

Luftfahrtantriebe
Institut für Luft- und Raumfahrt F1
Technische Universität Berlin
Marchstraße 14
D - 10587 Berlin



Luftfahrtantriebe

Bericht
12/99-1

TEC (Total Engine Control)

Neuronale Netze

Dipl.-Phys. Detlef Schweng
Juli 1999

I.1 Zusammenfassung

Die Anforderungen an die Sicherheit von Flugzeugen und ihre Verfügbarkeit, sowie die Forderung nach niedrigen Wartungskosten haben zur Entwicklung von Überwachungssystemen von Triebwerken (Engine Monitoring Systems) geführt. Die heute verfügbaren Methoden für die Überwachung von Triebwerken haben einen hohen Stand der Technik erreicht. Grenzen solcher Systeme liegen in Unterschieden zwischen einzelnen Triebwerken einer Triebwerksserie, ihrer geringen Flexibilität und ihrer begrenzten Möglichkeiten mit verrauschten Meßwerten umzugehen. Die Technologie der neuronalen Netze zeigt hier einen alternativen Ansatz.

Nach einer Besprechung der charakteristischen Eigenschaften künstlicher neuronaler Netze und des Standes der Technik wird ein System vorgestellt, welches auf Grund von Kreisprozeßdaten, welche im stabilisierten Zustand des Triebwerkes gemessen werden, den Zustand einzelner Triebwerkskomponenten identifizieren kann. Die Fähigkeiten des Systems werden anhand von numerischen Simulationen und experimentellen Daten eines realen Triebwerkes verifiziert. Die Ergebnisse zeigen in beiden Fällen eine sehr gute Identifikationsrate.

Verteiler: TIB Hannover (2)
BGT, Herrn Elsing (1)
BRR, Dr. Dirmeier (1)

DARA (5)
BRR, Dr. Richter (1)
Prof. Fottner, Universität der
Bundeswehr (1)

Unterschrift

I.2 Inhaltsverzeichnis

I.1	ZUSAMMENFASSUNG.....	1
I.2	INHALTSVERZEICHNIS	2
I.3	SYMBOLS.....	3
I.4	EINFÜHRUNG.....	3
KAPITEL 2	6
2.1	NEURONALE NETZE	6
KAPITEL 3	12
3.1	HEUTIGE SYSTEME ZUR ÜBERWACHUNG MIT HILFE NEURONALER NETZE.....	12
3.2	BESTIMMUNG VON KREISPROZESSPARAMETERN ZUR REGELUNG EINER BRENNKAMMER MIT ZWEIFACHER EINSPRITZUNG	15
3.3	TRIEBWERKSREGELUNG.....	16
3.4	ANWENDUNG ZUR AUSWERTUNG VON VIBRATIONEN UND ROTORDYNAMIKEN	17
3.5	ÜBERWACHUNG VON HILFSSYSTEMEN.....	20
3.6	DETEKTION VON EINSETZENDEM VERDICHTERPUMPEN	23
3.7	IDENTIFIKATION VON SENSORFEHLERN	23
KAPITEL 4	26
4.1	FEHLERKLASSIFIKATION DES TRIEBWERKES MIT HILFE VON NEURONALE NETZEN	26
4.2	DAS SYSTEM.....	26
4.3	ANALYTISCHE ERGEBNISSE.....	27
4.4	NUMERISCHE ERGEBNISSE	29
4.5	KLASSIFIKATIONSSYSTEM AUF DER BASIS VON KÜNSTLICHEN NEURONALEN NETZEN	32
4.6	ERGEBNISSE DER SIMULATION MIT NEURONALEN NETZEN	35
4.7	VERIFIKATION AN EINEM REALEM TRIEBWERK	38
4.8	UNTERSUCHUNGEN AN ZWEIKREISTRIEBWERKEN.....	39
4.9	WEITERE UNTERSUCHUNGEN	40
KAPITEL 5	42
5.1	ZUSAMMENFASSUNG.....	42
KAPITEL 6	43
6.1	VERÖFFENTLICHUNGEN UND VORTRÄGE	43
ANHANG	44
A.1	LITERATURLISTE	44

1.3 Symbole

Bez. Einh. Beschreibung

ECU		Electronic Control Unit
FADEC		Full Authority Digital Engine Control
i_i		Eingangsneuron
h_i		Neuron der Zwischenschicht
N_1	rpm	Drehzahl Niederdruckwelle
N_2	rpm	Drehzahl Hochdruckwelle
o_i		Ausgangsneuron
P_2	Pa	Totaldruck Triebwerkseinlaß
P_{13}	Pa	Totaldruck am Fanausgang
P_{25}	Pa	Totaldruck am Hochdruckverdichtereingang
P_3	Pa	Totaldruck am Hochdruckverdichterausgang
P_5	Pa	Totaldruck an der Niederdruckturbine
T_2	K	Totaltemperatur am Triebwerkseinlaß
T_{25}	K	Totaltemperatur am Hochdruckverdichtereingang
T_3	K	Totaltemperatur am Hochdruckverdichterausgang
T_{44}	K	Turbinengastemperatur (Turbine Gas Total Temperature TGT)
T_5	K	Totaltemperatur am Niederdruckturbinenausgang
TTRF	K	Brennkammer Referenz Temperatur
TLA	deg.	Schubhebelstellung (Throttle Lever Angle)
WF	g/s	Brennstoffdurchsatz
w_{ij}		Gewicht des neuronalen Netzwerkes

1.4 Einführung

Eines der wichtigsten ökonomischen Ziele aller Fluggesellschaften sind niedrige Betriebskosten. Die Einführung neuer Technologien bei der Entwicklung von Flugzeugen hat zu einer signifikanten Zunahme der Zuverlässigkeit geführt; andererseits stellt die Wartung immer noch einen der Hauptposten im Rahmen der Betriebskosten dar. Zur Senkung der Betriebskosten sind erhebliche Anstrengungen unternommen worden. In der zivilen Luftfahrt hat sich die

zustandsabhängige Wartung durchgesetzt, was sowohl zu einer direkten Verringerung des Kraftstoffverbrauchs, als auch zu einer Verringerung der Material- und Personalkosten bei der Wartung geführt hat. Die zustandsabhängige Wartung erfordert eine frühe Erkennung von Fehlern, um eine korrigierende Maßnahme planen zu können, wodurch die Zuverlässigkeit und die Betriebssicherheit erhöht wird.

Die Erkennung einer Wirkungsgradverschlechterung oder einer Fehlfunktion des Triebwerkes erfordert eine kontinuierliche Überwachung. Wenn das System nicht nur die Abweichung vom Normalzustand, sondern auch die Ursache des Fehlers erkennen kann, ist man in der Lage eine korrigierende Maßnahme bei erheblich niedrigeren Kosten durchzuführen. Heutige Überwachungssysteme nutzen eine Trendanalyse für diese Aufgabe. Sie beinhaltet die Analyse von Parametern des Kreisprozesses, Vibrationen und Signalen der Hilfssysteme. Mit Hilfe spezieller Techniken sind auch Versuche zur Erkennung von Sensorfehlern unternommen worden. Dabei auftretende Probleme sind vor allem die Erkennung von Mustern bei verrauschten Meßdaten, unvollständige Daten für eine vollständige Analyse sowie die unterschiedlichen Referenzbedingungen jedes einzelnen Triebwerkes. Die neue Technologie der künstlichen neuronalen Netzwerke kann eine nützliche Alternative sein. Die Fähigkeit zu lernen, die Adaptionen- und Klassifikationsmöglichkeiten scheinen für die Lösung bisheriger Probleme geeignet zu sein.

Der folgende Bericht gibt eine kurze Einführung in die Technik der neuronalen Netze, ihre funktionellen Prinzipien und ihre Klassifikationseigenschaften. Es folgt die Beschreibung der heutigen Entwicklungen neuronaler Netze zur Triebwerksüberwachung, sowie des Einsatzes unterschiedlicher Netzwerkarten für die unterschiedlichen Überwachungsaufgaben.

Im Hauptteil des Berichts wird ein System vorgestellt, welches auf Grund von Kreisprozeßdaten, welche im stabilisiertem Zustand des Triebwerkes gemessen werden, den Zustand einzelner Triebwerkskomponenten identifizieren kann. Die Fähigkeiten des Systems werden anhand von numerischen Simulationen und

experimentellen Daten eines realen Triebwerkes verifiziert. Die Ergebnisse zeigen in beiden Fällen eine sehr gute Identifikationsrate.

Kapitel 2

2.1 Neuronale Netze

Bei viele Aufgaben ist das menschliche Gehirn den heutigen digitalen Computern weit überlegen. Sogar ein einjähriges Kind ist in der Lage Objekte, Gesichter usw. viel schneller und besser zu erkennen als das heute beste System aus der künstlichen Intelligenz (KI), auch wenn es auf dem schnellsten Superrechner läuft. Das Gehirn besitzt eine Reihe von Fähigkeiten, welche für die künstliche Intelligenz notwendig sind:

- Es ist robust und fehlertolerant. Der Tod einiger Nervenzellen wirkt sich nicht auf die Leistungsfähigkeit des Gehirns aus.
- Es ist flexibel, da es sehr einfach anhand von Lernbeispielen an eine neue Umgebung angepaßt werden kann.
- Es kann mit Informationen, die verrauscht oder unvollständig sind, arbeiten.
- Es ist massiv parallel.
- Es ist klein, kompakt und hat einen "einfachen" Aufbau.

Bild 1 zeigt eine Art eines biologischen Neurons. Es besteht aus Nervenleitungen, den Dendriten, auf denen Signale von anderen Neuronen empfangen werden. Die Dendriten senden die Eingaben zum Zellkern, wo alle Eingaben summiert werden. Sobald die Eingangsinformationen einen bestimmten Schwellwert überschreiten, wird das Neuron aktiviert und beginnt Ausgangssignale über das Axon zu senden. Das Axon sendet das Ausgangssignal zu einer Reihe von Synapsen, welche mit den Dendriten anderer Neuronen verbunden sind. Die Synapsen übertragen das Signal zu den anderen Neuronen, wobei sie in der Lage sind, das Signal zu verstärken oder abzuschwächen.




Bild 1 Biologisches Neuron (Hertz1991)

Heutige Forschung in diesem Bereich konzentriert sich auf die Entwicklung von künstlichen neuronalen Netzen. Das erste Modell eines binären Neurons wurde von McCulloch und Pitts (1942) eingeführt und ist Ausgangspunkt aller bisherigen Computermodelle. Dieses künstliche Neuron (Bild 2) empfängt die Eingabe über die Punkte i von anderen Neuronen. Die Synapsen, welche das Signal übertragen, können das Signal über die Gewichtungen w_i verstärken oder abschwächen. Diese Eingangsleitungen entsprechen im biologischen Neuron den Dendriten, die folgende Summenbildung und der Schwellwert entsprechen dem Zellkörper und die Ausgangsleitung entspricht dem Axon.




