

Diagnose von Gerätefehlern in Satellitenlageregelungssystemen mittels Fuzzy-Neuro-Methoden

Helmut Bischoff, Klaus Janschek, Heiko Rind

Kurzfassung

Zur Fehlerdiagnose technischer Systeme werden im allgemeinen ausgehend von geeigneten Meßsignalen fehlersignifikante Merkmale gebildet, mit deren Hilfe in einem weiteren Schritt Symptome für Systemfehler abgeleitet werden.

Die Strukturierung des Merkmalsraumes (Lage von Merkmalsvektoren für Normalbetrieb bzw. Fehlbetrieb) erfolgte durch verschiedene Klassifizierungsverfahren, die auf Fuzzy-Clusterung bzw. Clusterung mittels zweiseitigen Kohonen-Netzen beruhen.

Bei Fuzzy-Clusterung wurden die Symptome (unscharf) durch Abstandsmessungen im Merkmalsraum ermittelt und die Diagnose durch Auswertung von Zugehörigkeitswerten gestellt. Bei Kohonen-Clusterung erfolgte die Symptomerzeugung durch Index-Bestimmung des Gewinner-Neurons in der Netz-Eingangsschicht und die Fehlerdiagnose durch Ausgabe des zugehörigen Gewichtsvektors in der Netz-Ausgangsschicht.

Beide Methoden wurden am Beispiel von Gerätekomponenten eines Satellitenlageregelungskreises simulativ erprobt. Merkmalsgewinnung, Symptomerzeugung und Fehlerdiagnose erfolgten dabei sowohl an einzelnen Baugliedern des Systems als auch im geschlossenen Regelkreis.

Die Untersuchungen zeigten die prinzipielle Eignung beider Clusterungs-Methoden zur Fehlerdiagnose.

1. Einleitung

Die bordautonome Erkennung, Diagnose und allfällige Behebung von Fehlern spielt bei Satellitensystemen naturgemäß eine bedeutsame Rolle. Der prinzipielle Mangel des direkten manuellen Zugriffes im Fehlerfall wird noch durch den Sachverhalt verstärkt, daß in vielen Fällen nicht einmal über Funk (Telekommando/Telemetrie) ein kontinuierlicher Kontakt zu den Bodenkontrollstationen möglich ist. So haben Satelliten in erdnahen Bahnen (LEO - Low Earth Orbit) mit typischen Bahnhöhen von 1000 km nur etwa während 15% ihrer Umlaufzeit Bodenkontakt zu einer festen Station.

Die derzeit im Aufbau befindlichen *satellitengestützten Kommunikationssysteme der Mobilkommunikation* (z.B. Globalstar, Iridium) betreiben Netzwerke mit 50-70 solcher LEO-Satelliten. Um in diesen Anwendungsfällen aus ökonomischen Gründen die Betriebskosten (d.h. Anzahl und Arbeitsbelastung der Bodenstationen) klein zu halten, ist eine maximale Bordautonomie im Normal- und Fehlbetrieb gefordert. Damit spielt die Bordautomatisierung eine Schlüsselrolle für die kommerzielle Machbarkeit derartiger Kommunikationssysteme.

Die missionskritische und hochautomatisierte Bordfunktion der Stabilisierung und Ausrichtung (pointing) eines Satelliten wird durch das *Bahn- und Lageregelungssystem* realisiert.

Nach [1] werden etwa drei Viertel der Fehler von Einrichtungen des Satellitengrundsystems (Energieversorgung, Stellglieder, Meß- und Navigationssysteme) verursacht, davon wiederum ein Viertel durch Ausfall von Steuerungskomponenten.

Eine unzureichende Behandlung solcher Fehler führt im günstigsten Fall zu einem zeitlich begrenzten Verlust der Kommunikationsverbindung (outage). Im Fehlerfall von mechatronischen Geräten wie *Drallrädern* (momentum/reaction wheels) und *Kreisel*n (gyroscopes) kann dies jedoch zur mechanischen Zerstörung der Geräte und im Extremfall bis zum Verlust der gesamten Mission führen.

An der Technischen Universität Dresden (TUD) werden zur Zeit im Rahmen eines interfakultären Forschungsprojektes (*TUD-Satellitenkolleg*) Schlüsseltechnologien für derartige *LEO-Satellitennetzwerke* der nächsten Generation untersucht. Ausgewählte Ergebnisse dieser Forschungsarbeiten sollen dann mit einem an der TUD entwickelten und gebauten Mikrosatelliten (100 kg) als Technologiedemonstrator im Weltraum erprobt werden.

Das *Institut für Automatisierungstechnik* hat dabei die Bearbeitung der folgenden Aufgaben übernommen:

- o Bahn- und Lageregelung
- o Onboard-Data-Handling
- o Fehlermanagement.

