

**KfK 4197
Juni 1987**

**Mustererkennung und
Prognoseverfahren in
parametrischen Signalmodellen
zu Fehlerfrühdiagnosen**

**K. Scherer
Institut für Datenverarbeitung in der Technik
Projekt Schneller Brüter**

Kernforschungszentrum Karlsruhe

KERNFORSCHUNGSZENTRUM KARLSRUHE

Institut für Datenverarbeitung in der Technik

Projekt Schneller Brüter

KfK 4197

Mustererkennung und Prognoseverfahren in parametrischen Signalmodellen
zu Fehlerfrühdiagnosen +)

Klaus - Peter Scherer

Kernforschungszentrum Karlsruhe GmbH, Karlsruhe

+) Von der Fakultät für Elektrotechnik der Universität
Karlsruhe genehmigte Dissertation

Als Manuskript vervielfältigt
Für diesen Bericht behalten wir uns alle Rechte vor

Kernforschungszentrum Karlsruhe GmbH
Postfach 3640, 7500 Karlsruhe 1

ISSN 0303-4003

Zusammenfassung

Zur Fehlerfrühdiagnose bei gefährlichen Anlagen ist es wichtig, intelligente Signalverarbeitungsmethoden mit lernenden Verfahren einzusetzen, sodaß eine Prozeßbeurteilung schon auf der Signalverarbeitungsebene optimiert werden kann. Einerseits bieten sich Ansätze aus der Mustererkennung geradezu an, andererseits ist von Überwachungsstrukturen mit parametrischen Signalmodellen noch recht wenig bekannt.

In dieser Arbeit wird am Beispiel einer Siedeüberwachung von realen akustischen Signalen demonstriert, wie ein solcher physikalischer Prozeß mit Methoden der Mustererkennung unter Einbeziehung parametrischer Signalmodelle überwacht werden kann. Die Einführung von Prognosemodellen ermöglicht es, den Entscheidungsprozeß in Form von Klassifikationen zeitlich vorwegzunehmen.

Mit den entwickelten Verfahren wird eine Überwachung durchgeführt und die Ergebnisse werden präsentiert.

Pattern recognition and prognostic methods in parametric signal models for early failure detection

Abstract

For early failure detection in critical devices it is important to use intelligent signal processing methods in learning systems, so that a process evaluation can be optimized already on the signal processing level. On the one hand, pattern recognition methods are useful. On the other hand, about surveillance structures with parametric signal models there are a lot of questions not solved. In this report, a boiling detection system of real acoustic signals is demonstrated, how to survey such a physical process by methods of pattern recognition with enclosed parametric signal models. By introduction of prognostic models, a decision in form of a classification process can be made in advance.

A surveillance is performed by the developed methods and the results are presented.

<u>Inhaltsverzeichnis:</u>	<u>Seite</u>
1. Einleitung	1
2. Siededetektion: Stand und Ziele	4
3. Experimenteller Hintergrund	8
4. Mustererkennung: Konzept und Modellbildung	15
4.1 Allgemeiner Aufbau eines Klassifikatorsystems	15
4.2 Merkmalsgewinnung und -darstellung im Merkmalsraum	17
4.3 Generierung statistischer Primärmerkmale	21
5. Prognoseverfahren im Merkmalsraum	24
5.1 Das Verfahren der Linearen Vorhersage	26
5.2 Schätzmethoden mit einem Differenzenverfahren	30
5.2.1 Stabilitätsaussagen	32
5.2.2 Modellbildung im Merkmalsraum	34
5.3 Kalmanfilter für zeitdiskrete stochastische Prozesse	35
5.4 Das Berliner Verfahren	42
5.5 ARIMA - Modellierung im Merkmalsraum	45
5.6 Anwendung der Prognoseverfahren	52
6. Merkmalsbewertungen	60
6.1 Gütekriterien für statistisch unabhängige Merkmale	60
6.2 Bewertung für korrelierte Merkmale	60
6.3 Anwendung auf KNS - Signale	61
7. Lernprozesse	67
7.1 Generierung von Ballungszentren im Merkmalsraum	67
7.2 Überwachtes Lernen, unüberwachtes Selbstlernen	68
7.3 Clusterbereinigung und Kompaktifizierung	69

8.	Gesamtkonzept zur Siededetektion	77
8.1	Simulation der Siedeüberwachung	77
8.2	Klassifikationsergebnisse	81
8.3	Vergleich zu Schwellwertverfahren	92
9.	Ausblick	97
10.	Zusammenfassung	99
11.	Literatur	101

<u>Abbildungsverzeichnis:</u>	<u>Seite</u>	
Abb. 1.0:	Einsatz partieller Überwachungssysteme	2
Abb. 2.1:	Anforderungsprofil	6
Abb. 3.1:	Komplexe Coregeometrie	9
Abb. 3.2:	Kompakte - Natrium - Siedeteststrecke (KNS)	10
Abb. 3.3:	RMS - Signal Extrakt; 0 db	12
Abb. 3.4:	RMS - Signal Extrakt; -11 db	13
Abb. 3.5:	RMS - Signal Extrakt; -14 db	14
Abb. 4.1:	Klassifikatormodell	16
Abb. 4.2:	Leistungsdichtespektren	20
Abb. 5.0:	adaptives System	25
Abb. 5.2:	äquidistante Zeitunterteilung	29
Abb. 5.5.1:	Programmstruktur zur ARIMA - Modellierung	53
Abb. 5.5.2:	Iterative Dimensionierung des ARIMA - Modells	54
Abb. 5.6.1:	Klassische Überwachung	52
Abb. 5.6.2:	Modellbildung und Parameterschätzung	58
Abb. 6.3:	Merkmale - Güte Tabelle	62
Abb. 6.4:	Bewertungsschema; 0 db	63
Abb. 6.5:	Bewertungsschema; -11 db	64
Abb. 6.6:	Bewertungsschema; -14 db	65
Abb. 6.7:	Gaußverteilungen eines Merkmals	66
Abb. 7.3.1:	Zwei separate Cluster	70
Abb. 7.3.2:	Clustervereinigung	70
Abb. 7.3.3:	Clusterzugehörigkeit 1	71
Abb. 7.3.4:	Clusterzugehörigkeit 2	71
Abb. 7.3.5:	m - Nachbarschaft	72
Abb. 7.3.6:	unüberwachtes Lernen: Musterbereich: Block 20 - 70 und 200 - 250	74
Abb. 7.3.7:	unüberwachtes Lernen: Musterbereich: Block 40 - 90 und 280 - 330	75
Abb. 7.3.8:	unüberwachtes Lernen: Musterbereich: Block 120 - 170 und 175 - 225	76
Abb. 8.0:	Hardware - Software - Konfiguration	78
Abb. 8.1:	Mustererkennung - Überwachungsmodell	80
Abb. 8.2.1:	Modellergebnisse (Extrakt)	84
Abb. 8.2.2:	Klassifikationstabellen; 0 db; Merkmale: 5, 42; (aktuell u. Summe)	86
Abb. 8.2.3:	Klassifikationstabellen; 0 db; Merkmale: 5, 42; (Lin. Vorhersage, Dgln.)	87
Abb. 8.2.4:	Klassifikationstabellen; 0 db; Merkmale: 5, 42; (Berl., ARIMA)	88
Abb. 8.2.5:	Klassifikationstabellen; 0 db; Merkmale: 20,21; (aktuell u. Summe)	89

Abb. 8.2.6:	Klassifikationstabellen; -11 db; Merkmale: 4, 42; (aktuell u. Summe)	90
Abb. 8.2.7:	Klassifikationstabellen; -14 db; Merkmale: 31,33; (aktuell u. Summe)	91
Abb. 8.3.1:	Klassifikationstabellen; 0 db; Schwellwertverfahren	93
Abb. 8.3.2:	Klassifikationstabellen; -11 db; Schwellwertverfahren	94
Abb. 8.3.3:	Klassifikationstabellen; -14 db; Schwellwertverfahren	95
Abb. 8.3.4:	Daten- und Programmstruktur	96

1. Einleitung

Im Rahmen der Sicherheitsmaßnahmen in kerntechnischen Anlagen sind bereits eine Vielzahl von Überwachungssystemen installiert. Viele Systeme sind speziell für einzelne Anlagenkomponenten konstruiert und arbeiten zunächst unabhängig als Einzelsysteme.

Die vielfältige Kombination aller Überwachungskomponenten findet sich letztlich in einem Diagnosesystem als Informationszentrum wieder. Hier werden Soll- und Istwerte verglichen, womit der Reaktorzustand erfaßt werden kann. Entsprechende Steuerungen und Maßnahmen werden von hier eingeleitet. Da die Prozeßbeurteilung nach Aufzeichnung im wesentlichen visuell vom Operator durchgeführt wird, sind die Schwachstellen eines solchen Systems offensichtlich. Die Beurteilung ist operatorabhängig und somit subjektiven Einflüssen stark unterworfen. Es existiert kaum eine objektive Entscheidungsunterstützung, und wenn, dann erfolgt sie zum Teil mit zeitlich beträchtlicher Verzögerung an die Prozeßsteuerung. Neben dieser inspektionsweisen off-line Beurteilung werden zeitkritische Zustände durch einfache Schwellwertüberwachungen der gemittelten Signalamplituden abgedeckt, was erhebliche Mängel in der Aussagenqualität mit sich bringt. Abb. 1.0 zeigt zunächst einen groben Überblick über partielle Überwachungskomponenten in Kernkraftwerken, ihren Einsatz und ihre Arbeitsweise.

Da eine optimale Entscheidung zur Diagnose des Gesamtprozesses im wesentlichen aus intelligenten Teilentscheidungen auf der Signalverarbeitungsebene erfolgt, scheint ein sinnvoller Ansatz zu sein, mit modernen und leistungsfähigen Verfahren der Mustererkennung auf der Signalverarbeitungsebene Prozeßzustände zu klassifizieren und dem Gesamtsystem zugänglich zu machen.

Die vorliegende Arbeit zeigt am Beispiel der Siededetektion, wie mit Verfahren der Mustererkennung (ME) eine akustische Überwachung erfolgen kann, wobei die einzelnen ME-Komponenten in ihrer Leistungsfähigkeit analysiert werden und zum Schluß eine on-line-Überwachung bei den vorhandenen Experimentdaten simuliert wird.

In dieser Arbeit werden allgemeine Methoden entwickelt, die im Sinne der ME zur Detektion gefährlicher Zustände bei eindimensionalen Signalen geeignet sind. Es wird gezeigt, wie über parametrische Signalmodelle aufgrund von intelligenten Lernprozessen Signalzustände schnell und mit hoher Aussagekraft erfaßt werden können, die dann als partielle Entscheidungen einem übergeordneten System zur Verfügung gestellt werden können. Die Akustik ist hier nur ein exemplarisches Anwendungsgebiet, wo die Lösung von akutem Interesse ist.

In Kapitel 2 wird der derzeitige Stand zur Siededetektion erläutert. Aus den spezifischen Schwachstellen der vorhandenen Systeme resultiert dann die Zielsetzung für diese Arbeit. Kapitel 3 gibt eine Kurzdarstellung, woher und wie die zu verarbeitenden Signale gewonnen wurden und wie das experimentelle Vorfeld aussah.

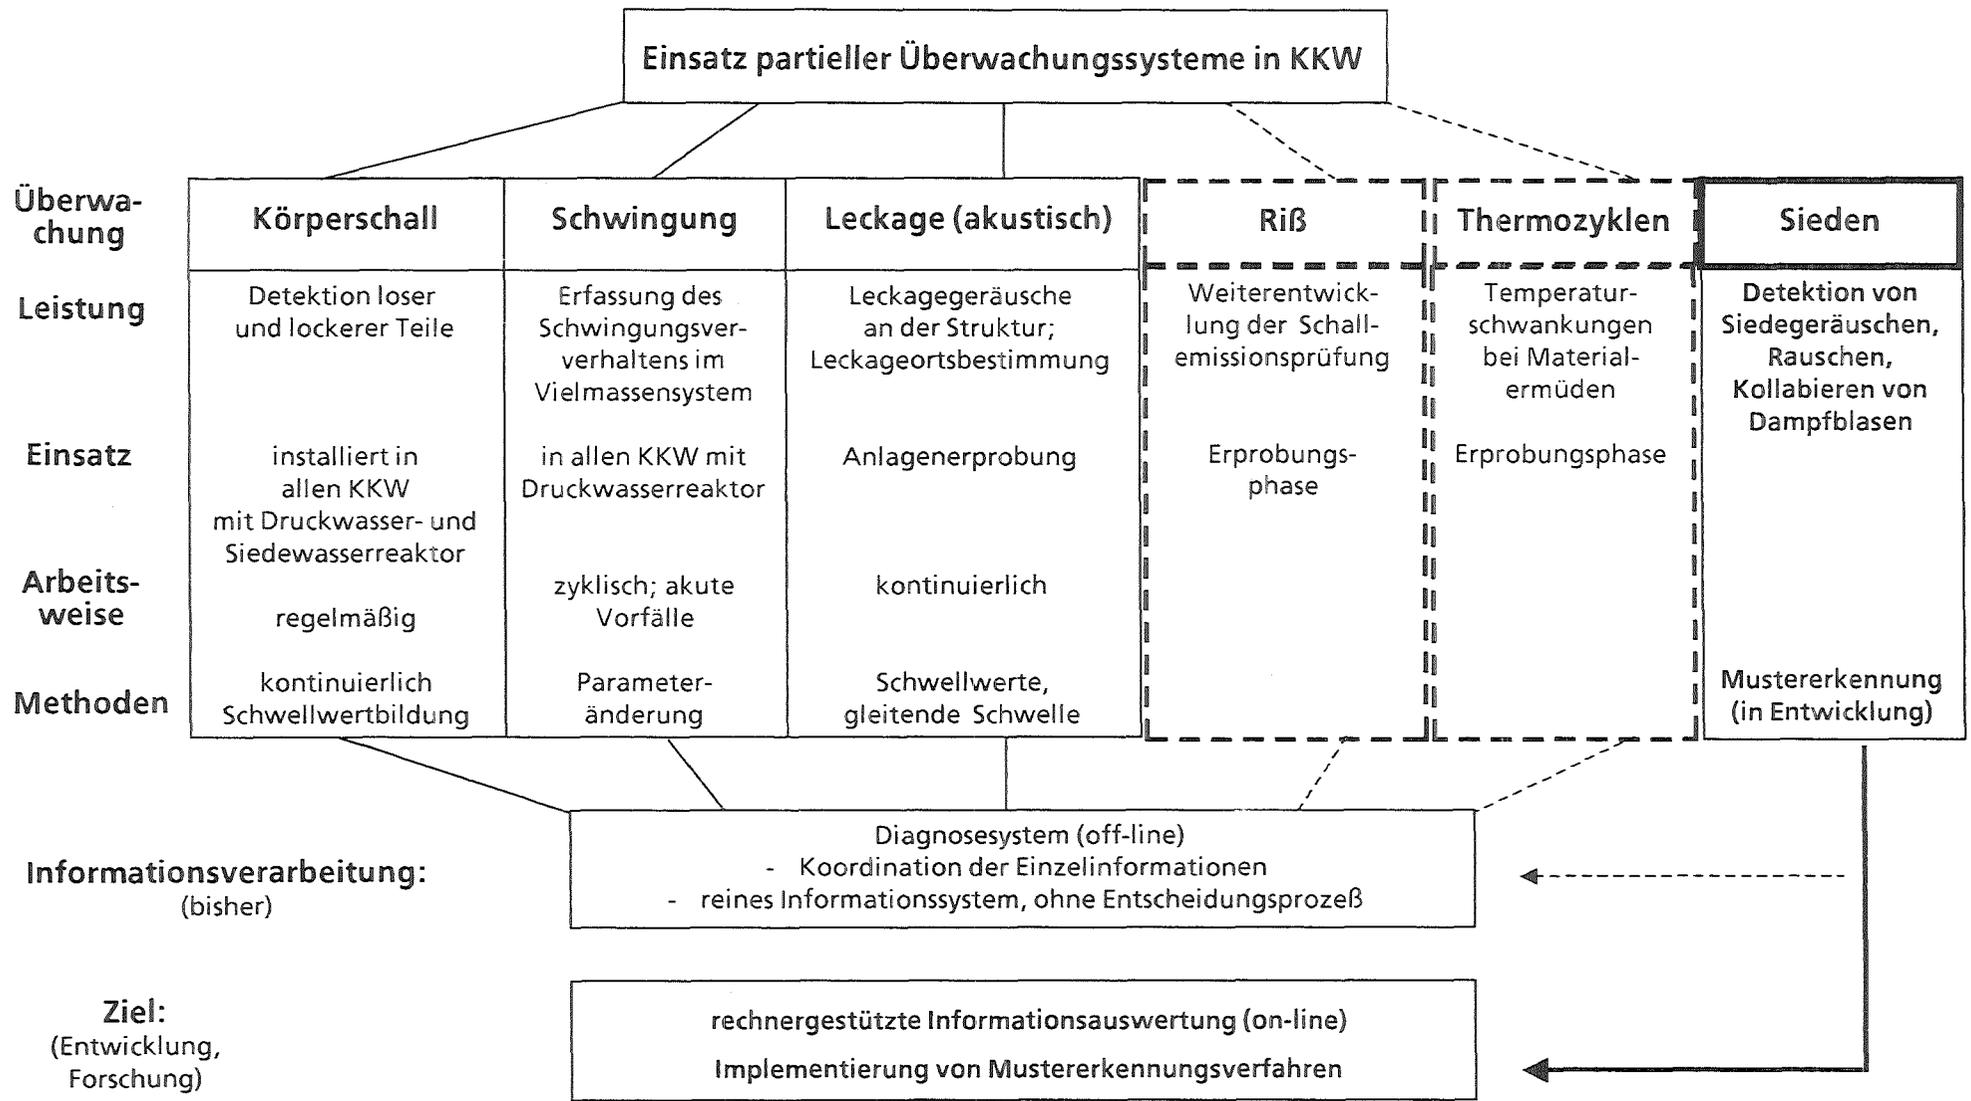


Abb. 1.0 : Einsatz partieller Überwachungssysteme

Kapitel 4 beschäftigt sich mit dem Problemkreis der ME - Modellierung und insbesondere mit der Merkmalsgenerierung.

In Kapitel 5 werden die Einsatzmöglichkeiten von Prognosemodellen und Trendanalyse zur frühzeitigen Schadensdetektion untersucht.

Nach der Entwicklung von Gütekriterien in Kapitel 6, welche einen großen Anteil an der Systemintelligenz haben in bezug auf optimale Entscheidungen, werden im Kapitel 7 Lernprozesse analysiert.

Im anschließenden Kapitel 8 wird nun ein geschlossenes Konzept zur Siededetektion dargestellt und eine on-line-Überwachung am Beispiel der vorhandenen KNS - Signale (KNS = Kompakte Natrium Siedeteststrecke) simuliert. Die Ergebnisse werden präsentiert in einem Leistungsvergleich zu einem herkömmlichen Schwellwertverfahren.

Unter dem Aspekt der anwendungsunabhängigen Verfahren der ME wird in Kapitel 9 ein Ausblick gegeben, wo diese Methoden und Verfahren außerhalb der Siededetektion eine sinnvolle Anwendung finden können. Insbesondere sind bei den theoretischen Untersuchungen in Kapitel 5 verschiedene Ausprägungen zulässig, die sich für den einen oder anderen Problemkreis in besonderer Art eignen. Es werden die anwendungstypischen und generellen Gesichtspunkte unterschieden.

Schließlich gibt Kapitel 10 eine Zusammenfassung der erzielten Ergebnisse an diesem speziellen Beispiel der Siededetektion .

2. Siededetektion: Stand und Ziele

Im Rahmen der Kühlmittelüberwachung für natriumgekühlte Schnelle Brutreaktoren (Liquid Metal Fast Breeder Reactor = LMFBR) werden vor allem in England, Frankreich und in der BRD Forschungsarbeiten angestrengt. Im Kernforschungszentrum Karlsruhe sind eine Menge von Experimenten durchgeführt worden, die unter anderem auch dazu dienen, Siedeprozesse zu analysieren. Die Verarbeitung der unter verschiedensten Versuchsbedingungen aufgenommenen Signale erfolgte im wesentlichen mit den klassischen Verarbeitungsmethoden und off-line. Die anschließende Beurteilung erfolgte dann durch visuelle Inspektion der Effektivwerte und der Spektren.

Bei gegenwärtigen Forschungsarbeiten zur Coreüberwachung Schneller Brutreaktoren denkt man an eine rechnergestützte Entscheidungsebene, deren Eingabe partielle Prozeßzustände sind, die mit moderneren Verfahren und Methoden der intelligenten Signalverarbeitung diagnostiziert werden. Eine Einbettung in ein mögliches Expertensystem ist bis Anfang der neunziger Jahre vorgesehen. Die Grundlagen für eine solch integrierte Gesamtlösung im Schnellen Brüter sind in einer EG - Studie (Teil I und Teil II) verankert / 19 /.

Bisherige Lösungsansätze (/32/) gingen davon aus, daß die akustische Signalübertragungsfunktion zumindest annähernd bestimmt werden kann, sodaß von Pumpen und sonstigen Reaktorbauteilen ausgehende akustische Störungen aus dem resultierenden Geräuschktrum entfernt werden können und anschließend eine Detektion von Siedezuständen möglich ist. Es erscheint ein schwieriges und vielleicht nicht mit Erfolg durchzuführendes Unterfangen, die Signalübertragungsfunktion und sämtliche möglicherweise auftretenden Geräusche exakt zu erfassen und entsprechend zu verarbeiten.

Bei den bisherigen Ansätzen (/32/) wird die Auswertung der Summenamplituden innerhalb eines vorgegebenen Zeitintervalls und die sogenannte Pulsratendetektion zur Ermittlung von Periodizität von auftretenden Ereignissen verwendet. Beide Funktionen sind in ihrer direkt vorliegenden Form nicht unmittelbar aussagekräftig zur signifikanten Geräuscherkennung.

Weitere Nachteile der bisher vorhandenen Systeme bei der Siededetektion sind anschließend aufgeführt.

Warn- und Abschaltinformationen basieren auf festen Schwellwertüberschreitungen.

Bei bisherigen Siedeexperimenten stellt man in ganz bestimmten Frequenzbändern Energieverschiebungen fest. Die Bandbreiten hängen jedoch von vielen (auch anlagenspezifischen) Parametern ab.

Im Prozeß sind keine Lern- und Trainingsphasen vorgesehen.

Die Analyse geschieht bei herkömmlichen Systemen inspektionsweise off - line mit visueller Auswertung.

Es existiert noch keine rechnergestützte Auswertung.

Es existieren keine hinreichenden Aussagen über typische Muster, die den Siedeprozess charakterisieren. Hinzu kommen Unsicherheiten im Entscheidungsprozeß.

Es liegen keine Erkennungsraten von kritischen Zuständen vor. Eine Aussage über die Leistungsfähigkeit von modernen ME - Verfahren gibt es noch nicht.

Es liegen keine Untersuchungen vor, welche Merkmale zur Siededetektion signifikant sind.

Ausgehend von den aufgezählten Schwachpunkten, die im wesentlichen auf der Signalverarbeitungsebene liegen, werden in verschiedenen Ländern (vor allem England / 11 / und Frankreich / 10 / , /31/) Forschungs- und Entwicklungsaktivitäten im Bereich moderner ME - Methoden beobachtet. Hauptschwerpunkte liegen auf dem Gebiet der Merkmalsgenerierung und der Entscheidungsprozesse im Hinblick auf ein frühzeitiges Erkennen der kritischen Phase und sichere Entscheidungen, sodaß ein Propagieren der gefährlichen Prozeßzustände verhindert werden kann. Insbesondere tut man sich schwer mit der Akquisition guter Merkmale, die den Prozeß in seinen verschiedenen Phasen charakterisieren. Oft ist man auf eine heuristische Vorgehensweise angewiesen. Anhand von Erfahrungen kann man zwar bestimmte Verfahren und Modelle als günstig einstufen, aber letzten Endes kommt es auf die reale Signalumgebung an. Daraus ergibt sich ein Anforderungsprofil an ein mögliches ME - System, was in folgender Abb. 2.1 dargestellt ist.

