenhang zwischen Eigenwerten und Eigenvektoren des Systems (Absolutbeträge, größte Einträge markiert)

Bei einem zweifach unterbestimmten System ($n=11, m=9$) existieren zwei Eigenwerte mit dem Wert null. Die entsprechenden Eigenvektoren stellen demnach die Richtungen der schlechtesten Beobachtbarkeit dar. Danach folgen in aufsteigender Reihenfolge die Richtungen besserer Beobachtbarkeit. Folgende Sortierungslogik wird angewendet:

- » Die jeweils größten Einträge jedes Eigenvektors werden markiert.
- » Dabei kann der Fall auftreten, dass einige Leistungsparameter in keinem der Eigenvektoren den größten Eintrag darstellen. In diesem Fall werden die Einträge des betreffenden Leistungsparameters in allen Eigenvektoren verglichen und anschließend der größte Eintrag markiert.
- » Sollten nach diesen zwei Schritten Leistungsparameter mehrfach markiert sein, so wird nur der Eintrag im Eigenvektor mit dem geringeren Eigenwert zur Sortierung herangezogen.

In Bild 6.6 wurden die Markierungen entsprechend der erläuterten Logik vorgenommen. Es ergibt sich die folgende Liste der Leistungsparameter sortiert nach aufsteigender Beobachtbarkeit:




Bild 6.7: Sortierung der Leistungsparameter bezüglich ihrer relativen Beobachtbarkeit

Die im vorherigen Abschnitt bezüglich ihrer Diagnosegüte als kritisch identifizierten Parameter LP1, LP3, LP9 und LP10 stellen in dieser Sortierung die ersten vier Einträge dar. Es konnte somit gezeigt werden, dass mit Hilfe der beschriebenen einfachen Beobachtbarkeitsanalyse eine Bewertung der Beobachtbarkeit und damit der zu erwartenden Diagnosegüte der Leistungsparameter möglich ist.

Kapitel 7: Umsetzung des Konzeptes

Das in Abschnitt 3 entwickelte integrierte Konzept zur Zustandsüberwachung von Gasturbinen wurde mit den in den Abschnitten 4 bis 6 erläuterten Algorithmen im Rahmen der Diagnosesoftware HealthGT[®] umgesetzt. In den folgenden Abschnitten werden die wichtigsten Funktionen von HealthGT[®] vorgestellt und ausgewählte Ergebnisse präsentiert. Weiterführende Informationen zur Diagnosesoftware HealthGT[®] sind im zugehörigen Handbuch ^[67] zu finden.

7.1 Diagnosesoftware HealthGT[®]

Alle in HealthGT[®] verwendeten Algorithmen wurden in der Programmiersprache MATLAB programmiert. Darüber hinaus verfügt HealthGT[®] über eine grafische Benutzeroberfläche, die ebenfalls in MATLAB erstellt wurde. Dadurch wird nicht nur eine einfache Bedienbarkeit erreicht, sondern auch die Möglichkeit, HealthGT[®] in kompilierter Form, d.h. ohne Installation von MATLAB zu betreiben. Name und Logo der Software wurden beim Deutschen Patent- und Markenamt als Wort- und Bildmarke eingetragen ^[115] und sind somit markenrechtlich geschützt (Bild 7.1).



Bild 7.1: Startbildschirm der Diagnosesoftware HealthGT[®]

Die Oberfläche des Hauptprogramms von HealthGT[®] spiegelt das in Abschnitt 3 erläuterte dreistufige Konzept wieder. Die drei Hauptprozesse (Detektion von Einzelfehlern, Diagnose gradueller Verschlechterung und Diagnose von Einzelfehlern) sind in Bild 7.2 dunkel eingefärbt.

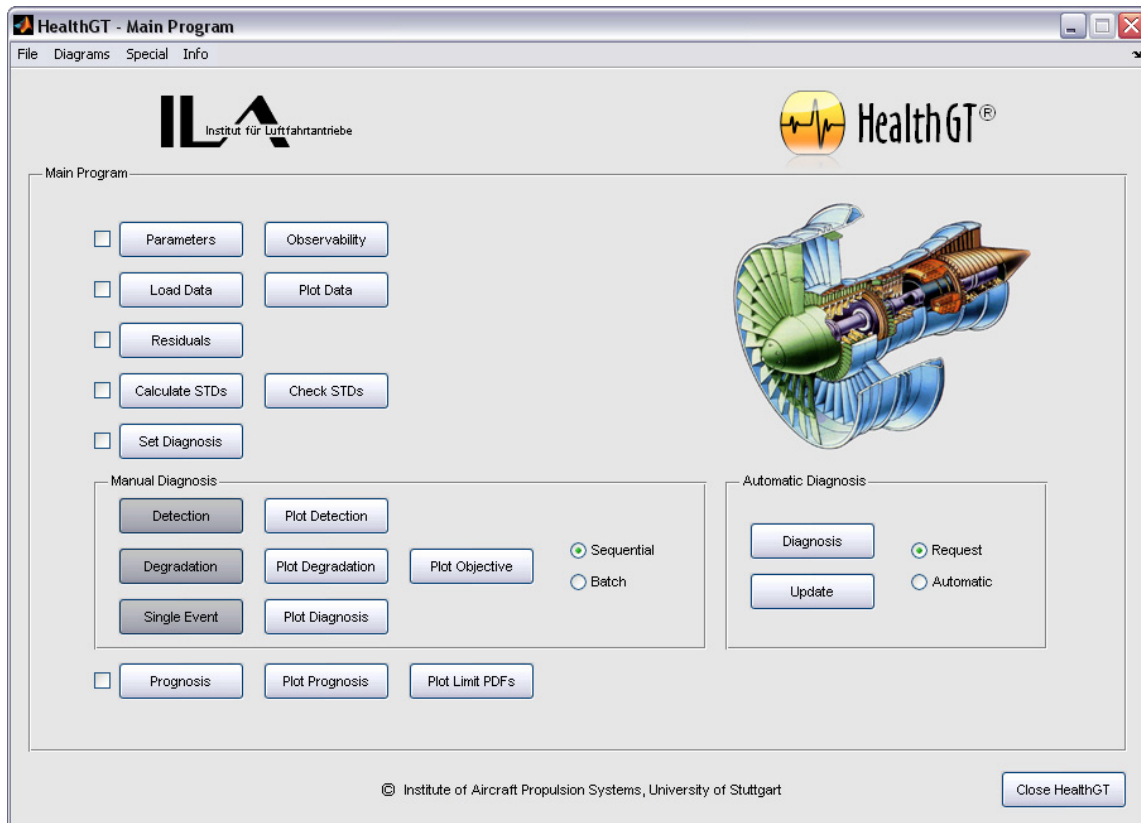


Bild 7.2: Hauptprogramm der Diagnosesoftware HealthGT[®]
(die drei Hauptprozesse sind dunkel eingefärbt)

Vor der Bearbeitung der Hauptprozesse sind die folgenden 5 Schritte notwendig:

- (1) Definition der Parameter und optionale Bewertung der Beobachtbarkeit
- (2) Laden und optionale Darstellung der Daten
- (3) Berechnung der Residuen
- (4) Berechnung und Überprüfung der Standardabweichungen der Residuen mittels eines statistischen Tests (χ^2 -Test)
- (5) Definition der Parameter für die Detektion und die Diagnose

Zur Berechnung der Standardabweichung der Residuen sollte eine ausreichende Anzahl an Messwerten vorliegen, in denen kein Einzelereignis aufgetreten ist. Alterungseinflüsse werden vor der Berechnung durch eine automatische Trendbereinigung der Daten eliminiert. Liegen zu wenige Messdaten vor, so ist die Be-

rechnung der Standardabweichungen nicht aussagekräftig und der Chi²-Test fällt negativ aus. In diesen Fällen muss die Standardabweichung der Messwerte aus anderen Quellen bekannt sein.

Durch Auswahl der entsprechenden Schaltflächen gelangt man zu weiteren Oberflächen, um weitere Einstellungen vorzunehmen und die oben genannten Funktionen auszuführen. Für die Bearbeitung der drei Hauptprozesse steht eine manuelle und eine automatische Variante zur Verfügung. Bei der manuellen Variante kann jeder Zyklus der Datenreihe einzeln betrachtet und analysiert werden. Bei der automatischen Bearbeitung erfolgt dagegen die Bearbeitung des gesamten Datensatzes in einem Schritt. Für die Hauptprozesse stehen jeweils entsprechende Visualisierungsmöglichkeiten zur Verfügung.

Nach der Bearbeitung der drei Hauptprozesse kann eine Prognose der Residuenverläufe folgen. Dabei können, wie in Abschnitt 4.3.5 beschrieben, die Dichte- und Verteilungsfunktionen für die Über- bzw. Unterschreitung von Grenzwerten berechnet werden. In der Rubrik »Special« der Menuleiste des Hauptprogramms stehen weitere Funktionen für besondere Anwendungen zur Verfügung, wie z.B. die in den Abschnitten 4.3.6 und 5.3.4 erläuterten statistischen Auswertungen der Verfahren.

Im Anhang A.4 sind weitere Bilder der Oberfläche zu finden. Die Definition der Leistungsparameter, der Messwerte und der Betriebsparameter ist in Bild A.2 bis Bild A.4 dargestellt. Die Oberfläche zur Beobachtbarkeitsanalyse ist in Bild A.5 gezeigt, die Oberfläche zum Laden von Daten in Bild A.6. Die Definition der verwendeten Parameter ist in Bild A.7 dokumentiert. Das Diagnoseergebnis eines Einzelereignisses ist in Bild A.8 dargestellt, das Ergebnis einer Alterungsdiagnose in Bild A.9. Die Betrachtung des Zielfunktionsverlaufes (Bild A.10) zeigt, dass sich die Diagnose der ersten 50 Zyklen schwierig gestaltet, was in den geringen Abweichungswerten der Leistungsparameter begründet ist. Die Analyse des Diagnoseergebnisses am Ende des betrachteten Zeitraumes ($t=400$) ergibt, dass alle Leistungsparameter bezüglich eines Diagnoselimits von 0,5% korrekt diagnostiziert werden (Bild A.11). Am Beispiel des Alterungsverlaufes ist in Bild A.12 die Prognose der Messwertresiduen für die Zyklen $401 < t < 450$ dargestellt. Es ist zu erkennen, dass mit fortschreitendem Prognosezeitpunkt die Unsicherheit der Prognose zunimmt. Abschließend sind in Bild A.13 die Verläufe der Dichte- und Verteilungsfunktionen für die Grenzwertüberschreitung der Messwerte dargestellt. Wie in Abschnitt 4.3.5 erläutert, geben die Verteilungsfunktionen die Wahrscheinlichkeit an, mit der der entsprechende Grenzwert zum jeweiligen Zeitpunkt überschritten wird und liefern nur dann sinnvolle Ergebnisse, wenn der

betrachtete Zeitraum ausreichend ist. Die Dichtefunktion muss dafür nach dem Erreichen eines Maximums bereits wieder asymptotisch gegen null gehen. Dies ist im dargestellten Beispiel für die Messwerte NH, WF, P25 und T5 der Fall, so dass nur für diese Messwerte die Verteilungsfunktionen angegeben sind.