Bild 2 Von McCulloch and Pitts eingeführtes künstliches Neuron (Hertz 1991)

Anfang der 60'er Jahre entwickelte sich eine Welle von Aktivitäten rund um die Gruppe von Frank Rosenblatt, welche sich auf das Problem konzentrierten, wie man Gewichte w für eine spezielle zu lösende Aufgabe findet. Diese Gruppe

arbeitete an "Perceptron" genannten Netzwerken, in denen die einzelnen Einheiten in Schichten angeordnet sind und mit sogenannten "feed-forward" Verbindungen zwischen einer und der nächsten Schicht, wie in Bild 3 gezeigt, verbunden sind.




Bild 3 Einschicht Perceptron (Hertz 1991)

Rosenblatt konnte einen Lernalgorithmus für die einfachste Klasse von Perceptronen ohne Zwischenschichten erstellen und bewies dessen Konvergenz. Leider ist diese Art von Perceptronen nicht in der Lage alle vorgegebenen Probleme zu lösen. Der Durchbruch erfolgte erst mit den in Bild 4 gezeigten Vielschichtperceptronen (multilayer perceptron), als zunächst Werbos (1974) und dann Rumelhart, Hinton und Williams (1986) einen Lernalgorithmus vorstellten, welcher eine Lernregel zur Adaption der Gewichte in einem Multilayer Perceptron beinhaltet.




Bild 4 Zweischicht Perceptron (Hertz1991)

Die meisten künstlichen neuronalen Netze beruhen auf einer Abwandlung dieser Vielschichtperceptrons. Die Einführung einer zeitlichen Auflösung der Eingangssignale führt zu einem Netzwerk (Time Delay Network), welches zur Erkennung einer zeitlichen Sequenz von Ereignissen benutzt werden kann. Dieses Netzwerk ist zur Zeit das einzige System, welches zur Analyse von transienten Übergängen genutzt werden kann.

Ein weiteres Netzwerk, das sogenannte Kohonennetzwerk (Kohonen Feature Map), ist besonders geeignet zur Klassifizierung von Datensätzen. Dieses Netzwerk beinhaltet eine Anzahl von Neuronen, wobei jedem Neuron eine Klasse von Eingangsdaten zugeordnet sind, z.B. ein bestimmter Triebwerksfehler oder eine Kombination verschiedener Fehler. Es ist daher sehr gut geeignet, die Ursache eines Triebwerksfehlers zu identifizieren.

Nähere Informationen über neuronale Netze finden sich in den Büchern von Hertz, Krogh and Palmer (1991), Rojas (1993) und Arbib (1995). Tabelle 1 zeigt einen Überblick über drei Haupttypen von neuronalen Netzen und deren Anwendung zur Zustandsüberwachung von Triebwerken.

Multilayer Perceptron	Time Delay Network	Kohonen Feature Map
Kreisprozeß-Vorhersage (Long 1995) Kreisprozeß-Überwachung (Chen et al 1994) (Eustace et al 1995) (Torella et al 1995) (Chbat et al 1996)		
	Flugregelung (Krogmann 1993) Triebwerksregelung (Song et al 1995)	
Vibrationsüberwachung (Roemer et al 1996) (Steinhardt et al 1996)	Vibrationsüberwachung (Long 1993)	Vibrationsüberwachung (Carret al 1995)
	Diagnose des Brennstoff- systems (Illi et al 1994)	
		Detektion von einsetzendem Verdichterpumpen (Hönen et al 1996)
	Sensorfehlererkennung (Konstantopoulos et al 1994) (Nepach et al 1995) (Napolitano et al 1995)	

Tabelle 1 Anwendung Neuronaler Netze bei der Triebwerksüberwachung

Künstliche neuronale Netze haben einige generelle Charakteristiken, welche berücksichtigt werden müssen, wenn sie in technische Anwendungen implementiert werden sollen.

- Ein neuronales Netz muß anhand von Beispielen des fehlerfreien Betriebszustands, sowie den möglichen Fehlern oder Abweichungen innerhalb

der zu erwartenden Bereiche trainiert werden, bevor es einen Triebwerkszustand korrekt klassifizieren kann. Dadurch erhält das System die Fähigkeit sich an neue Zustände zu adaptieren.

- Ein neuronales Netz klassifiziert Eingangsdaten. Diese Klassifikation ist nicht perfekt, was heißt, daß es immer Zustände geben kann, welche nicht korrekt interpretiert werden. Es kann mit verrauschten oder unvollständigen Daten zurechtkommen, diese erhöhen jedoch das Risiko von Fehlklassifikationen.
- Im Falle von ständig lernenden Netzwerken kann die Reproduzierbarkeit der Ergebnisse nicht garantiert werden. Dies ist eine harte Einschränkung für Anwendungen, welche präzise, vorhersagbare Ausgabewerte in Abhängigkeit von den Eingangsdaten liefern müssen.

Kapitel 3

3.1 Heutige Systeme zur Überwachung mit Hilfe neuronaler Netze

Heutige Methoden der Triebwerksüberwachung sammeln Triebwerksdaten beispielsweise mit Hilfe der Ausgangssignale der FADEC des Triebwerkes sowie Signale anderer Wandler, speichern diese in digitaler Form im Flugzeug, und übertragen sie schließlich zu einem Verarbeitungssystem am Boden in Form eines Ausdrucks, per Diskette oder per Funk. Die Verarbeitungssysteme sind meistens "Mainframe Computer" oder PC's, welche zur Analyse der Daten genutzt werden. Diese berechnen aus den Daten die zur Behebung der Fehler notwendigen Wartungsarbeiten. Für Langstreckenflüge wird diese Analyse mehrere Male wiederholt um eine Trendanalyse, bzw. eine Modulanalyse durchführen zu können. Für ein Zweikreistriebwerk besteht ein typischer Datensatz aus den folgenden Parametern (Burnell 1995):




Bild 5 BR700 Main Engine Parameters
(Burnell 1995)

Bez. Einh. Beschreibung

TLA	deg.	Schubhebelstellung (Throttle Lever Angle)
T ₂	K	Totaltemperatur am Triebwerkseinlaß
T ₂₅	K	Totaltemperatur am Hochdruckverdichtereingang
T ₃	K	Totaltemperatur am Hochdruckverdichterausgang
T ₄₄	K	Turbinengastemperatur (Turbine Gas Total Temperature TGT)

P_2	Pa	Totaldruck Triebwerkseinlaß
P_{13}	Pa	Totaldruck am Fanausgang
P_{25}	Pa	Totaldruck am Hochdruckverdichtereingang
P_3	Pa	Totaldruck am Hochdruckverdichterausgang
P_5	Pa	Totaldruck an der Niederdruckturbine
N_1	rpm	Drehzahl Niederdruckwelle
N_2	rpm	Drehzahl Hochdruckwelle
WF	g/s	Brennstoffdurchsatz

Bei Kurzstreckenflügen wird zur Trendanalyse je ein Datensatz bei jedem Take-Off aufgenommen. Parameter für einen solchen Datensatz werden von Burnell (1995) für ein Zweikreistriebwerk folgendermaßen angegeben:

Bez. Einh. Beschreibung

TLA	deg.	Schubhebelstellung (Throttle Lever Angle)
T_2	K	Totaltemperatur am Triebwerkseinlaß
T_{44}	K	Turbinengastemperatur (Turbine Gas Total Temperature TGT)
P_2	Pa	Totaldruck Triebwerkseinlaß
N_1	rpm	Drehzahl Niederdruckwelle
N_2	rpm	Drehzahl Hochdruckwelle

Klassische Methoden, welche bei der Analyse des Kreisprozesses angewandt werden, sind die Trendanalyse und die Modulanalyse. Dabei werden zunächst potentielle Fehler durch Analyse der Veränderungen (Trendanalyse) einiger Hauptparameter erkannt. Die folgende Modulanalyse wird benutzt, um die Ursache des Fehlers zu lokalisieren. Der größte Nachteil dieser Methoden ist die schwierige Anpassungsmöglichkeit an neue Arten von Fehlern. Dieses Problem kann mit Hilfe von neuronalen Netzen gelöst werden.

Eine der wichtigsten Entwicklungen unter Verwendung neuronaler Netze ist in diesem Bereich von Eustace and Merrington [1995] vom "Aeronautical and Maritime Research Laboratory in Melbourne, Australia" gemacht worden. Sie benutzten ein Backpropagation Netz mit einer versteckten Schicht zur Analyse

von experimentellen Daten eines F404 Triebwerkes. Zur Bestimmung von fünf Fehlerzuständen werden 60 Neuronen in der Zwischenschicht benötigt. Als größtes Problem erwiesen sich die Unterschiede einzelner Triebwerke, welche durch Herstellungstoleranzen hervorgerufen werden. Dies führte zu einer maximalen Diagnosegenauigkeit von 87 %.

Torella (1995) von der "Italian Air Force Academy in Neapel" und Lombardo von der "Università di Palermo" entwickelten ein Einschicht-Perceptron mit unterschiedlichen Typen von Aktivierungsfunktionen in den Neuronen und identifizierten das Netzwerk, welches für ihre Aufgaben die beste Erkennungsrate lieferte.

Chen Daguang und Liu Fusheng (1994) von der "Beijing University of Aeronautics and Astronautics" wendeten ein Dreischicht Backpropagation Netzwerk mit einem Fuzzylogikteil an, und konnten damit eine erfolgreiche Fehlerdiagnose durchführen.

Eine spezielle Anwendung wird von Long (1995) beschrieben, welche an der P&W F1128 im integrierten aircraft flight system benutzt wurde. Die Anwendung benötigt eine kontinuierliche Bestimmung der Maschinenleistung. Um dies zu erreichen müssen die Wirkungsgrade der einzelnen Komponenten und der Luftmassenstrom bestimmt werden. Ein System gekoppelter Backpropagation Netzwerke wurde zur Bestimmung dieser Parameter entwickelt. Die Genauigkeit dieser Berechnungen liegen innerhalb der Grenzen, welche von der Genauigkeit der Eingangsdaten zu erwarten sind. Die Architektur des neuronalen Netzwerkes wurde von einem weiteren Netzwerk optimiert.

Ein Beispiel zur Analyse des Kreisprozesses wurde zur näheren Diskussion in diesem Kapitel ausgewählt: Die Bestimmung der Referenztemperatur zur Aufteilung des Brennstoffmassenstroms in einer Brennkammer mit zweifacher Einspritzung von General Electric (Chbat, Rajamani and Ashley, 1996).

Eine weitere interessante Anwendung, welche hier diskutiert werden soll, wird von Neppach und Casdorff (1995) präsentiert, welche mit Hilfe der Überwachung von dynamischen Zustände des Triebwerkes Sensorfehler identifizieren kann.