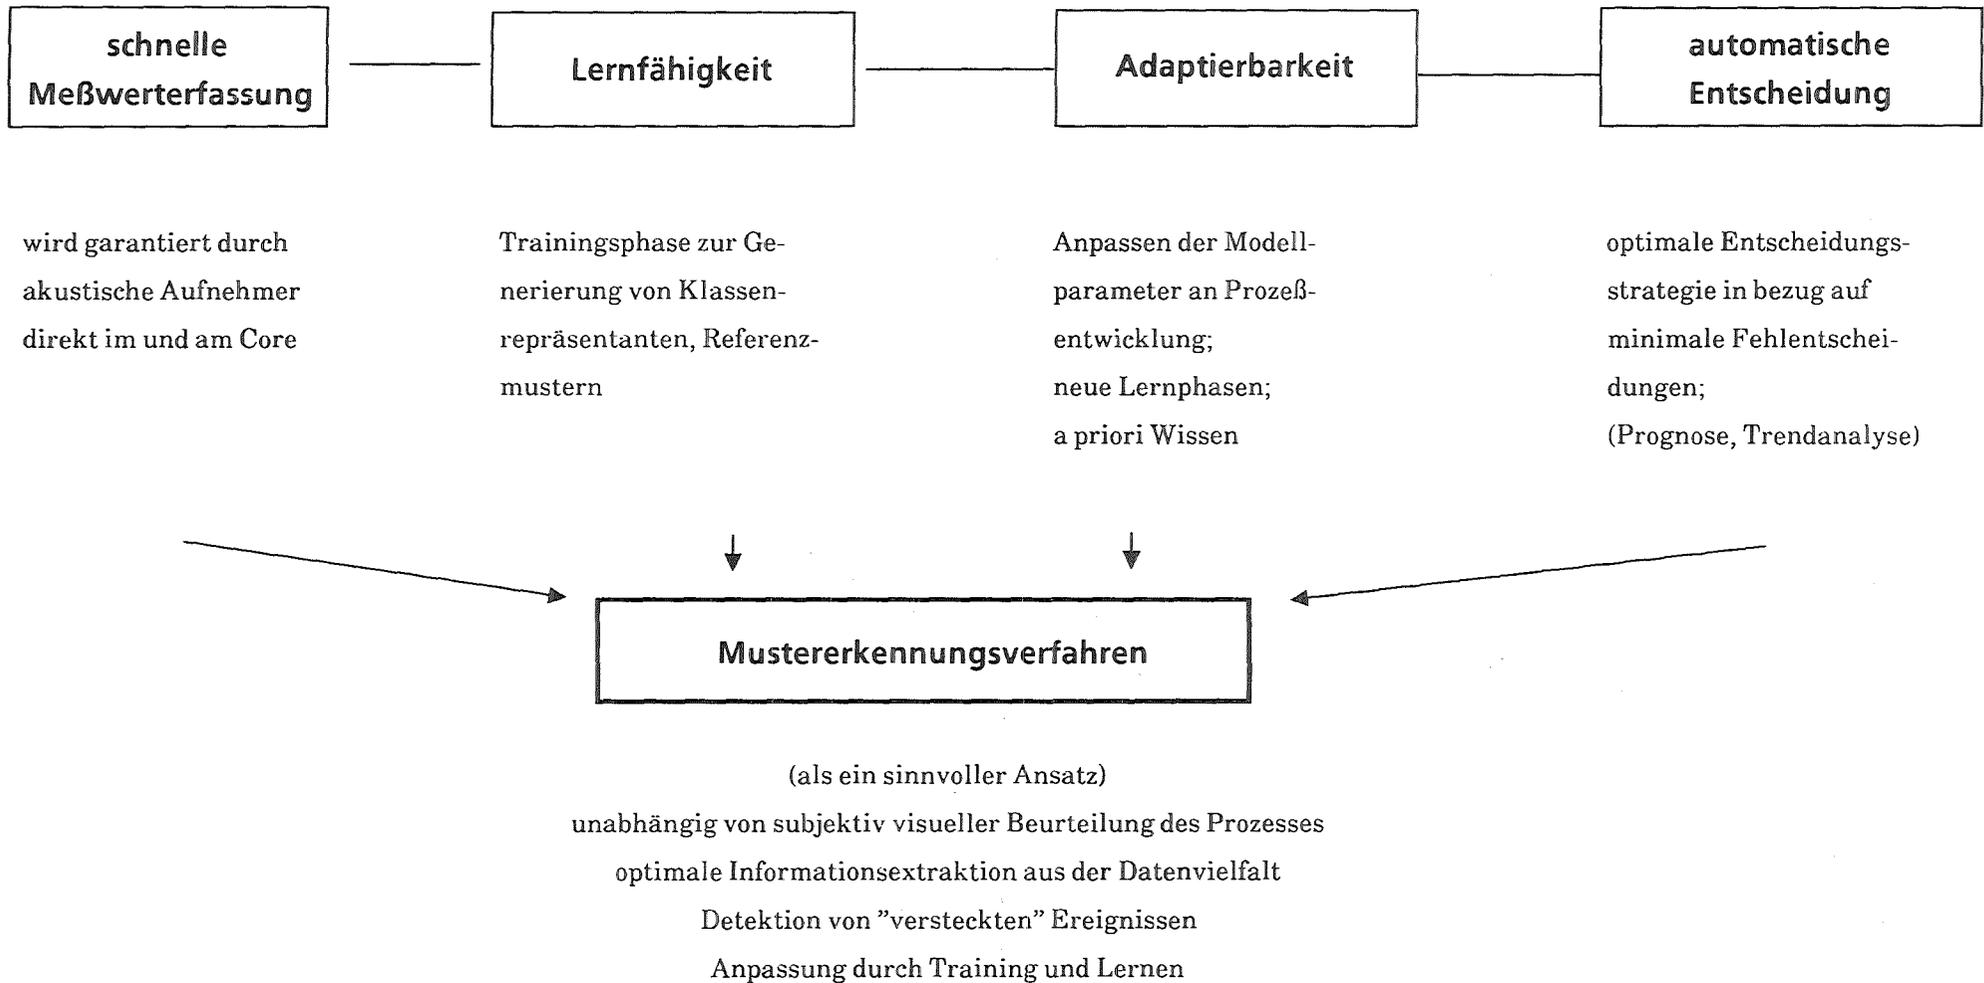


Abb. 2.1: Anforderungsprofil

Das Ziel einer intelligenten rechnergestützten Entscheidungsfindung auf der Signalverarbeitungsebene muß ein lernfähiges System sein, welches das vom Menschen eingebrachte Wissen in optimaler Weise nutzt, um die während der Prozeßüberwachung anfallenden Zustände zu verarbeiten und einer automatischen Entscheidungsstufe zugänglich zu machen.

Wie bereits festgestellt, bedeutet die Einführung von festen Schwellwerten eine Einschränkung für die Güte der Entscheidungen. Zum einen sind die Signale von Reaktor zu Reaktor verschieden. Die Anlagenumgebung beeinflußt die Rauschkomponenten. Weiterhin hat sich durch viele Experimente gezeigt, daß auch von Sensor zu Sensor die Signal / Rausch -Verhältnisse total verschieden sein können. Dies wird bedingt durch verschiedene Sensortypen, wie auch unterschiedliche Sensorpositionen, sodaß Reflexionen und Dämpfungen aufgrund des Schallweges zu Verfälschungen führen. Ein Entscheidungssystem auf der Signalverarbeitungsebene kann sich also nur auf einen Reaktor und einen Sensor an einer bestimmten Position beziehen.

3. Experimenteller Hintergrund:

Schnelle Brutreaktoren benutzen als Kühlmittel flüssiges Natrium, welches unter Systemdruck bei etwa 1000 Grad Celsius siedet. Sieden des Natriums kann das Versagen der Brennstabhüllen zur Folge haben und erhebliche Schadensausbreitungen im betroffenen Brennelement nach sich ziehen, die es durch eine Früherkennung zu verhindern gilt. Betrachtet man den Siedeprozess im Detail, so kann man zwischen lokalem und integralem Sieden unterscheiden. Lokales Sieden kann als Folge von lokalen Kühlungsstörungen hervorgerufen durch Blockaden im Brennstabbündel entstehen. Von integralem Sieden spricht man, wenn aufgrund einer drastischen Verminderung des Kühlmitteldurchsatzes - z.B. infolge eines Pumpenausfalles - über den gesamten Brennelementquerschnitt das Natrium zum Sieden kommt.

Die Siedegeräusche selbst resultieren hauptsächlich aus dem Kollabieren der Dampfbläschen /20/. Da zum einen die Kollabierungsgeschwindigkeiten abhängig sind von der unbekanntem Temperaturverteilung im Umgebungsmedium, zum anderen die Geometrie der Brennelemente und der Coreumgebung ein sehr komplexes Gebilde darstellt, scheint eine Schallanalyse auf einem theoretischen modellhaften Wege aussichtslos. Außerdem verfälschen Reflexionen, Dämpfung und Überlappung die ursprünglichen Schalldruckwellen. Die Dämpfung im Zwei-Phasen-Zustand ist nichtlinear und frequenzabhängig.

Die komplexe Geometrie einer Coreumgebung ist in Abb. 3.1. dargestellt.

Innerhalb der letzten Jahre wurden zahlreiche Siedeeperimente durchgeführt. Im Hinblick auf verschiedene Zielrichtungen wurden unterschiedliche Fehlzustände simuliert, die Sieden zur Folge hatten. Lokale Kühlungsstörungen wurden durch den Einbau von Blockaden im Heizstabbündel erzeugt, integrales Sieden wurde durch Abschalten des Natriumdurchsatzes bei weiterhin konstanter Heizleistung eingeleitet.

Die Siedegeräusche, die der Signalauswertung in dieser Arbeit zugrunde liegen, entstammen dem MOL 7c Experiment, welches am belgischen Reaktor BR2 stattfand und einer Versuchsreihe an der Kompakten Natrium Siedeteststrecke (KNS), die vom IRE im Kernforschungszentrum durchgeführt wurde. Sieden wurde durch Absenken des Systemdruckes eingeleitet bzw. intensiviert. Die KNS - Teststrecke hatte ein Bündel mit 169 Stäben. 88 davon waren elektrisch beheizt. Das Bündel war mit einer Zentralblockade versehen.

Der Aufbau der KNS - Teststrecke ist in Abb. 3.2 dargestellt. Die Akustik hat gegenüber anderen Meßaufnehmersystemen (z.B. Temperatur) folgende wichtige Vorteile:

1. Die Schallanalyse erfolgt rein meßtechnisch schnell und ohne wesentliche Verzögerung
2. Es ist nicht für jedes Brennelement ein Sensor erforderlich, sondern es genügen einige im Natrium- Plenum verteilte Sensoren, um den Schall integral zu erfassen.

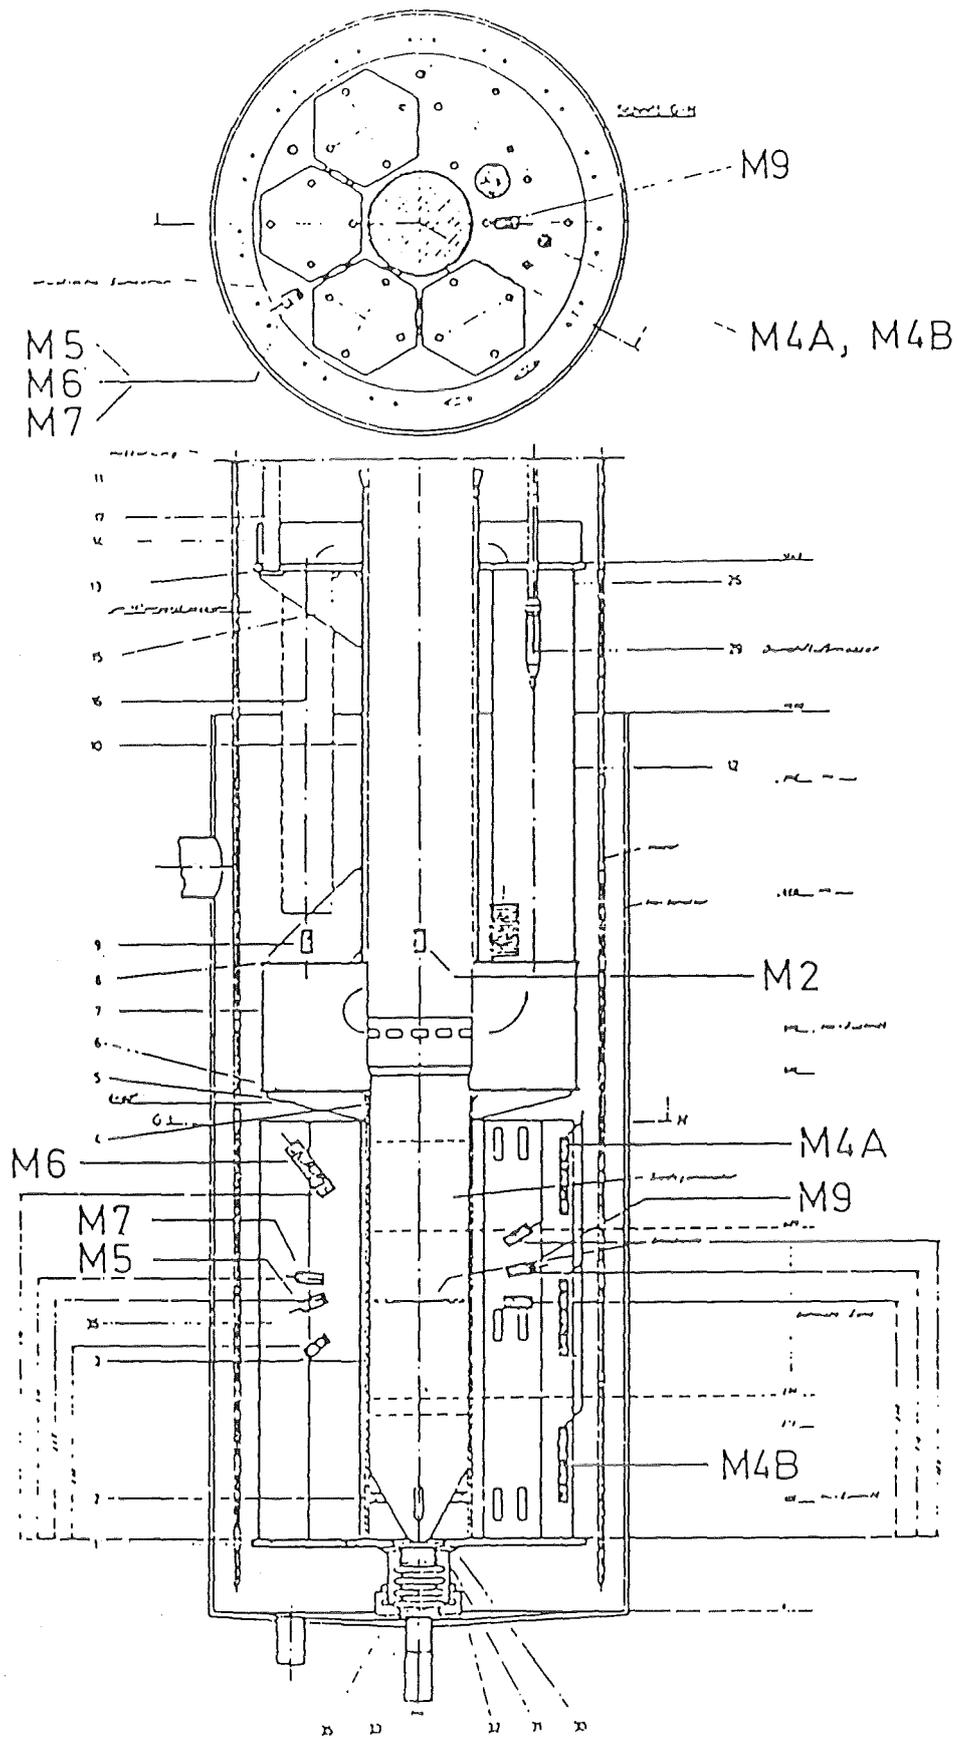


Abb. 3.1 Komplexe Coregeometrie

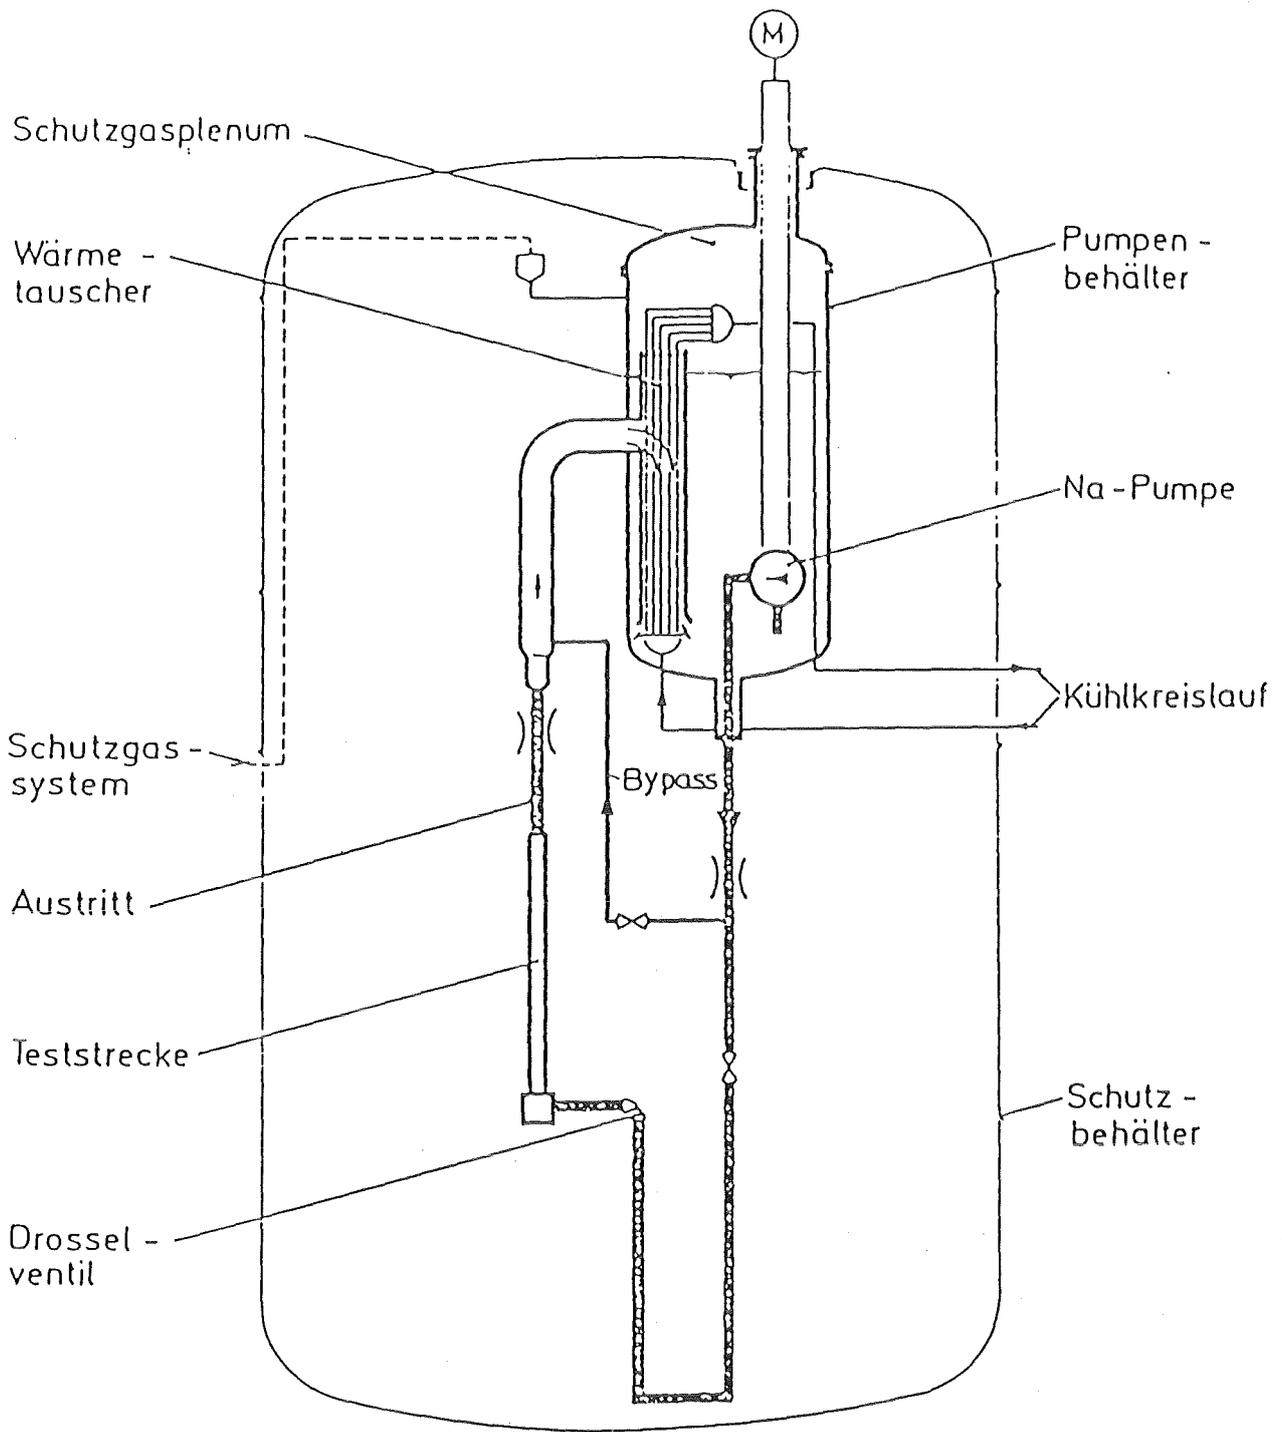
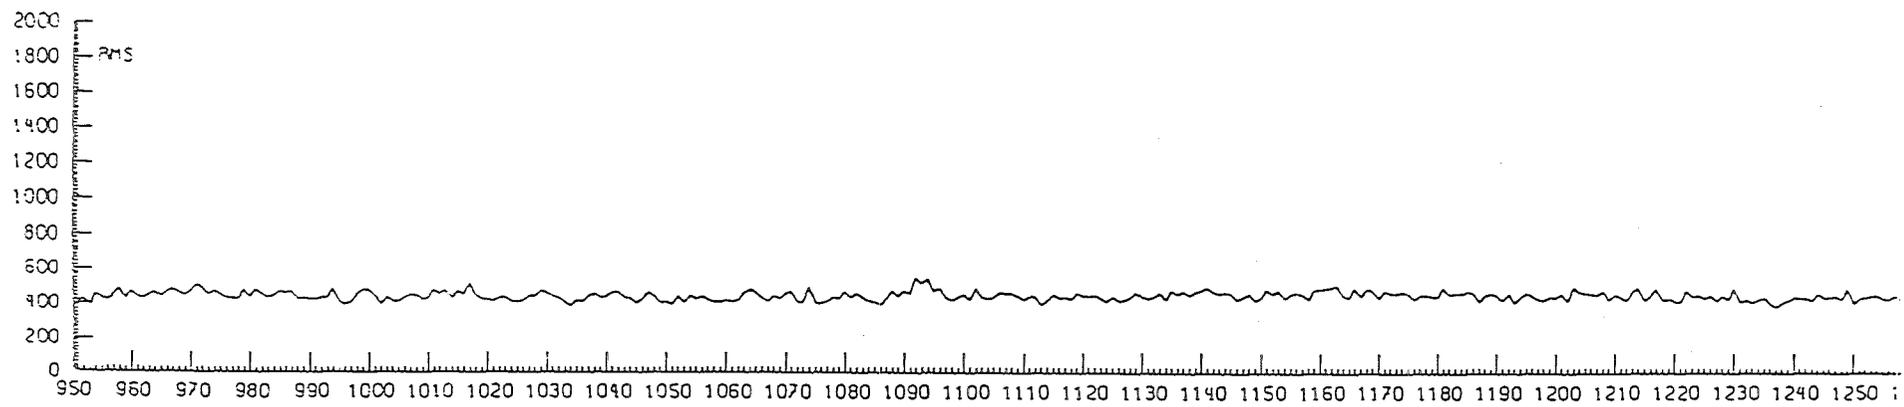


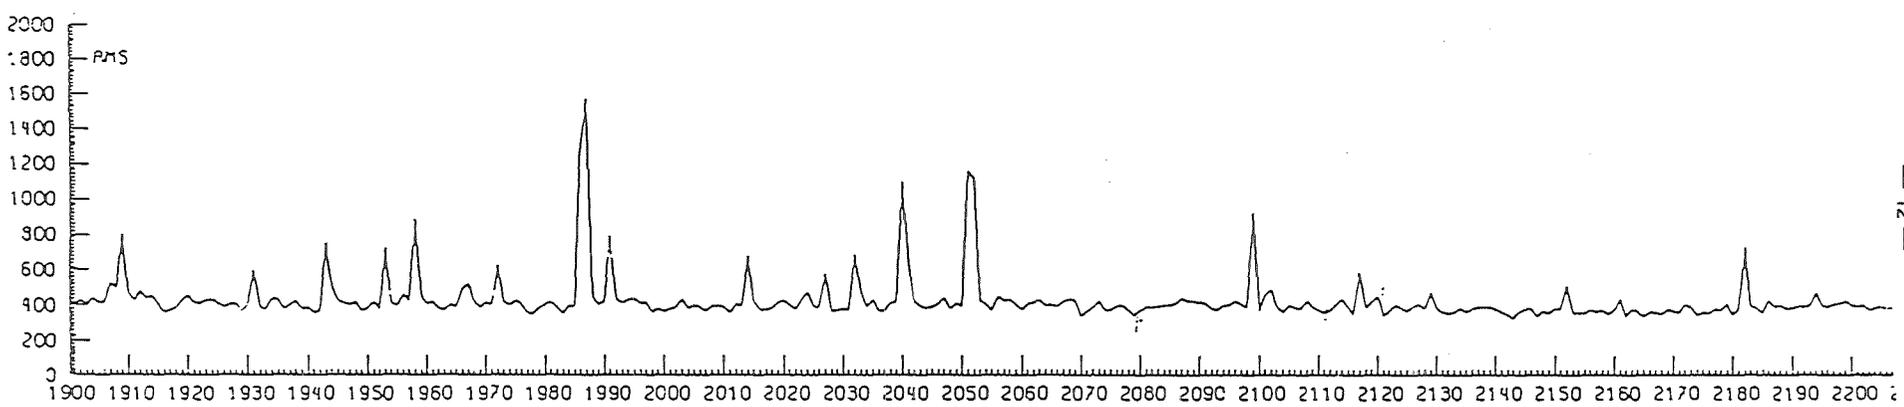
Abb. 3.2 Kompakte-Natrium-Siedestrecke

Zur Signalauswertung liegen von drei KNS-Signalen jeweils Ausschnitte von 10 sec vor. In diesen 10 sec sind die einzelnen Zustände (Nichtsieden- Siedebeginn-intensiviertes Sieden) exemplarisch vorhanden. Alle Signale liegen digitalisiert mit einer Abtastfrequenz von 200 kHz vor. Die Struktur der Daten ist blockweise gegeben. Ein Block entspricht 5120 Abtastwerten (25.6 msec). Die zeitliche Verarbeitung bezieht sich im folgenden stets auf Blocknummern. In diesen drei Signalen ist das gleiche Nutzsignal vorhanden, sie unterscheiden sich lediglich durch Überlagerungen mit verschieden starkem Untergrundrauschen. Somit kann man die Effizienz der ME - Verfahren auch bei stark verrauschten Signalen analysieren. In den Abbildungen 3.3, 3.4 und 3.5 sind die drei Siedesignale dargestellt mit 0 db in Abb. 3.3, -11 db in Abb. 3.4 und -14 db in Abb. 3.5. Über die Gesamtzeit von 10 sec sind die RMS (Root-Mean-Square)-Werte in drei Zeitausschnitten aufgetragen.