Dazu wird im Folgenden über erste Untersuchungen und Ergebnisse zur *bordautonomen Erkennung von Gerätefehlern* am Beispiel eines *Drallrades* (momentum wheel [2,3]) berichtet.

2. Drallrad-Funktion und Gerätefehler

Satelliten unterliegen verschiedenartigen Störmomenten, die ihre Ursachen im Magnet- bzw. Gravitationsfeld der Erde, in deren Restatmosphäre, im Solarwind und im Strahlungsdruck der Sonne haben und sich im Wesentlichen beim Erdumlauf periodisch ändern [2]. Für eine genaue Ausrichtung des Satelliten in seiner Bahn müssen diese Störmomente bzw. deren Wirkungen über Regelkreise kompensiert werden.

Drallräder mit einem Nominaldrall (d.h. konstante Nominaldrehzahl) sind speziell für erdausgerichtete Satelliten attraktiv. Bereits mit *einem* solchen Drallrad (momentum wheel) kann eine Satellitenachse normal zur Bahnebene gehalten werden. Darüber hinaus können um diese Achse durch Variation der Raddrehzahl ($\pm 15\%$ der Nenndrehzahl) stetige Stellmomente erzeugt werden (*bias momentum system* [2]). Beim Einsatz von Reaktionsrädern (Nenndrehzahl ist Null) in orthogonalen Satellitenachsen kann sogar eine volle 3-Achsen Stellmöglichkeit realisiert werden. In jedem Fall kann zur Energieversorgung von derartigen Stellgliedern auf die regenerative Sonnenenergie zurückgegriffen werden.

Der in Bild 1 gezeigte Lageregelkreis für die Satellitenachse normal zur Bahnebene (Nickachse) eines *Bias Momentum Systems* dient als repräsentative Grundlage für die vorliegenden Untersuchungen.

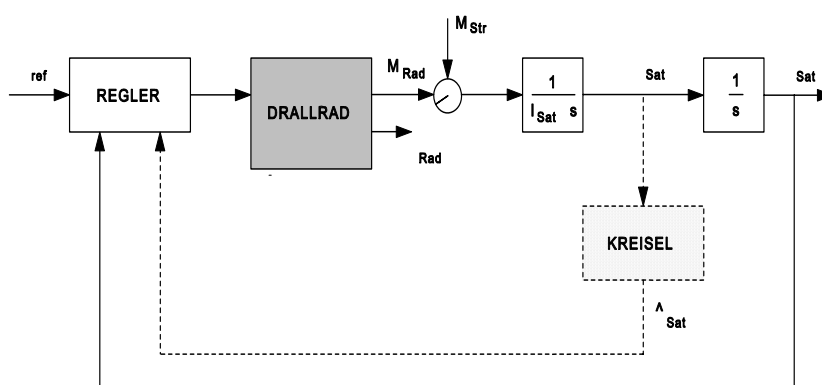


Bild 1 Lageregelkreis für die Nickachse eines Bias Momentum Systems

Beim Betrieb von Drallrädern können folgende typische *Gerätefehler* auftreten [4]:

□ Hochlauffehler

Der Hochlauffehler entsteht in der Elektronikeinheit und äußert sich im plötzlichen Hochtouren des Rades, ohne daß eine entsprechende Anforderung vorliegt. Das Rad fährt bis an seine Maximaldrehzahl und ist ab

Fehlereintritt unsteuerbar. Für die Lageregelung läßt sich nur noch der Stabilisierungseffekt der Kreiselwirkung nutzen, der durch den Fehler allerdings mit hohen Anlaufströmen, Wärmeentwicklung und Kugellagerbelastung verbunden ist.

□ Eingangskurzschluß

Bei Auftreten des Eingangskurzschlußfehlers ist das Rad ebenfalls nicht mehr steuerbar. Dieser Fehler kann z.B. durch Ausfall elektronischer Bauelemente, durch Unterbrechung der Verbindungsleitungen oder durch Erdschluß zustandekommen. Durch Wirkung der Lagerreibung wird das Rad abtounen und zum Stillstand kommen.

□ Tachoausfall

Über den Tacho wird die Winkelgeschwindigkeit des Rades gemessen. Bei Ausfall fehlt dem Lageregelungskreis eine wichtige Zustandsinformation, von der z.B. die Steuerung des Drallrad-Entladevorganges abhängig ist.

□ Kugellagerschaden

Trotz der in Langzeittests bewiesenen Zuverlässigkeit, können Kugellager in der Start- bzw. Aussetzphase des Satelliten infolge Vibrationen deformiert werden. Die Folge davon ist eingeschränkte Schmierung und erhöhter metallischer Kontakt. Die damit verbundene Haftreibung (Hitzeentwicklung, Abrieb) kann zur Zerstörung der Lagereinheit und zum Verlust des Drallrades führen. Durch rechtzeitiges Abtounen kann u.U. das Drallrad noch längere Zeit im unteren Drehzahlbereich (Betriebsart reaction wheel) gefahren werden, obwohl dort der Effekt der Kreiselsteifigkeit entfällt. Sich analog auswirkende Haftreibungsschäden können neben Kugellagerschäden z.B. auch durch Behinderung der Kugellager-Rollbewegung durch Festpartikel oder auch durch Gehäuseanschläge auftreten.