7.2 Ausgewählte Ergebnisse

7.2.1 Diagnose der OBIDICOTE Testfälle

Im Rahmen des EU-Projektes OBIDICOTE (*On Board Identification, Diagnosis and Control of Gas Turbine Engines*) wurden 15 Referenzfehlerfälle definiert ^[20], die typische Komponentenfehler von Gasturbinen repräsentieren (Tabelle 7.1, linke Spalte). Das entwickelte Zustandsüberwachungsprogramm HealthGT[®] wurde auf diese Fehlerfälle angewendet, wobei die in Abschnitt 5.1.1 erläuterte Instrumentierung zugrunde gelegt wurde.

Nr.	OBIDICOTE Testfälle	diagnostizierte Leistungsparameter
1	LP1=-0,5, LP2=-1, LP3=-0,4, LP4=-0,7	LP1=0 , LP2=-0,98, LP3=0 , LP4=-0,93
2	LP1=-1	LP1=-1
3	LP5=-0,7, LP6=-1	LP5=-0,7, LP6=-1
4	LP5=-1	LP5=-1
5	LP6=-1	LP6=-1
6	LP8=1	LP8=1
7	LP7=-1, LP8=-1	LP7=-1, LP8=-1
8	LP7=-1	LP7=-1
9	LP9=-1	LP9=-1
10	LP9=-0,4, LP10=-1	LP9=0 , LP10=-0,7
11	LP10=-1	LP10=-1
12	LP9=-0,6, LP10=1	LP9=0 , LP10=1,62
13	LP11=1	LP11=1
14	LP11=-1	LP11=-1
15	LP11=2	LP11=2

Tabelle 7.1: Übersicht über die im EU-Projekt OBIDICOTE definierten Testfälle ^[20] und die entsprechenden Diagnoseergebnisse (Abweichungen über dem Diagnoselimit von 0,1% markiert)

Exemplarisch ist in Bild 7.3 das Diagnoseergebnis des Testfalls Nr.1 abgebildet. Die Darstellung besteht aus den folgenden vier Diagrammen:

- » Verlauf der Fuzzy Indizes über den Kumulationsschritten
- » Fuzzy Indizes nach dem letzten Kumulationsschritt
- » Gemitteltetes Diagnoseergebnis der kombinatorischen Auswertungen
- » Diagnoseergebnis der nichtlinearen Gas-Pfad-Analyse unter Berücksichtigung des Detektionsergebnisses.

Es ist zu erkennen, dass die Fuzzy Indizes der Parameter LP1, LP2 und LP4 im Laufe der Kumulation ansteigen, dass jedoch nur die Fuzzy Indizes der Parameter LP2 und LP4 das Identifikationslimit von 0,5 überschreiten. Damit werden lediglich zwei der insgesamt vier betroffenen Leistungsparameter identifiziert. Die Abweichungen der nicht identifizierten Parameter (LP1 und LP3) liegen mit $\Delta LP1 = -0,5\%$ und $\Delta LP3 = -0,4\%$ jedoch im Bereich der Diagnoseschwelle für Einzelereignisse, deren Bestimmung für jeden Leistungsparameter in Abschnitt 8.1 durchgeführt wird.




Bild 7.3: Diagnoseergebnis des OBIDICOTE Testfalls Nr.1

Das Ergebnis der nichtlinearen Gas-Pfad-Analyse unter Verwendung der identifizierten Parameter LP2 und LP4 ist im rechten unteren Diagramm in Bild 7.3

dargestellt. Die Abweichung zwischen den diagnostizierten und den wahren Verschlechterungen beträgt im Parameter LP2 0,01% und im Parameter LP4 0,21%.

Die Diagnoseergebnisse aller weiteren Testfälle sind in Tabelle 7.1 (rechte Spalte) angegeben. Die statistische Auswertung der Ergebnisse mit den in den Abschnitten 4.3.6 und 5.3.4 erläuterten Kennzahlen ergibt eine Identifikationsrate von 97,58% und eine Diagnoserate von 95,76% bei einem Diagnoselimit von 0,1%. Bezogen auf die Komponenten wurden alle 15 Testfälle korrekt identifiziert, d.h. es wurde in jedem der 15 Testfälle mindestens einer der Leistungsparameter einer betroffenen Komponenten als fehlerhaft identifiziert. Es lässt sich eine Komponentenidentifikationsrate (KIR) definieren, die das Verhältnis aus der Anzahl der korrekt identifizierten betroffenen Komponenten und der Anzahl der fehlerbehafteten Komponenten darstellt (siehe Gleichung (7.1)). Diese Komponentenidentifikationsrate liegt für die OBIDICOTE Testfälle bei 100%.

$$\text{KIR} = \frac{\text{Anzahl korrekt identifizierter fehlerbehafteter Komponenten}}{\text{Anzahl fehlerbehafteter Komponenten}} \quad (7.1)$$

7.2.2 Diagnose eines Einzelereignisses mit überlagerter gradueller Verschlechterung

Ein entscheidender Vorteil des entwickelten integrierten Konzeptes ist, dass Einzelereignisse und alterungsbedingte Verschlechterungen auch dann analysiert werden können, wenn sie in überlagerter Form auftreten. In diesem Abschnitt wird ein derartiges Beispiel präsentiert, dessen Alterungsverlauf dem in Abschnitt 6.1 generierten Beispiel entspricht. Der Alterung wurde zum Zyklus $t=16$ ein Einzelfehler mit den Abweichungen $\Delta\text{LP2}=-1\%$ und $\Delta\text{LP5}=-1\%$ überlagert. Zur Optimierung wurden Nebenbedingung entsprechend der Definition von Version 2 verwendet.

Dem in Bild 7.4 dargestellten Verlauf der Zielfunktion (ZF) ist zu entnehmen, dass die Güte der Einzelfehlerdiagnose (Zyklus $t=16$) bezüglich des erreichten Zielfunktionswertes um den Faktor 2 schlechter ausfällt als die Diagnosen der graduellen Verschlechterung. Die Diagnose des Einzelfehlers übersteigt mit $\Delta\text{LP2}=-1,15\%$ und $\Delta\text{LP5}=-1,70\%$ den tatsächlichen Fehler ($\Delta\text{LP2}=-1\%$ und $\Delta\text{LP5}=-1\%$) besonders im Parameter LP5. Die Diagnose des Beispielfalls weist einen über alle Leistungsparameter gemittelten RMS Wert von 0,1997% auf.




Bild 7.4: Diagnoseergebnis (o) der Alterung mit überlagertem Einzelfehler (—) und Verlauf der Zielfunktion (ZF)

Abschließend bleibt festzuhalten, dass mit Hilfe des entwickelten Konzeptes eine integrierte Zustandsdiagnose durchgeführt werden kann, d.h. dass das Auftreten von Einzelereignissen auch bei überlagerter alterungsbedingter Verschlechterung korrekt identifiziert und diagnostiziert wird.

Kapitel 8: Bewertung des Konzeptes

8.1 Integrierte Sensitivitätsanalyse

Um die Leistungsfähigkeit der Konzeptintegration zu bewerten, wurde eine Sensitivitätsanalyse durchgeführt, die aus den folgenden drei Schritten besteht:

- » Bestimmung der Diagnoseschwelle für jeden Leistungsparameter
- » Bestimmung der korrespondierenden Messwertresiduen
- » Bestimmung der Diagnoseschwelle des integrierten Systems unter Berücksichtigung der Messwertresiduen

8.1.1 Bestimmung der Diagnoseschwelle

Unter Diagnoseschwelle wird die minimale Abweichung eines Leistungsparameters verstanden, der in der Einzelfehlerdiagnose zu einem Fuzzy Index des entsprechenden Parameters führt, der die Identifikationsschwelle von 0,5 überschreitet. Bei der durchgeführten Parameterstudie wurden die Leistungsparameter einzeln variiert, um die jeweilige Diagnoseschwelle zu ermitteln. Einflüsse von Interaktionen zwischen den Leistungsparametern wurden nicht berücksichtigt. Die Parameterstudie wurde mit einer Schrittweite von -0,01% durchgeführt. Es ergeben sich die in Bild 8.1 dargestellten Beträge der Diagnoseschwellen.

Auffällig ist, dass der Großteil der Leistungsparameter eine Diagnoseschwelle von ~0,5% aufweist. Diese Tatsache liegt in der Definition der Fuzzy Logic Systeme begründet. Für eine Diagnose müssen die Leistungsparameter in ihrer Klassifizierung mindestens die erste Klasse (»low«) erreichen. Bild 5.18 ist zu entnehmen, dass das betragsmäßige Maximum dieser Klasse bei 0,5 liegt. Eine Ausnahme bildet der Parameter LP7, dessen Diagnoseschwelle mit 0,76% an der Grenze zwischen der ersten und der zweiten Klasse (»medium«) liegt.




Bild 8.1: Diagnoseschwellen der Leistungsparameter

Eine Erklärung hierzu kann aus der Betrachtung der Korrelationen zwischen den Leistungsparametern abgeleitet werden. Die Korrelationskoeffizienten der Leistungsparameter lassen sich wie folgt berechnen:

$$KK_{i,k} = \frac{LKM_{i,k}}{\sqrt{LKM_{i,i} \cdot LKM_{k,k}}}, \quad (8.1)$$

wobei LKM die Leistungsparameter-Kovarianz-Matrix darstellt, die sich aus der Einfluss-Koeffizienten-Matrix des Systems ergibt. Es gilt:

$$LKM_{i,k} = \text{cov}(\text{EKM}) = \begin{bmatrix} \sigma_{\Delta X_1, \Delta X_1}^2 & \cdots & \sigma_{\Delta X_1, \Delta X_i}^2 & \cdots & \sigma_{\Delta X_1, \Delta X_n}^2 \\ \vdots & & \vdots & & \vdots \\ \sigma_{\Delta X_i, \Delta X_1}^2 & \cdots & \sigma_{\Delta X_i, \Delta X_i}^2 & \cdots & \sigma_{\Delta X_i, \Delta X_n}^2 \\ \vdots & & \vdots & & \vdots \\ \sigma_{\Delta X_n, \Delta X_1}^2 & \cdots & \sigma_{\Delta X_n, \Delta X_i}^2 & \cdots & \sigma_{\Delta X_n, \Delta X_n}^2 \end{bmatrix}, \quad (8.2)$$

wobei die Varianz σ^2 durch die Beziehung

$$\sigma_{\Delta X_i, \Delta X_k}^2 = \frac{1}{n-1} \cdot \sum_{j=1}^n [(EKM_{j,i} - \mu(EKM_i)) \cdot (EKM_{j,k} - \mu(EKM_k))] \quad (8.3)$$

gegeben ist. Die Terme $\mu(EKM_i)$ und $\mu(EKM_k)$ beschreiben dabei die Mittelwerte der i -ten bzw. k -ten Spalten der EKM. Der Parameter n gibt die Anzahl der Leistungsparameter wieder. Die Leistungsparameter-Kovarianz-Matrix ist im Anhang in Tabelle A.7 abgebildet.