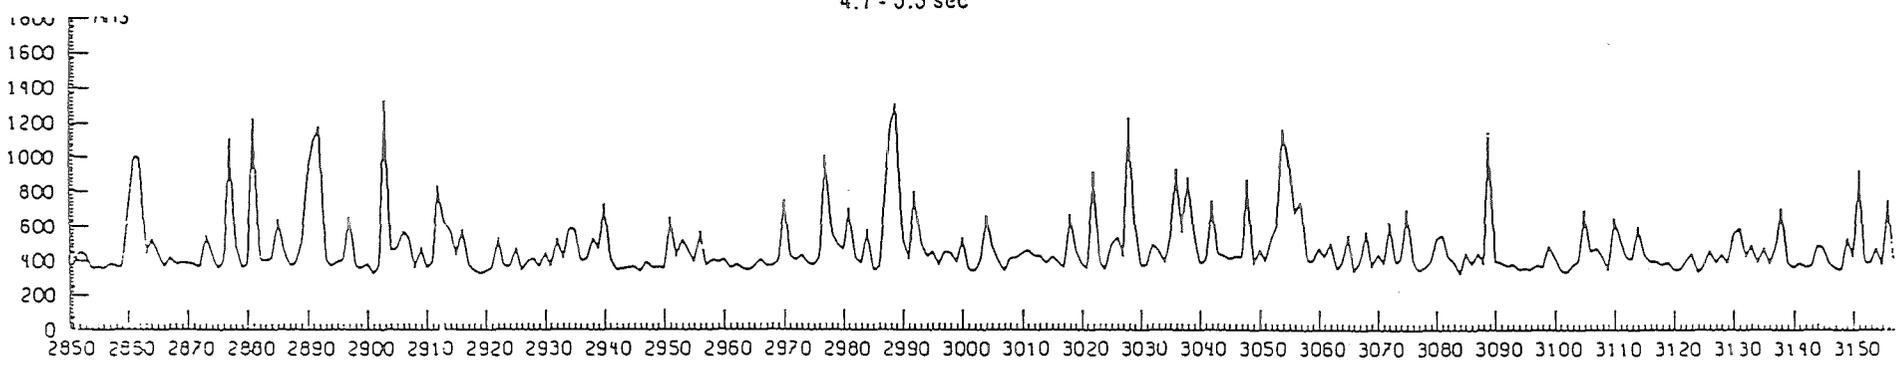
obere Zeile:	2.4 - 3.2 sec	(Nichtsieden)
mittlere Zeile:	4.7 - 5.5 sec	(Siedebeginn)
untere Zeile:	7.1 - 7.9 sec	(intensives Sieden)



2.4 - 3.2 sec

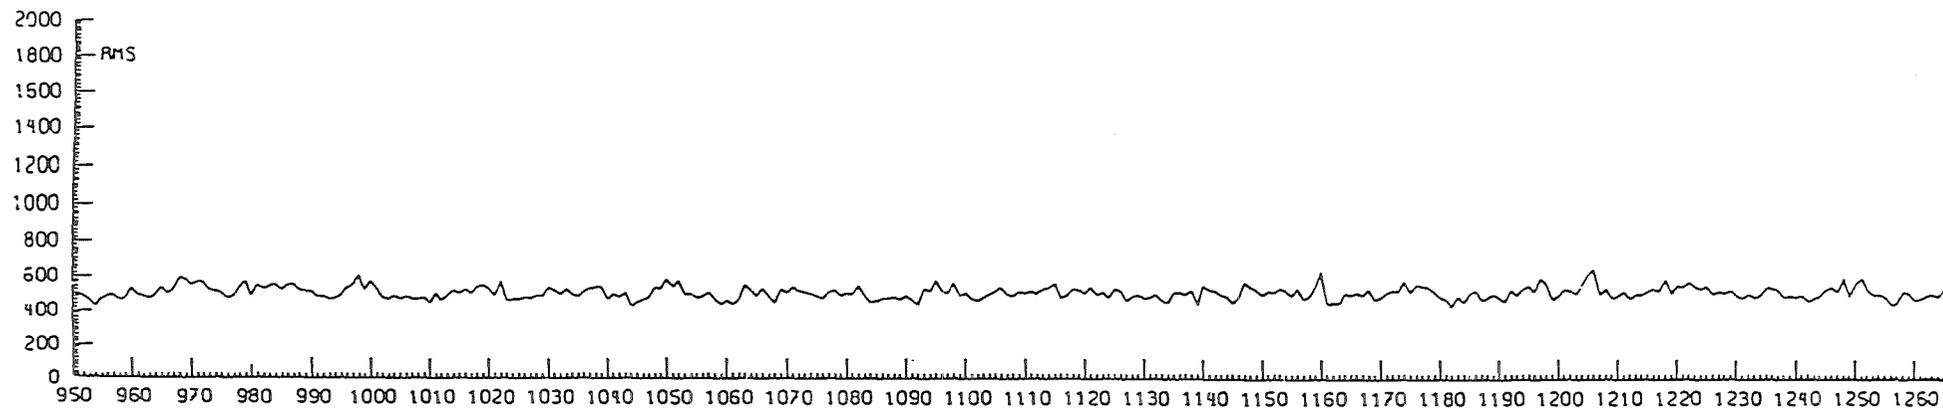


4.7 - 5.5 sec

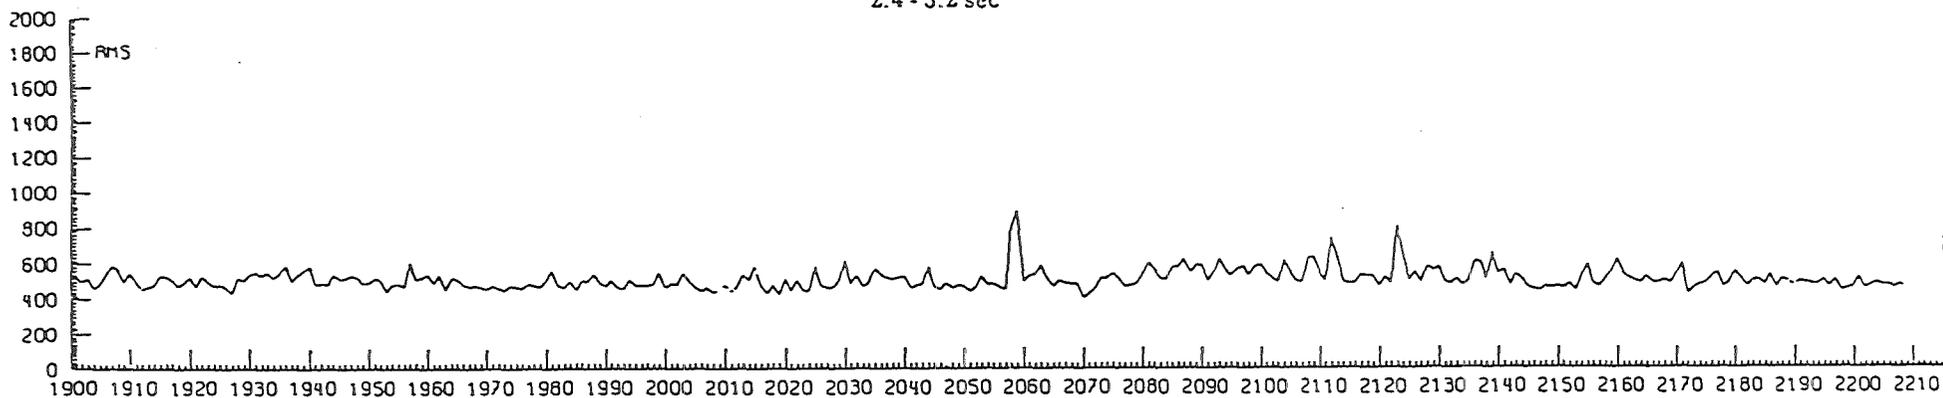


7.1 - 7.9 sec

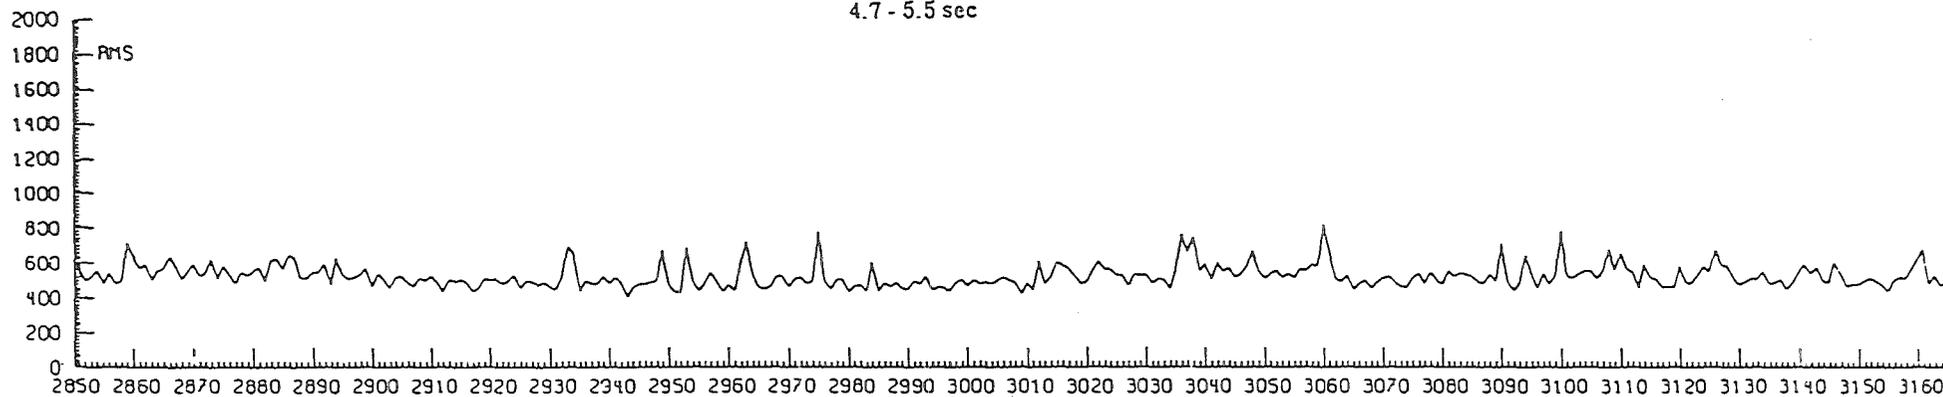
Abb. 3.3 RMS Signal Extrakt; 0 db



2.4 - 3.2 sec



4.7 - 5.5 sec



7.1 - 7.9 sec

Abb. 3.4 RMS Signal Extrakt; -11 db

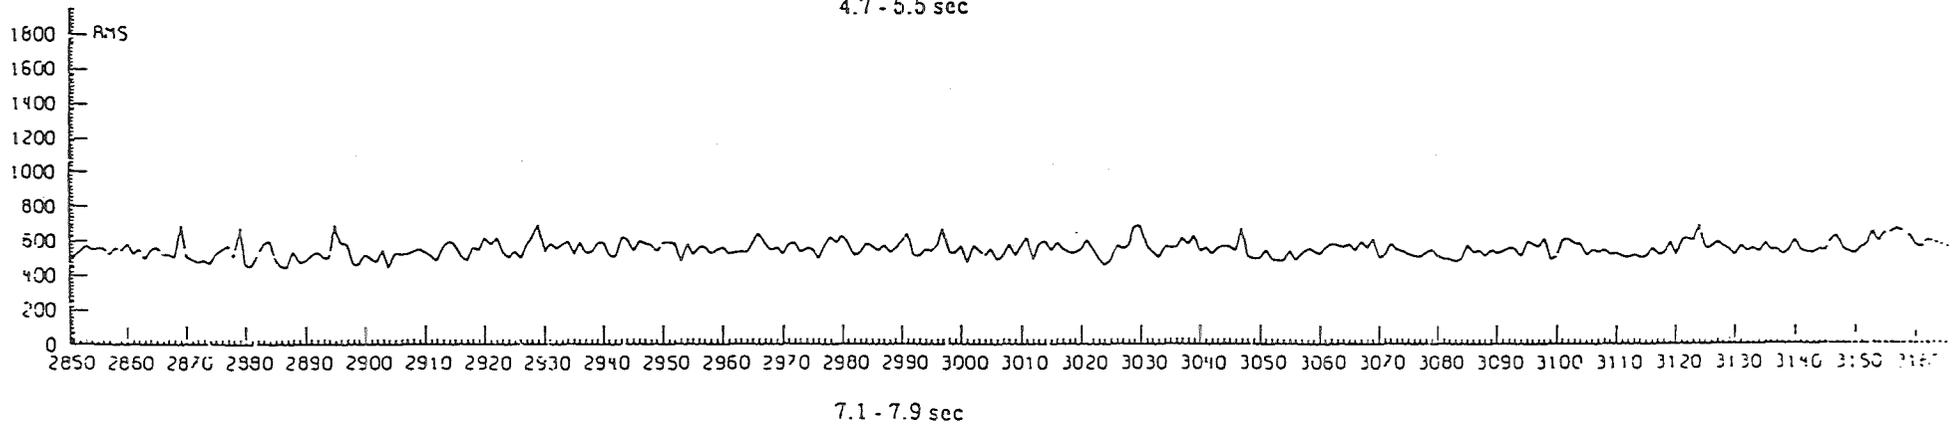
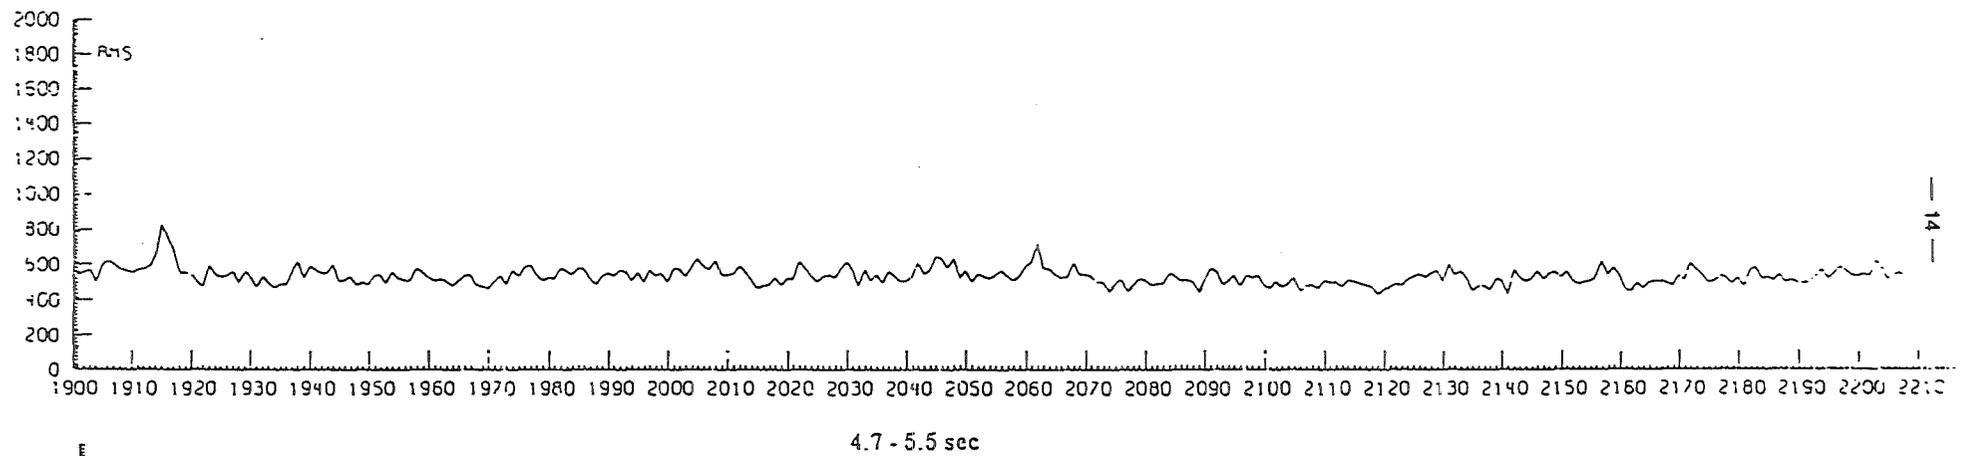
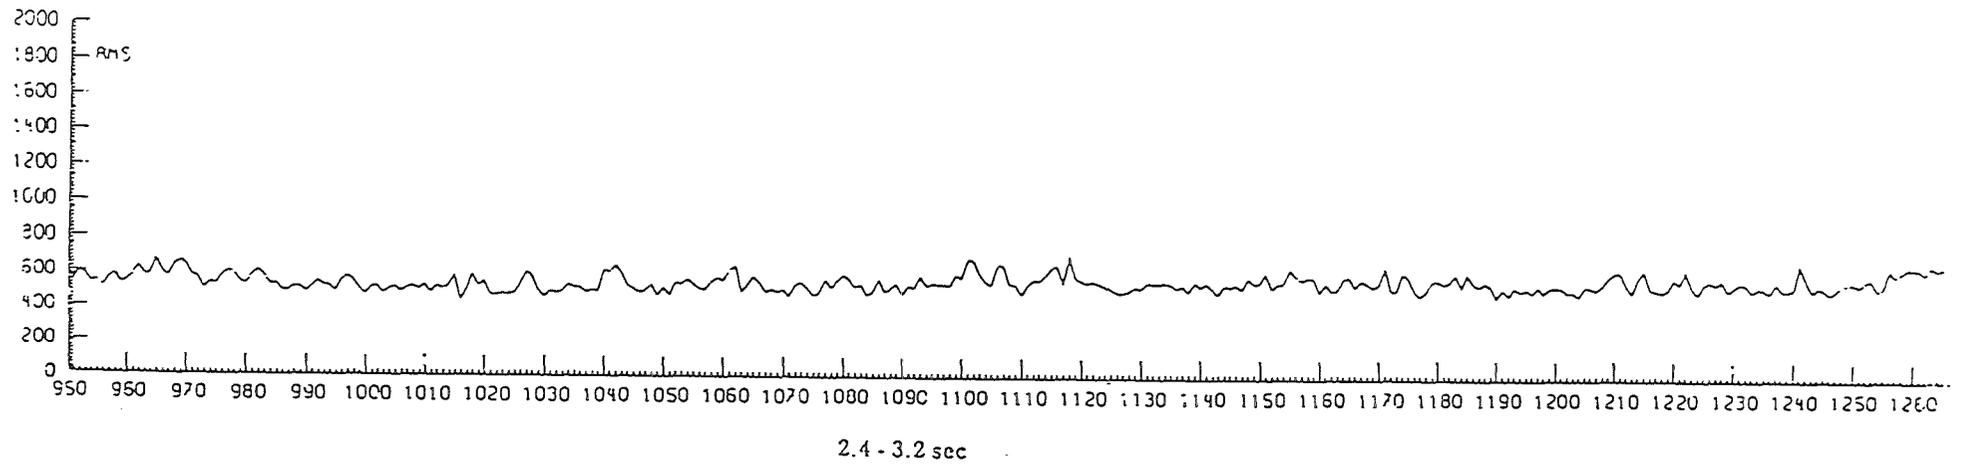


Abb. 3.5 RMS Signal Extrakt; -14 db

4. Mustererkennung: Konzept und Modellbildung

4.1 Allgemeiner Aufbau eines Klassifikatorsystems

In diesem Kapitel werden die Grobstrukturen eines Mustererkennungssystems aufgeführt, wie sie auch im folgenden Anwendung finden. Im wesentlichen handelt es sich um die Komponenten

Datenakquisition

Merkmalsgenerierung

Klassifikation

Als Ausgangsbasis für alle weiteren Berechnungen im ME - System dienen die digitalisierten Druckamplituden des zu überwachenden Signals. Nach verschiedenen Vorverarbeitungsschritten und einer Transformation in den Frequenzbereich stehen diese Rohdaten sowohl im Zeit- als auch im Frequenzbereich zur eigentlichen Merkmalsgewinnung zur Verfügung. Ein Datensatz solcher Rohdaten wird als ein Muster (Zeitausschnitt) bezeichnet, welches den Prozeß zu dieser Zeit repräsentiert.

Beim zweiten Problemkreis, der Merkmalsgenerierung, kommt es darauf an, aus dem beobachteten Prozeß typische Muster, d.h. charakteristische Merkmale für die einzelnen Klassenzustände zu gewinnen, sodaß eine Trennung der einzelnen Klassen möglichst gut vollzogen werden kann und die Zuordnung von neuen beobachteten Mustern in eine der vorhandenen Klassen eindeutig geschieht.

Eine Klasse ist die Zusammenfassung aller vorkommenden Muster, die syntaktisch dasselbe bedeuten. In unserem Anwendungsfall wird es darauf ankommen, die unbekanntes Muster in dem zu überwachenden Signal richtig zu klassifizieren und somit sich anbahnende gefährliche Zustände schon im Ansatz zu erkennen. Es gilt also einmal, einen dem Problemkreis angemessenen Klassifikator zu benutzen. Es gibt eine Fülle von Klassifikatoren, die je nach Einsatzgebiet (z. B. a priori Wissen um die zu klassifizierenden Zustände) mehr oder weniger geeignet sind. (numerische: darunter statistische, verteilungsfreie, nichtparametrische, und nichtnumerische) / 17/. Da die akustischen Signale alle in Form eindimensionaler stochastischer Signale vorliegen, scheint ein numerisches Klassifikatormodell sinnvoll zu sein. In dieser Arbeit wird im folgenden stets ein Abstandsklassifikator benutzt, der auf dem Mahalanobisabstand basiert.