3.2 *Bestimmung von Kreisprozeßparametern zur Regelung einer Brennkammer mit zweifacher Einspritzung*

Chbat, Rajamani und Ashley (1996) haben eine Anwendung von neuronalen Netzen zur Regelung einer industriellen Turbine betrachtet. Die Maschine hat ein zweifaches Einspritzsystem (Bild 6), wobei eine Brennkammerreferenztemperatur zur Regelung des Aufteilungsverhältnisses zwischen dem primären und sekundären Brennstoffstrom zur Minimierung der Emission von Stickstoffoxid (NO_x) benutzt wird. Die Referenztemperatur ist ein Parameter, der nicht direkt gemessen werden kann, sondern von den übrigen Kreisprozeßparametern bestimmt werden muß. Der vollständige Satz von Gleichungen zur Bestimmung dieser Temperatur ist zu kompliziert, um im Regler selbst durchgerechnet zu werden. Dieses Problem wird heute mit Hilfe einer vereinfachten nichtlinearen Modellapproximation gelöst. Ein alternativer Ansatz dazu ist der Einsatz eines Neuronalen Netzes.

Das neuronale Netz wird zur Approximation des kompletten Satzes der Gleichungen direkt im Regler benutzt. Die vier Parameter Verdichterausgangsdruck und -temperatur, Abgastemperatur und Abgasmassenstrom sind der Eingang zu einem einfachen Zweischichtperceptron (Bild 7), welches die Brennkammerreferenztemperatur als kontinuierliches Ausgangssignal generiert.




Bild 6 Schema einer "Dry Low NO_x Brennkammer" (Chbat et al 1996)




Bild 7 Neuronales Netzwerk zur Bestimmung einer Brennkammerreferenztemperatur (Chbat et al 1996)

Die Ergebnisse einer Studie, welche berechnete Eingangsdaten benutzt, sind ermutigend. Folgende Vorteile können identifiziert werden:

- Die Berechnungsgeschwindigkeit eines neuronalen Netzes ist höher als die eines vereinfachten nichtlinearen Modells.
- Der Fehler ist von der gleichen Ordnung wie beim vereinfachten Modell.
- Das Perceptron ist weniger anfällig gegen Fehler in den Modellparametern.

Es muß jedoch festgestellt werden, daß der Abgasmassenstrom normalerweise nicht direkt gemessen wird, was zu einer weiteren Berechnung führt und damit die Genauigkeit der gesamten Berechnung weiter verschlechtert.

3.3 Triebwerksregelung

Die Zuverlässigkeits- und Sicherheitsanforderungen für Triebwerksregelungssysteme sind wegen ihrer Genauigkeitsgrenzen sowie der Reproduzierbarkeit der Ausgaben ein Hindernis zur Anwendung von neuronalen Netzen. Krogmann (1993) beschreibt in seinem Patent einen adaptiven Flugregler, welcher auf der

Basis eines Time-Delay Netzwerkes beruht. Dabei geht er nicht auf das Problem einer falschen Antwort bezüglich der eingegebenen Eingangsdaten ein.

Song und Grimble (1996) berichten über die Anwendung von neuronalen Netzwerken in allgemeinen multivariablen Reglern. Ein festes, multivariablen, robustes, rückgekoppeltes System wird hier als Regler benutzt. Zwei neuronale Netze arbeiten dabei zusammen, um ein nichtlineares Signal zur Regelung zu erzeugen. Dieser Ansatz könnte akzeptabel sein, wenn die Einheit der neuronalen Netze mit Hilfe von Grenzwerten überwacht wird, um einen sicheren Betrieb zu gewährleisten.

Sicherheitsansprüche an Triebwerksregler werden wahrscheinlich die Anwendung von neuronalen Netzen auf Optimierungsaufgaben begrenzen, die keinerlei Auswirkungen auf den sicheren Betrieb haben.

3.4 Anwendung zur Auswertung von Vibrationen und Rotordynamiken

Die allgemein benutzte Methode zur Analyse der Vibrationen beruht auf der Messung der Vibrationsamplituden. Korrigierende Maßnahmen werden notwendig, sobald die mittlere Vibrationsenergie einen bestimmten Schwellwert überschreitet. Das hauptsächliche Problem der Rotordynamik ist ein unausgewuchteter Fan. Dieses Problem kann mit Hilfe der Messung der Phase und der Amplitude der Vibrationen im Bereich des Fans festgestellt und korrigiert werden.

Andererseits enthalten die Vibrationsdaten wesentlich mehr Informationen über den Zustand des Triebwerkes als die Information über einen unausgewuchteten Fan. Die Analyse einer solchen Menge von Daten ist sehr rechenaufwendig und kann mit Hilfe heutiger Methoden nicht während des Fluges erfolgen. Die ausgezeichneten Mustererkennungsfähigkeiten von neuronalen Netzen könnten eine neue Möglichkeit zur Analyse und Klassifikation solcher Daten liefern, welche sogar während des Fluges Anwendung finden könnte.

Zwei fundamental unterschiedliche Methoden werden von diversen Wissenschaftlern genutzt:

- Die Vorverarbeitung des Vibrationssignals mit Hilfe der Fourier-Analyse und die Benutzung des Amplituden- und des Phasenspektrums als Eingangssignal zum neuronalen Netz.
- Die direkte Eingabe des Zeitsignals der Vibrationsamplituden in ein neuronales Netzwerk zur Identifikation von Vibrationsmustern im Zeitsignal.

Das erstere Prinzip wird von Roemer, Hong und Hesler (1996) von der "Stress Technology Inc. in Rochester, New York" benutzt. Sie verwenden einen digitalen Signalanalysator zur Generierung der Amplituden- und Phaseninformationen aus den Signalen der Beschleunigungsaufnehmer zur Eingabe in das neuronale Netzwerk. Das System wurde auf ein Experimentalrotorsystem angewendet. Das einzelne Perceptron, welches zunächst zur Lösung des Gesamtproblems benutzt wurde, wurde zugunsten einer geteilten Netzwerkarchitektur aufgegeben. Ein vorverarbeitendes Zweischichtperceptron wird zur groben Diagnose der Fehler und der Ursachen benutzt; ein zweites, spezialisiertes Perceptron bestimmt dann weitere Details des Zustandes, welcher vom vorverarbeitenden Netzwerk herausgefunden wurde. Das Training des Netzes wurde sowohl mit experimentellen Daten als auch mit numerischen Ergebnissen des Experimentalsystems, welche auf der finiten Elemente Methode (FEM) beruhen, durchgeführt. Ein unausgewuchteter Fan wurde sicher festgestellt, sogar gekoppelte Fehler wurden erkannt, allerdings nicht mit der gleichen Genauigkeit. Das getrennte Netzwerk hat sich als das zuverlässigere System herausgestellt.

Auf der Basis der Fourier-Analyse wird ein System zur Vibrationsanalyse von Carr und Cowley (1995), Rolls-Royce diskutiert. Das Spektrum wird in ein Kohonennetzwerk eingegeben, welches bezüglich der charakteristischen Form eine Klassifikation des Fehlers vornehmen kann. Sie betrachten das Netzwerk als ein System, welches zur Echtzeitanalyse des Zustandes des Triebwerkrotorsystems im Cockpit eingesetzt werden kann. Ein ähnlicher Ansatz

wird von Steinhardt et al (1996) von der MTU, München verfolgt, welcher ein Finite Elemente Modell des gesamten Triebwerkes benutzt.

Long (1993) von der NeuroDyne Inc., Cambridge, Massachusetts nutzt direkt das Zeitsignal als Eingabe zum neuronalen Netzwerk. Sie untersucht eine Anzahl von Time Delay Networks zur Klassifikation und Identifikation von Vibrationen flexibler Strukturen, wie Tragflügel mit unbekanntem dynamischen Eigenschaften. Das Ziel der Studie ist die Entwicklung eines Systems mit einigen Vorhersagemöglichkeiten, welche von einer Abfolge von trainierten Ereignissen abgeleitet wird, so daß eine kompensierende Maßnahme ausgeführt werden kann. Die numerische Anwendung inklusive des Reglers ist geeignet für einfache Vibrationsmoden; Fehler traten vermehrt bei komplexeren Moden auf.

3.5 Überwachung von Hilfssystemen

Die sekundären Systeme eines Triebwerkes wie das Luftsystem, das Ölsystem und die Hilfssystemeinheiten sind zur Zeit nicht Gegenstand einer intensiven Überwachung. Druckverluste über dem Filter, einige Öl- und Lufttemperaturen, sowie die Detektion von Span im Öl werden normalerweise zur Ausgabe einer Warnmeldung, sowie zur Identifikation von internen Feuern gemessen. Kein neuronales Netz wurde bisher in diesem Bereich eingesetzt.

Dem Brennstoffsystem, eines der Hauptkomponenten des Triebwerkes, wurde bisher mehr Aufmerksamkeit gewidmet. Illi, Greitzer, Kangas und Reeve (1994), beschreiben das System einer neuronalen Netzwerkkomponente zum Einsatz im Diagnosesystem des AGT 1500 Triebwerkes. Das TEDANN (Turbine Engine Diagnostic Artificial Neural Networks) analysiert die Dynamik des Brennstoffstroms, wobei Fehler im Brennstoffsystem mit Hilfe der Signale aus dem ECU Diagnose Stecker erkannt werden. Diese Signale zeigen den Zustand der einzelnen elektromechanischen Komponenten des Brennstoffsystems als Antwort auf die ECU-Kommandos an. Der Prototyp des TEDANN-Systems konzentriert sich dabei auf folgende drei Brennstoffsystemfehler:

- anschlagendes Hauptventil,
- hängendes Hauptventil ,
- Brennstoffstromfehler.

Die Diagnose wird aufgrund von drei Brennstoffsystemsignalen durchgeführt:

- WF-request,
- WF-actual und
- WF-solenoid.

Diese Werte bestimmen den spezifischen Bedarf an Brennstoff, welcher in die Brennkammer geleitet werden soll. Das WF-request Signal ist die Anforderung der

ECU an Brennstoff, das WF-solenoid Signal ist das ECU Signal zur Positionierung des Hauptventils als Antwort auf die Signale WF-request und WF-actual. Das WF-actual Signal ist das Rückantwortsignal des Hauptventils über die aktuelle Stellung des Ventils. Bild 8 zeigt das Verhalten dieser Parameter während eines normalen Starts und während der drei Fehlersituationen. Die Überwachungsprinzipien beruhen auf der Antwortrate des Systems, welches eine Abtastrate von 3 bis 10 Werten pro Sekunde besitzt.

Zu Lösung der Aufgabe wurde ein Perceptron gewählt, welches kein Time Delay Netzwerk ist. Daher kann es aus dem Zeitsignal auch nicht die Antwortzeiten, bzw. erste und zweite Ableitungen bestimmen. Diese werden separat bestimmt und als Input dem Netzwerk zur Verfügung gestellt.

Tabelle 2 zeigt die Ausgabe des Netzwerkes für die vier untersuchten Fehlerzustände. Die Ausgabewerte werden auf folgende Weise interpretiert:

0.00 - 0.25 kein Fehler

0.26 - 0.75 Warnung (Fehler)

0.76 - 1.00 kritisch (Fehler)

<u>Aktueller Zustand</u>	Anschlag. Hauptventil	hängendes Hauptventil	Brennstoff- strom Fehler
Anschlagendes Hauptventil	<u>0.84</u>	0.22	0.06
Hängendes Hauptventil	0.03	<u>1.00</u>	0.00
Brennstoffmassenstromfehler	0.10	0.09	<u>0.47</u>
Kein Fehler	0.06	0.19	0.41

Tabelle 2 TEDANN's Diagnose Leistung

Die korrekt diagnostizierten Werte für die drei Fehler sind unterstrichen. Im Falle des hängenden Ventils bestimmt das neuronale Netz korrekterweise den Wert 1.0 für den Fehler, während die übrigen Fehlerwerte eindeutig im Bereich "kein Fehler" liegen. Allerdings zeigt das Netz beim fehlerfreien Zustand eine Warnung beim Brennstoffstrom an. Dies zeigt die vorher beschriebenen Grenzen des Systems an.