Mit Hilfe der resultierenden Korrelationskoeffizienten lassen sich Rückschlüsse auf die Eindeutigkeit der Diagnosen ziehen. Verfügen zwei Leistungsparameter über einen hohen Korrelationskoeffizienten, so führen sie zu ähnlichen Mustern in den Messwertresiduen. Provost ^[92] führt eine Klassifizierung der Korrelationskoeffizienten mit einem kritischen Wert von 0,9 ein. Wird dieser Wert überschritten,

so ist die Unterscheidung, welcher der beiden Leistungsparameter zu den vorliegenden Messwertresiduen geführt hat, schwierig. Dies gilt insbesondere für den Fall, dass nur kleine Leistungsparameterabweichungen vorliegen, wie es in der Nähe der Diagnoseschwelle der Fall ist. Da die Berechnung der Korrelationskoeffizienten auf der Einfluss-Koeffizienten-Matrix basiert, handelt es sich um eine linearisierte Analysemethode. Liegen die Abweichungen deutlich über dem Wert der Diagnoseschwelle, so führen die wachsenden nichtlinearen Effekte zu einer besseren Unterscheidung zwischen den gesuchten Leistungsparametern.

	LP1	LP2	LP3	LP4	LP5	LP6	LP7	LP8	LP9	LP10	LP11
LP1	1,00										
LP2	-0,89	1,00									
LP3	0,16	-0,11	1,00								
LP4	0,91	-0,87	-0,01	1,00							
LP5	-0,69	0,72	0,21	-0,76	1,00						
LP6	-0,02	-0,01	0,06	-0,12	-0,27	1,00					
LP7	-0,69	0,71	0,14	-0,74	0,91	-0,23	1,00				
LP8	0,22	-0,13	-0,18	0,07	-0,38	-0,04	-0,47	1,00			
LP9	0,92	-0,89	0,26	0,90	-0,61	-0,02	-0,61	0,14	1,00		
LP10	-0,89	0,87	-0,03	-0,89	0,92	-0,15	0,93	-0,37	-0,85	1,00	
LP11	0,21	-0,58	0,19	0,36	-0,43	0,20	-0,43	-0,14	0,35	-0,44	1,00

Tabelle 8.1: Korrelationskoeffizienten der Leistungsparameter

Die Korrelationskoeffizienten sind in Tabelle 8.1 zusammengefasst. Da es sich bei der Matrix der Korrelationskoeffizienten um eine symmetrische Matrix handelt, ist aus Gründen der Übersichtlichkeit nur die untere Dreiecksmatrix abgebildet. Alle Einträge $>0,9$ sind markiert. Die Analyse der Korrelationskoeffizienten zeigt, dass die Leistungsparameter LP7 und LP10 mit $KK_{7,10}=0,93$ über den größten Korrelationskoeffizienten verfügen. Dies führt dazu, dass die von einer Veränderung des Parameters LP7 induzierten Messwertresiduen in der Diagnose dem Parameter LP10 zugeordnet werden. Erst für Abweichungen, die den Wert $\Delta LP7=-0,76$ überschreiten, gelingt eine korrekte Diagnose.

8.1.2 Bestimmung der korrespondierenden Residuen

Da das in dieser Arbeit entwickelte Konzept die Funktionen der Detektion und der Diagnose miteinander verbindet, muss im Rahmen der Sensitivitätsanalyse untersucht werden, ob die von den Leistungsparameterveränderungen verursachten Messwertresiduen detektiert werden können. In Abschnitt 4.3.6 wurde ge-

zeigt, dass der entwickelte Detektionsalgorithmus in der Lage ist, Veränderungen der Messwertresiduen zu detektieren, falls diese das 1,5-fache der Standardabweichung des jeweiligen Messwertes überschreiten.

Mit Hilfe des Leistungsrechnungsmodells wurden aus den in Bild 8.1 dargestellten Diagnoseschwellen die entsprechenden Messwertresiduen berechnet. Die Analyse der Messwertresiduen ergibt, dass lediglich die entsprechende Abweichung im Leistungsparameter LP3 ($\Delta LP3 = -0,51\%$) nicht zu Messwertresiduen $> 1,5\sigma$ in mindestens einem der Messwerte führt (siehe Tabelle 8.2). Alle übrigen Leistungsparameterabweichungen bewirken eine Überschreitung des Wertes von $1,5\sigma$ in mindestens einem Messwertresiduum.

	LP1	LP2	LP3	LP4	LP5	LP6	LP7	LP8	LP9	LP10	LP11
MW1	x	x		x			x		x	x	x
MW2	x	x		x	x	x	x	x	x	x	x
MW3	x			x					x		x
MW4											
MW5	x	x		x	x		x		x	x	x
MW6		x					x				x
MW7		x		x			x	x			x
MW8							x				x
MW9	x	x		x			x		x		x

Tabelle 8.2: Übersicht über die korrespondierenden Messwertresiduen (Werte $> 1,5\sigma$ sind mit »x« markiert)

8.1.3 Bestimmung der Diagnoseschwelle des integrierten Systems

Im Fall des Leistungsparameters LP3 liegt die Diagnoseschwelle des integrierten Systems über dem in Abschnitt 8.1.1 berechneten Wert von $\Delta LP3 = -0,51\%$. Mit Hilfe des Leistungsrechnungsprogramms wurde der Wert $\Delta LP3 = -0,62\%$ ermittelt, der zu einem Messwertresiduum von $1,5\sigma$ in der Niederdruckwellendrehzahl (MW1) führt. Für alle übrigen Leistungsparameter stimmen die Diagnoseschwellen des integrierten Systems mit den in Abschnitt 8.1.1 berechneten Werten überein. Damit ergeben sich die in Bild 8.2 dargestellten Diagnoseschwellen für das integrierte System.




Bild 8.2: Diagnoseschwellen der Leistungsparameter unter der Forderung, dass mindestens ein Messwertresiduum die Detektionsschwelle von $1,5\sigma$ überschreitet

8.2 Diagnose stark unterbestimmter Systeme

Das entwickelte System ist für überbestimmte, bestimmte und unterbestimmte Systeme anwendbar. Die durchgeführte statistischen Bewertungen basieren auf einem 2-fach unterbestimmten System. Um die Grenze der Unterbestimmtheit zu bestimmen, bis zu der das entwickelte System anwendbar ist, wurden einige Untersuchungen mit stärker unterbestimmten Systemen durchgeführt. Es wurde jedoch keine derart umfangreiche statistische Analysen betrieben wie für das 2-fach unterbestimmte System. Die in diesem Abschnitt erläuterten Systeme wurden nur hinsichtlich der 15 Testfälle des OBIDICOTE Programms untersucht.

Es wurde ein 6-fach unterbestimmtes System untersucht, in dem nur die Messwerte MW1, MW2, MW7, MW8 und MW9 aus Tabelle 5.2 zur Verfügung standen. Die in Gleichung (7.1) definierte Komponentenidentifikationsrate liegt bei 75%. Ein Beispiel einer erfolgreichen Diagnose ist in Bild 8.3 gezeigt.

Des Weiteren wurde die Diagnose der OBIDICOTE Testfälle mit einem 8-fach unterbestimmten System untersucht, bei dem lediglich die Messwerte MW1, MW2 und MW9 aus Tabelle 5.2 verwendet wurden. Die Komponentenidentifikationsrate sinkt auf 62,5%, wobei eine korrekte Diagnose nur noch bei Fehlerfällen möglich ist, die über lediglich einen veränderten Leistungsparameter verfügen.




Bild 8.3: Diagnoseergebnis des OBIDICOTE Testfalls Nr.7 mit einem 6-fach unterbestimmten System

Um bei derartig stark unterbestimmten Systemen eine Erhöhung der Komponentenidentifikationsrate zu erzielen, ist es sinnvoll, andere Ansätze zu wählen. Eine Methode, die auf der Zusammenfassung der Komponenten zu Blöcken basiert, wird von Nagy ^[85] vorgestellt. Er nimmt folgende Blockbildung vor:

- » Aufteilung in Verdichter und Turbinenteil
- » Aufteilung in Hoch- und Niederdruckteil

Liegen in diesen Blöcken isolierte Fehler vor, d.h. sind zu einem Zeitpunkt ausschließlich Komponenten eines dieser Blöcke fehlerbehaftet, so können mit der von Nagy ^[85] vorgestellten Methode stark unterbestimmte Systeme analysiert werden. Bei einem 5-fach unterbestimmten System werden Blockidentifikationsraten von 94-98% erzielt. Eine Diagnose der Leistungsparameterabweichungen ist mit der vorgestellten Methode allerdings nicht möglich.

Die von Joos ^[50] entwickelte Methode basiert ebenfalls auf einer Blockbildung. Es werden die vier Blöcke »FAN+LPC«, »HPC«, »HPT+LPT« und »NC« gebildet. Das entwickelte System verfügt neben der Identifikation auch über Diagnoseeigenschaften. Für Isolationsfehler werden bei einem 4-fach unterbestimmten Sys-

tem Identifikationsraten von $>98,6\%$ erreicht. Im Falle einer korrekten Identifikation des betroffenen Blocks liegt die Diagnoserate bei 100% .

Wie bereits erwähnt, sind die von Nagy ^[85] und Joos ^[50] vorgestellten Verfahren nur auf Isolationsfehler anwendbar. Liegen betroffene Komponenten in mehreren Blöcken vor, so führen die Verfahren zu unbrauchbaren Ergebnissen. Darüber hinaus ist zu beachten, dass die Verfahren keinen Hinweis auf das Auftreten eines Kombinationsfehlers liefern und den Fehler einem der definierten Blöcke zuweisen.

8.3 Zusammenfassung

Das entwickelte Konzept erfüllt alle in Abschnitt 3.2 aufgeführten Anforderungen an ein fortschrittliches Zustandsüberwachungssystem für Gasturbinen. Dabei liegt der entscheidende Vorteil des entwickelten Konzeptes gegenüber bisher in der Literatur dokumentierten Systemen in der funktionalen Trennung von Einzelereignis- und Alterungsdiagnose. Durch die anschließende Zusammenführung der Ergebnisse ist es möglich, Einzelereignisse und alterungsbedingte Verschlechterungen auch dann zu analysieren, wenn sie in überlagerter Form auftreten.