Der grobe Ablauf eines ME - Systems sieht vor, daß in einer 1. Phase (Training, Lernphase) vorab Prototypen von typischen Klassen erzeugt werden, gegen die in einem späteren realen Prozeß die berechneten Muster referiert werden.

Abb. 4.1 zeigt die Grobstruktur eines Klassifikatormodells.

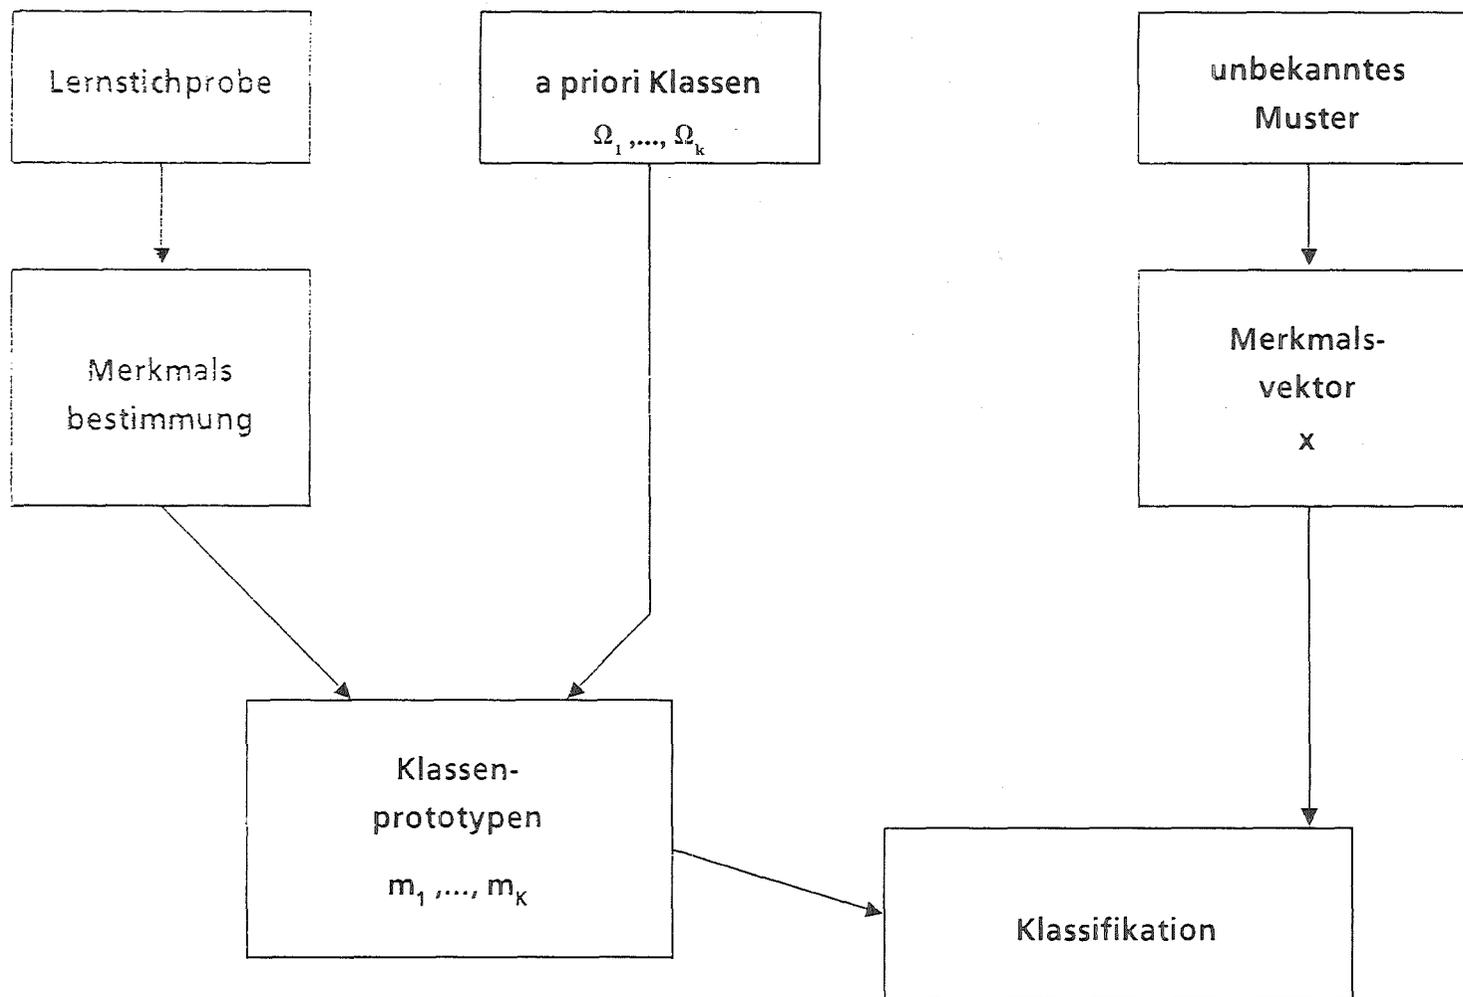


Abb. 4.1: Klassifikatormodell

4.2 Merkmalsgewinnung und -darstellung im Merkmalsraum

Die Merkmalsgenerierung und -auswahl ist maßgeblich an der Güte des Klassifikationsergebnisses beteiligt. Ob die gefundenen Merkmale geeignet gewählt sind, läßt sich oft nur heuristisch begründen bzw. am Ergebnis feststellen.

In einem Prozeßausschnitt werden die Merkmale eines Musters in Form skalarer Größen bestimmt. Jedes Muster ist gerade durch seine Merkmale charakterisiert. Die n skalaren Merkmale x_1, \dots, x_n werden zu einem Merkmalsvektor \mathbf{x} zusammengefaßt. Für ein festes Muster ist \mathbf{x} ein Punkt im n -dimensionalen Merkmalsraum. Für jedes zu erkennende Muster wird der Merkmalsvektor berechnet. Diese Merkmalsvektoren bilden Cluster im Merkmalsraum. Man erwartet statistisch eine Clusterstruktur, in welcher Merkmalsvektoren von Mustern einer Klasse sich um einen Häufungspunkt gruppieren. Dieser Punkt ist der Erwartungswert für ein Muster dieser Klasse. Große Abstände der Clustermittelpunkte und geringe Streuung innerhalb der Cluster erleichtern die Klassifikation. Diese Kriterien werden im Kapitel 6 wichtig bei der Einführung von Bewertungsmaßen zur Güteberechnung.

Sei M die Anzahl aller vorhandenen Muster. Sei $\mathbf{x}_1, \dots, \mathbf{x}_M$ der dazugehörige Merkmalsatz. Jedes Muster ist repräsentiert durch einen diskreten Punkt im Merkmalsraum \mathbb{R}^n .

Seien $\Omega_1, \dots, \Omega_K$ die a priori vorgegebenen Klassen ($K < M$). Ein unbekanntes Muster, nach seiner Merkmalsberechnung ein Punkt im n -dimensionalen Merkmalsraum, soll nun seiner Klasse richtig zugeordnet werden. Alle existierenden Muster einer beliebigen festen Klasse sind zufälligen Schwankungen unterworfen. Somit wird \mathbf{x} als reelle Zufallsvariable im \mathbb{R}^n aufgefaßt. Mittelwerte und Streuungen sind wichtige Maße dafür, wie die Muster innerhalb einer Klasse verteilt sind.

Notation: Für die Klasse Ω_i sei

\mathbf{m}_i der Erwartungswert $E\{\mathbf{x}\}$ der Zufallsvariablen \mathbf{x}

\mathbf{K}_i die Kovarianzmatrix $E\{(\mathbf{x} - \mathbf{m}_i)(\mathbf{x} - \mathbf{m}_i)^T\}$ mit $\mathbf{x} \in \Omega_i$

Mit $i \in \{1, \dots, K\}$ erhalten wir für \mathbf{m}_i und \mathbf{K}_i einen Schätzwert gemäß :

$$\tilde{\mathbf{m}}_i = \sum_{\Omega_i} \mathbf{x} / N_i \quad (4.2.1)$$

$$\tilde{\mathbf{K}}_i = \sum_{\Omega_i} (\mathbf{x} - \tilde{\mathbf{m}}_i) (\mathbf{x} - \tilde{\mathbf{m}}_i)^T / N_i \quad (4.2.2)$$

\mathbf{x} bezeichne stets einen Spaltenvektor, \mathbf{x}^T den transponierten Zeilenvektor.

N_i bezeichnet die Anzahl der Elemente in der Klasse Ω_i .

Der Mahalanobisabstand d eines Vektors \mathbf{x} zum Vektor $\tilde{\mathbf{m}}_i$ ist $d = (\mathbf{x} - \tilde{\mathbf{m}}_i)^T \tilde{\mathbf{K}}_i^{-1} (\mathbf{x} - \tilde{\mathbf{m}}_i)$

Da es sich um stochastische Signale handelt, scheint eine Menge von statistischen Parametern, welche den Prozeßzustand beschreiben, als Merkmale geeignet. Da oft eine Darstellungsform der Signale im Zeit- und Frequenzbereich benötigt wird, soll zunächst über eine Fast - Fourier - Transformation eine Darstellungsform für zeitlich begrenzte diskrete Signale gefunden werden.

Die Darstellung einer Funktion über ihr Fourierspektrum liefert nützliche Information über die Verteilung der Frequenzanteile. Da das Signal aber nicht in kontinuierlicher Form, sondern in digitalisierten diskreten Werten vorliegt, benötigt man eine Darstellung der Fouriertransformierten für Abtastsignale.

Wir betrachten zur kontinuierlichen Funktion $h(t)$ die Funktion

$$\hat{h}(t) = \sum_{n=-\infty}^{+\infty} h(nT) \delta(t - nT) \quad (4.2.3)$$

Hierbei ist T die Abtastperiode und δ die diskrete Deltafunktion mit $\delta(t - nT) = 1$ für $t = nT$ und 0 sonst.

Diese Funktion \hat{h} ist eine Überlagerung von unendlich vielen Deltafunktionen, die an den Stellen $t = nT$ mit $h(nT)$ gewichtet werden und an diesen Stellen mit der Funktion $h(t)$ übereinstimmen.

Zwischen diesen Stützstellen ist $\hat{h} = 0$.

Es gilt: $\hat{h}(nT) = h(nT)$ für alle ganzen Zahlen n
 $\hat{h}(t) = 0$ sonst

Es ist nun die Fouriertransformierte von \hat{h} zu berechnen.

Die reelle Zeitachse sei diskretisiert in die Stützstellen $t = 0, 1, \dots$

Dem endlichen Zeitintervall $[t - T, t]$ entspreche im diskreten Fall das Intervall $[j - N, j - 1]$ mit den N Stützstellen $j - N, j - N + 1, \dots, j - 1$. Hierbei sind j und N fest ($N < j$).

Auf dem Intervall $[j - N, j - 1]$ sei die diskrete Funktion \hat{h}_j definiert durch

$$\hat{h}_j(n) := \hat{h}(j - N + n) \text{ für } n = 0, \dots, N - 1 \text{ und } j = N, 2N, \dots$$

Dann lautet die zu Gl. 4.2.3 diskrete FFT:

$$H(f, j) = \sum_{n=0}^{N-1} \hat{h}(n) w(j-n) e^{-2\pi i k n / N} = \sum_{n=0}^{N-1} \hat{h}_j(n) e^{-2\pi i k n / N} \quad (4.2.4)$$

mit $f = k / NT$, $k = 0, 1, \dots, N - 1$ und w als Rechteck-Fensterfunktion.

$H(f, j)$ ist charakterisiert durch das Verhalten der Funktion \hat{h} im diskreten Zeitintervall $[j - N, j - 1]$. Für alle interessierenden f und alle j ist $H(f, j)$ eine endliche komplexwertige Größe.

$$H(f, j) = \operatorname{Re}(H(f, j)) + i \cdot \operatorname{Im}(H(f, j)) \quad (4.2.5)$$

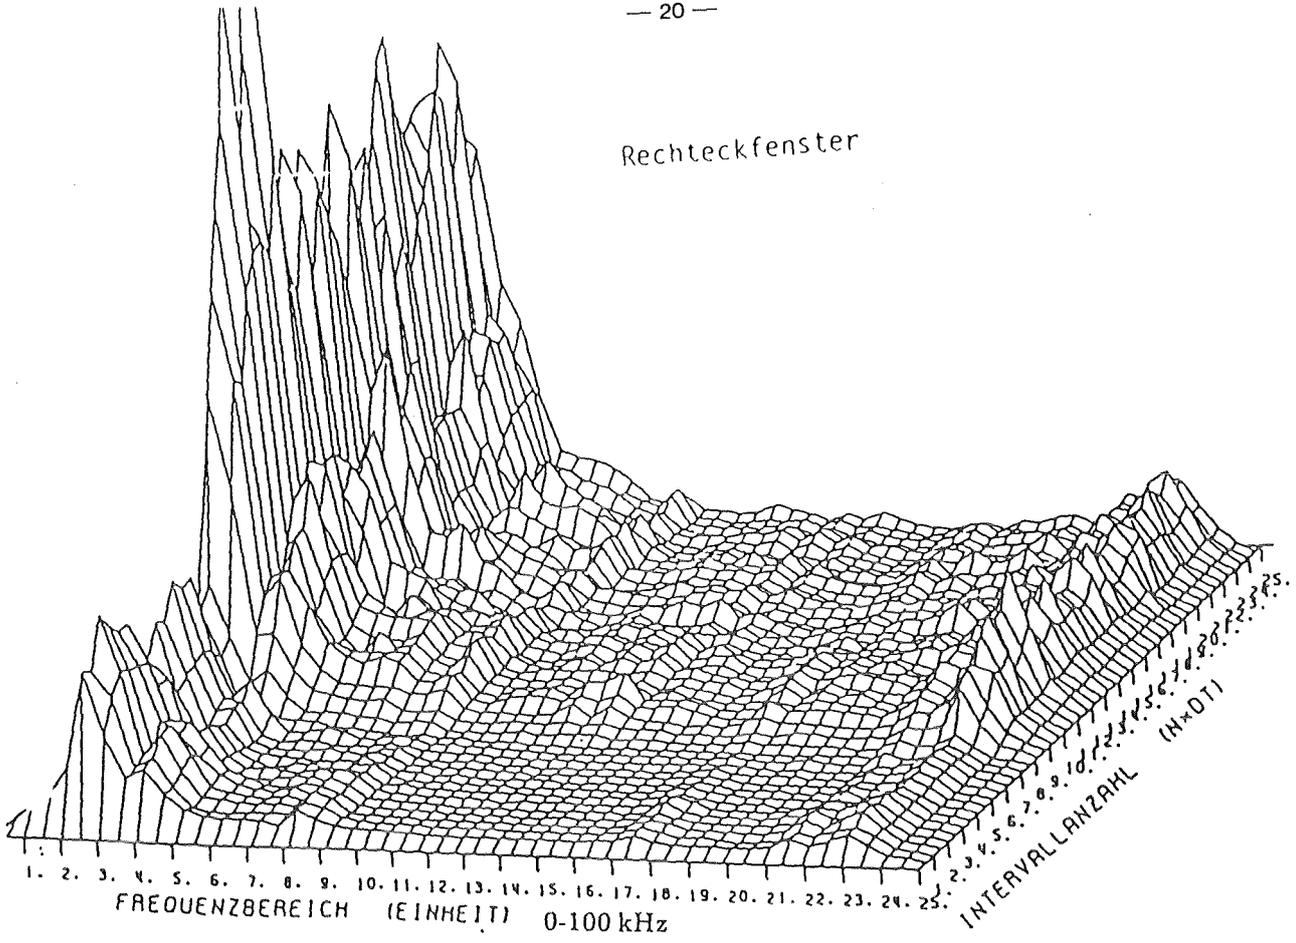
Information über die Leistungsdichte in den einzelnen Frequenzbändern zu einem Zeitpunkt liefert der Betrag der Größe H :

$$|H|^2 = \operatorname{Re}^2(H) + \operatorname{Im}^2(H) \quad (4.2.6)$$

Berechnet man sequentiell für aufeinanderfolgende Zeitintervalle jeweils das Leistungsdichtespektrum und stellt die Leistungsdichten auf der Zeitachse hintereinander dar, so erhält man ein Kurzzeitspektrum. Mustererkennungsaufgaben kommen allgemein dort zum Einsatz, wo große Datenmengen in ihrer Struktur untersucht werden müssen. Dies bedeutet, daß die Darstellungsform und die Möglichkeit der Datenreduktion z.B. in Form einer Merkmalsreduktion wichtige Komponenten sind. Im Kurzzeitspektrum kann man die zeitabhängige Frequenzverteilung über die einzelnen Frequenzbänder deutlich ablesen.

Das Kurzzeitspektrum in Abb. 4.2 zeigt eine zweidimensionale Darstellung der Leistungsdichten. Die Höhe des Gebirges gibt den Betrag in einem Zeitintervall ΔT für ein Frequenzband an. Es sind zwei geglättete Kurzzeitspektren ein und desselben Siedesignals dargestellt, einmal mit einem Hanningfenster und einmal mit einer Rechteckfunktion gewichtet. Es handelt sich hier um ein

Rechteckfenster



Hanningfenster

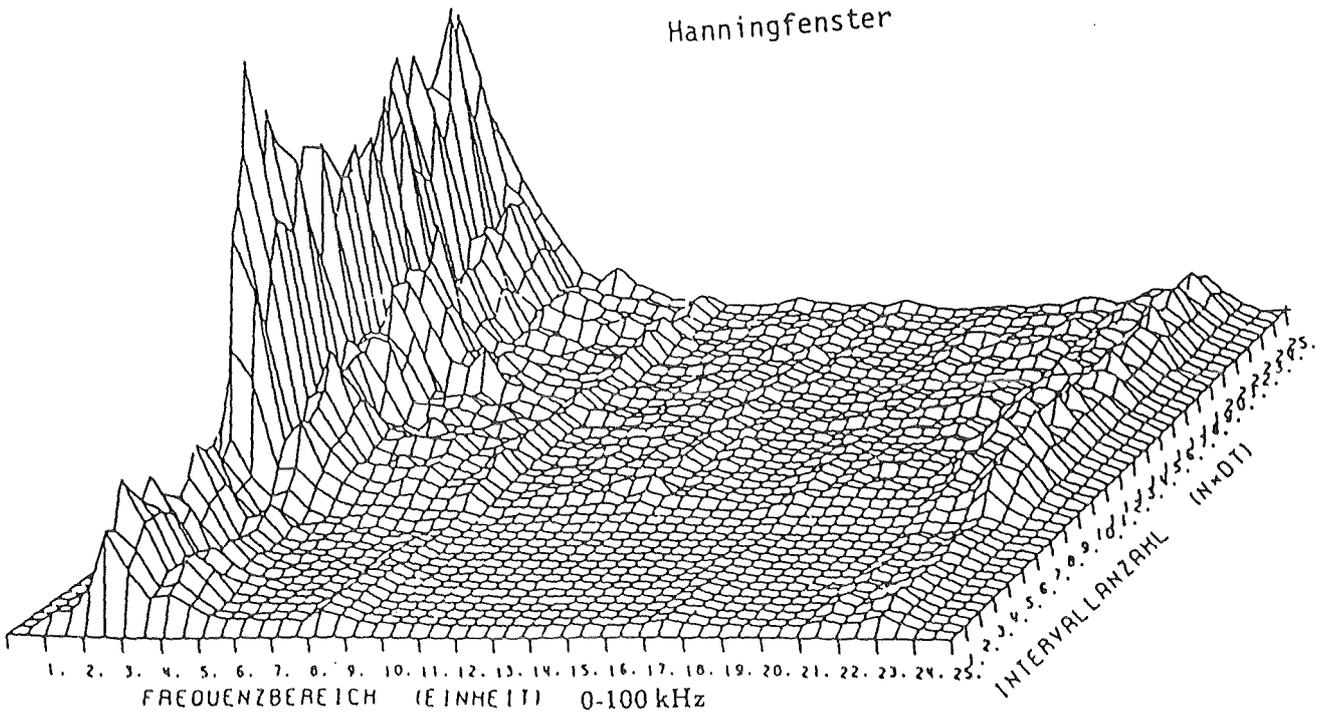


Abb. 4.2: Leistungsdichtespektren

Siedesignal von einem MOL 7c Experiment. Der Frequenzbereich erstreckt sich von 0 bis 100 kHz. Die absolute Höhe der Spektralanteile ist hier nicht maßgebend, sondern die generelle Anhebung über das gesamte Frequenzspektrum ist interessant. Das Bild bestärkt die Vermutung, daß man für klassentrennende signifikante Merkmale nicht alle Frequenzbänder benötigt, sondern daß nach geeigneten Reduktionsmethoden relativ wenig Komponenten der Spektren ausreichen dürften. Eine optimierte Auswahl wird vom ME - System automatisch vorgenommen.

4.3. Generierung statistischer Primärmerkmale

Es wird zunächst eine Grundmenge von Merkmalen generiert, ohne Beachtung irgendwelcher Dimensionsreduktionen oder Optimierungskriterien. Da es sich bei dem Signal um einen stochastischen Prozeß handelt, werden im wesentlichen statistische Kenngrößen als Merkmale verwendet. Der Berechnung aller folgenden statistischen Parameter p_1, \dots, p_n liegt ein Zeitintervall I mit den Stützstellen x_0, x_1, \dots, x_{N-1} der momentanen Beobachtung zugrunde.

Weitere Merkmale werden im Frequenzbereich generiert. Nach einer FFT steht folgender positiver reeller Vektor zur Verfügung.

$$(F_m)_m \text{ mit } F_m = \left| \sum_{n=0}^{N-1} x_n e^{-2\pi i m n / N} \right|^2 \quad (4.3.1)$$

mit N gerade, $m = 1, \dots, N/2 + 1 = :N_F$

Für eine normierte Zufallsvariable y ($E\{y\} = 0; \sigma^2 = 1$) sei $\phi(y)$ die Normalverteilungsdichte; dann kann man für eine beliebige Wahrscheinlichkeitsdichte $w(y)$ folgende Reihenentwicklung angeben (/21/)

$$w(y) = \phi(y) \left(1 + \sum_n \frac{c_n}{n!} H_n(y) \right) \quad (4.3.2)$$

wobei die c_n Quasimomente heißen. Die c_n charakterisieren die Form der Verteilungsdichte. H_n sind Hermitpolynome.

Die c_n mit geraden n geben ein Maß für die Flachheit der Verteilung an, die mit ungeraden n drücken die Symmetrie bzw. die Asymmetrie aus.

Mit $\mu_n = E\{(y - E\{y\})^n\}$ als Zentralmomente gilt

$$\left. \begin{aligned} c_3 &= \mu_3 \\ c_4 &= \mu_4 - 3\mu_2^2 \\ c_5 &= \mu_5 - 10\mu_2\mu_3. \end{aligned} \right\} \text{Quasimomente} \quad (4.3.3)$$

Auf der Basis der berechneten Größen F_m lassen sich im Frequenzbereich unter anderem folgende Merkmale berechnen

$$\bar{F} = \sum_{i=1}^{N_F} F_i / N_F \quad (4.3.4)$$

als mittlere Leistungsdichte über die N_F Frequenzspektren.

Für die Leistungsdichteverteilung über das gesamte Frequenzband lassen sich wie im Zeitbereich die Quasimomente (u.a. Schiefe und Exzeß) berechnen, die in diesem Falle eine Aussage über die Verteilungsstruktur der einzelnen F_i machen. ($\mu_n = E \{ (F - E \{ F \})^n \}$). Weitere Merkmale sind die Anteile, die die F_i in einem Histogramm um den mittleren Wert \bar{F} einnehmen. Auch die Streuung der einzelnen F_i um das mittlere \bar{F} kann als Merkmal für den Prozeß gewählt werden. Schließlich werden die Vorzeichenwechsel berücksichtigt, die anzeigen, ob die F_i größer oder kleiner als das mittlere \bar{F} sind. Sie sind ein Maß für die Rauheit der Verteilung. Diese Liste von Merkmalen muß für den späteren Einsatz offen bleiben, dh. im Programmsystem muß diese Merkmalsliste leicht und einfach erweiterbar sein. Es wird an dieser Stelle noch keine Aussage über die Güte und Tauglichkeit der Merkmale gemacht, sondern es ist lediglich eine heuristische Ansammlung. Das System wird die Bewertung selbst automatisch durchführen anhand noch zu spezifizierender Kriterien.

Sei N = Anzahl der Stützstellen x_i im Gesamtintervall I (Hier ist $N = 5120$).