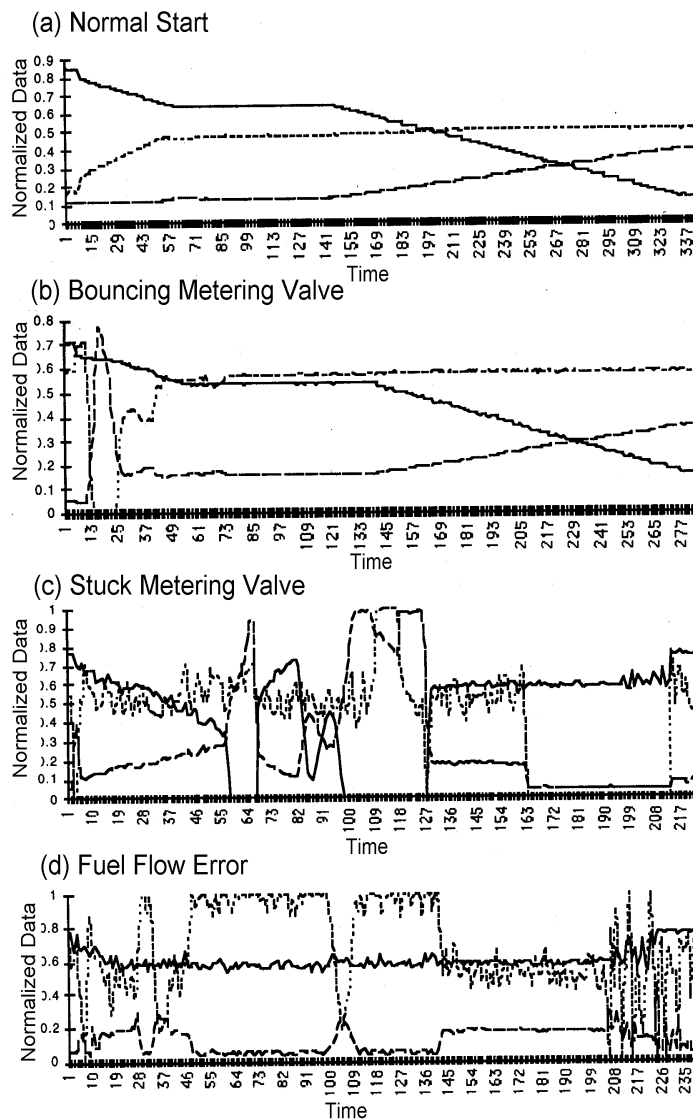


Bild 8: Plots der Sensordaten (Normalisiert)

unter vier verschiedenen Triebwerkszuständen: (a) normaler Start; (b) Anschlagendes Ventil; (c) hängendes Ventil; und (d) Brennstoffmassenstromfehler. Sensordaten: WF-Request (durchgezogene Linie); WF-Actual (gestrichelte Linie); WF-Solenoid (gepunktete Linie). (Illfi1994)

Die Autoren konnten damit zeigen, daß das System nachweisbares Potential zur Verringerung der Wartungskosten besitzt.

3.6 *Detektion von einsetzendem Verdichterpumpen*

Die Erkennung von einsetzendem Verdichterpumpen benötigt eine sehr schnelle Auswertung von dynamischen Signalen. Hönnen, Gallus and Regnery (1996) von der Rheinisch-Westfälischen Technischen Hochschule (RWTH) in Aachen berichten über ihren Versuch, in dem mit Hilfe einer Musterklassifikation für zeitlich schnell veränderliche statische Drucksignale das einsetzende Verdichterpumpen detektiert wird. Dabei benutzen sie ein Kohonennetzwerk zur Klassifikation. Eine Anzahl von Charakteristiken der gemessenen Signale wurden für den Erkennungsprozeß untersucht. Für die Anwendung in einer industriellen Gasturbine scheinen die Ergebnisse sehr vielversprechend zu sein.

3.7 *Identifikation von Sensorfehlern*

Die Erkennung von Sensorfehlern ist äußerst schwierig, da man anhand der Meßwerte nur sehr schwer zwischen einem Sensorfehler und einem Triebwerksfehler unterscheiden kann. Heute gibt es zwei verschiedene klassische Methoden, welche zur Sensorfehlerdetektion eingesetzt werden können: Kalmanfilter und Redundanzanalyse. Auch hier können neuronale Netze eine nützliche Alternative darstellen.

Konstantinopoulos und Antsaklis (1994), University of Notre Dame, Indiana, schlagen einen Neuronalen-Netze-Regler für industrielle Turbinen mit eingebauten Diagnosemöglichkeiten für Sensor- und Aktuatorfehler vor. Allerdings

wird damit das Problem der Unterscheidung zwischen den beiden oben genannten Fällen nicht gelöst.

Neppach und Casdorff (1995) zeigen einen vielversprechenden Ansatz auf Basis von neuronalen Netzen zur Überwachung des dynamischen Flugzeugzustandes kombiniert mit dem Problem der Sensorfehlererkennung und -korrektur. Die hohen Ansprüche an die Zuverlässigkeit des Betriebes führen heute dazu, daß ein System mit reduzierter Anzahl von Sensoren (und damit der Redundanz) einen Einsatz verhindert.

Die Überwachung der dynamischen Performance benötigt ein Time Delay Netzwerk. Das Problem wird gelöst durch die Einführung einer Kombination aus mehreren Netzwerken. Ein Hauptnetzwerk (Main Neural Network (MNN)), welches die Triebwerksfehler detektiert, und eine Reihe von dezentralisierten neuronalen Netzwerken (DNNs), eines für jedes nicht redundante Sensorsignal. Die Eingänge des MNN sind die Sensorsignale, welche zu jedem der DNN und jedem anderen dynamischen Signal, sowie den Regelungsdaten vorheriger Zeitpunkte gehören. Die Ausgabe des MNN besteht aus der Vorhersage der dynamischen Parameter zum aktuellen Zeitpunkt. Ein Flugzeugfehler wird detektiert durch den Vergleich zwischen der Vorhersage und dem aktuellen Sensorsignal.

Im Falle eines Sensorfehlers haben die dezentralisierten neuronalen Netzwerke die Aufgabe, den fehlerhaften Sensor zu ermitteln, und ein Ersatzsignal zu liefern. Dazu werden den DNN die Regelungsdaten, sowie die Sensordaten aller übrigen Sensoren als Eingabe geliefert. Die Ausgabe ist der erwartete aktuelle Wert des Sensors. Ein Fehler wird detektiert, indem der Ausgabewert mit dem aktuellem Sensorwert verglichen wird. Die DNN bestimmen den Parameter, welcher dann zum MNN als Eingangswert übermittelt wird. Wenn ein Sensorfehler detektiert wird, werden die DNN anstatt den aktuellen Sensorwert den selbst bestimmten Wert zum MNN senden. Wenn kein Fehler detektiert wird, wird der aktuelle Sensorwert zu dem MNN transferiert.

Das System ist sicherlich gut für die unbemannte Raumfahrt, für die es entwickelt wurde, geeignet. In einer Triebwerksumgebung würde dieses System

unüberwindliche Schwierigkeiten wegen der benötigten Rechenleistung, welche zum Trainieren und Bestimmen aller dynamischen Situationen benötigt wird, bekommen. Das Prinzip wurde hier dennoch wegen zwei wichtigen Eigenschaften näher erläutert:

- Es hat die Fähigkeit Sensorfehler von Maschinenfehlern zu trennen und
- es kann den dynamischen Betrieb analysieren.

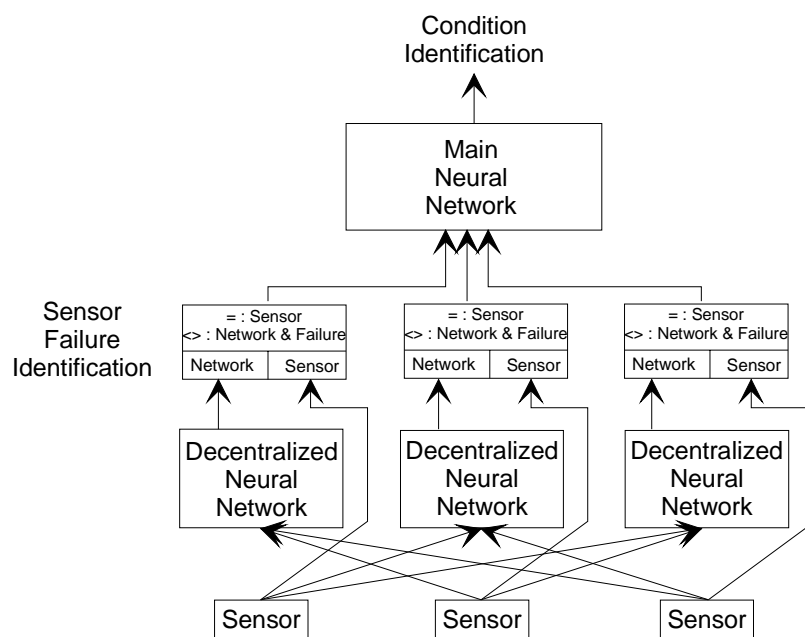


Bild 9: Beispiel einer Architektur eines allgemeinen MNNs

Kapitel 4

4.1 Fehlerklassifikation des Triebwerkes mit Hilfe von neuronale Netzen

Im Rahmen des vom Bundesministerium für Wirtschaft geförderten Verbundpartnerprojektes Total Engine Control (TEC) wurde am Institut für Luft- und Raumfahrt der TU-Berlin im Bereich Flugantriebe ein zustandsabhängiges Überwachungssystem für Triebwerke auf der Basis von neuronalen Netzwerken entwickelt. Im folgenden wird am Beispiel eines Einkreistriebwerkes der Aufbau des Überwachungssystems beschrieben. Dabei wird Bezug auf analytische und numerische Ergebnisse genommen. Zuletzt werden die Klassifikationsfähigkeiten des Systems mittels experimenteller Daten verifiziert.

4.2 Das System

Bild 10 zeigt ein Schema des Triebwerkes Marboré, einem Einkreistriebwerk, welches zur Verifikation des Fehlerklassifikationssystems dient. Da es bis heute nicht möglich ist alle thermodynamischen Parameter eines Triebwerkes zu messen, muß man den Parametersatz auf die einfach zu messenden Größen beschränken.