□ Schmiermittelausfall

Durch Auftreten von Lecks im Schmierstoffreservoir, behinderten Schmierstoffausstoß, Partikel im Schmierfilm, verstopfte Kriechlabyrinth, aufgebrauchtes Schmiermittelreservoir oder durch Überschmierung kann sich die Gleitreibung im Lager erhöhen. Verbunden mit einer Temperaturerhöhung in den Lagern erhöht sich das Verlustmoment, und die Ausregelung der Satellitenlage verzögert sich entsprechend. Das Drallrad tourt mit dem als Bremse wirkenden Verlustmoment schneller ab. Mit der voraussichtlich kürzeren Lebensdauer der Lager droht auch Totalverlust in der Missionszeit. Es ist deshalb wichtig, das Rad rechtzeitig zu entlasten und evtl. mit geringerer Drehzahl noch zu betreiben.

Für die Simulationsexperimente wurde ein Drallrad mit folgenden Gerätekennwerten benutzt [5]:

Nominaldrall	$L_D = 50 \text{ Nms}$	Trägheitsmoment	$J = 0.1038 \text{ Nm s}^2$
Reaktionsmoment	$M_D = 0.1 \text{ Nm}$	maximaler Motorstrom	$i_{\text{Motor}} = 2.2 \text{ A}$
Nominal-Drehzahl	$n = 4600 \text{ U/min}$	Motorkonstante	0.055 Nm/A
Maximal-Drehzahl	$n_{\text{MAX}} = 5400 \text{ U/min}$	Steuerspannungsbereich	$\pm 10 \text{ V}$

Tabelle 1: Gerätekennwerte für das Drallrad

3. Zielstellung für das bordautonome Fehlerdiagnosesystem

Die an Bord implementierten Fehlermanagementsysteme von Satelliten (*FDIR - Failure Detection, Isolation and Recovery*) stützen sich in den meisten Fällen auf das *Erkennen* von Fehlfunktionen (*detection*) und die *Lokalisierung* des defekten Gerätes (*isolation*). Dazu werden üblicherweise Statussignale und Schwellwertüberwachungen von meßbaren Gerätezustandsgrößen ausgewertet [6]. Im Falle der Erkennung und Validierung eines Fehlersymptoms wird dann auf ein redundantes Gerät umgeschaltet (*recovery*), wodurch im allgemeinen eine hinreichende Systemverfügbarkeit sichergestellt ist. Die eigentliche Fehlerdiagnose wird jedoch durch Auswertung der Fehlerhistorie über Telemetriedaten in der Bodenstation durchgeführt.

Zur Realisierung der geforderten erhöhten Bordautonomie (siehe Kapitel 1) ist demnach die Diagnosefunktion in den Satelliten selbst zu verlagern und gegebenenfalls die Fehlerlokalisierung zu verfeinern.

Ausgehend von diesem Anwendungshintergrund bilden folgende *Fragestellungen* die Grundlage für die durchgeführten Untersuchungen:

- inwieweit lassen sich aus der vorhandenen Signalstruktur (Statussignale, meßbare Gerätezustandsgrößen) durch erweiterte Vernüpfungen über *stationäre Klassifikatoren* zusätzliche Informationen zur

Fehlerlokalisierung und -diagnose gewinnen (dies entspricht einer logischen Erweiterung der gegenwärtig verwendeten Fehlerkennungsverfahren)

- wie eignen sich im speziellen *Clusterungsverfahren* für diese Klassifikationsaufgaben (z.B. Fuzzy, Künstliche Neuronale Netze)
- reichen die bereits an Bord zur Verfügung stehenden “*einfachen*” *Merkmale* (Statussignale, Momentanwerte, eventuell gefilterte Größen) für eine hinreichende Klassentrennung aus
- inwieweit ist eine *lokale* Fehlererkennung und Diagnose möglich, besonders im Hinblick auf eine modulare, lokal begrenzte Implementierung der Algorithmen (Objektorientierung).