Der entwickelte Detektionsalgorithmus verbindet die gegensätzlichen Anforderungen einer schnellen Reaktion und eines hohen Glättungsgrades. Darüber hinaus stehen Funktionen zur Ausreißererkennung und zur Messwertprognose zur Verfügung. Aufgrund der Kombination verschiedener Elemente zur Detektion (Bayes Faktoren, kumulative Bayes Faktoren, Lauflängen) erlaubt die Methode zuverlässige Detektionen selbst bei Sprunghöhen, die kleiner als das Dreifache der Standardabweichungen der Residuenverläufe sind.

Das entwickelte Verfahren zur Diagnose von Einzelereignissen bedarf keiner a-priori Informationen über die betroffenen Leistungsparameter, weder deren Anzahl noch deren Kombination. Darüber hinaus werden keinerlei Annahmen über die Beziehungen zwischen den Leistungsparametern getroffen. Es können beliebige Kombinationen an betroffenen Leistungsparametern diagnostiziert werden, wobei die maximal diagnostizierbare Anzahl an Leistungsparametern der Anzahl der vorhandenen Messwerte entspricht. Die Diagnose ist auf der Basis einzelner Messzeitpunkte durchführbar, d.h. es ist keine zeitliche Beobachtung der Messwerte notwendig. Das Diagnoseergebnis der Methode besteht nicht nur in der Berechnung der Abweichungen der Leistungsparameter, sondern auch aus der

Berechnung des Fuzzy Index jedes Parameters. Der Fuzzy Index kann als Wahrscheinlichkeit interpretiert werden, mit der der entsprechende Leistungsparameter vom Fehler betroffen ist.

Die Diagnose gradueller Verschlechterungen wurde mit bereits bekannten Optimierungsverfahren durchgeführt. Dabei wurden verschiedene Definitionen von Nebenbedingungen und die Verbesserung der Optimierung durch Startwertsuche mittels eines Genetischen Algorithmus untersucht. Die Analysen haben ergeben, dass bei der Diagnose der graduellen Verschlechterungen noch Verbesserungspotential besteht. Eine sinnvolle Erweiterung der erarbeiteten Methode besteht in der Modellierung der Diagnoseergebnisse. Dadurch können die Nebenbedingungen, wie z.B. die Schrittweitendefinition, adaptiv gestaltet werden.

Mit der Diagnosesoftware HealthGT[®] liegt das entwickelte integrierte Konzept in einem leicht zu bedienenden Programm vor. Darüber hinaus gestattet die modulare Programmierweise von HealthGT[®] eine einfache Einarbeitung zukünftiger Funktionalitäten.

Anhang

A.1 Fuzzy Logic System FLS1b

relative Häufigkeit	mittlere Abweichung	Fuzzy Index
1 = low	1 = high +	1 = not existent
2 = medium	2 = medium +	2 = unlikely
3 = high	3 = low	3 = likely
	4 = medium -	4 = very likely
	5 = high -	5 = existent

Tabelle A.1: Klassifizierung der Ein- und Ausgänge des FLS1b

Nr.	Regel	Nr.	Regel	Nr.	Regel
1	1 1 \rightarrow 3	6	2 1 \rightarrow 4	11	3 1 \rightarrow 5
2	1 2 \rightarrow 2	7	2 2 \rightarrow 3	12	3 2 \rightarrow 4
3	1 3 \rightarrow 1	8	2 3 \rightarrow 2	13	3 3 \rightarrow 3
4	1 4 \rightarrow 2	9	2 4 \rightarrow 3	14	3 4 \rightarrow 4
5	1 5 \rightarrow 3	10	2 5 \rightarrow 4	15	3 5 \rightarrow 5

Tabelle A.2: Übersicht über die Regeln des FLS1b




Bild A.1: Visualisierung des FLS1b mit Hilfe einer Antwortfläche

A.2 Fuzzy Logic System FLS2

mittlere Abweichung	Fuzzy Index (aktuell)	Fuzzy Index (alt)	Fuzzy Index (neu)
1 = low	1 = not existent	1 = not existent	1 = not existent
2 = medium	2 = unlikely	2 = unlikely	2 = unlikely
3 = high	3 = likely	3 = likely	3 = likely
	4 = very likely	4 = very likely	4 = very likely
	5 = existent	5 = existent	5 = existent

Tabelle A.3: Klassifizierung der Ein- und Ausgänge des FLS2

Nr.	Regel	Nr.	Regel	Nr.	Regel	Nr.	Regel
1	0 1 1 → 1	15	1 2 5 → 4	29	2 2 4 → 3	43	3 2 3 → 3
2	0 1 2 → 1	16	1 3 1 → 1	30	2 2 5 → 4	44	3 2 4 → 4
3	0 1 3 → 2	17	1 3 2 → 1	31	2 3 1 → 1	45	3 2 5 → 5
4	0 1 4 → 3	18	1 3 3 → 2	32	2 3 2 → 2	46	3 3 1 → 2
5	0 1 5 → 4	19	1 3 4 → 3	33	2 3 3 → 3	47	3 3 2 → 3
6	0 5 1 → 2	20	1 3 5 → 4	34	2 3 4 → 4	48	3 3 3 → 4
7	0 5 2 → 3	21	1 4 1 → 1	35	2 3 5 → 5	49	3 3 4 → 5
8	0 5 3 → 4	22	1 4 2 → 2	36	2 4 1 → 2	50	3 3 5 → 5
9	0 5 4 → 5	23	1 4 3 → 3	37	2 4 2 → 3	51	3 4 1 → 2
10	0 5 5 → 5	24	1 4 4 → 4	38	2 4 3 → 4	52	3 4 2 → 3
11	1 2 1 → 1	25	1 4 5 → 5	39	2 4 4 → 5	53	3 4 3 → 4
12	1 2 2 → 1	26	2 2 1 → 1	40	2 4 5 → 5	54	3 4 4 → 5
13	1 2 3 → 2	27	2 2 2 → 1	41	3 2 1 → 1	55	3 4 5 → 5
14	1 2 4 → 3	28	2 2 3 → 2	42	3 2 2 → 2		

Tabelle A.4: Übersicht über die Regeln des FLS2

A.3 Fuzzy Logic System FLS2b

mittlere Abweichung	Fuzzy Index (aktuell)	Fuzzy Index (alt)	Fuzzy Index (neu)
1 = high +	1 = not existent	1 = not existent	1 = not existent
2 = medium +	2 = unlikely	2 = unlikely	2 = unlikely
3 = low	3 = likely	3 = likely	3 = likely
4 = medium -	4 = very likely	4 = very likely	4 = very likely
5 = high -	5 = existent	5 = existent	5 = existent

Tabelle A.5: Klassifizierung der Ein- und Ausgänge des FLS2b

Nr.	Regel	Nr.	Regel	Nr.	Regel	Nr.	Regel
1	0 2 1 \rightarrow 2	23	1 5 3 \rightarrow 2	45	3 1 5 \rightarrow 5	67	4 5 2 \rightarrow 2
2	0 2 2 \rightarrow 3	24	1 5 4 \rightarrow 3	46	3 4 1 \rightarrow 1	68	4 5 3 \rightarrow 3
3	0 2 3 \rightarrow 4	25	1 5 5 \rightarrow 4	47	3 4 2 \rightarrow 2	69	4 5 4 \rightarrow 4
4	0 2 4 \rightarrow 5	26	2 1 1 \rightarrow 2	48	3 4 3 \rightarrow 3	70	4 5 5 \rightarrow 5
5	0 2 5 \rightarrow 5	27	2 1 2 \rightarrow 3	49	3 4 4 \rightarrow 4	71	5 1 1 \rightarrow 2
6	0 3 1 \rightarrow 1	28	2 1 3 \rightarrow 4	50	3 4 5 \rightarrow 5	72	5 1 2 \rightarrow 3
7	0 3 2 \rightarrow 1	29	2 1 4 \rightarrow 5	51	3 5 1 \rightarrow 2	73	5 1 3 \rightarrow 4
8	0 3 3 \rightarrow 2	30	2 1 5 \rightarrow 5	52	3 5 2 \rightarrow 3	74	5 1 4 \rightarrow 5
9	0 3 4 \rightarrow 3	31	2 4 1 \rightarrow 1	53	3 5 3 \rightarrow 4	75	5 1 5 \rightarrow 5
10	0 3 5 \rightarrow 4	32	2 4 2 \rightarrow 1	54	3 5 4 \rightarrow 5	76	5 4 1 \rightarrow 1
11	1 1 1 \rightarrow 1	33	2 4 3 \rightarrow 2	55	3 5 5 \rightarrow 5	77	5 4 2 \rightarrow 2
12	1 1 2 \rightarrow 2	34	2 4 4 \rightarrow 3	56	4 1 1 \rightarrow 2	78	5 4 3 \rightarrow 3
13	1 1 3 \rightarrow 3	35	2 4 5 \rightarrow 4	57	4 1 2 \rightarrow 3	79	5 4 4 \rightarrow 4
14	1 1 4 \rightarrow 4	36	2 5 1 \rightarrow 1	58	4 1 3 \rightarrow 4	80	5 4 5 \rightarrow 5
15	1 1 5 \rightarrow 5	37	2 5 2 \rightarrow 2	59	4 1 4 \rightarrow 5	81	5 5 1 \rightarrow 2
16	1 4 1 \rightarrow 1	38	2 5 3 \rightarrow 3	60	4 1 5 \rightarrow 5	82	5 5 2 \rightarrow 3
17	1 4 2 \rightarrow 1	39	2 5 4 \rightarrow 4	61	4 4 1 \rightarrow 1	83	5 5 3 \rightarrow 4
18	1 4 3 \rightarrow 2	40	2 5 5 \rightarrow 5	62	4 4 2 \rightarrow 1	84	5 5 4 \rightarrow 5
19	1 4 4 \rightarrow 3	41	3 1 1 \rightarrow 2	63	4 4 3 \rightarrow 2	85	5 5 5 \rightarrow 5
20	1 4 5 \rightarrow 4	42	3 1 2 \rightarrow 3	64	4 4 4 \rightarrow 3		
21	1 5 1 \rightarrow 1	43	3 1 3 \rightarrow 4	65	4 4 5 \rightarrow 4		
22	1 5 2 \rightarrow 1	44	3 1 4 \rightarrow 5	66	4 5 1 \rightarrow 1		