Sei RMS (Root-Mean-Square) der Effektivwert über das Gesamtintervall I .

Das Gesamtintervall I sei unterteilt in 80 Teilintervalle: dann sei $PRMS_i$ der i -te Effektivwert für dieses Teilintervall (bestehend aus 64 Stützstellen) und $PRMS$ sei der Mittelwert der einzelnen $PRMS_i$.

Im Frequenzbereich habe man eine äquidistante Unterteilung von 0 bis 100 kHz in 16

Frequenzbänder. F_m bezeichne die Leistungsdichte im m -ten Band, \bar{F} die mittlere Leistungsdichte.

Es folgt nun eine Liste der in dieser Arbeit verwendeten Merkmale:

1. zeitliches Quadratmittel über ein gesamtes Fenster

$$RMS = \sqrt{\sum_{i=0}^{N-1} x_i^2 / N} \quad (4.3.5)$$

2. Streuung der Zeitwerte

$$\sigma_{RMS} = \sqrt{\left[\sum_{i=0}^{N-1} (x_i - RMS)^2 / N \right]} \quad (4.3.6)$$

3. Mittelwert der 80 partiellen Effektivwerte $PRMS_i$

$$PRMS = \sqrt{\left[\sum_{i=1}^{80} PRMS_i^2 / 80 \right]} \quad (4.3.7)$$

4. Streuung der partiellen $PRMS_i$ Werte um den mittleren Wert

$$\sigma_{PRMS} = \sqrt{\left[\sum_{i=1}^{80} (PRMS_i - PRMS)^2 / 80 \right]} \quad (4.3.8)$$

- 5.-10.: Histogramm in 6 Bändern um RMS im Intervall $[RMS - 2\sigma_{RMS}, RMS + 2\sigma_{RMS}]$
- 11.-26.: Wirkleistungsdichten in 16 Frequenzbändern 0-100 kHz
- 27.: mittlere Wirkleistungsdichte von den 16 Bändern
- 28.: Streuung der Wirkleistungsdichten
- 29-33.: 5 Quasimomente im Frequenzbereich
- 34-39.: Histogramm im Frequenzbereich in 6 Bändern um \bar{F} im Intervall $[\bar{F} - 2\sigma, \bar{F} + 2\sigma]$ wobei σ die Streuung der F_i ist.
- 40.: Anzahl der Vorzeichenwechsel um den Referenzwert RMS
- 41.: Anzahl der Vorzeichenwechsel um den Referenzwert \bar{F}
- 42.: Verhältnis von Histogrammanteilen: Merkmal 5 / Merkmal 7
- 43.: Verhältnis von Histogrammanteilen: Merkmal 34 / Merkmal 36
- 44.: Quotient aus gegenwärtigem RMS - Wert und Nichtsiedereferenzwert
- 45-60.: Quotient aus Spektrum des momentanen Zustandes zum Spektrum des Referenznichtsiedemusters für die 16 Frequenzbänder
 $[F_m(\text{momentan}) / (\text{Nichtsiedereferenz})]_{m=1, \dots, 16}$

5. Prognoseverfahren im Merkmalsraum

Im Rahmen der frühen Schadensdetektion wird ein System entwickelt, welches ausgehend von einem unkritischen Normalzustand Fehlzustände, insbesondere das Aufkommen von Sieden schnell und sicher erkennt. Im Sinne der Mustererkennung wird eine Klassifikation stattfinden in normale und anomale (kritische) Zustände (Nichtsieden und Sieden).

Im Unterschied zur herkömmlichen Merkmalsgenerierung ist der Prozeß der Merkmalsbildung nicht mit einem festen Satz von Merkmalen abgeschlossen. Es können im Laufe des Prozesses neue Modellparameter als weitere Merkmale hinzukommen.

Zunächst wird ein Satz von Primärmerkmalen bereitgestellt. Er enthält eine Menge statistischer Parameter und Kenngrößen, die das typische von stochastischen Schwankungen überlagerte Signal darstellen. Es kommen die in Kapitel 4 gewählten Parameter zur Geltung. Aus den berechneten Primärmerkmalen eines Fensterausschnittes bei der Signalüberwachung werden dann Modellparameter geschätzt und aufgrund dieser parametrisierten Modelle zukünftige Merkmale prognostiziert.

Im folgenden wird es wichtig sein, leistungsfähige Modelle zur Verfügung zu stellen, um aus gegenwärtigen Zuständen (Mustern) lokal zukünftige prognostizieren zu können. Die Modellparameter selbst werden als Sekundärmerkmale in den Klassifikator eingehen.

Durch die fortlaufende Merkmalsgenerierung und die damit verbundene neue Parametrisierung des Modells wird das System stets aktualisiert und angepaßt. Abb. 5.0 zeigt das Konzept eines adaptiven Systems. Die Prognose und Entscheidungsfindung benutzt jeweils den letzten aktuellen Stand des Prozesses als Wissensbasis. In diesem Sinne ist auch die Trainingsphase nicht an einmal fest vorgegebene Muster gebunden.

In diesem Kapitel beziehen wir uns generell auf eine Systemdarstellung folgender Art:

$$y(z) = \frac{b_0 + b_1 z + \dots + b_n z^n}{a_0 + a_1 z + \dots + a_n z^n} u(z) \quad (5.1)$$

mit der Eingangsfunktion $u(z)$, der Ausgangsfunktion $y(z)$ und den zu schätzenden Parametern $a_0, \dots, a_n, b_0, \dots, b_n$ bzw. auf das äquivalente Zustandsraummodell

$$\begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ \dots \\ x_n(k+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \dots \\ 0 & 0 & 1 \dots \\ \dots & \dots & \dots \\ -a_0/a_n & -a_1/a_n & -a_2/a_n \dots -a_{n-1}/a_n \end{bmatrix} \cdot \begin{bmatrix} x_1(k) \\ x_2(k) \\ \dots \\ x_n(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \dots \\ 1 \end{bmatrix} \cdot u(z) \quad (5.2)$$

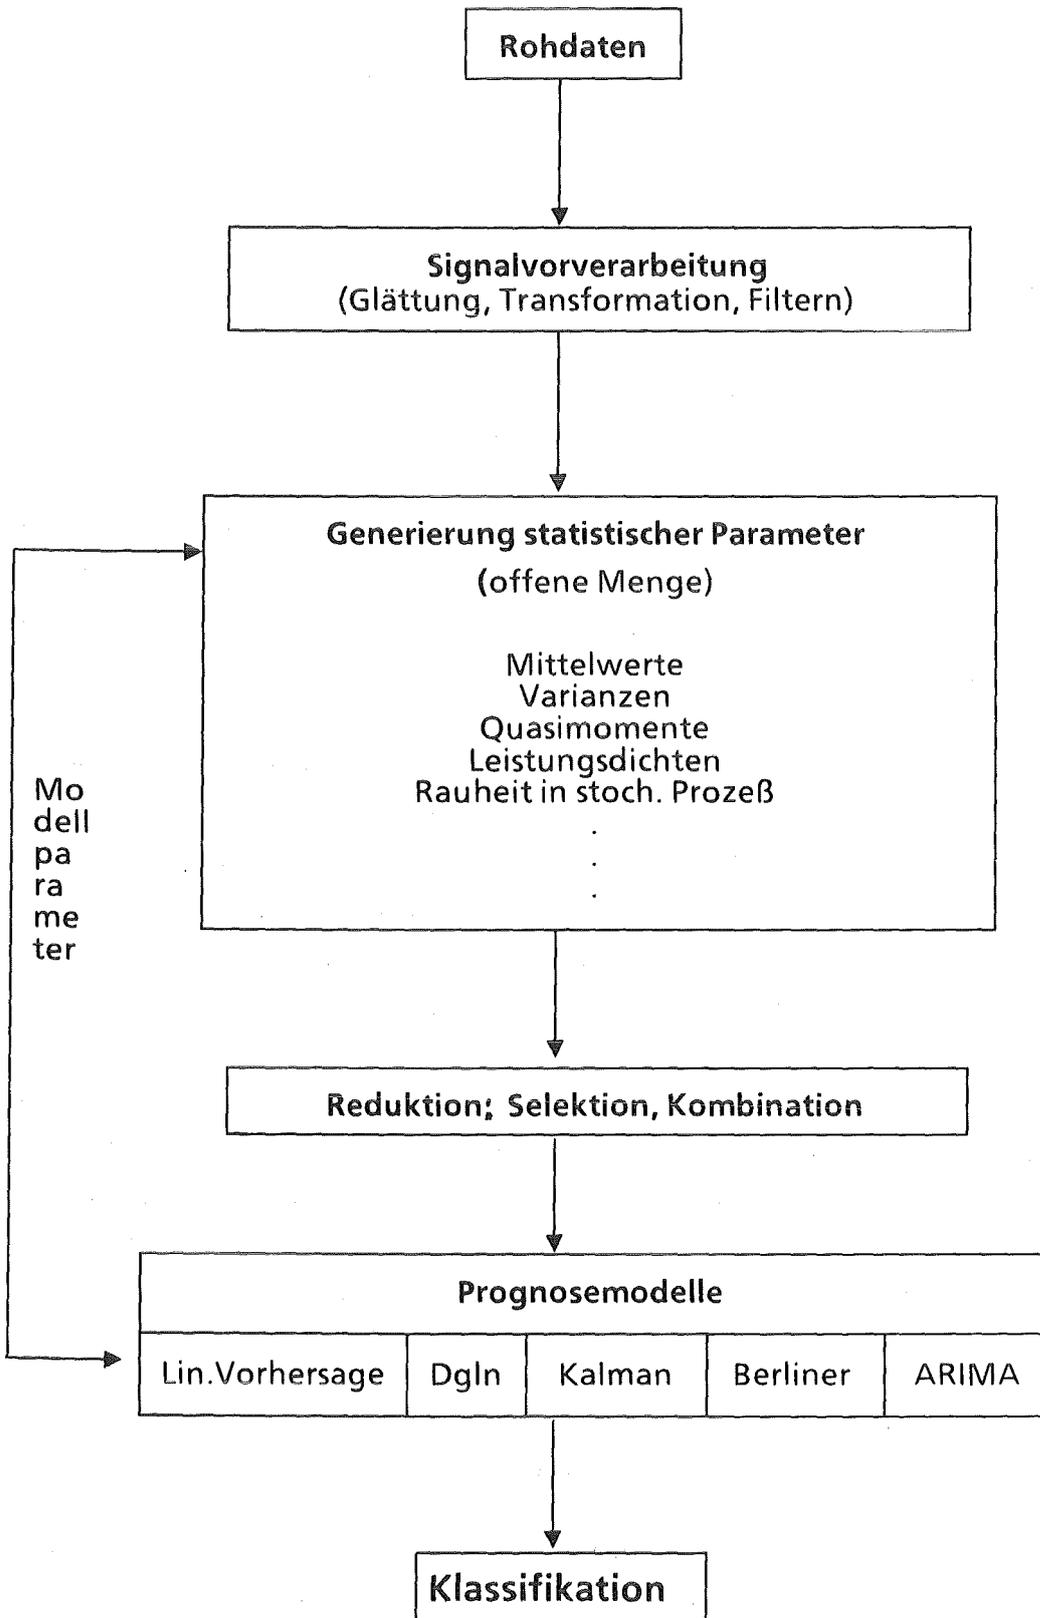


Abb. 5.0: adaptives System

$$y = (b_0 - a_0 b_n / a_n) x_1 + (b_1 - a_1 b_n / a_n) x_2 + \dots + (b_{n-1} - a_{n-1} b_n / a_n) x_n + b_n u(z)$$

falls man $x_1(z) = u(z) / N(z)$, $x_2(z) = z x_1(z)$, ... und $x_n(z) = z^{n-1} x_{n-1}$ setzt mit $N(z) = (a_0 + \dots + a_n z^n)^{-1}$ und die z-Transformation berücksichtigt.

Es handelt sich um ein System n-ter Ordnung. Im folgenden werden vier Schätzmodelle vorgestellt, die zu verschiedenen Schätzmethoden führen und von der obigen Darstellung durch Berücksichtigung verschiedener Aspekte abgeleitet werden können. Die Prognosemodelle werden separat entwickelt und es wird jeweils der Bezug zu der allgemeinen Systemdarstellung angegeben.

Es ist wichtig festzustellen, daß man keinerlei a priori Wissen über die Güte eines Modellansatzes hat. Zu keinem Zeitpunkt während der Überwachung kann man sagen, welcher Modellansatz das Merkmalsverhalten am besten beschreibt und somit für die Prognose am geeignetsten ist. Aus diesem Grunde werden verschiedene Schätzmethoden angestrebt, um ein breites Spektrum an Modellen abzudecken. Falls alle Prognosemodelle zum Beispiel auf einen Siedezustand deuten, so hat diese Aussage ein größeres Gewicht als wenn einige Verfahren ein Sieden und andere ein Nichtsieden prognostizieren.

Es werden nun Regressionsansätze entwickelt, und zwar komponentenweise für jedes Merkmal separat (Lineare Vorhersage), dann unter Berücksichtigung von abklingenden Störungen (ARMA - Modelle), auch im instationären Fall (ARIMA-Modelle). Ein Polynomansatz für den Trend eines Merkmals führt dann zum Berliner Verfahren. Die Berücksichtigung einer Kopplung der einzelnen Komponenten des Merkmalsvektor geht in den Ansatz der Differenzgleichung ein. Dafür hat man hier nur ein System 1.ter Ordnung. In dieser Darstellung wird mehr ein exponentielles Wachstum oder Abfallen der Merkmale simuliert.

Alle genannten Verfahren lassen sich generell auf Zeitreihen anwenden, wobei die Elemente der Zeitreihe in unserem Falle Merkmale sind. Hat man in einem anderen Anwendungsfall mehr a priori Wissen über den Prozeß bzw. über das zeitliche Verhalten der Merkmale, so kann man die Verfahren entsprechend gewichten. In dieser Arbeit ist es wichtig, wegen der Unkenntnis des Merkmalsverlaufes ein Spektrum von verschiedenen möglichen Merkmalsverläufen zu simulieren.

5.1 Das Verfahren der Linearen Vorhersage

In diesem Unterkapitel wird das Verfahren der Linearen Vorhersage benutzt, um bei dem zu überwachenden Signal Merkmale im Merkmalsraum über einen gewissen Zeitraum prognostizieren zu können. Das Verfahren wird auf eine noch näher zu spezifizierende Zeitreihe angewandt. Es kann z.B. die um stochastische Schwankungen bereinigte Funktion eines statistischen Parameters sein,

d.h. eines skalaren Merkmals. Aus der Beobachtung früherer Daten wird ein linearer Modellansatz gemacht. Der momentane Wert zum Zeitpunkt k läßt sich als Linearkombination aus m früheren Werten berechnen. Die Modellparameter werden so bestimmt, daß der mittlere zu erwartende Fehler bei der vorgegebenen Stichprobenmenge minimal ist.

Parameterschätzung:

Gegeben sei eine digitalisierte diskrete eindimensionale beobachtete Funktion y mit den endlich vielen Abtastwerten $y(1), \dots, y(k-1)$.

Gesucht ist ein Schätzwert für y zum Zeitpunkt k .

Linearer Ansatz:

$$\hat{y}(k) = - \sum_{\mu=1}^m \alpha_{\mu} y(k-\mu) \tag{5.1.1}$$

Geht man von der Systemdarstellung (5.1) aus, so erhält man

$$a_0 y(z) + a_1 z y(z) + \dots + a_n z^n y(z) = b_0 u(z) + b_1 z u(z) + \dots + b_n z^n u(z)$$

Unter Berücksichtigung der Verschiebungsregel der z -Transformation $y(z+1) = z y(z)$ hat man

$$a_0 y(k) + a_1 y(k+1) + \dots + a_n y(k+n) = b_0 u(k) + b_1 u(k+1) + \dots + b_n u(k+n).$$

Für zeitinvariante Systeme gewinnt man nach einer Translation um n

$$a_0 y(k-n) + a_1 y(k+1-n) + \dots + a_n y(k) = b_0 u(k-n) + b_1 u(k+1-n) + \dots + b_n u(k).$$

Werden die Eingangsgrößen $u(k) = 0$ gesetzt, so ergibt sich aus $a_0 y(k-n) + \dots + a_n y(k) = 0$ der lineare Ansatz

$$a_n y(k) = \sum_{i=0}^{n-1} -\alpha_i y(k-n+i)$$

bzw. mit $\alpha_i := a_{n-i} / a_n$

$$y(k) = - \sum_{i=1}^n \alpha_i y(k-i)$$

Für $n = m$ ist dies genau der Ansatz (5.1).

Interpretation des Ansatzes:

Der Wert $\hat{y}(k)$ läßt sich als Linearkombination aus den m vorangehenden Werten mit den Gewichten α_μ berechnen. Die Koeffizienten α_μ sind unbekannt und müssen aus den Nebenbedingungen berechnet werden.

Sei $y(k)$ der wahre Wert zum Zeitpunkt k , $\hat{y}(k)$ der geschätzte, dann gilt für den Fehler zum Zeitpunkt k

$$e(k) = y(k) - \hat{y}(k) = y(k) - \sum_{\mu=1}^m \alpha_\mu y(k-\mu) \quad (5.1.2)$$

Unter der Nebenbedingung für den mittleren quadratischen Fehler (/17/ S 98)

$$E = \sum_k e(k)^2 \rightarrow \text{Min!}$$

zur Bestimmung der Koeffizienten ist folgende Extremwertaufgabe zu lösen:

$$E = \sum_k \left(y(k) - \sum_{\mu=1}^m \alpha_\mu y(k-\mu) \right)^2 \rightarrow \text{Min!} \quad (5.1.3)$$

Es muß wegen $\delta E / \delta \alpha_i = 0$ für $i = 1, \dots, m$ gelten

$$- \sum_k y(k) y(k-i) = \sum_{\mu=1}^m \alpha_\mu \sum_k y(k-\mu) y(k-i) \quad (5.1.4)$$

$$\text{Mit } R(\mu, i) := \sum_k y(k-\mu) y(k-i) \text{ und } R(0, i) = \sum_k y(k) y(k-i)$$

erhält man folgendes zu lösendes Gleichungssystem in den α_i :

$$\sum_{\mu=1}^m \alpha_\mu R(\mu, i) = -R(0, i) \quad \text{für } 1 \leq i \leq m \quad (5.1.5)$$

Bemerkung:

Die Größe R entsteht durch Summation über k .

1. Fall: Summation über $-\infty < k < \infty$

Dann gilt: $\sum y(k-\mu) y(k-i)$ hängt nur von $| \mu - i |$ ab.

Somit lautet die Normalgleichung

$$\sum_{\mu=1}^m \alpha_{\mu} R(i-\mu) = -R(i) \tag{5.1.6}$$

Es gilt: R ist symmetrisch d.h. $R(i, j) = R(j, i) = R(|i-j|)$

R ist konstant entlang der Diagonalen und es gilt $R(0) = R(i, i)$ für alle $i = 1, \dots, m$

2. Fall: endliche Summation über $1 \leq k \leq N-1$

Dann gilt: $\sum y(k-\mu) y(k-i)$ hängt von μ und von i ab

Somit lautet die Normalgleichung

$$\sum_{\mu=1}^m \alpha_{\mu} \tilde{R}(\mu, i) = -\tilde{R}(0, i) \tag{5.1.7}$$

Da in unserem Falle endlich viele Stützpunkte vorhanden sind, wird der 2. Fall benutzt, um die Größen α_i zu berechnen.

Für die Abschätzung des mittleren quadratischen Fehlers gilt:

$$E = \sum_k y(k)^2 + \sum_{\mu=1}^m \alpha_{\mu} \sum_k y(k-\mu) y(k) \tag{5.1.8}$$

Im 1. Fall erhält man durch Einsetzen

$$E = R(0) + \sum_{\mu=1}^m \alpha_{\mu} R(\mu) \tag{5.1.9}$$

Im 2. Fall erhält man

$$E = \tilde{R}(0,0) + \sum_{\mu=1}^m \alpha_{\mu} \tilde{R}(0,\mu) \quad (5.1.10)$$

Der Lösungsvektor α des Gl.systems (5.1.7) kann als Sekundärmerkmalsvektor benutzt werden. Des weiteren dienen diese Merkmale α_i zur Prognose des weiteren Kurvenverlaufes der diskreten Funktion y . Für die skalare diskrete Funktion y werden die Primärmerkmale eingesetzt.

Schätzung zukünftiger Systemzustände

Aus der momentanen Merkmalsgenerierung resultieren die Modellparameter α_{μ} mit $\mu = 1, \dots, m$. Seien also $y(1), \dots, y(k)$ zum gegenwärtigen Zeitpunkt k gegeben. Für einen Zeitpunkt $k + 1$ gilt dann

$$\hat{y}(k+1) = - \sum_{\mu=1}^m \alpha_{\mu} y(k+1-\mu) \quad (5.1.11)$$

und für einen Zeitpunkt $k+j$ gilt entsprechend

$$\hat{y}(k+j) = - \sum_{\mu=1}^m \alpha_{\mu} y(k+j-\mu) \quad (5.1.12)$$

Die Parameter α_{μ} sind fest durch das bisherige Verhalten des Systems bestimmt und werden für die Abschätzung in den Zeitpunkten als fix betrachtet. Die Größe j für die Länge des Prognoseintervalls sei noch offen aber fest gewählt. Mit wachsendem j nimmt die Sicherheit der Prognose ab. Man beachte, die $y(k)$ sind nicht etwa Funktionswerte des ursprünglichen Signals, sondern Schätzwerte für statistische Parameter, die jeder für sich ein ganzes Intervall beschreiben. Der 2. Fall (endlich viele Stützstellen) findet im Programm seine Anwendung.

5.2 Schätzmethoden mit einem Differenzenverfahren

Unter einem anderen Aspekt wird nun eine weitere Methode entwickelt, wie man aus der Beobachtung gegenwärtiger Muster auf zukünftige schließen kann.

Das zu überwachende digitalisierte Signal sei äquidistant zerlegt in Zeitintervalle der Länge T . Auf der Stufe der Merkmalsgenerierung werden für jedes solche Zeitintervall die statistischen Parameter

gemäß Kapitel 4 als Primärmerkmale berechnet und zu einem Vektor der Dimension n zusammengefaßt. Die Zeitintervalle werden mit k durchnummeriert.

Wir bezeichnen diesen Vektor mit $y = (p_1, \dots, p_n)^T$, wobei p_i die einzelnen statistischen Parameter sind.

Abb. 5.2 verdeutlicht die Situation:

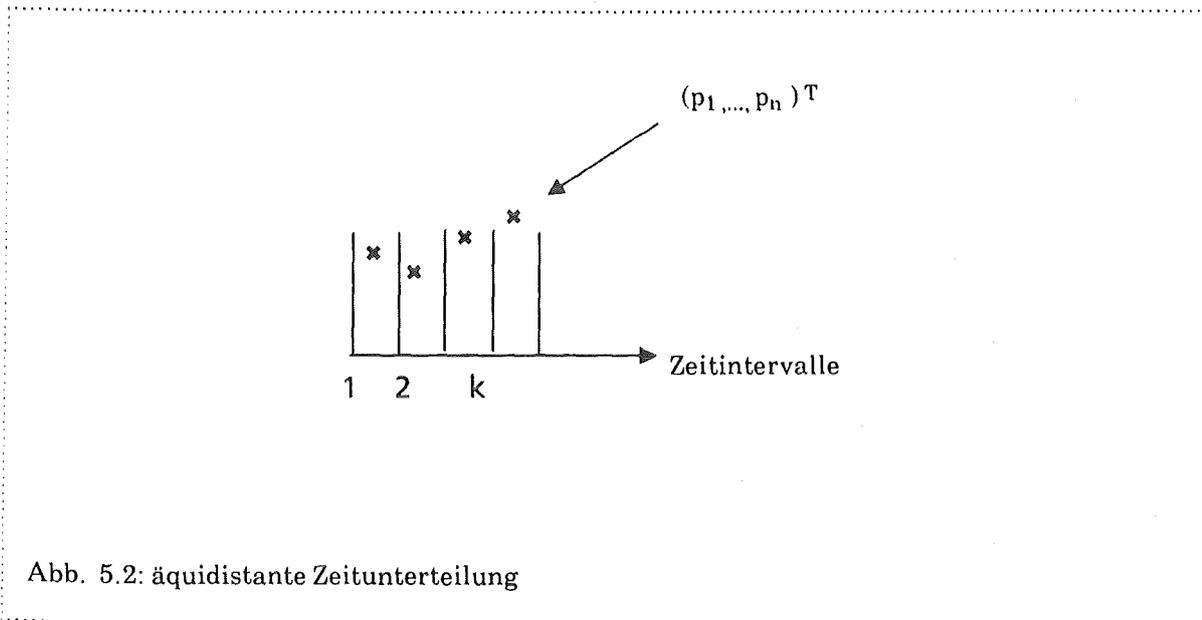


Abb. 5.2: äquidistante Zeitunterteilung

Betrachtet man die Funktion, die jedem Zeitintervall einen Merkmalsvektor zuordnet, so erwartet man im Nichtsiedezustand ein gewisses 'stabiles' Verhalten. Kommt man in den Bereich der Übergangsphase, wird das Verhalten gewissermaßen 'instabil'. Die Stabilitätsbegriffe werden noch genauer definiert.