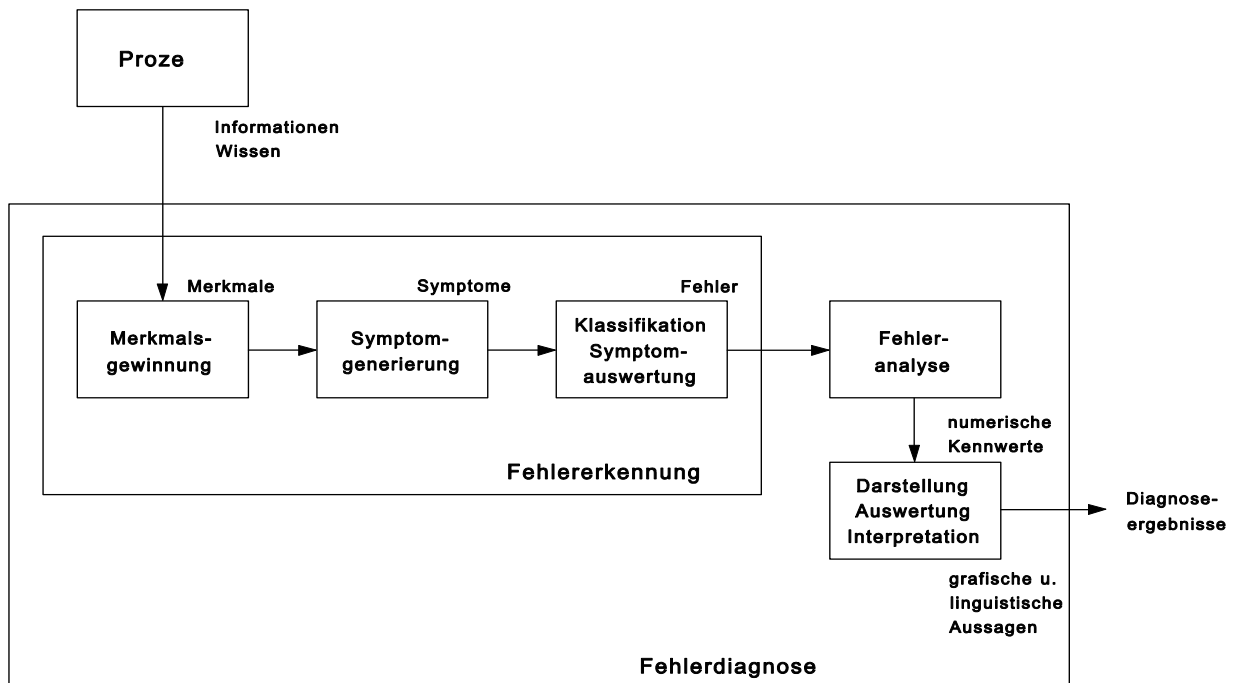
Zur Konzipierung des Fehlerdiagnosesystems wurde folgende Vorgehensweise gewählt:

- o Modellierung des fehlerbehafteten Drallrades
- o Simulation von Drallrad und Fehlermodellen mittels CAE-System MATRIXx [7]
- o Bereitstellung von Werkzeugen zur Datenanalyse (Symptomerzeugung) mittels
 - Fuzzy-Clustering (FCM-, FSC-, MinMax-Verfahren [8,9,10]) bzw.
 - Kohonen-Netz [11].
- o Auswahl geeigneter Primär- und Sekundärmerkmale und Definition eines Merkmalsraumes
- o Gewinnung von Trainings- und Testdaten über Simulationsexperimente (‘überwachtes Lernen’)
- o Erprobung und wertender Vergleich der Klassifikatoren zur Fehlererkennung (Lernphase/Testphase)
- o Bereitstellung von Mitteln zur Fehleranalyse und -auswertung.

Hierbei wurden in der Lernphase den Klassifikatoren blockweise Merkmalsvektoren aus Normalbetriebs- bzw. bekannten Fehlbetriebsphasen, in denen jeweils einer der oben genannten fünf Gerätefehler simuliert wurde, angeboten.

Bild 2 zeigt die grundlegende Struktur des untersuchten Fehlererdiagnosesystems (nach [12]).

Bild 2 Struktur des Fehlerdiagnose-Systems (nach [12])



4. Datenanalyse mittels Cluster-Verfahren

Bei der Datenanalyse durch *Fuzzy-Clustering* wird der Merkmalsraum unscharf strukturiert, indem nach einer Lernphase für jeden anliegenden Merkmalsvektor \underline{m} im Sinne einer Fuzzy-Beschreibung der Zugehörigkeitsgrad zu einem prototypischen Repräsentanten der Fehlerklasse bestimmt wird. Zur feineren Strukturierung des Raumes wird dabei jede Fehlerklasse noch in Unterklassen, die dann jeweils einen eigenen Prototyp besitzen, eingeteilt. Klassenzahl, Klassifizierungsschärfe, Abbruchschranken usw. werden neben Anfangsbedingungen für diese in der Lernphase iterativ arbeitenden Verfahren vorgegeben.