Zur thermodynamischen Analyse wird folgender Satz meßbarer Parameter benutzt:

Bez. Einh. Beschreibung

T_2	K	Totaltemperatur am Triebwerkseinlaß
T_3	K	Totaltemperatur am Verdichterausgang
T_5	K	Totaltemperatur hinter der Turbine
P_2	Pa	Totaldruck Triebwerkseinlaß
P_3	Pa	Totaldruck am Verdichterausgang
P_5	Pa	Totaldruck hinter der Turbine
N	rpm	Drehzahl




Bild 10: Schema des Einkreistriebwerks Marboré (Ebenen 2,3 und 5 wurden gekennzeichnet)

WF g/s Brennstoffdurchsatz

4.3 Analytische Ergebnisse

Erhaltungsgleichungen wie die Leistungsbilanz zwischen Verdichter und Turbine, die Brennkammerbilanz, Erhaltung der Masse etc. ergeben eine komplette thermodynamische Beschreibung des Triebwerkes. Neben den eigentlich interessierenden Parametern wie den Wirkungsgraden einzelner Komponenten enthalten die Gleichungen Parameter, welche in einem kommerziellen Triebwerk nicht gemessen werden, z.B. die Temperatur in der Brennkammer. Aus diesem Grund muß das Gleichungssystem auf ein Satz von wenigen Gleichungen reduziert werden, in denen alle nicht meßbaren Parameter eliminiert werden.

Zusätzliche Informationen erhält man über Gleichungen, welche die Wellendrehzahl mit den thermodynamischen Parametern verbindet. Normalerweise ist es sehr schwer einen analytischen Ausdruck dafür zu finden, da diese Beziehung üblicherweise in einem Verdichter- und Turbinenkennfeld aufgetragen wird. Aus diesem Grund können diese Gleichungen nicht zur analytischen Identifikation von Komponentenfehlern herangezogen werden.

Alle Parameter in dem oben beschriebenen Satz von Gleichungen hängen direkt vom aktuellen Flugzustand ab und benötigen daher zusätzliche Informationen. Das System kann jedoch weiter vereinfacht werden, indem alle Parameter in Ähnlichkeitsgrößen umgewandelt werden. Der Satz von Ähnlichkeitsgrößen, welche letztendlich zur Untersuchung eines (Einkreis-) Triebwerkes benutzt werden können, sind:

T_3/T_2	Totaltemperatur am Verdichterausgang
T_5/T_2	Totaltemperatur hinter der Turbine
P_3/P_2	Totaldruck am Verdichterausgang
P_5/P_2	Totaldruck hinter der Turbine
$N/\sqrt{T_2}$	reduzierte Drehzahl
$W_f^*\sqrt{T_2}/P_2$	reduzierter Brennstoffdurchsatz

Das endgültige System zur kompletten Analyse des Triebwerkzustandes besteht somit lediglich aus wenigen Gleichungen. Die Anzahl der Werte, welche analytisch bestimmt werden können, werden somit reduziert. Aus diesem Grund ist es unbedingt notwendig die Beziehungen aus dem Verdichter- und dem Turbinenkennfeld mit in die Fehleranalyse einzubeziehen.

Das Einbeziehen der Kennfelder in das Gleichungssystem führt direkt auf die Benutzung einer einfachen, aber sehr effektiven Methode. Für die Analyse des Zustandes einzelner Komponenten werden die Gleichungen linearisiert, d.h. es werden in den Gleichungen anstatt absoluter Werte ausschließlich Abweichungen vom Normalzustand des Triebwerkes betrachtet. Diese Methode kann immer dann angewandt werden, wenn die Abweichungen sehr klein sind. Dabei kann das nichtlineare Verhalten des Systems zu Fehlklassifikationen führen, wenn die Abweichungen einen bestimmten kritischen Wert überschreiten.

Künstliche neuronale Netze können dieses spezielle Problem aufgrund ihrer Fähigkeiten zu lernen und ihrer Fähigkeit nichtlineare Beziehungen zu reproduzieren lösen.

4.4 Numerische Ergebnisse

Die Ergebnisse der analytischen Untersuchungen können mit Hilfe von Numerischen Ergebnissen vervollständigt werden. Ein heute übliches Performance-Modell wird benutzt, um die thermodynamischen Parameter des Triebwerkes zu simulieren. Die Vielzahl der Triebwerksfehler, welche mit einer solchen Simulation untersucht werden können, sind weitaus größer, als die Anzahl der Fehler, welche in einem realem Triebwerk implementiert werden können.

Daher beschränken wir uns auf die Erkennung folgender Fehler:

- Änderung des Verdichterwirkungsgrades
- Änderung des Turbinenwirkungsgrades
- Änderung des mechanischen Wirkungsgrades
- Änderung der Düsenfläche
- Änderung der Turbinenkapazität
- Fehlerhafte Luftentnahme im Verdichter

Das Simulationsprogramm ist in der Lage eine Arbeitslinie für jeden beliebigen Triebwerkszustand auszugeben, d.h. für jede beliebige Kombination einer der oben genannten Fehler. Es berechnet alle geeigneten thermodynamischen Parameter wie Temperaturen, Drücke und Brennstoffmassenstrom, welche dann zur Weiterverarbeitung genutzt werden können. Aus diesen numerischen Simulationen können dann direkt die benötigten Ähnlichkeitsgrößen bestimmt werden.

Die simulierten Abweichungen zwischen einem defekten Triebwerk und dem fehlerfreien Zustand werden dann für den folgenden Klassifikationsprozeß berechnet. Für das Marboré Triebwerk werden die folgenden Werte bestimmt:

$$D\left(\frac{T_3}{T_2}\right) = \frac{\frac{T_3}{T_2}\Big|_{\text{actual}} - \frac{T_3}{T_2}\Big|_{\text{normal}}}{\frac{T_3}{T_2}\Big|_{\text{normal}}}$$

und

$$D\left(\frac{P_3}{P_2}\right), D\left(\frac{T_5}{T_2}\right), D\left(\frac{P_5}{P_2}\right), D\left(\frac{W_f \sqrt{T_2}}{P_2}\right),$$

welche auf gleiche Weise berechnet werden, wobei die reduzierte Drehzahl konstant gehalten wird. Diese Werte stellen dann die Komponenten eines Vektors dar, welcher jeweils als ein bestimmter Fehler klassifiziert werden kann. Bild 11 zeigt solche (Basis-) Vektoren für vier Arten von Fehlern:

1% Änderung des Verdichterwirkungsgrades ,

1% Änderung des Turbinenwirkungsgrades,

1% Änderung der Düsenfläche und

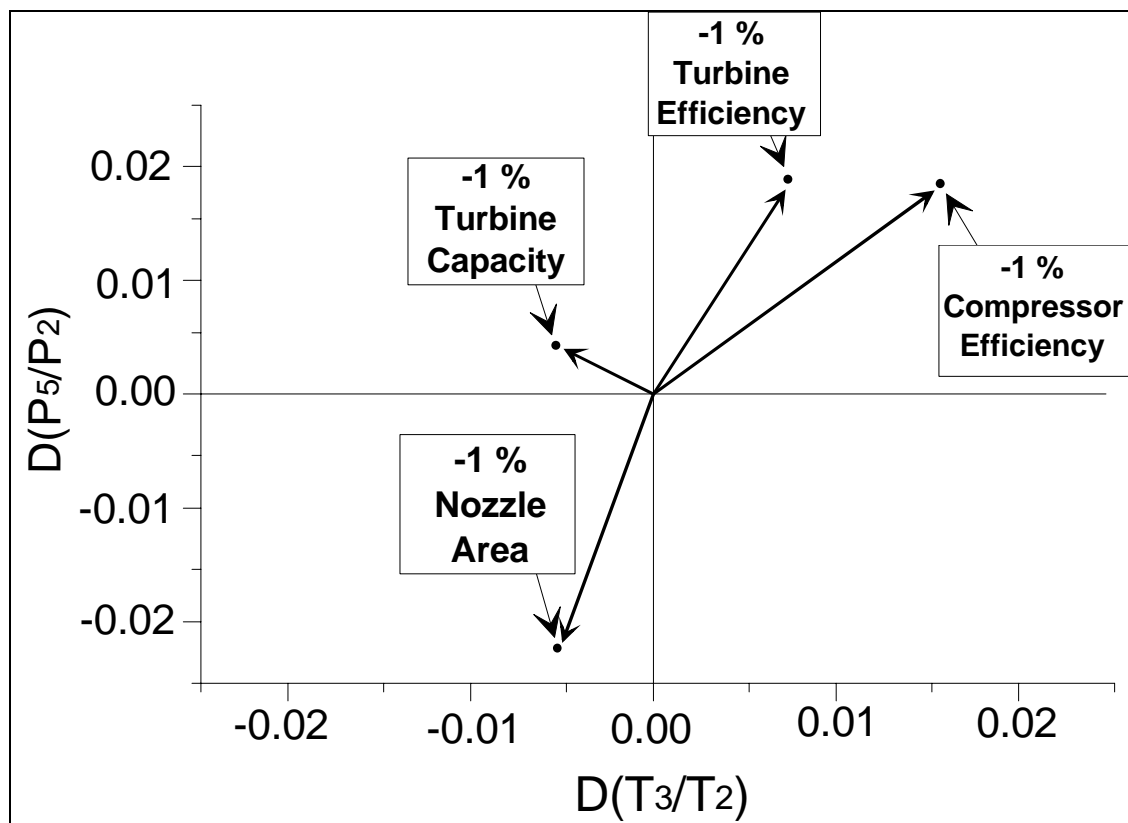


Bild 11: Abweichung von T_3/T_2 und P_5/P_2 für Beispiele von Fehlern

1% Änderung der Turbinenkapazität.

Bild 11 zeigt nur die Abweichungen für die Parameter T_3/T_2 und P_5/P_2 . Dennoch ist es möglich den aufgetretenen Fehler zu bestimmen. Die Anzahl der erkennbaren Fehler kann durch Einbeziehung weiterer Ähnlichkeitsgrößen erhöht werden.

Desweiteren erlaubt das System die Klassifikation von Kombinationen mehrerer Fehler. Dazu muß der resultierende Fehlervektor als Kombination der Basisvektoren dargestellt werden. Bild 12 zeigt die Überlagerung zweier unterschiedlicher Fehler und den daraus resultierenden Fehlervektor.

Da die Basisvektoren nicht immer linear unabhängig sind, ist ein Aufspalten des Fehlervektors zum Teil sehr schwierig. Dennoch ist es möglich, die Fehler zu bestimmen, wenn man bedenkt, daß nicht alle möglichen Kombinationen von Fehlern in einem realen System auftreten.