Ziel ist es nun, aus den berechneten Merkmalen im diskreten Fall eine Differenzgleichung zu erstellen, um die Modellparameter zu schätzen und dann anhand dieses Modelles zukünftige Merkmale zu prognostizieren.

Die Differenzgleichung lautet:

$$y(k+1) - y(k) = D y(k) + b \quad \text{mit } y(k), b \in \mathbb{R}^n, D \text{ eine } n \times n \text{ Matrix}$$

Betrachtet man jede Zeile dieser Vektorgleichung separat, so hat man genau das Modell des Linearen

Prädiktors mit $m = 1$. Dies bedeutet, der Zustand zum Zeitpunkt $k + 1$ hängt nur von dem Zustand zum Zeitpunkt k und nicht von den weiter zurückliegenden ab. Durch die Vektorgleichung wird hier jedoch eine Kopplung der n Komponenten des Merkmalvektors zugelassen, d.h. alle Merkmalskomponenten des Vektors zur Zeit k beeinflussen den Zustand der einen Komponente zum Zeitpunkt $k + 1$. Wir haben nun im Vergleich zur Linearen Vorhersage ein System 1.ter Ordnung, aber mit n Kopplungen.

Bemerkung:

1. Dieses Verfahren berücksichtigt die Abhängigkeit einer Komponente des Merkmalvektors von allen andern. Sowohl bei der Linearen Vorhersage als auch bei diesem Differenzenansatz werden im Merkmalsraum statistische Parameter als Primärmerkmale prognostiziert und Modellparameter als Sekundärmerkmale verwendet.
2. Bei der Anwendung auf unsere Signale ist in beiden Fällen das Ergebnis abhängig von der Merkmalsauswahl.

5.2.1 Stabilitätsaussagen

Es stellt sich die Frage, ob aus dem Differenzenansatz auch sinnvolle Sekundärmerkmale gewonnen werden können. Dazu wird in diesem Unterkapitel das Gebiet der Ljapunovtheorie bei einem kontinuierlichen gewöhnlichen Differentialgleichungssystem kurz behandelt, welches im diskreten formal dem Differenzenmodell entspricht. Man wird sehen, daß ein typisches Lösungsverhalten an der Matrix des Systems zu erkennen ist. Diese Aussagen assoziieren, daß auch im diskreten Modell solche Größen der Matrix benutzt werden können, um typische Merkmale, d.h. hier Sekundärmerkmale zu gewinnen.

Im folgenden werden die Stabilitätsbegriffe im Sinne von Ljapunov am kontinuierlichen System angegeben. Für die exakte mathematische Definition von Stabilität, Attraktivität und asymptotischer Stabilität sei auf die einschlägige Literatur verwiesen. (/4/)

Wir gehen aus von einer Dgl. $\dot{y} = f(t, y)$, welche die Funktion $y(t) \equiv 0$ als Lösung hat. Dann folgt $f(t, 0) = 0$ für alle Zeiten. [Für $y(t) \equiv c \neq 0$ erhält man über eine lineare Transformation $z = y(t) - c$: $\dot{z} = \dot{y} = f(t, y - c) = f(t, z)$.]

Man betrachte das Anfangswertproblem (AWP)

$$\dot{y} = f(t, y) \text{ mit } f(t, 0) = 0; \quad y(t_0) = 0 \tag{5.2.1}$$

mit gewissen Stetigkeitsvoraussetzungen an die Funktion f .

Def 1: Die Lösung $y = 0$ des Systems heißt stabil \Leftrightarrow

Zu einem vorgegebenem $\varepsilon > 0$ und einem vorgegebenem t_0 existiert ein $\delta(t_0) > 0$ so daß gilt: Jede Lösung des AWP mit einem Startwert $\|y_0\| < \delta(t_0)$ existiert für alle Zeit und bleibt in einer vorgegebenen ε -Umgebung der Nulllösung.

Def 2: Die Lösung heißt instabil, wenn sie nicht stabil ist.

Def 3: Die Lösung heißt attraktiv, wenn sie sich asymptotisch der Nulllösung nähert für t gegen unendlich (i.a. nicht stabil!).

Def 4: Die Lösung heißt asymptotisch stabil, wenn die Bedingungen in Definition 1 und 3 erfüllt sind.

Def 5: Gleichmäßige Stabilität bzw. gleichmäßige asymptotische Stabilität bedeutet, daß in Def 1 zu vorgegebenem ε die δ -Umgebung unabhängig vom Anfangswert t_0 gewählt werden kann.

Es werden einige Aussagen gemacht, die später bei unserer Modell Anwendung finden werden.

Satz 1:

Für autonome (d.h. nicht explizit zeitabhängige) Systeme $\dot{y} = A y + b$ kann stabil bzw. asymptotisch stabil durch gleichmäßig stabil bzw. gleichmäßig asymptotisch stabil ersetzt werden (/4/S 147).

Man betrachte nun den Spezialfall eines linearen autonomen Systems.

$$\dot{y} = A \cdot y \tag{5.2.2}$$

Satz 2:

a) Haben alle Eigenwerte von A negativen Realteil, dann ist die Nulllösung $y = 0$ glm. asymptotisch stabil.

b) Haben alle Eigenwerte λ von A nichtpositiven Realteil und gibt es zu λ mit $\text{Re}(\lambda) = 0$ der Vielfachheit k genau k linear unabhängige Eigenvektoren, dann ist $y = 0$ glm. stabil.

Das Verhalten der Lösungen ist vollständig charakterisiert durch die Eigenwerte der Matrix A .
 Hat A keine rein imaginären Eigenwerte, so ist A ähnlich einer Matrix (/4/ S 87)

$$\begin{bmatrix} A_1 & 0 \\ 0 & A_2 \end{bmatrix} \quad (5.2.3)$$

wobei A_1 nur Eigenwerte mit negativem Realteil, und A_2 nur Eigenwerte mit positivem Realteil besitzt. Dies bedeutet, daß der n -dimensionale Lösungsraum Y in 2 Komplementärräume aufgespalten wird. Man kann zeigen, daß Lösungen, die in Y_1 bzw. in Y_2 starten, auch in Y_1 bzw. in Y_2 bleiben. Man spricht dann auch von einer stabilen bzw. instabilen Mannigfaltigkeit. (/4/ S 247). Die Dimension der Mannigfaltigkeiten bzw. charakteristische Unterschiede in den Eigenwerten können zur Charakterisierung der Muster benutzt werden. Somit liegt es nahe, auch im diskreten Fall die Eigenwerte bzw. die Dimension der Unterräume, die nur Eigenwerte mit negativem Realteil bzw. mit nichtnegativem Realteil haben, als Sekundärmerkmale zu nehmen.

5.2.2 Modellbildung im Merkmalsraum

Im n -dimensionalen Merkmalsraum \mathbb{R}^n sei der Merkmalsvektor $(p_1, \dots, p_n)^T$ im folgenden mit y bezeichnet. Über die diskrete Zeitachse stellt y die Trajektorie des Merkmalvektors dar. Für jede diskrete Zeit k bezeichnet $y(k)$ den speziellen n -dimensionalen Merkmalsvektor des Zustandes zum Zeitpunkt k . (siehe Abb. 5.2)

Wir betrachten eine deterministische Lösung der noch aufzustellenden Differenzgleichung. Die berechneten Merkmalsvektoren seien $y(1), \dots, y(m)$, wobei $y(k) = (p(k)_1, \dots, p(k)_n)^T$ der Merkmalsvektor zum Zeitpunkt k ist.

Ansatz für die Differenzgleichung: $y(k+1) = A y(k) + b$ (5.2.4)

bzw. $y(k+1) - y(k) = D y(k) + b$ mit $D = A - I$ und $k = 1, \dots, m$.

A und b sind die zu bestimmenden Modellparameter.

Das System lautet ausgeschrieben in den einzelnen Komponenten:

Wir betrachten das mathematische Modell:

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}(k) \mathbf{x}(k) + \mathbf{v}(k) & \text{(I)} \\ \mathbf{y}(k) &= \mathbf{C}(k) \mathbf{x}(k) + \mathbf{w}(k) & \text{(II)} \end{aligned} \tag{5.3.3}$$

(I) beschreibt die Zustandsgleichung mit der Übergangsmatrix \mathbf{A} , (II) die Beobachtungsgleichung mit der Beobachtungsmatrix \mathbf{C} .

Es sei $\mathbf{x} \in \mathbb{R}^n$ der gesuchte unbekannte Zustandsvektor mit Anfangswert $\mathbf{x}(k_0)$.

Der Erwartungswert $E\{\mathbf{x}(k_0)\}$ sei $\mathbf{0}$ und die Kovarianzmatrix sei $\mathbf{P}(k_0)$.

$\mathbf{y} \in \mathbb{R}^n$ ist die beobachtete Meßgröße.

Für die Störgröße \mathbf{v} und den Meßfehler \mathbf{w} des Systems soll gelten:

$$\begin{aligned} E\{\mathbf{v}(k)\} &= E\{\mathbf{w}(k)\} = \mathbf{0} \\ E\{\mathbf{v}(k) \mathbf{v}^T(l)\} &= \mathbf{Q}(k) \delta_{kl} \\ E\{\mathbf{w}(k) \mathbf{w}^T(l)\} &= \mathbf{R}(k) \delta_{kl} \end{aligned} \tag{5.3.4}$$

mit $\delta_{kl} = 1$ für $k = l$ und 0 sonst.

Weiterhin seien der Anfangszustand $\mathbf{x}(k_0)$, \mathbf{v} und \mathbf{w} gegenseitig unkorreliert:

$$E\{\mathbf{x}(k_0) \mathbf{v}^T\} = E\{\mathbf{x}(k_0) \mathbf{w}^T\} = E\{\mathbf{v} \mathbf{w}^T\} = \mathbf{0} \tag{5.3.5}$$

Aufgabe:

Ausgehend von den Beobachtungsgrößen $y(0), y(1), \dots, y(k)$ soll der Zustand $\mathbf{x}(k)$ linear, erwartungstreu und mit minimaler Varianz geschätzt werden

Sei $\hat{\mathbf{x}}(k, k-1)$ bereits die geschätzte Größe für \mathbf{x} aus den Beobachtungsdaten $y(0), y(1), \dots, y(k-1)$.

Sei zum Zeitpunkt k $y(k)$ die gestörte Beobachtungsgröße.

Dann gilt für die optimale Schätzung zum Zeitpunkt $k+1$ folgende rekursive Filtergleichung (/28/)

$$\hat{\mathbf{x}}(k+1, k) = \mathbf{A}(k) \hat{\mathbf{x}}(k, k-1) + \mathbf{K}(k) \{y(k) - \mathbf{C}(k) \hat{\mathbf{x}}(k, k-1)\} \tag{5.3.6}$$

mit der Verstärkungsmatrix :

$$\mathbf{K}(k) = \mathbf{A}(k) \mathbf{P}(k) \mathbf{C}^T(k) \{ \mathbf{C}(k) \mathbf{P}(k) \mathbf{C}^T(k) + \mathbf{R}(k) \}^{-1} \tag{5.3.7 a}$$

wobei in der sogenannten Varianzgleichung rekursiv gilt:

$$P(k) = \{ A(k-1) - K(k-1)C(k-1) \} P(k-1) A^T(k-1) + Q(k-1) \quad (5.3.7b)$$

Bemerkung:

Dieser Algorithmus bezieht sich auf zentrierte Anfangswerte. Für $\xi := E\{ x(k_0) \} \neq 0$ ist $x - \xi$ zu filtern und der Schätzwert ist zu ξ zu addieren.

Für die reine Prognose hat man durch sukzessive Anwendung der Ein-Schritt-Schätzungen mit $l > 1$:

$$\begin{aligned} \hat{x}(k+1, k) &= \Phi(k+1) \hat{x}(k+1) \text{ mit} \\ \Phi(k+1) &= A(k+1-1) \cdot \dots \cdot A(k+1) \end{aligned} \quad (5.3.8)$$

Anwendung des Kalmanfilters bei der Siededetektion

In diesem Abschnitt wird untersucht, ob ein Kalmanfilter ein geeignetes Modell darstellt, um das akustische Signal zur Siededetektion zu überwachen bzw. welche Restriktionen gemacht werden müssen.

Der Abschnitt gliedert sich in 3 Unterabschnitte:

In einem ersten Schritt werden beim herkömmlichen Filterproblem die Situation und Bedeutung der gegebenen und abzuschätzenden Parameter erläutert. Danach wird die spezielle Situation der Parameterwahl im Falle der Siededetektion und die damit verbundene Problematik angeschnitten.

Im dritten Teil wird versucht, aus dem deterministischen Bereich stammende Parameter zur Modellbildung des stochastischen Systems zu benutzen, um so fehlende Systemkomponenten zu ersetzen und das Modell an ein Kalmanfilter anzugleichen.

ad 1)

Wir gehen aus von den Modellgleichungen (5.3.3)

$$x(k+1) = A(k) x(k) + v(k) \quad (I)$$

$$y(k) = C(k) x(k) + w(k) \quad (II)$$

In diesem Modell wird ein lineares System vorausgesetzt, welches aus dem wahren Zustandsvektor x zum Zeitpunkt k einen Zustandsvektor zum Zeitpunkt $k+1$ erzeugt. Im System, welches durch die Matrix A beschrieben ist, wirken noch stochastische Störungen v als weißes Rauschen auf das System

und die unbekannte Zustandsgröße x .

Die gemessene Größe ist y , eine verrauschte Linearkombination von x . Zudem geht ein Meßfehler w in Form weißen Rauschens in die Beobachtungsgleichung ein. Wesentlich ist, daß neben den Korrelationen zwischen $x(k)$, v und w insbesondere die Matrizen A und C a priori gegeben sind, um die wahre Zustandsgröße x mit Hilfe der Meßwerte y abzuschätzen.

ad 2)

Im speziellen Fall der Siedegeräusche hat man zunächst ein mit solchen Parametern bestücktes Modell nicht zur Verfügung. Eine Matrix A , welche die lineare Auswirkung des Systems auf den Zustand x beschreibt, fehlt ebenso wie der Parameter C , der die Darstellung des Wertes x über die Meßwerte angibt. Das Reaktorsystem ist von der Komplexität her nicht geeignet, durch solch ein Modell beschrieben zu werden.

Man kann aber über die Meßwerte y und andere Verfahren ein Kalmanfilter simulieren wie folgt.

ad 3)

Um eine Möglichkeit der Prädiktion des stochastischen Prozesses zu haben, wird ein Modell konzipiert, welches formal dem Kalmanfilter gleich ist. Dies erlaubt dann Aussagen über das zukünftige Verhalten des Zustandes machen zu können, wobei zum Teil stochastische Eigenschaften der Funktion berücksichtigt werden können. Das formale Modell bedient sich jedoch aus den in ad 2) angeführten Gründen solcher Parameter A und C , die aus dem deterministischen Modell resultieren. Durch das Differenzenverfahren wird ein Modell simuliert, welches als spezielles Kalmanfilter angesehen werden kann.

Wahl der Parameter

1. Die ungestörten Meßgrößen y beschreiben den wahren Zustand x identisch. Die Matrix C sei die Identität.

2. Als wirksames System auf den Zustand x bzw. wegen 1 auf y werde die Matrix benutzt, die im Differenzenverfahren ermittelt wurde.

Aus $y(k+1) - y(k) = D y(k) + b$ in (5.28) erhält man

$$x(k+1) = x(k) + D(k) x(k) + b(k) = A(k) x(k) + b(k) \quad (5.3.9)$$

mit $A(k) = D(k) + I(k)$

Mit dieser Matrix \mathbf{A} wird das Zustandsmodell simuliert. Der konstante Vektor \mathbf{b} hat die Bedeutung einer konstanten bekannten Stellgröße. \mathbf{I} ist die Identität (Einheitsmatrix).

3. Als Störgrößen im Zustandsmodell werden die Differenzen zwischen gemessenen und berechneten Merkmalsvektoren über das gesamte letzte Fenster der Merkmalsvektoren gewählt. Es wird die Annahme gemacht: Für den stochastische Störprozeß gelte für alle k im Fenster $E\{ \mathbf{v}(k) \mathbf{v}^T(k) \} = \mathbf{0}$

4. Die Meßfehler seien nicht angebar, $\mathbf{R}(k) = \mathbf{0}$ in (5.3.4).

Im Fenster der Länge k sind zu den k Intervallen der Länge T (vgl. Abb. 5.2), dargestellt als diskrete Zeiten, die k statistischen Merkmalsvektoren berechnet. Jeder Merkmalsvektor besteht aus n statistischen Kenngrößen. Die Parameter des Kalmanfilters werden aus den Daten dieses Fensters berechnet. Die Prognose wird aus den so gewonnenen Parametern für die Merkmalsvektoren außerhalb des überwachten Fensters durchgeführt.

Lösung mit Filtergleichungen

Geht man aus von einem Modell 1

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}(k) \mathbf{x}(k) + \mathbf{v}(k) \\ \mathbf{y}(k) &= \mathbf{C}(k) \mathbf{x}(k) + \mathbf{w}(k) \end{aligned} \tag{5.3.10}$$

mit den Modellparametern

$$\begin{aligned} \mathbf{A} &= \mathbf{D} + \mathbf{I}, & \mathbf{C} &= \mathbf{I}, & \mathbf{R}(k) &= \mathbf{0} \\ \mathbf{Q} &= E\{ \mathbf{v} \mathbf{v}^T \} \\ \mathbf{P}(k_0) &= E\{ \mathbf{x}(k_0) \mathbf{x}^T(k_0) \} \end{aligned} \tag{5.3.11}$$

dann erhält man aus (5.3.6) die Filtergleichung

$$\hat{\mathbf{x}}(k+1, k) = \mathbf{A}(k) \hat{\mathbf{x}}(k, k-1) + \mathbf{K}(k) \{ \mathbf{y}(k) - \mathbf{C}(k) \hat{\mathbf{x}}(k, k-1) \} \tag{5.3.12}$$

mit der Verstärkungsmatrix gemäß (5.3.7a)

$$\mathbf{K}(k) = \mathbf{A}(k) \mathbf{P}(k) \{ \mathbf{P}(k) + \mathbf{R}(k) \}^{-1} = \mathbf{A}(k)$$

Also lautet die Filtergleichung mit $\mathbf{K} = \mathbf{D}$ und $\mathbf{C} = \mathbf{I}$:

$$\hat{\mathbf{x}}(k+1, k) = \mathbf{A}(k) \hat{\mathbf{x}}(k, k-1) + \mathbf{A}(k) \{ \mathbf{y}(k) - \hat{\mathbf{x}}(k, k-1) \} = \mathbf{A}(k) \mathbf{y}(k) \quad (5.3.13)$$

Dies bedeutet, daß die Schätzung $\hat{\mathbf{x}}$ an der Stelle $k+1$ sich aus dem Beobachtungswert an der Stelle k berechnen läßt.

In diesem Falle hat man die gleiche Aussage wie beim Differenzenverfahren. Dies resultiert im wesentlichen aus der Bedingung

$$\mathbf{C} = \mathbf{I} \quad \text{und} \quad \mathbf{R}(k) = \mathbf{0} \quad (5.3.14)$$

und ist unabhängig von $\mathbf{Q}(k)$ und $\mathbf{P}(k_0)$.

Man betrachte nun eine Erweiterung des Modells 1 in folgender Form:

Die Rauschkomponenten im Beobachtungssystem seien als maximale relative Fehler gegeben (z.B. $w(k) = 0.1$) Dann ist

$$\mathbf{R} = \mathbf{E} \{ \mathbf{w}_k \mathbf{w}_k^T \} \neq \mathbf{0} \quad (5.1.15)$$

\mathbf{C} sei weiterhin die Identität.

Dann gilt für die Verstärkungsmatrix \mathbf{K} :

$$\mathbf{K}(k) = \mathbf{A}(k) \mathbf{P}(k) \{ \mathbf{P}(k) + \mathbf{R}(k) \}^{-1} \quad (5.3.16)$$

In diesem Modell ist also die Verstärkungsmatrix \mathbf{K} von \mathbf{A} verschieden.

Erst mit der Bedingung $\mathbf{R} \neq \mathbf{0}$ geht die Größe $\mathbf{P}(k)$ in die Filtergleichungen ein.

Bemerkung:

Mindestens eine der Bedingungen $\mathbf{R} \neq \mathbf{0}$ oder $\mathbf{C} \neq \mathbf{I}$ muß erfüllt sein, damit das Kalmanfilter eine echte Erweiterung des deterministischen Modells ist.

Über die Beobachtungsmatrix \mathbf{C} lassen sich vom Reaktorsystem her keine Aussagen machen. Man

identifiziert die Zustandsgrößen mit den Beobachtungsgrößen. Erst $\mathbf{R} \neq \mathbf{0}$ bewirkt eine optimale Filterung gegenüber dem deterministischen Modell. Ist die Kovarianzmatrix $\mathbf{R} = \mathbf{0}$, so sind beide Modelle identisch. Insbesondere bei der reinen Prognose sind nicht nur die Aussagen, sondern auch die Verfahren gleich, da keine Korrektur durch die Beobachtungsgrößen angesetzt wird. Ist nun $\mathbf{R} \neq \mathbf{0}$, so liefern die Filtergleichungen eine Korrektur, und durch die Überwachung des Fensters ergibt sich ein anderer Startwert für die reine Prognose. Damit ändern sich auch die Abweichungen für spätere Zeitpunkte.

5.4 Das Berliner Verfahren

Es werden zuerst die Begriffe "stationär" und "schwach stationär" definiert, da sie im folgenden verwendet werden.

Def.1: Ein stochastischer Prozeß $X = \{ X(k) \}$ heißt stationär (im Sinne von streng stationär) : \Leftrightarrow alle endlich dimensionalen Verteilungsfunktionen sind invariant gegenüber Zeitverschiebungen.

Def. 2: Ein stochastischer Prozeß $X = \{ X(k) \}$ heißt schwach stationär (oder auch stationär von zweiter Ordnung) \Leftrightarrow

- 1) $E \{ X(k) \} = \mu$
- 2) die Kovarianzfunktion hängt nur von der Differenz $h := k - s$ ab, d.h. es gilt:
 $\gamma (h) = \text{cov} (X(k+h) , X(k))$ für beliebige h .

Bemerkung: Es gelten folgende Beziehungen (/2/ S 211):

- a) X ist streng stationär $\Rightarrow X$ ist schwach stationär
- b) X ist schwach stationär und ein Gauß-Prozeß $\Rightarrow X$ ist stationär

Bei dem Berliner Verfahren handelt es sich um einen Regressionsansatz für instationäre stochastische Prozesse. Das Modell des instationären Prozesses bestehe aus einem stationären Anteil, der von einer systematischen additiven Störgröße überlagert ist.

Modellansatz: $y(k) = T(k) + X(k)$ (5.4.1)

Die beobachtete Zeitreihe $y(k)$ ist additiv zusammengesetzt aus einer Trendkomponente T und einem Rauschanteil X . X sei schwach stationär. Für die Trendkomponente werde ein polynomialer Ansatz vom Grad d gemacht

$$T(k) = \sum_{i=0}^d a_i k^i = a_0 + a_1 k + \dots + a_d k^d \quad (5.4.2)$$

Bemerkung:

Aus der Darstellung

$$y(k) = \sum_{i=0}^d a_i k^i$$

erhält man über die z-Transformation

$$y(z) = \sum_{i=0}^d a_i z \frac{z^{i-1} + \dots}{(z-1)^{i+1}} = \sum_{i=0}^d a_i z \frac{f_i(z)}{(z-1)^{d+1}}$$

mit Polynomen f_i in z . Faßt man den den Zähler zusammen, so erhält man die Darstellung

$$y(z) = \sum_{i=0}^d z \frac{b_i z^i}{(z-1)^{d+1}}$$

Dies ist für $d+1 = n$ die Darstellungsform (5.1), wobei die Koeffizienten des Nennerpolynoms fest sind und in den b_i die zu schätzenden Größen enthalten sind.