Die Symptomerzeugung bzw. Klassifikation erfolgt dann in der Arbeitsphase nach dem Prinzip des nächstgelegenen Nachbarn. Die Distanz d zwischen dem anliegenden Merkmalsvektor und dem nächstgelegenen Repräsentanten einer Fehlerklasse wird schließlich in einen Ähnlichkeitswert μ umgerechnet, und die Ähnlichkeitswerte zu allen Fehlerklassen werden im Ähnlichkeitsvektor $\underline{s} = (\mu_1, \dots, \mu_q)$, q : Anzahl der Fehlerklassen, zusammengefaßt.

In [13] wurden hierzu drei *fuzzy-basierte Klassifikatoren* simulativ erprobt:

- der *FCM-basierte Klassifikator* [8] strukturiert den Merkmalsraum mittels prototypischer Clusterzentrumsvektoren (s. Bild 3a). Als Abstandsmaß wird wie auch in der nachfolgenden Variante die euklidische Norm benutzt.
- beim (modifizierten) *FSC-Klassifikator* [9] wird der Merkmalsraum in Hyperkugeln zerlegt (s. Bild 3b); die Lage der Mittelpunkte dieser prototypischen Kugeln stimmt mit den FCM-Clusterzentrumsvektoren überein, und ihre Radien sind über die Zugehörigkeitsgrade gewichtete mittlere Abstände der Merkmalsvektoren von den Kugelmittelpunkten
- der *Fuzzy-Min-Max-Klassifikator* [10] zerlegt den Merkmalsraum in Hyperquader und benutzt zur Abstandsmessung die Hammingdistanz [s. Bild 3c].

Bild 3a:
Strukturierung des Merkmalsraumes
beim FCM-Verfahren durch
Clusterzentrusvektoren




Bild 3b:
Strukturierung des Merkmalsraumes
beim FSC-Verfahren durch
Hyperkugeln




Bild 3c:
Strukturierung des Merkmalsraumes
beim Min-Max-Verfahren durch
Hyperboxen





Bild 4:
Struktur des zweiseitigen Kohonen-
Netzes
(dargestellt während der Lernphase)



Bei der Datenanalyse mittels zweiseitigem *Kohonen-Netz* wird ähnlich wie beim FCM-basierten Verfahren der wertkontinuierliche Merkmalsraum durch eine vorgebbare Anzahl N prototypischer Vektoren \underline{w}_j möglichst problemangepaßt repräsentiert. Hierzu werden auf N Plätzen (an N "Neuronen"), die zu Feldern angeordnet sind, jeweils zwei Gewichtsvektoren \underline{w}_j und \underline{u}_j , die einem Lernvorgang unterliegen, angeheftet (siehe Bild 4). Während der Lernphase werden in jedem Schritt die "Eingangsgewichte" $\underline{w}_j(k)$ mit dem aktuellen Merkmalsvektor $\underline{m}(k)$ und die "Ausgangsgewichte" $\underline{u}_j(k)$ mit dem aktuellen, binären Fehlerklassenvektor $\underline{v}(k)$ hinsichtlich ihrer (euklidischen) Ähnlichkeit verglichen.

Aus der (momentanen) Vektordifferenz $\underline{m}(k) - \underline{w}_j(k)$ ($j = 1, \dots, N$) wird ein Gewinnerneuron N_j ermittelt, und werden daraufhin alle Gewichtsvektoren am Ein- und Ausgang entsprechend der Lernregel nach KOHONEN verändert, wobei die "Entfernung" $c_{ji}(k)$ zwischen den Plätzen N_j und N_i sowie ein Lernfaktor $\eta(k)$ die Gewichtsänderungen mitbestimmen. Gewichte eng benachbarter Plätze (Neuronen) werden stärker als Gewichte "weit abliegender" Plätze (Neuronen) verändert. Der Kohonen-Algorithmus sorgt dafür, daß am Schluß der Lernphase "benachbarte" Neuronen auch "ähnliche" Ein-/Ausgangsgewichte tragen. In der Arbeitsphase wird dann bei Anlegen eines Merkmalsvektors ausgangsseitig der zugehörige Fehlervektor \underline{u}_j angezeigt. Interne Neuronenfunktionen werden hierbei nicht genutzt.

Erste Erfahrungen [14] zeigen, daß sich bei ungünstiger Wahl der Netzparameter (Netzstruktur, Lernparameter) und ungeschickter Merkmalsbildung nicht der gewünschte Lernerfolg einstellt. Hier zeigen sich die bekannten methodischen Schwächen der Kohonen-Netze. Mit den fuzzy-basierten Klassifizierungsverfahren werden relativ rasch gute Ergebnisse erzielt, und aufgrund der Simulationsexperimente werden deshalb die FCM- bzw. FSC-basierten Varianten favorisiert und als gleichwertig angesehen. Im folgenden soll beispielhaft der FCM-Klassifikator zur Fehlererkennung am Drallrad eingesetzt werden.