Tabelle A.6: Übersicht über die Regeln des FLS2b

A.4 Diagnosesoftware Health GT

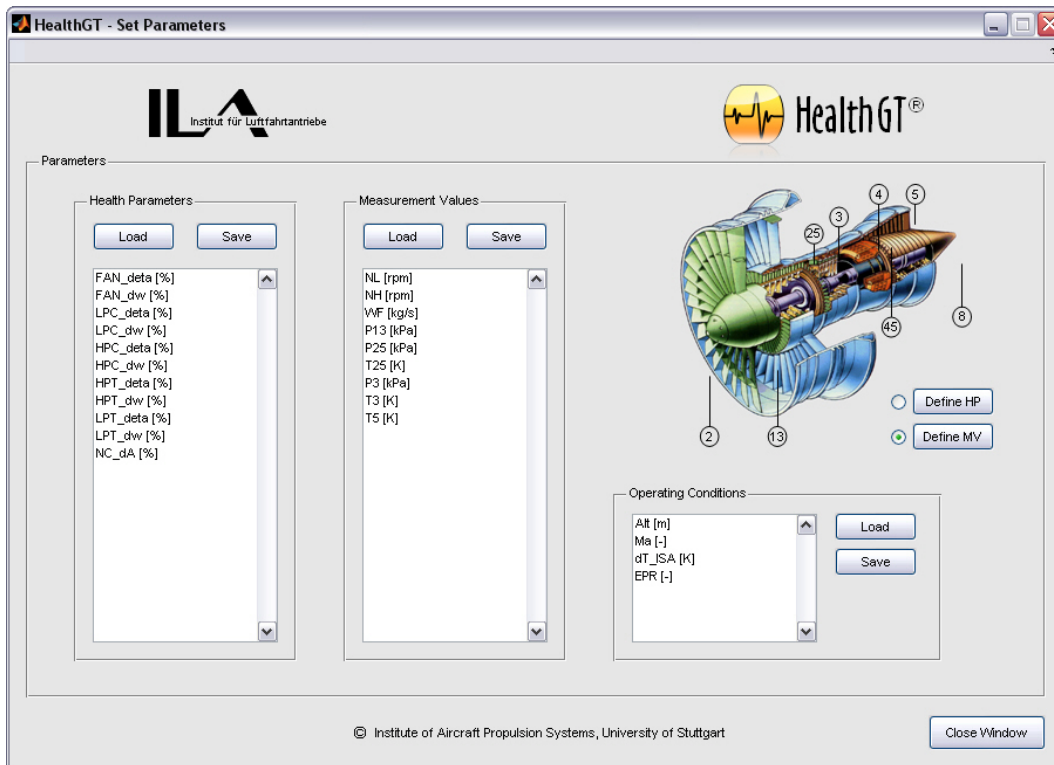


Bild A.2: Oberfläche zur Definition der Parameter (1)




Bild A.3: Oberfläche zur Definition der Parameter (2)




Bild A.4: Oberfläche zur Definition der Parameter (3)




Bild A.5: Oberfläche zur Beobachtbarkeitsanalyse

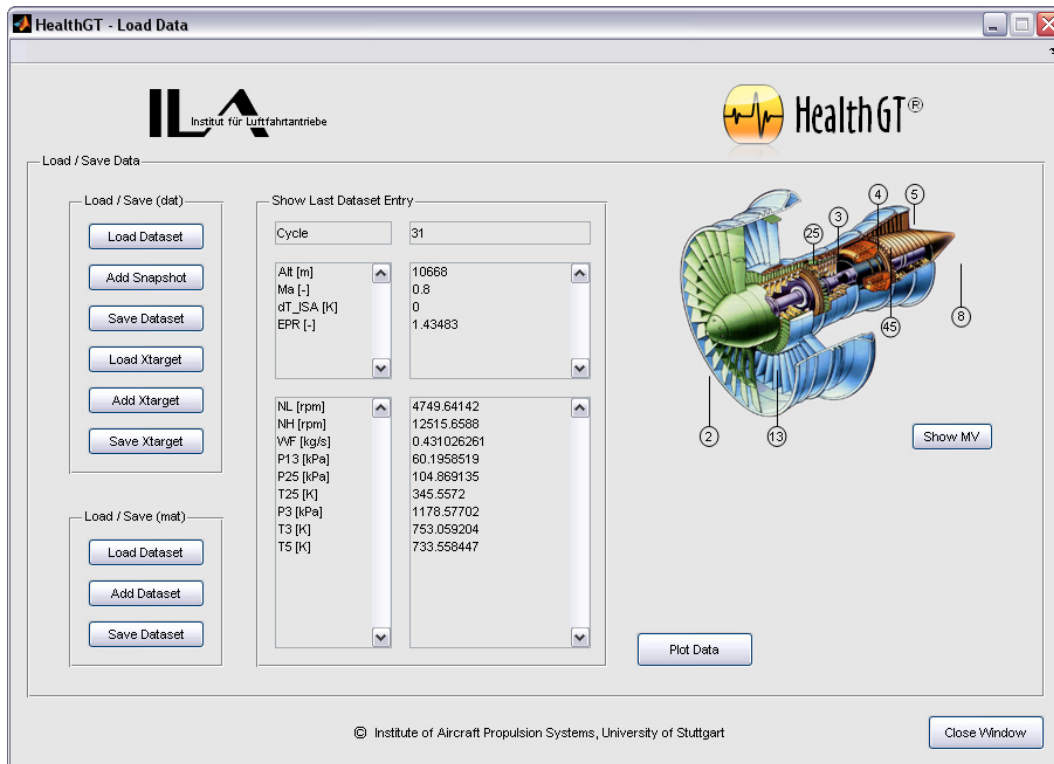


Bild A.6: Oberfläche zum Laden der Daten

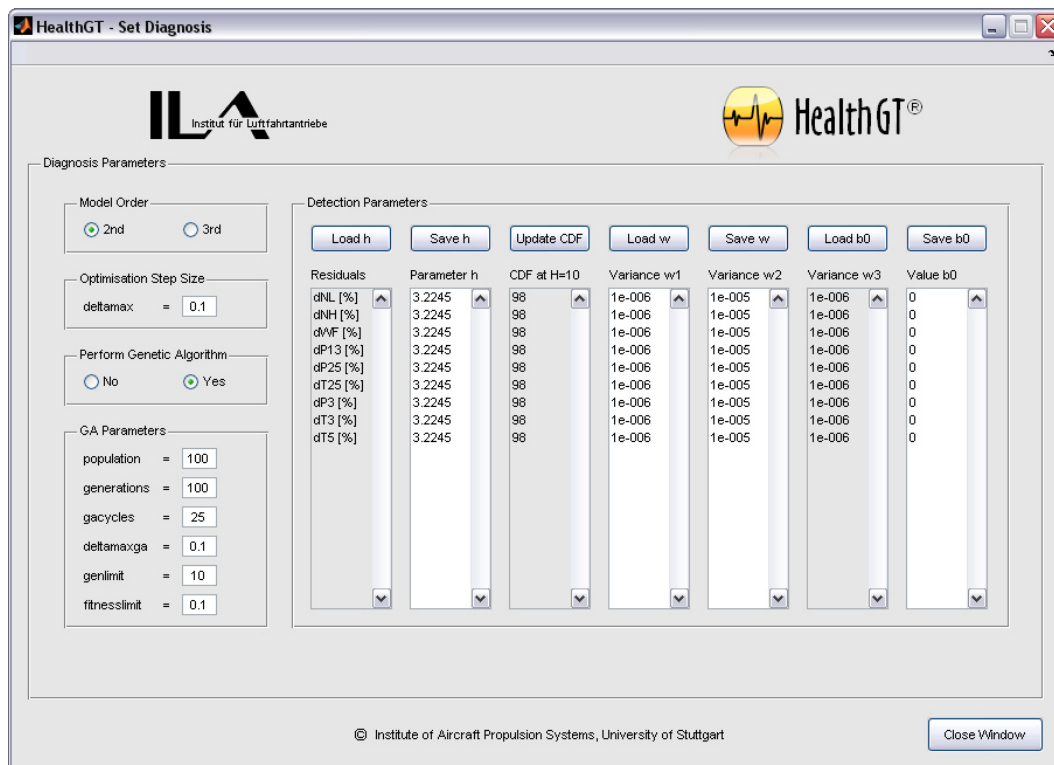


Bild A.7: Definition der Detektions- und Diagnoseparameter




Bild A.8: Diagnoseergebnis eines Einzelereignisses




Bild A.9: Verlauf der Diagnoseergebnisse für ein Alterungsbeispiel





Bild A.10: Verlauf der Zielfunktion des Alterungsbeispiels

Bild A.11: Diagnoseergebnis (□) und wahre Leistungsparameter (■) für das Alterungsbeispiel zum Zeitpunkt $t=400$




Bild A.12: Prognose der Messwertresiduen für das Alterungsbeispiel




Bild A.13: Verlauf der Dichtefunktionen (—) und der Verteilungsfunktionen (---) für das Alterungsbeispiel

A.5 Leistungsparameter-Kovarianz-Matrix

	LP1	LP2	LP3	LP4	LP5	LP6	LP7	LP8	LP9	LP10	LP11
1	0,203	-0,299	0,009	0,343	-0,267	-0,002	-0,369	0,037	0,268	-0,259	0,062
2	-0,299	0,557	-0,011	-0,543	0,463	-0,002	0,634	-0,037	-0,412	0,423	-0,285
3	0,009	-0,011	0,016	-0,004	0,024	0,002	0,022	-0,009	0,021	-0,003	0,016
4	0,343	-0,543	-0,004	0,703	-0,548	-0,022	-0,741	0,023	0,467	-0,486	0,201
5	-0,267	0,463	0,024	-0,548	0,739	-0,051	0,995	-0,124	-0,326	0,512	-0,243
6	-0,002	-0,002	0,002	-0,022	-0,051	0,047	-0,059	-0,004	-0,003	-0,021	0,028
7	-0,369	0,634	0,022	-0,741	0,995	-0,059	1,413	-0,209	-0,446	0,721	-0,335
8	0,037	-0,037	-0,009	0,023	-0,124	-0,004	-0,209	0,140	0,032	-0,091	-0,034
9	0,268	-0,412	0,021	0,467	-0,326	-0,003	-0,446	0,032	0,385	-0,343	0,145
10	-0,259	0,423	-0,003	-0,486	0,512	-0,021	0,721	-0,091	-0,343	0,422	-0,190
11	0,062	-0,285	0,016	0,201	-0,243	0,028	-0,335	-0,034	0,145	-0,190	0,436