Es werden jeweils die Daten aus einem gleitenden Stützbereich zur Berechnung verwendet. Das begleitende Intervall sei I_k mit m Stützstellen.

Es sei $I_k = \{k+1, k+2, \dots, k+m\}$ mit $k = 0, 1, \dots$

Mit

$$F_k := \begin{bmatrix} 1 & k+1 \dots & (k+1)^d \\ 1 & k+2 \dots & (k+2)^d \\ \dots & \dots & \dots \\ 1 & k+m \dots & (k+m)^d \end{bmatrix} \tag{5.4.3}$$

ist der KQ - Schätzer zu berechnen für

$$y(k) = F_k a \quad \text{mit } a = (a_0, a_1, \dots, a_d)^T \tag{5.4.4}$$

Im Falle $d = 1$ hat man für $k = 0$

$$F_0 = \begin{bmatrix} 1 & 1 \\ \dots & \dots \\ 1 & m \end{bmatrix} \quad \text{und somit} \tag{5.4.5}$$

$$\begin{aligned} y(1) &= a_0 + a_1 \\ \dots & \dots \\ y(m) &= a_0 + m \cdot a_1 \end{aligned}$$

Der beste Schätzer für a ist nun mit $F = F_0$ (/2/, S 256)

$$\hat{a} = (F^T \cdot F)^{-1} \cdot F^T \cdot y \tag{5.4.6}$$

Die Dimension des Polynomansatzes geht in F ein. Sie ist zunächst frei wählbar. Die so geschätzten Regressorkoeffizienten gehen als Sekundärmerkmale in die Klassifikation ein.

Bemerkung:

Das Zeitintervall I_k mit den m Stützstellen wird als Überwachungsfenster über den zu beobachtenden Merkmalsraum verschoben.

Im Programm ist das Berliner Verfahren implementiert mit $d = 2$. Eine Erweiterung ist jedoch ohne weiteres möglich.

5.5 ARIMA-Modellierung im Merkmalsraum

Ein weiteres und sehr mächtiges Verfahren bietet die Beschreibung des stochastischen Prozesses durch ein "autoregressives integriertes moving average" (ARIMA) Modell, in dem auch Instationaritäten erfaßt werden. In diesem Kapitel werden zuerst autoregressive (AR-), moving average (MA-) und die gemischte Form der autoregressiven moving average (ARMA-) Modelle vorgestellt. Anschließend werden die Probleme der Stationarität und Instationarität erläutert und der Übergang zum ARIMA-Modell vollzogen. Eigenschaften der Modellparameter und Kriterien zur Modellidentifikation werden angesprochen. In einem Diagramm wird schließlich der Programmablauf logisch festgelegt. Es wird der Bezug zu der übergeordneten Systemdarstellung angegeben.

Im folgenden seien mit $k, k-1, \dots$ die diskreten Zeitintervalle bezeichnet. $y(k), y(k-1), \dots$ sind die dazugehörigen Funktionswerte des Prozesses, in unserem Falle die eindimensionalen Komponenten der Merkmalsvektoren im Merkmalsraum der statistischen Kenngrößen.

$\tilde{y}(k) = y(k) - \mu$ seien die zentrierten Werte.

Mit $\varepsilon(k)$ sei stets weißes Rauschen bezeichnet.

Autoregressives Modell der Ordnung p: AR(p)

Def 1: Ein AR(p) - Prozeß wird dargestellt

$$\tilde{y}(k) = \sum_{i=1}^p \Phi_i \tilde{y}(k-i) + \varepsilon(k) \quad (5.5.1)$$

wobei $\varepsilon(k)$ weißes Rauschen mit $E\{\varepsilon(k)\} = 0$ und der Varianz σ^2 ist.

In diesem AR - Modell der Ordnung p sind p+2 Unbekannte. ($\Phi_1, \dots, \Phi_p, \sigma^2, \mu$)

Dieser unbekannt Parametersatz ist aus der Vergangenheit zu schätzen.

Moving average Modell der Ordnung q : MA(q)

Def. 2: Ein MA(q) - Prozeß hat die Darstellung

$$\tilde{y}(k) = \varepsilon(k) + \sum_{j=1}^q \Theta_j \varepsilon(k-j) \quad \text{bzw.} \quad \sum_{j=0}^q \Theta_j \varepsilon(k-j) \quad \text{mit } \Theta_0 = 1 \quad (5.5.2)$$

mit $\varepsilon(k)$ weißes Rauschen.

Autoregressives moving average Modell der Ordnung p,q : ARMA(p,q)

Def. 3: Ein ARMA(p,q) - Prozeß hat die Darstellung

$$\tilde{y}(k) = \sum_{i=1}^p \Phi_i \tilde{y}(k-i) + \varepsilon(k) + \sum_{j=1}^q \Theta_j \varepsilon(k-j) \quad (5.5.3)$$

In diesem Modell müssen die $p+q+2$ Parameter $\Phi_1, \dots, \Phi_p, \Theta_1, \dots, \Theta_q, \sigma^2, \mu$ aus dem gegebenen Datenmaterial geschätzt werden.

Schreibt man den ARMA(p,q) - Prozeß in der Form

$$-\sum_{i=0}^p \Phi_i \tilde{y}(k-i) = \sum_{j=0}^q \Theta_j \varepsilon(k-j) \quad \text{mit } -\Theta_0 = 1, -\Phi_0 = 1$$

und benutzt man die Verschiebeeigenschaft der z - Transformation, so gilt

$$\left(\sum_{i=0}^p -\Phi_i z^{n-i} \right) \tilde{y}(z) = \left(\sum_{i=0}^q \Theta_i z^{n-i} \right) \varepsilon(z)$$

und somit für $b_i = -\Phi_{p-i}, a_i = \Theta_{q-i}$

$$\tilde{y}(z) = \frac{\sum_{i=0}^q a_i z^i}{\sum_{i=1}^p b_i z^i} \varepsilon(z)$$

was für $p = q = n$ und $\varepsilon = u$ genau die Darstellung (5.1) ist.

Bemerkung:

1. Vernachlässigt man beim reinen AR - Prozeß die Rauschkomponente $\varepsilon(k)$, so hat man die Darstellung wie bei der Linearen Vorhersage mit $\Phi_i = -\alpha_i$
2. Ein MA - Prozeß der endlichen Ordnung q ist stets schwach stationär mit der Autokorrelationsfunktion (im folgenden mit AKF bezeichnet) (/2/ S 217)

$$\rho(h) = \frac{\sum_{j=0}^{q-h} \Theta_j \Theta_{j+h}}{\sum_{j=0}^q \Theta_j^2} \quad \text{für } 0 \leq h \leq q \quad (5.5.4)$$

Die AKF ist 0 für $h > q$.

Parameterschätzung aus den Yule Walker Gleichungen

Es sollen aus dem AR(p) - Modell die Parameter Φ_1, \dots, Φ_p geschätzt werden. Ausgangsmodell ist

$$\tilde{y}(k) = \sum_{i=1}^p \Phi_i \tilde{y}(k-i) + \varepsilon(k) \quad (5.5.5)$$

Durch Multiplikation mit $\tilde{y}(k-h)$ und Erwartungswertbildung erhält man

$$\gamma(h) = \sum_{i=1}^p \Phi_i \gamma(h-i) + \sigma^2 \quad \text{für } h > 0 \quad (5.5.6)$$

$$\gamma(0) = \sum_{i=1}^p \Phi_i \gamma(i) + \sigma^2 \quad \text{für } h = 0 \quad (5.5.7)$$

Zwischen γ bzw. ρ und den Parametern Φ_i gelten folgende Beziehungen:

- a) Aus γ bzw. ρ lassen sich die Φ_i berechnen
- b) Aus Φ_i kann man γ bzw. ρ berechnen gemäß

$$\begin{bmatrix} 1 & \rho(1) & \dots & \rho(p-1) \\ \rho(1) & 1 & & \rho(p-2) \\ \dots & \dots & \dots & \dots \\ \rho(p-1) & \rho(p-2) & & 1 \end{bmatrix} \cdot \begin{bmatrix} \Phi_1 \\ \Phi_2 \\ \dots \\ \Phi_p \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \dots \\ \rho(p) \end{bmatrix} \quad (5.5.8)$$

oder in Matrixschreibweise $\mathbf{R}_p \cdot \Phi_p = \rho_p$

Allgemeine Bedeutung der ARMA(p,q) - Prozesse

Der AR(p) - Prozeß modelliert eine Zeitreihe, in der ein momentaner Wert funktional linear aus p früheren Zeitreihenwerten, mit gewissen Faktoren Φ_i gewichtet, hervorgeht.

Der MA(q) - Prozeß (Prozeß der gleitenden Durchschnitte) findet oft Verwendung, wenn ein im Gleichgewicht befindlicher Zustand von additiven Störgrößen überlagert ist, die als weißes Rauschen mit der Zeit abklingen.

Ein ARMA - Prozeß beinhaltet beide Modellierungen: wenn z.B. bei einem AR - Prozeß die Störung selbst ein MA - Prozeß ist. Da ein MA - Prozeß stets schwach stationär ist, richtet sich die Frage nach der schwachen Stationarität eines ARMA - Prozesses nur nach dem AR- Anteil. Um Instationaritäten zu beseitigen, werden ARIMA - Modelle eingeführt.

Autoregr. integrierter moving average Prozeß der Ordnung (p,d,q) : ARIMA(p,d,q)

Def 4 Ein stochastischer Prozeß $Y(k)$ heißt ARIMA(p,d,q) - Prozeß, wenn es ein d gibt mit

$$\nabla^d Y(k) \text{ ist ein ARMA - Prozeß} \quad (5.5.9)$$

Hierbei ist

$$\begin{aligned} \nabla^1 Y(k) &= Y(k) - Y(k-1) \\ \nabla^2 Y(k) &= (Y(k) - Y(k-1)) - (Y(k-1) - Y(k-2)) \\ &\dots \end{aligned}$$

Durch den Operator ∇^d wird ein polynomialer Trend der Ordnung d-1 ausgeglichen um schwache Stationarität zu erreichen. In der Praxis genügt meist $d < 3$.

Die Bestimmung der Modellparameter geschieht im wesentlichen über die Berechnung der AKF und der partiellen Autokorrelationsfunktion (PAKF).

Bemerkung zur AKF und PAKF

Als Schätzfunktion für die AKF dient $\rho(h)$ mit $\rho(h) = \gamma(h) / \gamma(0)$ und $\gamma(h)$ wie folgt:

$$\gamma(h) = \frac{1}{n} \sum_{k=1}^{n-h} \tilde{y}(k) \tilde{y}(k+h) \quad (5.5.10)$$

Da bei sehr großem h die Schätzung ungenau wird, sollte $h \leq n/3$ nicht überschreiten.

Das Yule Walker GL.system

$$\begin{bmatrix} 1 & \rho(1) & \dots & \rho(h-1) \\ \rho(1) & 1 & & \rho(h-2) \\ \dots & \dots & \dots & \dots \\ \rho(h-1) & \rho(h-2) & & 1 \end{bmatrix} \cdot \begin{bmatrix} \Phi_{h1} \\ \Phi_{h2} \\ \dots \\ \Phi_{hh} \end{bmatrix} = \begin{bmatrix} \rho(1) \\ \rho(2) \\ \dots \\ \rho(h) \end{bmatrix} \quad (5.5.11)$$

oder in Matrixschreibweise $\mathbf{R}_h \cdot \Phi(h) = \rho_h$

hängt vom Parameter h ab, und die Lösung des Systems liefert eine Folge $\Phi_{11}, \Phi_{22}, \dots, \Phi_{hh}$. Die Folge (Φ_{hh}) heißt partielle Autokorrelationsfunktion (PAKF). Der Koeffizient Φ_{hh} gibt die Korrelation zwischen $\tilde{y}(k)$ und $\tilde{y}(k-h)$ nach Bereinigung des linearen Zusammenhanges in den anderen $\tilde{y}(k-i)$ an.

Kriterien zur Modellidentifizierung:

Ein Vergleich von (5.5.11) $\mathbf{R}_h \cdot \Phi(h) = \rho_h$ mit (5.5.8) $\mathbf{R}_p \cdot \Phi_p = \rho_p$ zeigt, daß für einen AR(p)-Prozeß gilt: $\Phi_p = \Phi_{pp}$

Außerdem ist für $h > p$ ein AR(p)-Prozeß ein AR(h)-Prozeß mit $\Phi_{p+1} = \Phi_{p+2} = \dots = \Phi_h = 0$.

Daraus folgt:

Ein AR(p)-Prozeß ist charakterisiert durch Abbrechen der PAKF. $\Phi_{hh} = 0$ ($h > p$)

Bricht die PAKF nicht ab, so handelt es sich um einen MA- bzw einen ARMA-Prozeß, da ein MA-Anteil vorhanden ist.

Es gilt: (/2/ S 238, /1/ S 264)

- a) $X \sim \text{AR}(p)$: $\rho(h)$ ist abklingend und $\Phi_{hh} = 0$ für $h > p$
- b) $X \sim \text{MA}(q)$: Φ_{hh} ist abklingend und $\rho(h) = 0$ für $h > q$
- c) $X \sim \text{ARMA}(p,q)$: Es gilt a) und b)

Anhand von $\rho(h)$ und Φ_{hh} wird auf das entsprechende Modell geschlossen.

Kriterien zur Stationarität, Instationarität

Die Frage nach der Stationarität des Prozesses im Sinne von schwach stationär kann alleine mit dem AR - Anteil entschieden werden, da der MA - Anteil immer schwach stationär ist.

Wir definieren eine Polynomfunktion mit

$$\Phi(\zeta) = 1 - \Phi_1 \zeta - \Phi_2 \zeta^2 - \dots - \Phi_p \zeta^p \text{ mit den Koeffizienten } \Phi_1, \dots, \Phi_p \text{ des ARMA - Modells.}$$

Analog sei $1 + \Theta_1 \zeta + \Theta_2 \zeta^2 + \dots + \Theta_q \zeta^q$ ein Polynom mit $\Theta_1, \dots, \Theta_q$ aus dem ARMA-Modell.

Sei nun B ein Verschiebeoperator mit $B \tilde{y}(k) = \tilde{y}(k-1)$

$$B^2 \tilde{y}(k) = \tilde{y}(k-2) \text{ usw.}$$

und setzt man den Operator B in das Polynom Φ ein, erhält man als Operatorpolynom

$\Phi(B) = 1 - \Phi_1 B - \dots - \Phi_p B^p$, welches angewendet auf $\tilde{y}(k)$ genau den AR - Prozeß $\Phi(B) \tilde{y}(k) = \varepsilon(k)$ beschreibt.

Stationaritätsbedingung für ARMA - Prozesse (/2/ S 221):

$\tilde{y}(k)$ ist stationär \Leftrightarrow Alle Nullstellen des Polynoms $\Phi(\zeta)$ liegen außerhalb des Einheitskreises (Insbesondere ist bei einem AR(1) - Prozeß $|\Phi_1| < 1$) $\Leftrightarrow \tilde{y}(k)$ ist lineares Filter und kann geschrieben werden

$$\tilde{y}(k) = \sum_{j=0}^{\infty} \psi_j \varepsilon(k-j) =: \psi(B) \varepsilon(k-j) \text{ mit } \sum_{j=0}^{\infty} \psi_j^2 < \infty \quad (5.5.12)$$

wobei das Polynom ψ auf den Verschiebeoperator angewendet wird.

Koeffizientenberechnung:

a) Ersetzt man für einen reinen AR - Prozeß das $\tilde{y}(k)$ durch obige Form (5.5.12), so erhält man

$\Phi(B) \tilde{y}(k) = \varepsilon(k)$ bzw. $\Phi(B) \psi(B) \varepsilon(k) = \varepsilon(k)$. Also gilt:
 $\Phi(B) \psi(B) = 1$. Daraus folgt die Berechnung der ψ_i .

b) Für einen ARMA - Prozeß werden die ψ_i berechnet durch Koeffizientenvergleich des Polynoms:

$$\Phi(B) \psi(B) = \Theta(B).$$

In beiden Fällen sind die Φ_i und die Θ_j gegeben.

Eine für die Praxis wichtige Aussage ist folgende:

Invertierbarkeitsbedingung:

Sei $\tilde{y}(k)$ stationär und alle Nullstellen von Θ liegen außerhalb des Einheitskreises, dann ist $\tilde{y}(k)$ darstellbar als AR (∞) - Prozeß (/2/ S 224)

Diese Darstellung erlaubt es, im Merkmalsraum über die AKF und PAKF signifikant von 0 verschiedene Werte zur Modellbildung zu verwenden.

Programmstruktur zur ARIMA - Modellierung mit Parametern (p,d,q)

In Abb. 5.5.1 wird die Vorgehensweise zur adäquaten Modellierung skizziert.

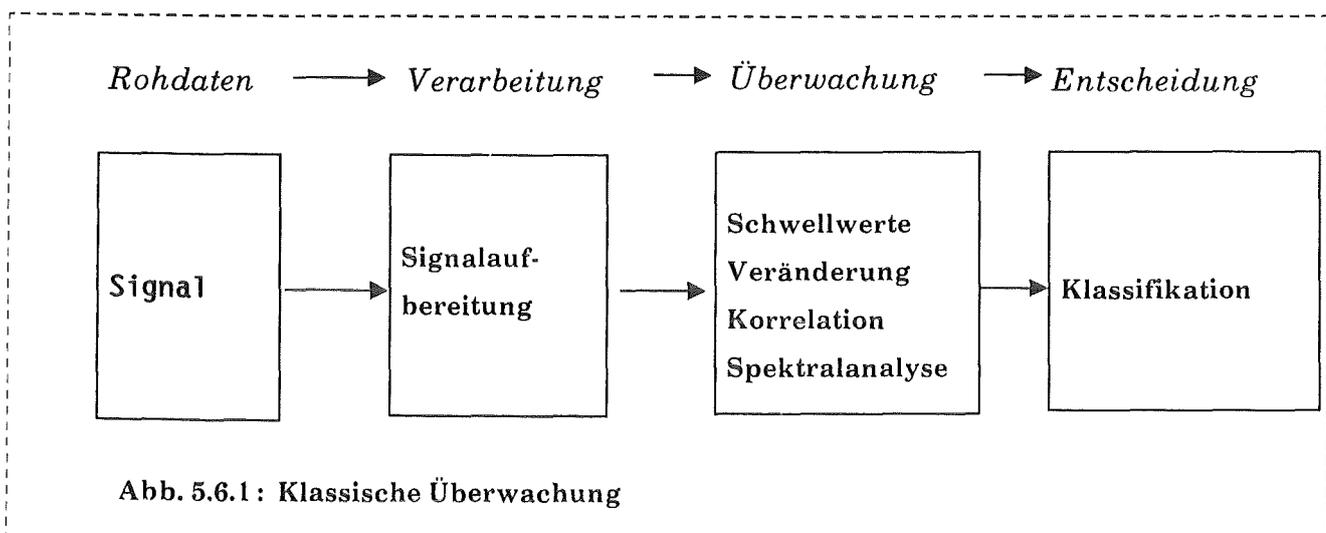
Ausgehend von den Merkmalen (Primärmerkmale), die die Zeitreihe darstellen, werden Modell- und Prozeßparameter geschätzt, welche die Struktur des Signals wiedergeben (Sekundärmerkmale). Diese können später als Zusatzinformation in den Klassifikationsprozeß einfließen. Die Größen p, q, d werden iterativ bestimmt.

Die Abb. 5.5.2 zeigt die Iterationsschleifen zur Dimensionierung der Größen p, d und q.

5.6 Anwendung der Prognoseverfahren

In dieser Arbeit wird die Schadensfrüherkennung unter dem Aspekt des Prognostizierens betrachtet. Als Beispiel einer Störung dient ein Experiment, in dem lokales Sieden simuliert wird. Da es Prozesse gibt, die sehr schnell propagieren, ist es wichtig, Fehlverhalten und erste Anzeichen schon früh richtig zu interpretieren, sodaß eine entsprechende Maßnahme getroffen werden kann. Es wird aufgezeigt, wie dieser Interpretations- und Entscheidungsprozeß durch Anwendung von Prognoseverfahren und Trendanalyse im Merkmalsraum durchgeführt werden kann.

Betrachtet man ein herkömmliches Überwachungssystem, so läßt sich der Informationsfluß wie in folgender Abb. 5.6.1 darstellen.