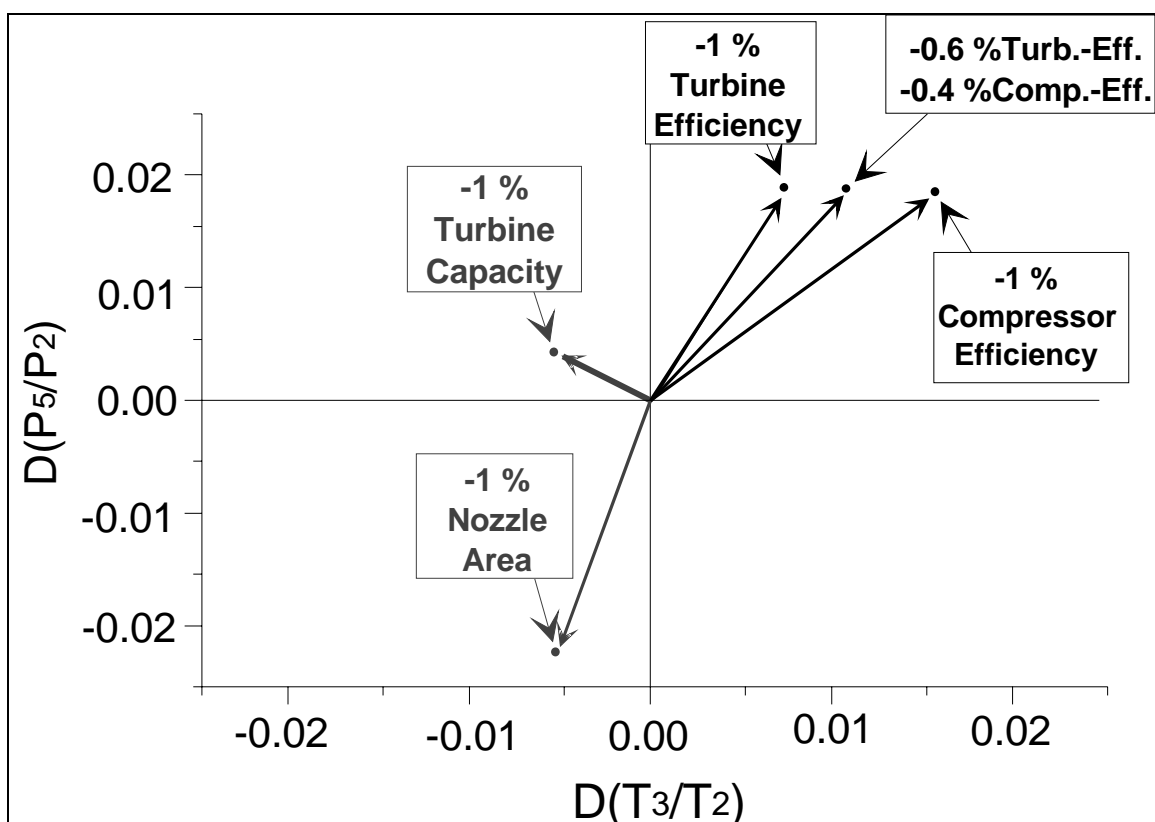


Bild 12: Überlagerung von zwei Fehlervektoren

Künstliche neuronale Netze sind eine angemessene Lösung für dieses Klassifikationsproblem, da sie zur Erkennung häufig vorkommender Kombinationen von Fehlern trainiert werden können. Sie können die Wahrscheinlichkeit des Auftretens bestimmter Fehler berechnen und lokalisieren.

4.5 Klassifikationssystem auf der Basis von künstlichen neuronalen Netzen

Zur Lösung des Klassifikationsproblems mit Hilfe neuronaler Netze muß die Aufgabe in zwei Teile geteilt werden:

Die Bestimmung der Abweichungen des aktuellen Zustandes vom fehlerfreien Zustand benötigt die Kenntnis des normalen, fehlerfreien Zustandes des Triebwerkes. Dazu ist es möglich, jeden beliebigen Referenzpunkt auf der Arbeitslinie zu benutzen. Das System wird jedoch starke Nichtlinearitäten aufweisen, wenn die Abweichungen zu groß werden. Es ist daher eine gute Wahl, wenn der Referenzpunkt möglichst nah am aktuellen Zustand gewählt wird. Der erste Schritt besteht also darin, einen geeigneten Referenzparameter zur Bestimmung des Referenzpunktes zu finden. Für das Marboré Triebwerk ist die reduzierte Drehzahl ein geeigneter Referenzparameter, aber man kann auch jeden anderen Parameter wählen, welcher monoton mit der reduzierten Drehzahl variiert.




Bild 13: Vorverarbeitendes neuronales Netzwerk

Bild 13 zeigt das vorverarbeitende neuronale Netzwerk, welches angewandt wird, um den Referenzpunkt zu berechnen. Das Netzwerk nutzt dabei die reduzierte Drehzahl, um die übrigen Ähnlichkeitsparameter am Referenzpunkt zu bestimmen.

Dies sind:

$$\frac{P_3}{P_2}, \frac{P_5}{P_2}, \frac{T_3}{T_2}, \frac{T_5}{T_2}, \frac{W_f \sqrt{T_2}}{P_2}$$

Nach dem Training des Netzwerkes mit der Arbeitslinie des fehlerfreien Triebwerkes ist das Netzwerk in der Lage jeden beliebigen Referenzpunkt der stationären Arbeitslinie in Bezug auf die reduzierte Drehzahl zu berechnen. Bild 14 zeigt die Ausgabe des vorverarbeitenden Netzwerkes für das Marboré Triebwerk.

Die Klassifikation von Fehlern benötigt zunächst die Umwandlung der aktuell gemessenen Daten in Ähnlichkeitsgrößen, sowie die Bestimmung des




Bild 14: Ausgabe des vorverarbeitenden Netzwerkes für das Marboré Triebwerk

Referenzpunktes mit Hilfe des vorverarbeitenden Netzwerkes. Die einzelnen Komponenten des Fehlervektors können dann mit Hilfe der folgenden Formeln berechnet werden:

$$D\left(\frac{T_3}{T_2}\right) = \frac{\frac{T_3}{T_2}\Big|_{actual} - \frac{T_3}{T_2}\Big|_{normal}}{\frac{T_3}{T_2}\Big|_{normal}}$$

Der komplette Vektor

$$\vec{F} = \left(D\left(\frac{P_3}{P_2}\right), D\left(\frac{P_5}{P_2}\right), D\left(\frac{T_3}{T_2}\right), D\left(\frac{T_5}{T_2}\right), D\left(\frac{W_f \sqrt{T_2}}{P_2}\right) \right)$$

wird dann in einem zweiten Schritt zur Klassifikation der Fehler benutzt:

Für die Klassifikation des Fehlervektors ist wiederum ein neuronales Netz geeignet. Die Eingänge des Perceptrons, welches für diese Aufgabe genutzt wird, sind die einzelnen Komponenten des Fehlervektors, während die Ausgänge die einzelnen Fehler repräsentieren.

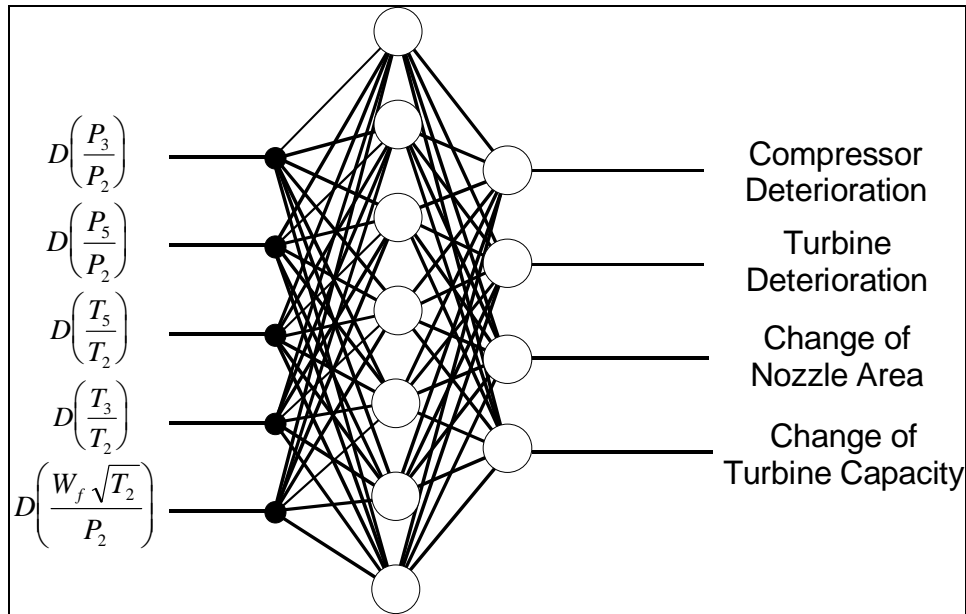


Bild 15: Klassifikationsnetzwerk zur Anwendung am Marboré Triebwerk

Bild 15 zeigt das Klassifikationsnetzwerk, welches am Marboré Triebwerk angewandt werden kann.

Das Training des Klassifikationsnetzwerkes führt zu dem Ergebnis, daß das Netzwerk fähig wird, eine Verschlechterung des Verdichters, sowie der Turbine und die Änderung der Düsenfläche zu detektieren. Nach dem Training kann das Klassifikationsnetzwerk für alle Triebwerke des gleichen Typs angewandt werden.

Der vollständige Klassifikationsprozeß ist nochmals in Bild 16 dargestellt.

4.6 Ergebnisse der Simulation mit neuronalen Netzen

Das Performance-Modell ist benutzt worden, um Datensätze des stationären Zustands des Marboré

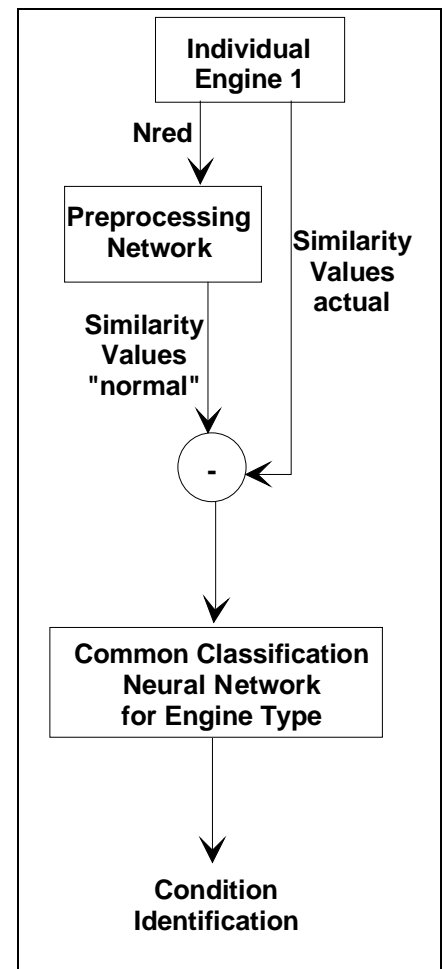


Bild 16:

Schema des vollständigen Klassifikationsprozesses

Triebwerkes für die gesamte Arbeitslinie zu generieren. Diese Daten werden dazu eingesetzt, um das vorverarbeitende Netzwerk zu trainieren, welches dann zur Bestimmung des fehlerfreien Zustandes benutzt werden kann. Das Simulationsprogramm ist außerdem in der Lage, Daten verschiedener Fehlerzustände des Triebwerkes zu berechnen. Die Abweichungen vom fehlerfreien Zustand des Triebwerkes werden mit Hilfe des trainierten, vorverarbeitenden Netzwerkes berechnet. Die erhaltenen Werte werden dann zum Training des Klassifikationsnetzwerkes benutzt, welches die einzelnen simulierten Fehler lernen soll. Im Gegensatz zum Klassifikationsnetzwerk, welches zur Fehlerklassifikation aller Triebwerke des gleichen Typs verwendet werden kann, muß das vorverarbeitende Netzwerk an jedes individuelle Triebwerk angepaßt und daher für jedes Triebwerk einzeln trainiert werden.