Tabelle A.7: Leistungsparameter-Kovarianz-Matrix

Literaturverzeichnis

- [1] **Alexiou A., Mathioudakis K.:** *Gas Turbine Engine Performance Model Applications Using an Object-Oriented Simulation Tool*, ASME Turbo Expo 2006, GT2006-90339, Barcelona, Spain, May 8-11, **2006**
- [2] **Aretakis N., Mathioudakis K., Stamatis A.:** *Non-Linear Engine Component Fault Diagnosis from a Limited Number of Measurements Using a Combinatorial Approach*, Journal of Engineering for Gas Turbines and Power, Vol. 125 (3), pp. 624-633, **2003**
- [3] **Aretakis N., Mathioudakis K., Stamatis A.:** *Identification of Sensor Faults on Turbofan Engines Using Pattern Recognition Techniques*, Journal of Control Engineering Practice, Vol. 12 (7), pp. 827-836, **2004**
- [4] **Bala A., Sethi V., et al.:** *PROOSIS - A Collaborative Venture for Gas Turbine Performance Simulation Using an Object Oriented Programming Schema*, 18th International Symposium on Air-Breathing Engines, ISABE-2007-1357, Beijing, China, Sept. 2-7, **2007**
- [5] **Bauer M.:** *Modulares Leistungsberechnungsverfahren zur automatischen modellbasierten Leistungsanalyse von Gasturbinen*, Insitut für Luftfahrtantriebe, Universität Stuttgart, Dissertation, **2005**
- [6] **Bauer M.:** *Steady State Test Data Analysis & Engine Monitoring*, DGLR Short Course - Gas Turbine Performance, Stuttgart, Germany, Sept 24-28, **2007**
- [7] **Bechini G., Ameyugo G., et al.:** *Gas path Diagnostics: The importance of measurement selection in the monitoring process*, 17th International Symposium on Air-Breathing Engines, ISABE-2005-1281, Munich, Germany, September 4-9, **2005**
- [8] **Borguet S., Léonard O.:** *A Sensor-Fault-Tolerant Diagnosis Tool Based on a Quadratic Programming Approach*, ASME Turbo Expo 2007, GT2007-27324, Montreal, Canada, May 14-17, **2007**
- [9] **Bothe H.H.:** *Futty Logic - Einführung in Theorie und Anwendungen*, Springer, Berlin, **1995**

-
- [10] **Bothe H.H.:** *Neuro-Fuzzy-Methoden - Einführung in Theorie und Anwendungen*, Springer, Berlin, **1998**
- [11] **Box G.E.P., Jenkins G.M.:** *Time Series Analysis - Forecasting and Control*, Revised Edition, Holden-Day, **1976**
- [12] **Broede J., Pfoertner H.:** *Incident Monitoring - General Requirements and First In-Service Experience*, 5th European Propulsion Forum, Pisa, Italy, April 5-7, **1995**
- [13] **Brotherton T., Jahns G., et al.:** *Prognosis of Faults in Gas Turbine Engines*, Proceedings of the IEEE Aerospace Conference 2000, Vol. 6, Big Sky, Montana, March 18-25, **2000**
- [14] **Brotherton T., Johnson T.:** *Anomaly Detection for Advance Military Aircraft Using Neural Networks*, Proceedings of the IEEE Aerospace Conference 2001, Big Sky, Montana, March 10-17, **2001**
- [15] **Brotherton T., Grabill P., Wroblewski D.:** *A Testbed for Data Fusion for Engine Diagnostics and Prognostics*, Proceedings of the IEEE Aerospace Conference 2002, Big Sky, Montana, March 9-16, **2002**
- [16] **Brotherton T., Volponi A., et al.:** *eSTORM: Enhanced Self Tuning On-board Real-time Engine Model*, Proceedings of the IEEE Aerospace Conference 2003, Vol. 7, Big Sky, Montana, March 8-15, **2003**
- [17] **Burchell B.:** *Reducing Costs in Engine Maintenance*, Aviation Week's Overhaul & Maintenance, October 2006, pp. 26-31, **2006**
- [18] **Coleman T.F., Li Y.:** *On the Convergence of Reflective Newton Methods for Large-Scale Nonlinear Minimization Subject to Bounds*, Mathematical Programming, Vol. 67 (2), pp. 189-224, **1994**
- [19] **Coleman T.F., Li Y.:** *An Interior Trust Region Approach for Nonlinear Minimization Subject to Bounds*, SIAM Journal on Optimization, Vol. 6, pp. 418-445, **1996**
- [20] **Curnock B.:** *OBIDICOTE Projekt - Work Package 4 - Steady State Test Cases*, Rolls-Royce Report, DNS62433, **2000**
- [21] **Davison C.R., Birk A.M.:** *Automated Fault Diagnosis For Small Gas Turbine Engines*, ASME Turbo Expo 2002, GT-2002-30029, Amsterdam, The Netherlands, June 3-6, **2002**
- [22] **Decoussemaeker P., Basler B., Douillard C.:** *Operational Effectiveness and Risk Management with Remote Diagnostic Expert Support*, ALSTOM Ltd. Switzerland, Internal Report, **2006**

- [23] Dewallef P., Romessis C., et al.: *Combining Classification Techniques With Kalman Filters for Aircraft Engine Diagnostics*, Journal of Engineering for Gas Turbines and Power, Vol.128, pp. 281-287, April, **2006**
- [24] Diao Y., Passino K.M.: *Fault Diagnosis for a Turbine Engine*, Journal for Control Engineering Practice, Vol. 12, pp. 1151-1165, **2004**
- [25] Doel D.L.: *An Assessment of Weighted-Least-Squares Based Gas Path Analysis*, International Gas Turbine and Aeroengines Congress 1993, 93-GT-119, Cincinnati, Ohio, May 24-27, **1993**
- [26] Doel D.L.: *TEMPER - A Gas Path Analysis Tool for Commercial Jet Engines*, Journal of Engineering for Gas Turbines and Power, Vol. 116 (1), pp. 82-89, January, **1994**
- [27] Doel D.L.: *A Weighted least Squares Gas Path Analysis Method for Test Cell or On-Wing Data*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [28] Doel D.L.: *Interpretation of Weighted-Least-Squares Results with General Rules of Thumb*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [29] Doel D.L.: *Sample Analysis Including Interpretation of Residual Error*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [30] Donat W., Choi K., et al.: *Data Visualization, Data Reduction and Classifier Fusion for Intelligent Fault Detection and Diagnosis in Gas Turbine Engines*, ASME Turbo Expo 2007, Montreal, Canada, May 14-17, **2007**
- [31] Eichler C.: *Instandhaltungstechnik*, 5. Auflage, Verlag Technik GmbH, Berlin, **1990**
- [32] EUROCONTROL: *Standard Inputs for EUROCONTROL Cost Benefit Analyses*, European Organisation for the Safety of Air Navigation, http://www.eurocontrol.int/ecosoc/public/standard_page/documents.html, 14.02.2008, **2007**
- [33] Eustace R.W: *A Real-World Application of Fuzzy Logic and Influence Coefficients for Gas Turbine Performance Diagnostics*, ASME Turbo Expo 2007, GT2007-27442, Montreal, Canada, May 14-17, **2007**
- [34] Evans A. L., Follen G., et al.: *Numerical Propulsion System Simulation's National Cycle Program*, 34th AIAA/ASME/SAE/ASEE Joint Propulsion Conference and Exhibit, AIAA-98-3113, Cleveland, Ohio, July 13-15, **1998**

- [35] **Fishbach L. H., Caddy M.J.:** *NNEP - The Navy Nasa Engine Program*, National Aeronautics and Space Administration (NASA), NASA/TM-X-71857, **1975**
- [36] **Förstemann M.:** *Optimierung der Architektur moderner ziviler Flugtriebwerke zur Verbesserung der Lebenswegkosten*, Institut für Luftfahrtantriebe, Universität Stuttgart, Dissertation, **2006**
- [37] **Friend R.:** *A Probabilistic, Diagnostic and Prognostic System for Engine Health and Usage Management*, Proceedings of the IEEE Aerospace Conference 2002, Vol. 6, Big Sky, Montana, March 9-16, **2002**
- [38] **Ganguli R.:** *Fuzzy Logic Intelligent System for Gas Turbine Module and System Fault Isolation*, Journal of Propulsion and Power, Vol. 18 (2), pp. 440-447, **2002**
- [39] **Ganguli R., Roy N., Verma R.:** *Soft Computing Application for Gas Path Performance Diagnostics*, ASME Turbo Expo 2004, Vienna, Austria, June 14-17, **2004**
- [40] **Gansel P.:** *Ereignisdetektion und Fehlerdiagnose von Gasturbinen mit Hilfe von Probabilistischen und Radial-Basisfunktions-Netzwerken*, Institut für Luftfahrtantriebe, Universität Stuttgart, Studienarbeit, **2008**
- [41] **Grimm W., Well K.H.:** *Nichtlineare Optimierung*, Institut für Flugmechanik und Flugregelung, Universität Stuttgart, Skriptum, **2001**
- [42] **Grodent M., Navez A.:** *Engine Physical Diagnosis Using a Robust Parameter Estimation Method*, 37th AIAA/ASME/SAE/ASEE Joint Propulsion Conference, AIAA 2001-3768, Salt Lake City, Utah, July 8-11, **2001**
- [43] **Grönstedt T.:** *Development of methods for analysis and optimization of complex jet engine systems*, Department of Thermo- and Fluid Dynamics, Chalmers University of Technology, Doctoral Thesis, **2000**
- [44] **Grönstedt T.:** *A Multi-Point Gas Path Analysis Tool for Gas Turbine Engines with a Moderate Level of Instrumentation*, 15th International Symposium on Air-Breathing Engines, ISABE-2001-1051, Bangalore, India, September 3-7, **2001**
- [45] **Grönstedt T.:** *Identifiability in Multi-Point Gas Turbine Parameter Estimation Problems*, ASME Turbo Expo 2002, 2002-GT-30020, Amsterdam, The Netherlands, June 3-6, **2002**
- [46] **Gulati A., Taylor D., Singh R.:** *Multiple Operating Point Analysis Using Genetic Algorithm Optimisation for Gas Turbine Diagnostics*, 15th Interna-

- tional Symposium on Air-Breathing Engines, Bangalore, India, September 3-7, **2001**
- [47] **Inan S., Frith P.C.W., Eustace R.W.:** *Gas-Path Diagnostics Using an Adaptive Model Modified to Accommodate Real-World Uncertainties*, 16th International Symposium on Air-Breathing Engines, Cleveland, OH, Aug 31 - Sep 5, **2003**
- [48] **Jaw L.C.:** *Recent Advancements in Aircraft Engine Health Management (EHM) - Technologies and Recommendations for the Next Step*, ASME Turbo Expo 2005, GT2005-68625, Reno-Tahoe, Nevada, USA, June 6-9, **2005**
- [49] **Jeffreys H.:** *Theory of Probability*, Oxford University Press, London, **1961**
- [50] **Joos A.:** *Untersuchung von Triebwerksdiagnoseverfahren basierend auf Neuronalen Netzen*, Institut für Luftfahrtantriebe, Universität Stuttgart, Studienarbeit, **2007**
- [51] **Kalman R.E.:** *A New Approach to Linear Filtering and Prediction Problems*, Journal of Basic Engineering, Vol. 82 (3), **1960**
- [52] **Kamboukos Ph., Mathioudakis K., Stamatis A.:** *A Comparative Study of Optimization Methods for Jet Engine Condition Diagnosis*, 16th International Symposium on Air-Breathing Engines, Cleveland, OH, Aug 31 - Sep 5, **2003**
- [53] **Karvounis G., Frith P.:** *Automated Detection of Engine Health Using a Hybrid Model-Based and Fuzzy-Logic Approach*, 16th International Symposium on Air-Breathing Engines, ISABE-2003-1232, Cleveland, OH, Aug 31 - Sep 5, **2003**
- [54] **Kobayashi T., Simon D.L.:** *A Hybrid Neural Network-Genetic Algorithm Technique for Aircraft Engine Performance Diagnostics*, Journal of Propulsion and Power, Vol. 21 (4), **2001**
- [55] **Kobayashi T., Simon D.L.:** *Evaluation of an Enhanced Bank of Kalman Filters for In-Flight Aircraft Engine Sensor Fault Diagnostics*, Journal of Engineering for Gas Turbines and Power, Vol. 127, July, **2005**
- [56] **Koenig R.W., Fishbach L.H.:** *GENENG II - Program for Calculating Design and Off-Design Performance of Two- and Three-Spool Turbofans with as Many as Thress Nozzles*, National Aeronautics and Space Administration (NASA), NASA/TN-D 6553, **1972**