Bild 5 verdeutlicht die beiden Betriebsarten Lernphase und Testphase des FCM-basierten Klassifikators. Der Ähnlichkeitsvektor \underline{s} erlaubt in den meisten Fällen bereits eine erste Aussage zum Betriebszustand (Normal-/Fehlbetrieb) des überwachten Gerätes.

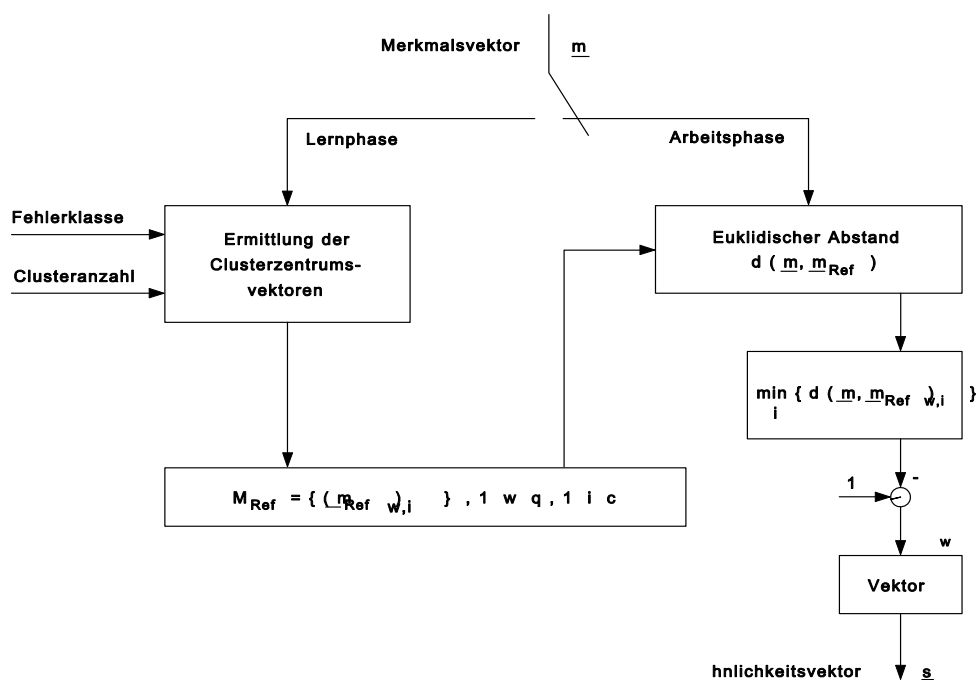


Bild 5: Betriebsarten des FCM-Klassifikators

5. Erprobung eines fuzzy-basierten Klassifikators am Drallrad

Zur Erkennung der o.g. fünf wesentlichen Drallradfehler (s. Tabelle 2, linke Spalte) müssen Merkmalsgrößen benutzt werden, in denen sich diese Fehler deutlich abbilden. Hier liegt das besondere Problem, Merkmalsvektoren derart zu finden, daß der Merkmalsraum durch das Klassifizierungsverfahren in möglichst auffallend getrennte Teilgebiete nach den Fehlerklassen zerlegt wird. Im vorliegenden Fall wurden nach umfangreichen Vorversuchen sieben (normierte) Merkmale herangezogen (s. Tabelle 2, rechte Spalte).

Fehler	Merkmale
F1: Eingangskurzschluß F2: Hochlauffehler F3: Tachoausfall F4: Kugellagerschaden sowie F5: Schmiermittelausfall	M1: Tachospannung $u \sim$ Drehzahl ω M2: Motorstrom i M3: Lagertemperatur θ M4: Differenz Δ zwischen gefordertem Moment (Drallrad-Eingangsgröße) und Motorstrom M 5: Abtourwert $a = k (1-\omega)$ M6: Oberer Strombereich $i > 0.3$ M7: Unterer Strombereich $-0.1 < i < 0.3$

Tabelle 2: Drallradfehler und Fehlermerkmale

Die Merkmale M1 bis M3 gehören zu den direkt meßbaren Signalen (Primärmerkmale), während die Merkmale M4 bis M7 aus diesen abgeleitet sind (Sekundärmerkmale). Die Merkmale M6 und M7 liegen nach einer Schwellwertabfrage nur als L/O-Signale vor.

Bild 6a zeigt die simulativ ermittelten Merkmalswerte (Trainingswerte) für die Betriebsphase "Normalbetrieb", und im Vergleich dazu sind im Bild 6b diese Werte für die Betriebsphase "Eingangskurzschluß" dargestellt. Das Drallrad wurde hierbei mit einem Zufallssignal angesteuert.

Derartige Trainingswerte wurden nun blockweise für jeden der fünf betrachteten Fehler erzeugt und zum Anlernen des Klassifikators eingesetzt.