Die erzeugten Daten für das Marboré Triebwerk beinhalten die folgenden Fehler, welche zwischen 0% und 1,5% variiert wurden:

- Verschlechterung des Wirkungsgrades des Verdichters
- Verschlechterung des Wirkungsgrades der Turbine,
- Änderung der Düsenfläche und
- die Änderung der Turbinenkapazität.

Diese Daten wurden genutzt, um das Klassifikationsnetzwerk zu trainieren. Ein zweiter Satz von Daten mit im Vergleich zum Trainingsdatensatz verschiedenen Werten innerhalb des gleichen Bereiches wurde zur Überprüfung des Systems generiert. Die Ergebnisse zeigen, daß das Netzwerk nicht einfach die trainierten Fehler auswendig gelernt hat, sondern eine geeignete Beziehung zwischen den Meßwerten und den Fehlern gefunden hat. Der maximal auftretende Klassifikationsfehler beträgt $\pm 0,01\%$, d.h. die Verschlechterung einer Komponente um 0,6 % führt zu einem Ausgabewert zwischen 0,59 % und 0,61 %. Um näher an die realistische Anwendung zu kommen, wurde zusätzliches Rauschen auf die simulierten Daten gegeben. Dabei stieg der Klassifikationsfehler um den Faktor 10, was bedeutet, daß eine Verschlechterung einer Komponente um 0,6 % einen Ausgabewert zwischen 0,5 % und 0,7 % produziert. Dies ist dennoch ein gutes Ergebnis vor allem in Hinblick darauf, daß man spezielle Filter

einsetzen kann, um die Genauigkeit der Meßwerte zu verbessern. Diese Filter sind einfach zu berechnen, da es sich bei den Meßwerten um Daten handelt, welche im stabilisierten Zustand des Triebwerkes gemessen werden.

Bild 17 zeigt die Varianz der Ausgabewerte des neuronalen Netzwerkes bei der Simulation von verschiedenen Triebwerksfehlern und deren Kombinationen. Die Summe zweier Fehler beträgt in diesem Bild immer 1 %. Das Diagramm zeigt dabei die minimale und maximale Ausgabeabweichung der Netzwerkausgabe von

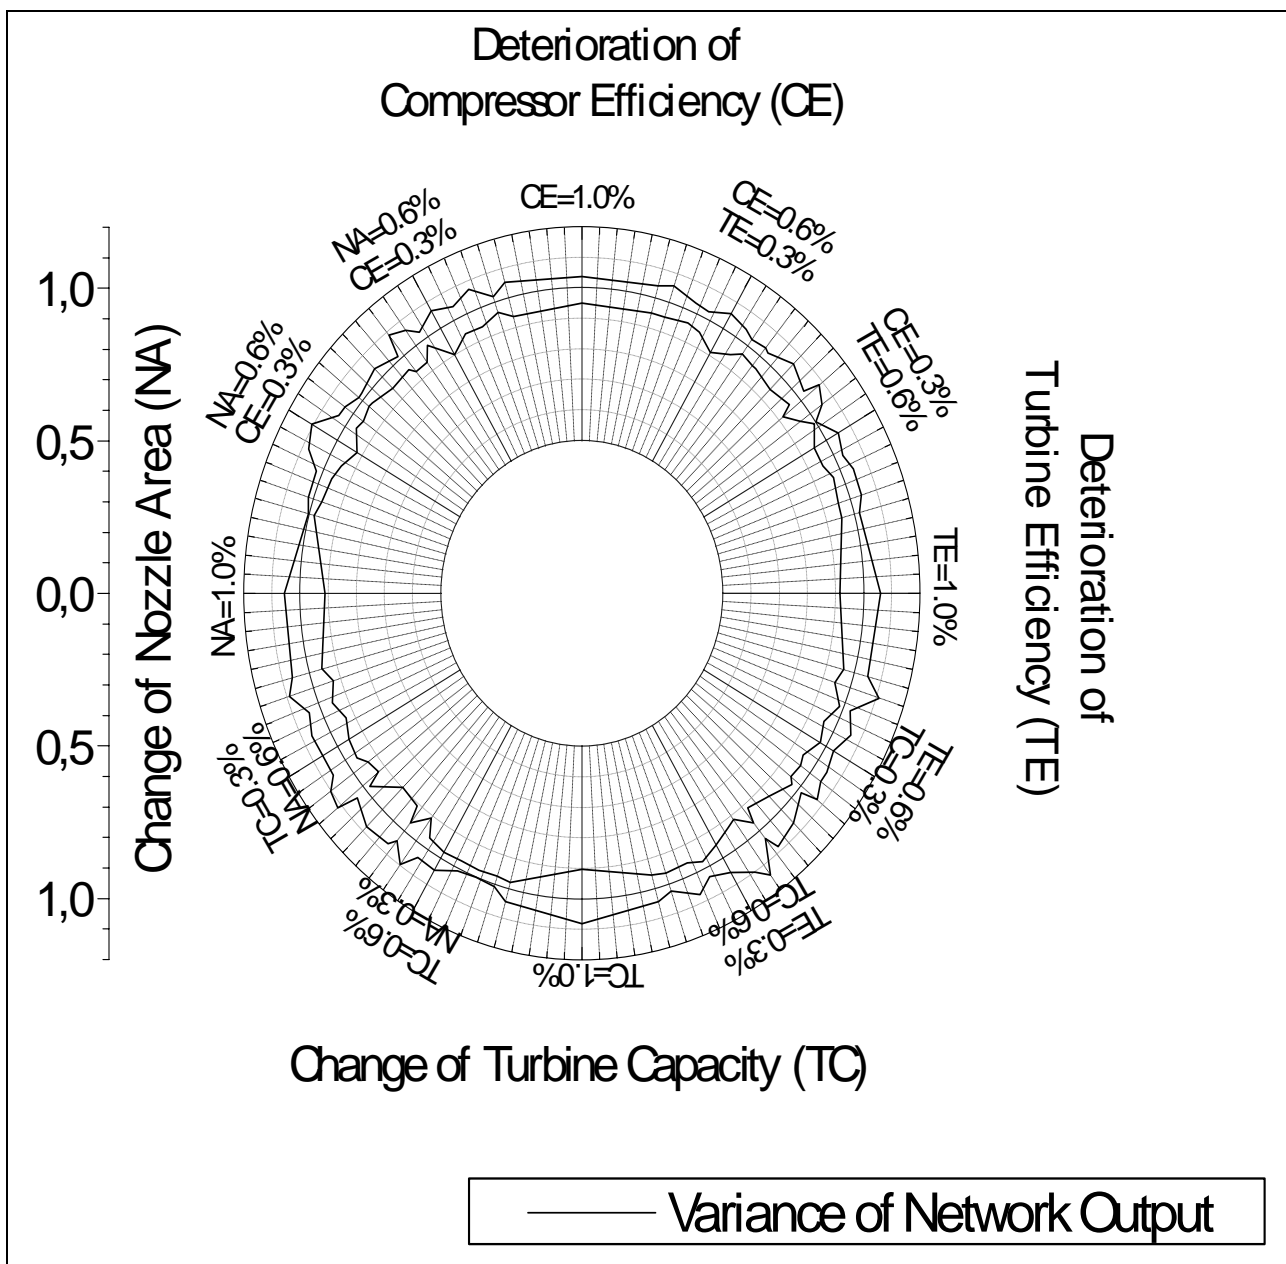


Bild 17: Varianz der Netzwerkausgabe bei Kombinationen von Fehlern

dem tatsächlich simulierten Fehler. Die maximale Abweichung der Netzwerkausgabe vom simulierten Fehler beträgt dabei nie mehr als $\pm 0,1$ %.

4.7 Verifikation an einem realem Triebwerk

Das dargestellte Klassifikationssystem wurde an dem im Triebwerkslabor der Technischen Universität Berlin vorhandenen Marboré Triebwerk verifiziert. Nur eine geringe Anzahl von Fehlern kann an dem Triebwerk implementiert werden. Dennoch ist es möglich, einen speziellen Test zur Verifikation des Klassifikationssystems durchzuführen.

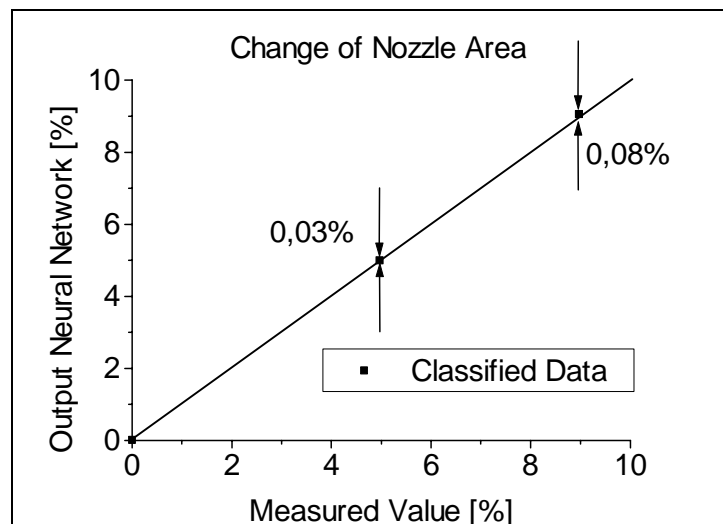


Bild 18: Verifikation der Klassifikationsausgabe an einem realem Triebwerk

Zunächst wurden eine Reihe von Experimenten zur Klassifikation des fehlerfreien Zustandes an verschiedenen Arbeitspunkten durchgeführt. Die Genauigkeit des Überwachungssystems lag in allen Fällen innerhalb von 0,1 %.

Die Änderung der Düsenfläche ist der einzige Fehler, welcher zur Zeit in dem Triebwerk implementierbar ist. Die Erkennung der Änderung der Düsenfläche lag wiederum in allen Fällen innerhalb einer Genauigkeit von 0,1 %. Bild 18 zeigt die Abweichung der Netzwerkausgabe von der gemessenen Änderung der Düsenfläche. Man sieht eine gute Übereinstimmung zwischen der Ausgabe und den tatsächlichen Werten sowohl für den fehlerfreien Fall als auch bei eingefügten Fehlern.

Andere Fehler wie die Verschlechterung des Verdichterwirkungsgrades oder des Turbinenwirkungsgrades konnten experimentell nicht verifiziert werden.

4.8 Untersuchungen an Zweikreistriebwerken

Ein weiteres Triebwerk, welches im Triebwerkslabor der Technischen Universität Berlin zur Verfügung stand, war das Zweikreistriebwerk Larsac. Zunächst wurde das Simulationsprogramm an dieses Triebwerk angepaßt. Die Adaption des Überwachungssystems an ein Zweikreistriebwerk geschieht auf sehr einfache Weise: die zusätzlichen Ähnlichkeitsparameter werden im vorverarbeitenden Netzwerk als weitere Ausgaben generiert, so daß diese im Klassifikationsnetzwerk zur Verfügung stehen. Als Eingabe dient die reduzierte Drehzahl der Hochdruckwelle, welche als Referenzparameter genutzt werden kann.