- [57] **Koenig R.W., Fishbach L.H.:** *GENENG - Program for Calculating Design and Off-Design erformance for Turbojets and Turbofan Engines*, National Aeronautics and Space Administration (NASA), NASA/TN-D 6552, **1972**
- [58] **Köhli R., Lipowsky H.:** *Literaturrecherche zum Thema: Monitoring und Diagnose von Gasturbinen*, Institut für Luftfahrtantriebe, Universität Stuttgart, Interner Bericht, ILA-05-A01, **2006**
- [59] **Kreiß J.-P., Neuhaus G.:** *Einführung in die Zeitreihenanalyse*, Springer, Berlin, **2006**
- [60] **Kuhn K.:** *Versuchs- und Messtechnik*, Vorlesungsmanuskript, Institut für Luftfahrtantriebe, Stuttgart, **2000**
- [61] **Kurzke J.:** *Calculation of Installation Effects Within Performance Computer Programs*, AGARD Lecture Series on Steady and Transient Performance Prediction of Gas Turbine Engines, AGARD-LS-183, **1992**
- [62] **Kurzke J.:** *Advanced User-Friendly Gas Turbine Performance Calculations on a Personal Computer*, ASME Turbo Expo 1995, ASME 95-GT-147, Houston, Texas, June 5-8, **1995**
- [63] **Kurzke J.:** *Gas Turbine Cycle Design*, DGLR Short Course - Gas Turbine Performance, Stuttgart, Germany, Sept 24-28, **2007**
- [64] **Li Y.G., Nilkitsaranont P.:** *A Gas Path Diagnostic and Prognostic Approach for Gas Turbine Applications*, ASME Turbo Expo 2007, GT2007-27275, Montreal, Canada, May 14-17, **2007**
- [65] **Lipowsky H., Staudacher S.:** *Vorrichtung und Verfahren zur Überwachung einer Gasturbine*, Deutsches Patent- und Markenamt, DPMA 10 2008 022 459.6, 8. März, **2008**
- [66] **Lipowsky H., Staudacher S., et al.:** *Gas Turbine Fault Diagnostics Using a Fusion of Least Squares Estimations and Fuzzy Logic Rules*, ASME Turbo Expo 2008, GT2008-50190, Berlin, Germany, June 9-13, **2008**
- [67] **Lipowsky H.:** *HealthGT User's Guide*, Institut für Luftfahrtantriebe, Universität Stuttgart, **2009**
- [68] **Lipowsky H., Staudacher S., et al.:** *Application of Bayesian Forecasting to Change Detection and Prognosis of Operational Behaviour of Gas Turbines*, ASME Turbo Expo 2009, GT2009-59447, Orlando, Florida, June 8-12, **2009**
- [69] **Lippe W.M.:** *Soft-Computing*, Springer, Berlin, **2006**

- [70] **Litt J.S., Simon D.L.:** *A Survey of Intelligent Control and Health Management Technologies for Aircraft Propulsion Systems*, National Aeronautics and Space Administration (NASA), NASA TM-2005-213622, **2005**
- [71] **Loboda I., Feldshteyn Y., Yepifanov S.:** *Gas Turbine Diagnostics Under Variable Operating Conditions*, ASME Turbo Expo 2007, GT2007-28085, Montreal, Canada, May 14-17, **2007**
- [72] **Loukis E., Mathioudakis K., Papailiou K.:** *Optimizing Automated Gas Turbine Fault Detection Using Statistical Pattern Recognition*, Journal of Engineering for Gas Turbines and Power, Vol. 116 (1), pp. 165-171, January, **1994**
- [73] **MacMillan W. L.:** *Development of a Modular Type Computer Program for the Calculation of Gas Turbine Design Performance*, Institute of Technology, Cranfield University, PhD Thesis, **1974**
- [74] **Marinai L., Singh R., et al.:** *Detection and Prediction of the Performance Deterioration of a Turbofan Engine*, Proceedings of the International Gas Turbine Congress, IGTC-2003-TS-005, Tokyo, Japan, November 2-7, **2003**
- [75] **Marinai L., Probert D., Singh R.:** *Prospects for Aero Gas-Turbine Diagnostics: A Review*, Journal for Applied Energy, Vol. 79, pp. 109-126, **2004**
- [76] **Marinai L., Singh R.:** *A Bias-tolerant Gas Path Diagnostics Approach Based on Fuzzy Logic*, 17th International Symposium on Air-Breathing Engines, ISABE-2005-1285, Munich, Germany, September 4-9, **2005**
- [77] **Mathioudakis K., Kamboukos Ph, Stamatis A.:** *Turbofan Performance Deterioration Tracking Using Non-Linear Models and Optimization Techniques*, ASME Turbo Expo 2002, GT-2002-30026, Amsterdam, The Netherlands, **2002**
- [78] **Mathioudakis K.:** *Non-linear Methods for Gas Turbine Fault Diagnostics*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [79] **Mathioudakis K., Romessis C.:** *Probabilistic Neural Networks for Validation of On-Board Jet Engine Data*, Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering, Vol. 218 (1), pp. 59-72, **2004**
- [80] **Mathioudakis K., Kamboukos Ph.:** *Assessment of the Effectiveness of Gas Path Diagnostic Schemes*, Journal of Engineering for Gas Turbines and Power, Vol. 128, pp. 57-63, January, **2006**

- [81] **McCulloch W.S., Pitts W.:** *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, Vol. 5, **1943**
- [82] **Merziger G., Wirth T.:** *Repetitorium der Höheren Mathematik*, 4. Auflage, Binomi Verlag, Springer, **1999**
- [83] **Münzberg H.G., Kurzke J.:** *Gasturbinen - Betriebsverhalten und Optimierung*, Springer, Berlin, **1977**
- [84] **Nagy D.:** *Trend- und Einzelfehlerdiagnose von Turboflugtriebwerken mit Hilfe von linearisierten Leistungsrechnungsmodellen*, Institut für Luftfahrtantriebe, Universität Stuttgart, Diplomarbeit, **2007**
- [85] **Nagy D., Staudacher S.:** *An Enhanced Combinatorial Approach for Fault Allocation Based on a Limited Number of Measurements*, Institut für Luftfahrtantriebe, Universität Stuttgart, Interner Bericht, ILA-09-B03, **2009**
- [86] **Nelder J.A., Mead R.:** *A Simplex Method of Function Minimisation*, Computer Journal, Vol. 7, pp. 308-313, **1965**
- [87] **Ong M., Ren X., et al.:** *Future Trends in Aircraft Engine Monitoring*, IEE Seminar - Aircraft Airborne Condition Monitoring, Gloucester, UK, May 14, **2003**
- [88] **Palade V., Bocaniala C.D., Jain L. (Hrsg):** *Computational Intelligence in Fault Diagnosis*, 1st Edition, Springer, London, **2006**
- [89] **Pfoertner H.:** *Engine Health Management - OEM Perspective MTU Aero Engines: OLMOS for RB199 / Tornado*, Aero Engine Life Management in the 21st Century, London, UK, March 2-3, **2004**
- [90] **Pole A., West M., Harrison J.:** *Applied Bayesian Forecasting and Time Series Analysis*, Chapman & Hall, New York, **1994**
- [91] **Priya A., Singh R.:** *Gas Turbine Engine Fault Diagnostics Using Fuzzy Concepts*, AIAA 1st Intelligent Systems Technical Conference, AIAA 2004-6223, Chicago, Illinois, September 20-22, **2004**
- [92] **Provost M.J.:** *COMPASS: A Generalized Ground-Based Monitoring System*, AGARD - Advisory Group for Aerospace Research and Development, AGARD-CP-448, Engine Condition Monitoring - Technology and Experience, Oktober, **1988**
- [93] **Provost M.J., Nevell D.A.:** *Data Processing System Using a Kalman Filtering*, United States Patent, US 5.105.372, April 14, **1992**

- [94] **Provost M.J.:** *Kalman Filtering Applied to Time Series Analysis*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [95] **Qiu H., Eklund N.H., et al.:** *Estimating Deterioration Level of Aircraft Engines*, ASME Turbo Expo 2007, GT2007-27519, Montreal, Canada, May 14-17, **2007**
- [96] **Rigoll G.:** *Neuronale Netze*, Expert-Verlag, Renningen, **1994**
- [97] **Ritter H., Martinetz T., Schulen K.:** *Neuronale Netze - Eine Einführung in die Neuroinformatik selbstorganisierender Netze*, Addison Wesley, **1992**
- [98] **Roesnick M.:** *Eine systemtheoretische Lösung des Fehlerdiagnoseproblems am Beispiel eines Flugtriebwerkes*, Institut für Automatisierungstechnik, Hochschule der Bundeswehr, Dissertation, **1984**
- [99] **Romessis C., Mathioudakis K.:** *Bayesian Network Approach for Gas Path Fault Diagnosis*, Journal of Engineering for Gas Turbines and Power, Vol. 128, pp. 64-72, January, **2006**
- [100] **Roth B.A., Doel D.L., et al.:** *High-Accouracy Matching of Engine Performance Models to Test Data*, ASME Turbo Expo 2003, GT-2003-38784, Atlanta, Georgia, June 16-19, **2003**
- [101] **Roth B.A., Doel D.L., Cissell J.J.:** *Probabilistic Matching of Turbofan Engine Performance Models to Test Data*, ASME Turbo Expo 2005, GT-2005-68201, Reno-Tahoe, Nevada, June 6-9, **2005**
- [102] **Rupp O.:** *Maintenance Cost Forecast for Civil Aircraft Gas Turbine Engines*, 14th International Symposium on Air-Breathing Engines, ISABE99-7021, Florence, Italy, Sept 5-10, **1999**
- [103] **Rupp O.:** *Instandhaltungskosten bei zivilen Strahltriebwerken*, DGLR-Workshop, Maintenance von Flugzeugen und Triebwerken, München, Juli 5-6, **2001**
- [104] **Sallee G.P.:** *Performance Deterioration Based on Existing (Historical) Data - JT9D Jet Engine Diagnostics Program*, National Aeronautics and Space Administration (NASA), Contractor Report, NASA-CR-135448, **1978**
- [105] **Sampath S., Gulati A., Singh R.:** *Development of a Gas Turbine Fault Diagnostics and Life Management Tool*, 17th International Symposium on Air-Breathing Engines, ISABE-2005-1286, Munich, Germany, September 4-9, **2005**