Die Testergebnisse für den FCM-Klassifikator zeigt auszugsweise Bild 7. Dargestellt ist im Teilbild 7a der Verlauf des Ähnlichkeitsvektors \underline{s} über der diskreten Zeit k . Hierbei wurde jeder der fünf Fehler jeweils dreimal generiert. Für einen Testzeitpunkt sind die Ähnlichkeitswerte μ_i ($i = 1,2,4$) beispielhaft hervorgehoben. Diese Momentanwerte des Vektors \underline{s} deuten im übrigen auf den möglichen Ausfall an Schmiermittel zum Testzeitpunkt hin.

Um das Klassifikationsergebnis (visuell) zu verbessern, wurden die Ähnlichkeitswerte noch über Schwellwertschalter gefiltert. Das führt schließlich zu einer Darstellung im Teilbild 7b.

Ferner wurden erste, orientierende Untersuchungen zur Fehleranalyse und -auswertung vorgenommen. Sie dienen der Interpretation, Darstellung und Verdichtung der aus der Symptomerzeugung bzw. Fehlerklassifizierung resultierenden Ergebnisse und zielen vorrangig auf Aussagen zu

- Güte des Klassifikationsergebnisses
- Fehlereintrittszeit
- Fehlerdauer
- Fehlerhäufigkeit sowie
- Fehlerverlauf.

6. Bewertung der Simulationsexperimente

Die Auswertung der experimentellen Ergebnisse erfolgte entsprechend den im Kapitel 3 genannten Zielstellungen.

➤ Fehlererkennung

- Alle vier eingesetzten Klassifizierungsverfahren eignen sich zur Erkennung der fünf untersuchten Fehler, sofern diese einzeln auftreten.
- Mehrfachfehler wurden nicht speziell trainiert und wurden deshalb auch nur teilweise erkannt. Hierzu sind weitere Untersuchungen geplant.
- Beim Anliegen des Fehlers "Kugellagerschaden" wird kurzzeitig auch der Fehler "Schmiermittelausfall" angezeigt. Der Grund hierfür liegt im Temperaturverhalten des Drallrades, wodurch die verwendeten Merkmale offensichtlich nicht für eine sichere Klassentrennung ausreichen.
- Die Betriebsphase "Normalbetrieb" wurde in allen Experimenten sicher erkannt. Damit ist eine Validierungsmöglichkeit des standardmäßig zur Verfügung stehenden "Health Status" des Gerätes möglich.
- Nichtgelernte Fehler, wie z.B. "Motor-Windungskurzschluß" werden entweder bestehenden Fehlerklassen in zum Teil charakteristischer Weise zugeordnet oder liefern (nahezu) Nullvektoren als Ähnlichkeitsvektoren.
- Die Reaktionszeiten der Fehlererkennung bzw. Diagnose lagen bei typisch 20 - 50 sec (Hochlauffehler). Damit ist eine sichere und schnellere Erkennung inklusive Diagnose möglich, als bei einer einfachen Schwellwertüberwachung.

➤ Charakter der Merkmalsgrößen

- Die drei fuzzy-basierten Verfahren (FCM, FSC, Min-Max) nutzen nur Primär- und Sekundärmerkmale, die aus Momentanwerten von Prozeßzustandsgrößen abgeleitet sind und arbeiten zufriedenstellend.
- Bei der Datenanalyse mittels Kohonen-Netz führte diese Vorgehensweise nicht zum Erfolg. Hier mußten deshalb sekundäre Merkmale durch Schätzung der Aufenthaltswahrscheinlichkeiten von Steuersignal, Motorstrom, Drehzahl und Temperatur in vorgewählten Signalbereichen gebildet werden.

➤ Vergleich der untersuchten Verfahren

- Alle vier eingesetzten Klassifikatoren bewiesen ihre prinzipielle Eignung für die gestellte Aufgabe.
- Favorisiert werden die fuzzy-basierten Verfahren aufgrund der einfacheren Merkmalsbildung (Merkmale aus Momentanwerten). Dabei erwiesen sich die Klassifizierungen durch Clusterung mittels Zentrumsvektoren (FCM) bzw. Hyperkugeln (FCS) als gleich leistungsfähig.
- Als gewichtige Nachteile des Kohonen-Netz basierten Verfahrens wurden erkannt:
 - . größerer Aufwand nötig für die Merkmalsbildung
 - . geringere Anschaulichkeit bezüglich Netzentwurf (Netzstruktur, Wahl der Lernparameter)
- Der bekannt hohe Lernaufwand konnte bei allen untersuchten Verfahren bestätigt werden, typisch 1000 Lernschritte.
Dies rechtfertigt zusätzlich die Verwendung von detaillierten Simulationsmodellen der Geräte für den Lernvorgang.