Bild 19 zeigt eine Realisierung eines solchen vorverarbeitenden Netzwerkes.




Bild 19: Realisierung des vorverarbeitenden Netzwerkes für ein Zweikreistriebwerk

Bei der Anwendung des Überwachungssystems auf ein Triebwerk neuester Bauart wie dem BR715 stellt sich ein weiteres Problem: Der Verdichter wird mit Hilfe von verstellbaren Leitschaufeln optimal an die Umgebungsbedingungen angepaßt, um jederzeit einen optimalen Wirkungsgrad zu erreichen. Leider verliert




Bild 20: Modifiziertes vorverarbeitendes Netzwerk

werden, daß dieses System mit Hilfe des modifizierten Netzwerkes in der Lage ist, Fehler beim BR715 zu erkennen und die Stärke des Fehlers, sowie die Ursache innerhalb der Fehlertoleranzen der Meßwerte zu bestimmen.

4.9 Weitere Untersuchungen

Bisher wurden nur stabilisierte Zustände des Triebwerkes in Betracht gezogen. Eine Analyse der dynamischen Arbeitszustände bei einem Triebwerk ist aufgrund der langsamen Temperaturänderungen innerhalb des Triebwerkes außerordentlich schwierig. Diese langsamen Prozesse überlagern sich mit den schnellen zu analysierenden Zuständen, welche beispielsweise bei Beschleunigungen oder Verzögerungen auftreten. Diese schnellen Prozesse könnten aber weitere Möglichkeiten schaffen, eine Vielzahl von Fehlerursachen zu erkennen, so daß die Forschung an solchen Fragestellungen außerordentlich wichtig ist. Neuronale Netze sind dabei sicherlich ein guter Ansatz, um die langsamen Temperaturänderungen von den schnellen Änderungen durch

Beschleunigung oder Verzögerung zu trennen. Dadurch wird es möglich sein, den fehlerfreien Zustand auch bei dynamischen Zustandsänderungen zu bestimmen und das Triebwerk bezüglich der auftretenden Fehler zu analysieren.

Kapitel 5

5.1 Zusammenfassung

Die neue Technologie der neuronalen Netze bietet eine vielversprechende Möglichkeit zur Anwendung in der zustandsabhängigen Triebwerksüberwachung. Die heutige Forschung beinhaltet sowohl die Überwachung der Kreisprozeßdaten, der Vibrationen und der Rotordynamiken, der Detektion von entstehendem Verdichterpumpen, Fehlfunktionen im Brennstoffsystem und Sensorfehler. Keine der veröffentlichten Untersuchungen sind bisher in die Anwendung gelangt.

Die analytischen Untersuchungen zeigen einen sehr eleganten Weg zur Realisierung eines zustandsabhängigen Überwachungssystems, welches in der Lage ist, Komponentenfehler durch die Abweichung der Meßwerte vom fehlerfreien Zustand zu detektieren. Zusätzliche numerische Untersuchungen geben Aufschluß über die benötigten Parameter, sowie über die Struktur eines Klassifikationssystems, welches mit Hilfe von neuronalen netzen realisiert werden kann.

Das so entwickelte Überwachungssystem konnte anhand eines Performance-Modell verifiziert werden, welches in der Lage ist, die stabilisierten Zustände eines Einkreistriebwerkes zu berechnen, wobei einige Triebwerksfehler simuliert werden konnten.

Untersuchungen an einem realem Einkreistriebwerk (Marboré) bestätigen die Ergebnisse der Simulation, sowie die Funktionstüchtigkeit des Überwachungssystems. Auf Grundlage der Ergebnisse wurde das System auf Zweikreistriebwerke angepaßt, wobei Triebwerke mit Leitschaufelverstellung ein zusätzlich angepaßtes vorverarbeitendes Netzwerk benötigen.

Das entwickelte System zur zustandsabhängigen Triebwerksüberwachung ist ein erster Schritt in die Anwendung neuronaler Netze zur Identifikation von Triebwerksfehlern mit Hilfe der stabilisierten Zustände des Triebwerkes. Weitere Schritte zur Implementation in bestehende Systeme sowie die Überprüfung

anhand von Daten, welche von Fluggesellschaften geliefert werden könnten, müssen nun folgen.

Kapitel 6

6.1 Veröffentlichungen und Vorträge

Schweng D., J. Hourmouziadis (1997)

Artificial Neural Networks in Engine Condition Monitoring

1997 European Propulsion Forum, Berlin, Germany, March 1997,

Schweng D., J. Hourmouziadis (1998)

Application of Artificial Neural Networks in Engine Condition Monitoring

19th International Symposium on Aircraft Integrated Monitoring Systems (AIMS98), May 4-7, 1998, Garmisch-Partenkirchen, Germany

Anhang

A.1 Literaturliste

Arbib Michael A. (1995)

The Handbook of Brain Theory and Neural Networks

MIT Press, Cambridge, Massachusetts, 1995

Allwood R.J., S.P. King, N.J. Pitts (1996)

The Automatic Interpretation of Vibration Data from Gas Turbines

Aeronautical Journal, March 1996, pp 99-107, Paper No. 2142

Carr H.R., Dr. P.H. Cowley (1995)

Application of Neural Networks to Aero Engine Vibration Monitoring

5th European Propulsion Forum, Centro Studi della Cassa di Risparmio di Pisa, Pisa, Italy, 5-7 April 1995

Chbat Nicolas W, Ravi Rajamani, Todd A. Ashley (1996)

Estimating Gas Turbine Internal Cycle Parameters Using a Neural Network,

International Gas Turbine and Aeroengine Congress & Exhibition, Birmingham, UK, June 10-13 1996, ASME paper 96-GT-316

Cybenko G. (1988)

Continuous Valued Neural Networks with two Hidden Layer are Sufficient

Technical Report 1988, Department of Computer Science, Tufts University, Medford, MA.

Eustace Richard, Graeme Merrington (1995)

Fault Diagnosis of Fleet Engines Using Neural Networks

12th International Symposium on Air Breathing Engines, Melbourne, Australia, September

10-15, 1995, ISABE 95-7085

Hertz John, Anders Krogh, Richard G. Palmer (1991)

Introduction to the Theory of Neural Computation

Addison-Wesley Publishing Company 1991, ISBN 0-201-51560-1

Hönen H., H.E. Gallus, D. Regenery (1996)

System zur Pumpgrenzüberwachung

5. Statusseminar der Arbeitsgemeinschaft "Hochtemperatur Gasturbine", 5.-6. December 1996, DLR, Köln-Porz

Illi Orlando J., Jr., Frank L. Greitzer, Lars J. Kangas, Tracy J. Reeve (1994)

An Artificial Neural Network System for Diagnosing Gas Turbine Engine Fuel Faults

48th Meeting of the Mechanical Failures Prevention Group (MFPG 48) 19-21 April 1994, Wakefield, MA, paper PNL-SA-22914

Konstantipoulos Ioannis K., Panos J. Antsaklis (1994)

Integration of Controls and Diagnostics Using Neural Networks

American Control Conference, Baltimore, Maryland, June 1994, TM7-2:10

Krogmann Uwe (1993)

Regler, insbesondere Flugregler

Deutsches Patent DE 4130164 A1, 18.3.1993

Lombardo G. (1996)

Adaptive Control of a Gas Turbine Engine for Axial Compressor Faults

International Gas Turbine and Aeroengine Conference & Exhibition, Birmingham, UK, June 10-13, 1996, ASME 96-GT-445

Long Theresa W. (1993)

A Self-Similar Neural Network for Distributed Vibration Control

32nd Conference on Decision and Control, Antonio, Texas, December 1993, FM9-2:30

T. W. Long (1995)

Computing Engine Efficiencies by Neural Nets

International Gas Turbine and Aeroengine Congress and Exposition Houston, Texas, June 5-8, 1995, ASME 95-GT-157

McCulloch W.S., W. Pitts (1988)

A Logical Calculus of Ideas Immanent in Nervous Activity

Bulletin of Mathematical Biophysics 5, 115-133, 1943. Reprinted in Anderson and Rosenfels (1988), *Neurocomputing: Foundations of Research*, Cambridge: MIT Press

Napolitano Marcello R., Steve Neppach, Van Casdorff (1995)

On-Line Learning Nonlinear Direct Neurocontrollers for Restructurable Control Systems Journal of Guidance, Control, And Dynamics, Vol. 18, No. 1, January-February 1995, pp. 170-176

Napolitano Marcello R., Charles Neppach, Van Casdorff, Steve Naylor (1995)

Neural-Network-Based Scheme for Sensor Failure Detection, Identification, and Accommodation

Journal of Guidance, Control and Dynamics Vol. 18, No.6 November-December 1995, pp. 1280-1286

Neppach Charles D., Van A. Casdorff (1995)

Sensor Failure Detection, Identification and Accommodation in a System Without Sensor Redundancy

33rd Aerospace Sciences Meeting & Exhibit, January 9-12, 1995, Reno, NV, AIAA paper AIAA-95-0011

Roemer M.J., C. Hong, S.H. Hesler (1996)

Machine Health Monitoring and Life Management, Using Finite-Element-Based Neural Networks

Transactions of the ASME, Vol 118, October 1996, pp. 830-835

Rojas Raül (1993)

Theorie der neuronalen Netze

Springer, Berlin / New York, 1993

Rumelhart D.E., G.E. Hinton, R.J. Williams (1986)
Learning Representation by Back-Propagating Errors
Nature 323, 533-536, 1986.

Schweng D., J. Hourmouziadis (1997)
Artificial Neural Networks in Engine Condition Monitoring
1997 European Propulsion Forum, Berlin, Germany, March 1997,

Schweng D., J. Hourmouziadis (1998)
Application of Artificial Neural Networks in Engine Condition Monitoring
19th International Symposium on Aircraft Integrated Monitoring Systems
(AIMS98), May 4-7, 1998, Garmisch-Partenkirchen, Germany

Song Q., M.J. Grimble (1995)
Design of a Multivariable Neural Controller and its Application to Gas Turbines
American Control Conference, Seattle, Washington, June 1995, TM13 - 1:55

Steinhardt, E, K.-H. Becker, W- Diepolder, O. Liebscher, J. Moreno-Barragan
(1996)
Effiziente Erstellung, Validierung und Anwendung strukturmechanischer
Gesamtriebwerksmodelle
Jahrbuch 1996 I der DGLR, pp 39-48

Torella G., G. Lombardo (1995)
Utilization of Neural Networks for Gas Turbine Engines
12th International Symposium on Air Breathing Engines, Melbourne, Australia,
September
10-15, 1995, ISABE 95-7032

Werbos P., Beyond Regression (1974)
New Tools for Prediction and Analysis in the Behavioural Sciences
Ph.D. Thesis, Harvard University, 1974.