- [106] **Sampath S., Marinai L., et al.:** »*Smart Engine*« - *A Gas Turbine Fault Diagnostics and Life Management Tool*, ASME Turbo Expo 2006, GT2006-91211, Barcelona, Spain, May 8-11, **2006**
- [107] **Sampath S., Singh R.:** *An Integrated Fault Diagnostics Model Using Genetic Algorithm and Neural Networks*, Journal of Engineering for Gas Turbines and Power, Vol. 128, pp. 49-56, January, **2006**
- [108] **Sellers J.J., Daniels C.J.:** *DYNGEN - A Program for Calculating Steady-state and Transient Performance of Turbojet and Turbofan Engines*, National Aeronautics and Space Administration (NASA), NASA/TN-D-7901, **1975**
- [109] **Simon D.L., Bird J., et al.:** *Benchmarking Gas Path Diagnostic Methods: A Public Approach*, ASME Turbo Expo 2008, GT2008-51360, Berlin, Germany, June 9-13, **2008**
- [110] **Singh R.:** *Advances and Opportunities in Gas Path Diagnostics*, 16th International Symposium on Air-Breathing Engines, Cleveland, OH, Aug 31 - Sep 5, **2003**
- [111] **Skölde P., Wallin M., Grönstedt T.:** *An Augmented Multipoint Estimation Technique for Gas Path Analysis Model Generation*, ASME Turbo Expo 2004, GT-2004-53995, Vienna, Austria, June 14-17, **2004**
- [112] **Smart Signal:** *Diagnostic Systems and Methods for Predictive Condition Monitoring*, Canadian Patent, CA 2443579, **2002**
- [113] **Spieler S., Staudacher S., et al.:** *Probabilistic Engine Performance Scatter and Deterioration Modeling*, ASME Turbo Expo 2007, GT2007-27051, Montreal, Canada, May 14-17, **2007**
- [114] **Stamatis A., Mathioudakis K., et al.:** *Jet Engine Fault Detection with Discrete Operating Points Gas Path Analysis*, Journal of Propulsion, Vol. 7 (6), pp. 1043-1048, Nov-Dec, **1991**
- [115] **Staudacher S.:** *HealthGT*, Deutsches Patent- und Markenamt, Wort- und Bildmarke, Registernummer 302008038067.5, Leitklasse 09, Tag der Eintragung 22.10.2008, **2008**
- [116] **Steffens K., Walther R.:** *Driving the Technological Edge in Airbreathing Propulsion*, 16th International Symposium on Air-Breathing Engines, ISABE-2003-1002, Cleveland, OH, Aug 31 - Sep 5, **2003**
- [117] **Szuch J.R.:** *HYDES - A Generalized Hybrid Computer Program for Studying Turbojet or Turbofan Engine Dynamics*, NASA/TM-X-3014, **1974**

- [118] **Tumer I.Y., Bajwa A.:** *A Survey of Aircraft Engine Health Monitoring Systems*, 1999
- [119] **Urban L.A.:** *Gas Path Analysis Applied to Turbine Engine Condition Monitoring*, AIAA/SAE 8th Joint Propulsion Specialist Conference, AIAA-72-1082, New Orleans, Louisiana, Nov 29 - Dec 1, 1972
- [120] **Urban L.A.:** *Parameter Selection for Multiple Fault Diagnostics of Gas Turbine Engines*, Journal of Engineering for Power, Vol. 97 (2), pp. 225-230, April, 1975
- [121] **Varma A., Bonissone P., et al.:** *Anomaly Detection Using Non-Parametric Information*, ASME Turbo Expo 2007, GT2007-28011, Montreal, Canada, May 14-17, 2007
- [122] **VDI Gesellschaft Energietechnik:** *Monitoring und Diagnose in Energietechnischen Anlagen - Trend Monitoring Systeme bei Gasturbinen*, Verein Deutscher Ingenieure (VDI), VDI Berichte 1359, 1997
- [123] **VDMA Fachgemeinschaft Kraftmaschinen:** *Trend Monitoring Systeme für Gasturbinenanlagen - Ein Leitfaden für die Praxis*, Verband Deutscher Maschinen- und Anlagenbau e.V. (VDMA), VDMA-Richtlinie, 2000
- [124] **Visser W.P.J.:** *Gas Turbine Engine Simulation at NLR*, CEAS Symposium on Simulation Technology, MOD05, Delft, The Netherlands, Oct 30 - Nov 1, 1995
- [125] **Visser W.P.J., Broomhead M.J.:** *GSP, a Generic Object-Oriented Gas Turbine Simulation Environment*, ASME Turbo Expo 2000, Munich, Germany, May 8-11, 2000
- [126] **Visser W.P.J., Kogenhop O., Oostveen M.:** *A Generic Approach for Gas Turbine Adaptive Modeling*, Journal of Engineering for Gas Turbines and Power, Vol. 128, pp. 13-19, January, 2006
- [127] **Visser W.P.J., Oostveen M., et al.:** *Experience with GSP as a Gas Path Analysis Tool*, ASME Turbo Expo 2006, Barcelona, Spain, May 8-11, 2006
- [128] **Volponi A.:** *Foundations of Gas Path Analysis I*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, 2003
- [129] **Volponi A.:** *Foundations of Gas Path Analysis II*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, 2003

- [130] **Volponi A.J.:** *Extending Gas Path Analysis Coverage for Other Fault Conditions*, VKI Lecture Series, Gas Turbine Condition Monitoring & Fault Diagnosis, LS-2003-01, Brussels, Belgium, January 13-17, **2003**
- [131] **Volponi A.J., Brotherton T., et al.:** *Development of an Information Fusion System for Engine Diagnostics and Health Management*, National Aeronautics and Space Administration (NASA), Glenn Research Center, Cleveland, Ohio, NASA/TM-2004-212924, **2004**
- [132] **Volponi A.J.:** *Data Fusion for Enhanced Aircraft Engine Prognostics and Health Management*, National Aeronautics and Space Administration (NASA), Glenn Research Center, Cleveland, Ohio, NASA/CR-2005-214055, **2005**
- [133] **Volponi A.J.:** *Use of Hybrid Engine Modeling for On-Board Module Performance Tracking*, ASME Turbo Expo 2005, GT-2005-68169, Reno-Tahoe, Nevada, Jun 6-9, **2005**
- [134] **Walsh P.P., Fletcher P.:** *Gas Turbine Performance*, Second Edition, Blackwell Science Ltd., **2004**
- [135] **Wang W., Lee J., et al.:** *Engine Health Assessment and Prediction Using the Group Method of Data Handling and the Method of Match Matrix - Autoregressive Moving Average*, ASME Turbo Expo 2007, GT2007-27672, Montreal, Canada, May 14-17, **2007**
- [136] **Welsh G., Bishop G.:** *An Introduction to the Kalman Filter*, University of North Carolina, Chapel Hill, TR-95-041, July, **2006**
- [137] **West M., Harrison P.J.:** *Bayesian Forecasting and Dynamic Models*, Springer, New York, **1989**
- [138] **Wulf R.H.:** *Engine Diagnostics Program CF6-50 Engine Performance Deterioration*, National Aeronautics and Space Administration (NASA), Contractor Report, NASA-CR-159867, **1980**
- [139] **Yan W., Li C.J., Goebel K.:** *A Multiple Classifier System for Aircraft Engine Fault Diagnosis*, Proceedings of the 60th Meeting of the Society for Machinery Failure Prevention Technology (MFPT), pp. 271-279, **2006**
- [140] **Yu L.J., Cleary D.J., Cuddihy P.E.:** *A Novel Approach to Aircraft Engine Anomaly Detection and Diagnostics*, Proceedings of the IEEE Aerospace Conference 2004, Vol. 5, pp. 3468-3475, Big Sky, Montana, March 6-13, **2004**

-
- [141] **Yu L.J., Cleary D., et al.:** *Information Fusion Strategy for Aircraft Engine Health Management*, ASME Turbo Expo 2007, GT2007-27174, Montreal, Canada, May 14-17, **2007**
- [142] **Zadeh L.A.:** *Fuzzy Sets*, Journal of Information and Control, Vol. 8, pp. 338-353, **1965**
- [143] **Zedda M., Singh R.:** *Gas Turbine Engine and Sensor Fault Diagnosis Using Optimisation Techniques*, 35th AIAA/ASME/SAE/ASEE Joint Propulsion Conference, AIAA 99-2530, Los Angeles, California, June 20-24, **1999**

Lebenslauf des Verfassers

PERSÖNLICHE DATEN

Name Holger Lipowsky
Geboren am 08. August 1978 in Schwetzingen
Nationalität Deutsch

BERUFLICHER WERDEGANG

seit Juli 09 Angestellter, Roland Berger Strategy Consultants GmbH, Stuttgart
Juli 05 – Juni 09 Wissenschaftlicher Mitarbeiter, Institut für Luftfahrtantriebe, Universität Stuttgart, Promotion im Verbundprojekt »Kraftwerke des 21. Jahrhunderts (KW21)« in Kooperation mit der MTU Aero Engines GmbH, München
Okt. 01 – März 02 Praxissemester, Lufthansa Technik AG, Hamburg, Abteilung »Design Engineering Structures & Systems«

STUDIUM

Juni 05 Abschluss des Diploms mit Note 1,3
Nov. 04 – Juni 05 Diplomarbeit, Whittle Laboratory, University of Cambridge (UK), Department of Engineering, »A Study of Lean-Premixed Combustor Dynamics«, Note 1,0
März 03 – Sept. 04 Studienarbeit, Institut für Thermodynamik der Luft- und Raumfahrt, Universität Stuttgart, »Aufbau und Inbetriebnahme eines Kanals zur Untersuchung von Filmkühlungsvorgängen mit Hilfe von Infrarotthermografie«, Note 1,0
Apr. 02 – Sept. 04 Hauptstudium der Luft- und Raumfahrttechnik, Universität Stuttgart, Vertiefungsfächer Thermodynamik und Luftfahrtantriebe
Okt. 99 – Sept. 01 Grundstudium der Luft- und Raumfahrttechnik, Universität Stuttgart, Abschluss des Vordiploms mit Note 1,7

SCHULBESUCH

Juni 98 Abschluss des Abiturs mit Note 1,1
Apr. 96 – Juni 96 Besuch der West Linn High School, Portland, Oregon
Aug. 89 – Juni 98 Besuch des Hebel-Gymnasium, Schwetzingen