➤ Lokale Fehlererkennung und -diagnose (Objektorientierung)

- Die Eignung aller untersuchten Verfahren zur sicheren lokalen Fehlererkennung für das *Drallrad* über alleinige Beobachtung der Drallradsignale konnte bestätigt werden.
Damit kann im Sinne der Objektorientierung die Fehlererkennungs- und Diagnosefunktion als eine dem jeweiligen Drallradtyp spezifische Methode in der Bordsoftware implementiert werden. Bei einem Wechsel des Drallradtyps muß dann auch nur der zugehörige Softwaremodul ausgetauscht werden.
- Orientierende Untersuchungen zur lokalen Fehlerdiagnose an einem *Sensor* (Kreisel in Bild 1) zeigten deutlich schlechtere Ergebnisse. Dies liegt offensichtlich daran, daß die physikalischen Eingangsgrößen des Sensors (Drehrate des Satelliten) nicht als Signal zur Verfügung steht und damit die Kausalbeziehung zu den beobachteten Gerätezuständen des Kreisels nicht ausgewertet werden kann. Dies ist nur möglich über eine zweite unabhängige Messung. Hierfür bieten sich entweder das Drallrad an (Kausalkette: Drallradeingang-Satellitendynamik-Kreisel) oder ein Lagesensor (Kausalkette: Kreiselausgang-inverse

Kreiseldynamik-Satellitenkinematik-Lagesensor). In jedem Fall wird aber das Lokalisierungsprinzip verletzt, d.h. es müssen gleichzeitig auch Signale anderer Geräte verarbeitet (und damit gelernt) werden, ebenso steigt die Wahrscheinlichkeit von Mehrfachfehlern.

7. Ausblick

Weiterführende Arbeiten beschäftigen sich u.a. mit dem Test der entwickelten Komponenten des Fehlerdiagnosesystems an realen Geräten unter Laborbedingungen. Dazu befindet sich zur Zeit ein *Echtzeitlabor Satellitenlageregelung* im Aufbau, als repräsentative Lageregelungshardware steht u.a. ein von der Firma *Teldix*, Heidelberg, gestelltes Drallrad zur Verfügung.

Ein weiterer Komplex beschäftigt sich mit der Untersuchung des Lokalisierungsprinzips hinsichtlich einer verbesserten Merkmalsbildung für Sensoren, der Anwendung der Verfahren auf andere Gerätetypen (Düsen, Lagesensoren) sowie die geeignete Vernetzung der verschiedenen lokal zur Verfügung stehenden Fehlerinformationen.

8. Literatur

- [1] Hallmann, Ley u.a.:
Handbuch der Raumfahrttechnik.
Carl Hanser Verlag, München, 1988.
- [2] Wertz, J.:
Spacecraft Attitude, Determination and Control.
D. Reidel Publishing Company, Dordrecht, Boston, London, 1995.
- [3] Auer, W.:
Stabilisierungsräder für die Lageregelung von Raumfahrzeugen- Technik u. Erfahrungen.
Zeitschrift für Flugwissenschaften und Weltraumforschung, Nr. 14 (1990), p. 309-314.
- [4] Janschek, K.:
Betriebsfehler bei Kreisel und Drallrad.
Interner Arbeitsbericht, TU Dresden, 1996.
- [5] Teldix - Produktkatalog.
Teldix-GmbH, Heidelberg, 1994.
- [6] Surauer, M., Bittner, H., Fichter, W., Fischer, H.D.:
Advanced Attitude and Orbit Control Concepts for 3-Axes Stabilized Communication and Application Satellites.
Proceedings of the IFAC Symposium on Automatic Control in Aerospace '92, Ottobrunn, 1992.
- [7] MATRIXx Product Family.
Integrated Systems, Inc., Santa Clara USA, 1996.
- [8] Zimmermann, H.-J.:
Neuro + Fuzzy.
Technologien-Anwendungen, VDI-Verlag, Düsseldorf, 1995.
- [9] Dave, R.N.:
Fuzzy-Shell Clustering and application to circle detection.
Int. J. General Systems 16, 1990 S. 343-352.
- [10] Simpson, P.K.:
Fuzzy-Min-Max Neural Networks, Part1&Part2.
IEEE Transactions on Fuzzy-Systems Vol.1, February 1993.
- [11] Kohonen, T.:
Self-Organizing Maps.
Springer-Verlag, Berlin, Heidelberg, 1995.

- [12] Isermann, R.:
Modellgestützte Überwachung und Fehlerdiagnose.
Automatisierungstechnische Praxis 38 (1996) H. 5, S. 9-20, H. 6, S. 48-57.
- [13] Rind, H.:
Fehlerdiagnose mittels Fuzzy-Clusterung.
Diplomarbeit, TU Dresden, 1996.
- [14] Reckzeh, S.:
Signalgestützte Fehlererkennung und -klassifizierung mittels Kohonennetzen.
Diplomarbeit, TU Dresden, 1996.