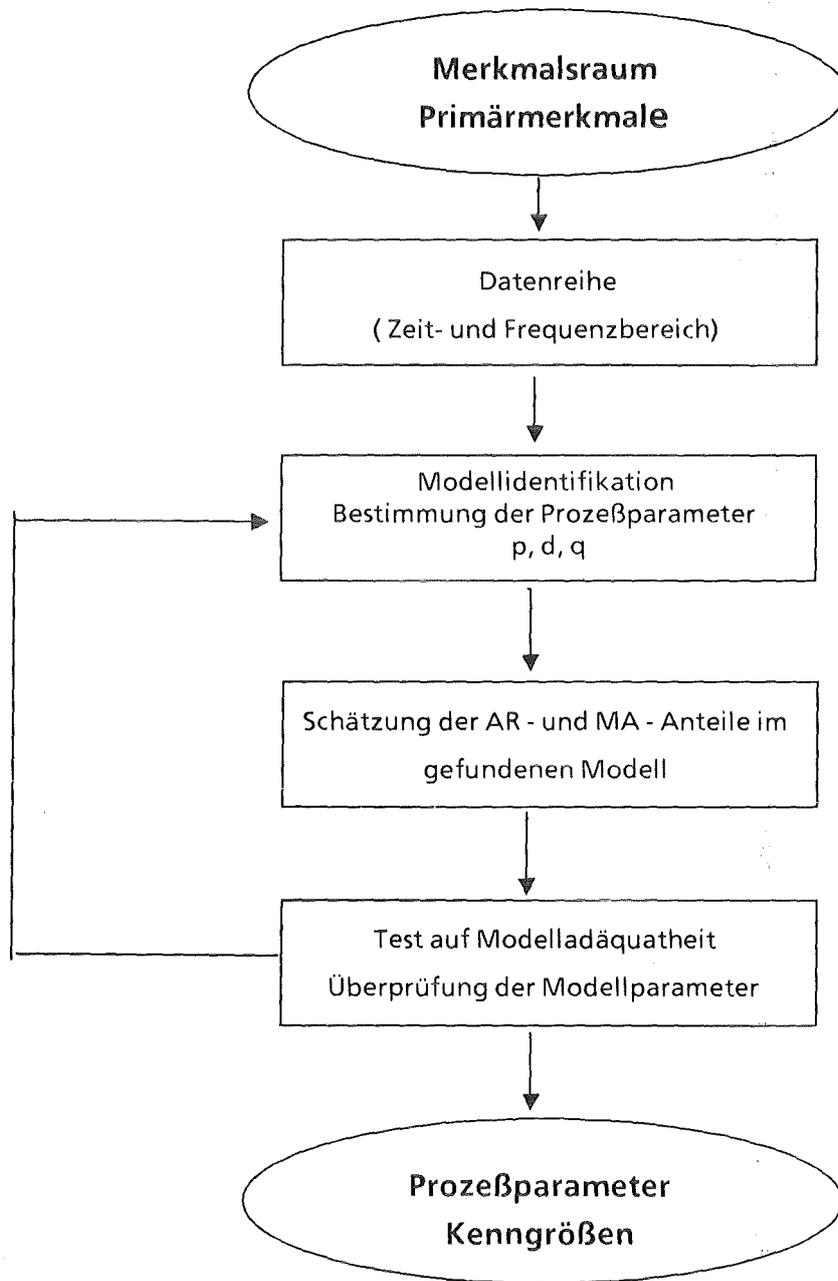


Abb. 5.5.1 : Programmstruktur zur ARIMA - Modellierung

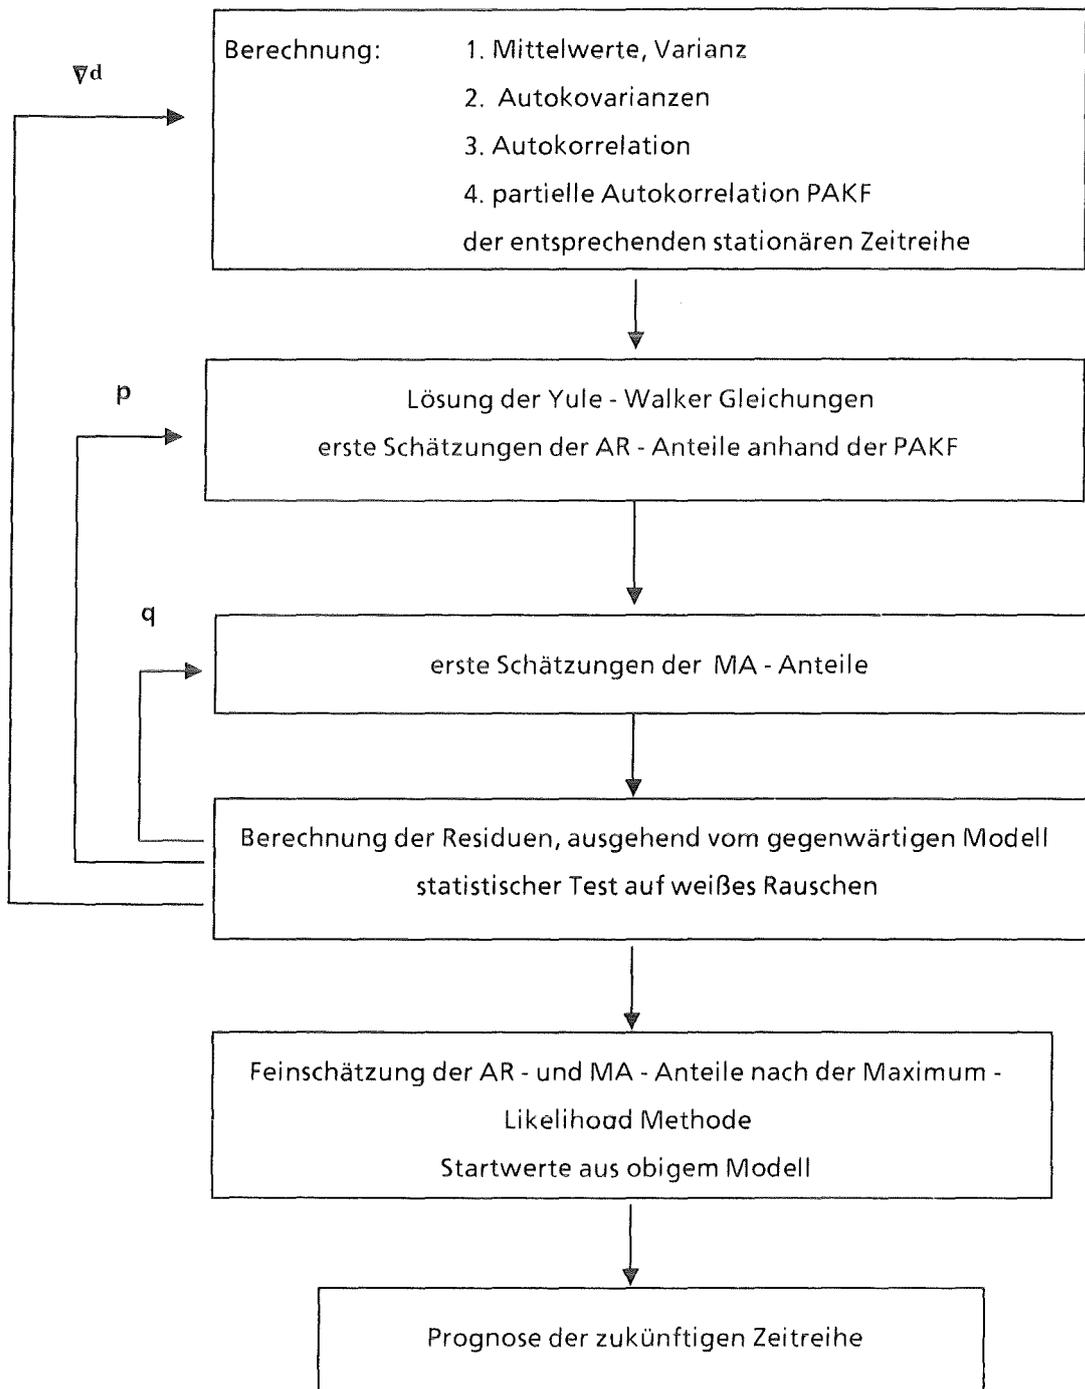


Abb.5.5.2: Iterative Dimensionierung des ARIMA - Modells

Die Zeit, die vom Auftreten des Schadens bis zu seiner Erkennung vergeht, hängt von mehreren Randbedingungen ab, z.B. von der Aufbereitung und Art der Merkmale. Auch der Klassifikationsprozeß ist nicht trivial und zeitintensiv. Eine a priori Ausnutzung der im Voraus abgeschätzten Information kann man mit Hilfe von Prognoseverfahren und Trendanalyse erreichen. Nach einer Berechnung der für den jeweiligen Anwendungsfall relevanten Kenngrößen werden im Merkmalsraum mathematische Modelle erstellt, die den beobachteten Prozeß beschreiben. Es werden nicht nur die Kenngrößen überwacht, sondern das Modell, repräsentiert durch seine Parameter, ist charakteristisch für den Prozeßzustand. Man hat eine parametrische Prozeß - bzw. Signal- beschreibung. Diese Prozeßparameter haben direkten Einfluß auf das zukünftige Verhalten. In diesem Sinne kann, ausgehend vom parametrischen Modell, eine Prognose des zeitlichen Verhaltens der Kenngrößen angegeben werden. Die Prognose vollzieht sich im Merkmalsraum, nicht auf Signalebene. Diese Tatsache ermöglicht die Ausdehnung des Klassifikationsprozesses auf die prognostizierten Merkmale. Es kann also bereits eine Entscheidungsfindung vorweggenommen werden, und die aus dem überwachten Signal berechneten Merkmale gehen nachträglich nur noch in eine schnelle Ja-Nein Entscheidung ein.

Es werden die einzelnen Verfahren vorgestellt und am Experiment des lokalen Siedens eingesetzt. An der Klassifikation sind im wesentlichen zwei Typen von Merkmalen beteiligt, zum einen prognostizierte Primärmerkmale- dies sind die gemäß dem mathematischen Modell vorausberechneten statistischen Kenngrößen- und zum anderen die Modellparameter selbst als Sekundärmerkmale.

Anwendung der einzelnen Verfahren:

Da kein a priori Wissen vorhanden ist, welches Modell den Prozeßverlauf im Merkmalsraum am besten beschreibt, werden mit verschiedenen Ansätzen unterschiedliche Aspekte betont und daraus die Modelle abgeleitet. Alle im folgenden vorgestellten Methoden operieren im Merkmalsraum. Die Merkmalsextraktionsstufe ist abgeschlossen und es steht der für die Klassifikation relevante dimensionsreduzierte Merkmalsraum im Zeit- und Frequenzbereich zur Verfügung.

1. Bei der Linearen Vorhersage wird mit dem Ansatz

$$\hat{y}(k) = - \sum_{v=1}^m \alpha_v y(k-v) \quad (5.6.1)$$

die momentane Merkmalsvektorkomponente $y(k)$ aus den m vorangehenden mit den linearen Gewichten α_v geschätzt. In einer Einstellungsphase werden die α_v durch ein Optimierungskriterium ermittelt: Der erwartete Fehler für die Summe der quadratischen Abweichungen sei minimal. Diese so berechneten α_v beschreiben dann das Modell. Ausgehend von ihnen werden die Prognosewerte berechnet. m ist zunächst frei wählbar, beeinflusst aber das Ergebnis.

2. Ein weiterer Prognoseansatz wird über die Modellbildung einer Differenzgleichung erzielt. Ausgehend von einem Satz Beobachtungswerten im n -dimensionalen Merkmalsraum wird eine n -dimensionale Differenzgleichung erster Ordnung angesetzt.

$$y(k+1) - y(k) = \mathbf{D} y(k) + \mathbf{b} \tag{5.6.2}$$

mit noch unbekanntem Modellparametern \mathbf{D} und \mathbf{b} .

Durch Berechnung der Merkmalsvektoren und ihrer Differenzen in einem Beobachtungsintervall werden \mathbf{D} und \mathbf{b} mit dem Verfahren der kleinsten Fehlerquadrate geschätzt. Bei einer ständigen Überwachung werden durch eine fortlaufende Verschiebung des Beobachtungsfensters im Merkmalsraum die Parameter \mathbf{D} und \mathbf{b} stets angepaßt. Somit beziehen sich die aus dem parametrischen Modell prognostizierten Werte immer auf den letzten aktuellen Prozeßzustand. Die Prognosewerte werden gemäß $y(k+1) = \mathbf{A} y(k) + \mathbf{b}$ berechnet mit $\mathbf{A} = \mathbf{D} + \mathbf{I}$.

$$\tag{5.6.3}$$

3. Ein dritter Ansatz zur Prognose von Merkmalsvektoren wird im Berliner Verfahren modelliert. Mit einer Rauschkomponente $X(k)$ und einer Trendkomponente $T(k)$ des stochastischen Prozesses wird durch den Ansatz $y(k) = X(k) + T(k)$ ein Polynom vom Grad d angesetzt, um den Merkmalsverlauf zu approximieren. Die Modellparameter a_j werden nach der Methode der kleinsten Quadrate geschätzt.

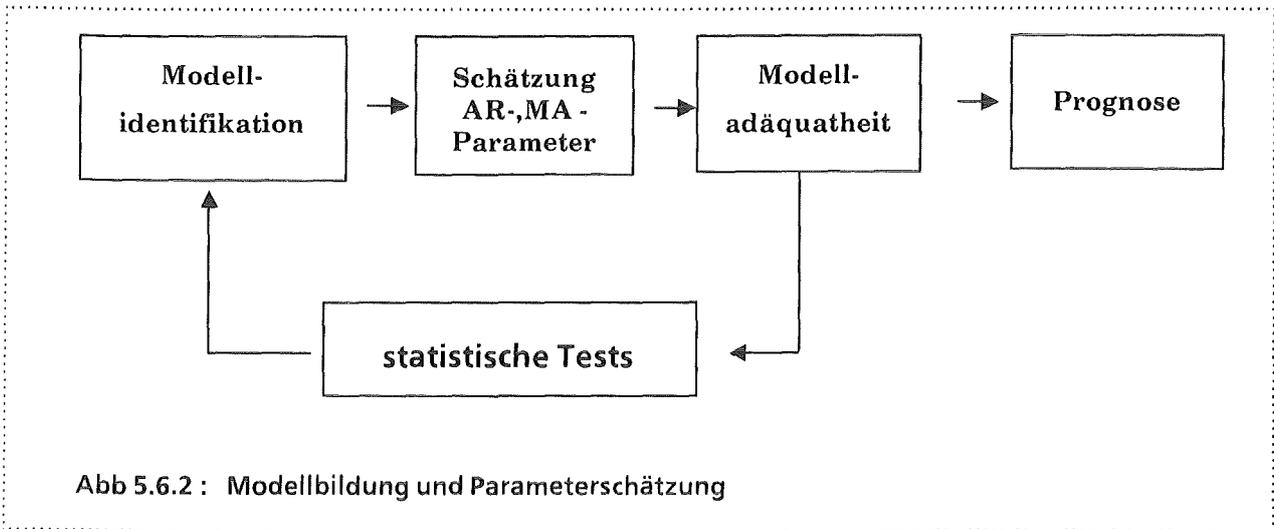
Einen Schätzer für \mathbf{a} in $y(k) = \mathbf{F}_k \cdot \mathbf{a}$ erhält man mit $\hat{\mathbf{a}} = (\mathbf{F}^T \mathbf{F})^{-1} \mathbf{F}^T \mathbf{Y}$. (5.6.4)

4. Ein mächtiges Werkzeug zur Modellierung stochastischer Prozesse bieten die ARIMA - Modelle.

$$\tilde{y}(k) = \sum_{i=1}^p \Phi_i \tilde{y}(k-i) + \sum_{j=0}^q \Theta_j \varepsilon(k-j) \quad \text{mit } \Theta_0 = 1 \tag{5.6.5}$$

Nach Elimination der Instationaritäten mit einem Differenzenoperator ∇^d werden die autoregressiven Anteile (AR- Anteile) und die moving average Anteile (MA - Anteile) geschätzt. Als

Beobachtungsgrößen dienen die berechneten Primärmerkmale. Die Modellbildung wird nach folgender Abb 5.6.2 vollzogen:



Folgende Tabelle gibt eine Zusammenfassung der Verfahren, der den Prozeß im Merkmalsraum darstellenden Rechenmodelle und der relevanten Sekundärmerkmale.

<u>Verfahren</u>	<u>Rechenmodell</u>	<u>Sekundärmerkmale</u>
<i>Lineare Vorhersage</i>	$y(k) = - \sum_{v=1}^m \alpha_v y(k-v)$	α_v
<i>Differenzenverfahren</i>	$y(k+1) = A y(k) + b$	A, b
<i>Berliner Verfahren</i>	$y(k) = X(k) + T(k) \text{ mit } T(k) = \sum_{i=0}^d a_i k^i$	a_i
<i>ARIMA – Modellierung</i>	$y(k) = \sum_{i=1}^p \Phi_i y(k-i) + \sum_{j=0}^q \Theta_j \varepsilon(k-j)$	Φ_i, Θ_j

Alle vier Verfahren gehen gleichzeitig in den Klassifikator während der Überwachung.

Die Verfahren basieren auf unterschiedlichen Ansätzen und bieten bei Paralleleinsatz bessere Entscheidungsmöglichkeiten. Im Sinne der Schadensfrüherkennung ist vor allem Punkt 2 von Bedeutung. Bei einer "explosiven" Propagation des Störfalles wird im Merkmalsraum die Zustandsdarstellung über die Differenzgleichung den Prozeß sehr gut beschreiben gegenüber einem linear gewichteten. Für die Darstellung eines lokal linearen Trends sorgt der konstante Vektor \mathbf{h} .

Es zeigt sich, daß alle vier Prognoseverfahren in einem gewissen Toleranzbereich ähnliche Werte voraussagen. Die Prognosewerte sind noch abhängig von der Fensterlänge und der Verschiebungslänge des Überwachungsfensters sowie der Prognoselänge (Zeitraum der Prognose).

In diesem Kapitel wurden verschiedene Ansätze gemacht, wie man ein parametrisches Signalmodell im Merkmalsraum simulieren kann, welches das vorgegebene Datenmaterial in seiner Struktur zum einen beschreibt und auch Aussagen über den künftigen Verlauf im Merkmalsraum macht. Die Merkmale werden prognostiziert und können in einen Klassifikator schon vor Eintreten der Ereignisse eingegeben werden.

Als weitere Wissensbasis über das System können die Modellparameter selbst als Sekundärmerkmale dienen.

6. Merkmalsbewertungen

6.1 Gütekriterien für statistisch unabhängige Merkmale

Da die Detektion der zu erkennenden Störfälle (hier sind es Siedezustände) neben einem adäquaten Klassifikatormodell auch noch von einer guten Merkmalsgenerierung abhängt, soll hier untersucht werden, nach welchen Kriterien Merkmale gefunden werden können, die eine möglichst gute Entscheidbarkeit, d.h. Klassenseparierung zulassen. Die Prognoseverfahren in Kapitel 5 waren merkmalsunabhängig und können daher auf alle Merkmale angewendet werden.

Da es keine Möglichkeit gibt, von vornherein die für das Problem besten typischen Merkmale zu finden, besteht nur die Möglichkeit, mit heuristischen Verfahren zunächst eine genügend große Obermenge zu erzeugen, die dann entsprechend einer Bewertung in optimaler Weise reduziert wird. Bei unserem Problem der akustischen Siedererkennung hat man es mit eindimensionalen stochastischen Signalen zu tun, sodaß statistische Parameter als den Prozeß beschreibende Größen geeignet erscheinen. Eine Menge solcher Merkmale wurde in Kapitel 4 erzeugt. Seien nun zwei Klassen A und B gegeben. Die Klassenrepräsentanten für die Muster der Klassen A bzw. B seien mit den Vektoren \mathbf{m}^A und \mathbf{m}^B bezeichnet. Der Merkmalsvektor \mathbf{m} mit den Komponenten m_v ist dann gut, wenn er die beiden Klassen gut trennt. Dies bedeutet, daß die beiden Klassenwolken möglichst dicht sind (jeweils geringe Streuung der Wolken in sich) und die Zentren weit auseinander liegen. Die Forderung lautet also

$|m_v^A - m_v^B|$ möglichst groß und $\sigma(m_v^A)$ und $\sigma(m_v^B)$ möglichst klein.

Insgesamt können wir als Maß für die Güte eines Merkmals einführen

$$G_v = \frac{|m_v^A - m_v^B|}{\sigma_A^2 + \sigma_B^2} \quad (6.1.1)$$

Je größer das Maß G_v ist, um so bessere Trennbarkeit der Cluster ist erreicht.

6.2 Bewertung für korrelierte Merkmale

Das oben eingeführte Maß gilt für skalare Merkmale bzw. für die Komponenten eines Merkmalsvektors separat. Wenn die einzelnen Merkmale nicht unabhängig sind, wird die Korrelation

untereinander in Form einer Kovarianzmatrix berücksichtigt. Als Erweiterung des Maßes G_v hat man dann im n-dimensionalen Fall:

$$G = (\mathbf{m}^A - \mathbf{m}^B)^T \cdot \frac{1}{2} (\mathbf{K}_A + \mathbf{K}_B)^{-1} (\mathbf{m}^A - \mathbf{m}^B) \quad (6.2.1)$$

mit \mathbf{m}^A und \mathbf{m}^B als Clusterschwerpunkte und \mathbf{K}_A , \mathbf{K}_B als Kovarianzmatrizen bzgl. der Klassen A und B, jeweils bei gleich vielen Mustern in A und B.

T bezeichnet den transponierten Vektor.

Die inverse Kovarianzmatrix stellt die Erweiterung der Division durch die Streuung dar.

6.3 Anwendung auf KNS - Signale

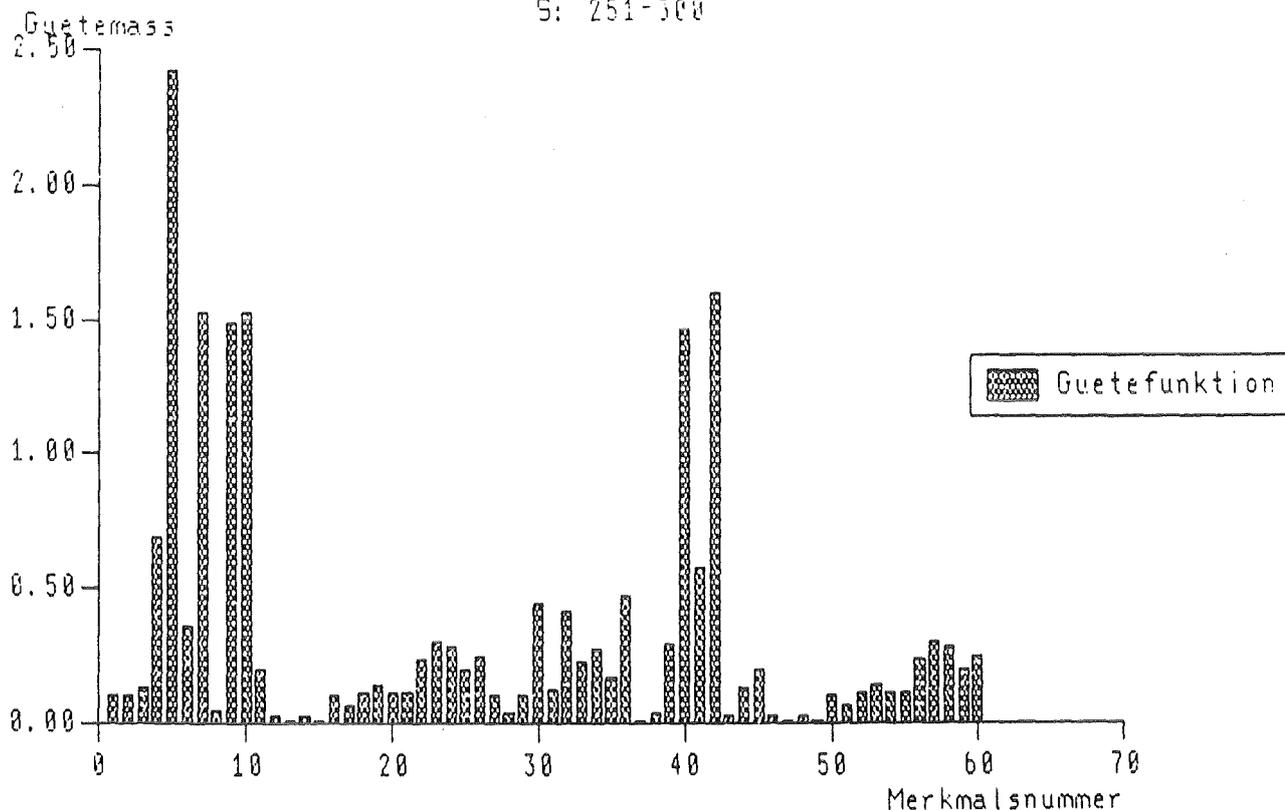
Die in Kapitel 4 generierten Merkmale werden zunächst alle bezüglich ihrer Separierbarkeit überprüft und das Maß G berechnet.

Als zu untersuchende Signale wurden aus den KNS-Experimenten drei herausgegriffen, die sich in ihrem Signal/Rauschverhältnis sehr stark unterscheiden. Zur Referenzbildung standen von jedem Signal genügend viele Muster (Größenordnung 100) zur Verfügung. In der folgenden Abbildung 6.3 sind für jedes der drei Signale (0 db, -11 db und -14 db) in Abhängigkeit von verschiedenen Trainingssätzen (bezüglich Anzahl und Bereich der Muster) die besten Merkmale und die entsprechenden Gütemaße angeführt. Für alle Trainingssätze innerhalb eines Signals fällt auf, daß die absoluten Gütemaße, die ein Bewertungsfaktor für das entsprechende Merkmal sind, in Abhängigkeit vom Musterbereich zwar variieren, aber die Merkmale selbst, die als gut eingestuft wurden, auch ihre hohe Güte während dieses Signalverlaufes behalten. Dies entspricht den Güteberechnungen in den Abbildungen 6.4 - 6.6. Man kann also sagen, die Güteverteilung der Merkmale innerhalb eines Signals ist sehr stabil, unabhängig davon, wo man die Trainingsmuster generiert. Andererseits erkennt man sehr deutlich, daß die besten Merkmale von Signal zu Signal unterschiedlich sind. Man beachte dabei, daß in allen drei Signalen das gleiche Nutzsinal steckt. In Abhängigkeit der Rauschanteile verschieben sich also die guten Merkmale. Dies hat große Bedeutung für die späteren Lernmodelle. Geht man in einer ersten Näherung von einer Normalverteilung der Merkmale aus, so zeigt die Abbildung 6.7 sehr anschaulich die Güte der Separierbarkeit anhand des Überlappungsbereiches der beiden Klassen bei der Beurteilung durch ein Merkmal. Es wurden in dieser Abbildung 6.7 bei dem 0 db - Signal das Merkmal Nr 5 (vgl. auch Abb. 6.4) und für das stark verrauschte -14 db - Signal das Merkmal Nr 31 (vgl. auch Abb. 6.6) benutzt.

S/N	NS-S	Musterbereich	max. Güte	Merkmale
0 db	NS S	31-80 251-300	2.4 / 1.5 / 1.5	5 / 40 / 10
0 db	NS S	61-110 281-330	5.7 / 5.1 / 3.2	5 / 40 / 42
0 db	NS S	41-110 261-330	4.8 / 3.1 / 2.5	5 / 40 / 42
0 db	NS S	31-130 251-350	4.0 / 2.9 / 2.3	5 / 40 / 42
-11 db	NS S	31-80 251-300	0.4 / 0.46 / 0.43	4 / 42 / 6
-11 db	NS S	61-110 281-330	1.1 / 1.1 / 1.1 / 0.9	4 / 23 / 26 / 42
-11 db	NS S	41-110 261-330	0.65 / 0.61 / 0.65 / 0.66	4 / 6 / 23 / 42
-11 db	NS S	31-130 251-350	0.55 / 0.58 / 0.45	4 / 42 / 6
-14 db	NS S	31-80 251-300	0.46 / 0.31 / 0.24	31 / 33 / 40
-14 db	NS S	61-110 281-330	0.37 / 0.39 / 0.27 / 0.33	31 / 33 / 40 / 32
-14 db	NS S	41-110 261-330	0.31 / 0.33 / 0.32 / 0.37	30 / 31 / 32 / 33
-14 db	NS S	31-130 251-350	0.52 / 0.31 / 0.39	31 / 32 / 33

Abb. 6.3: Merkmale-Güte Tabelle

0 db
50 Muster
NS: 31-80
S: 251-300



0 db
100 Muster
NS: 31-130
S: 251-350

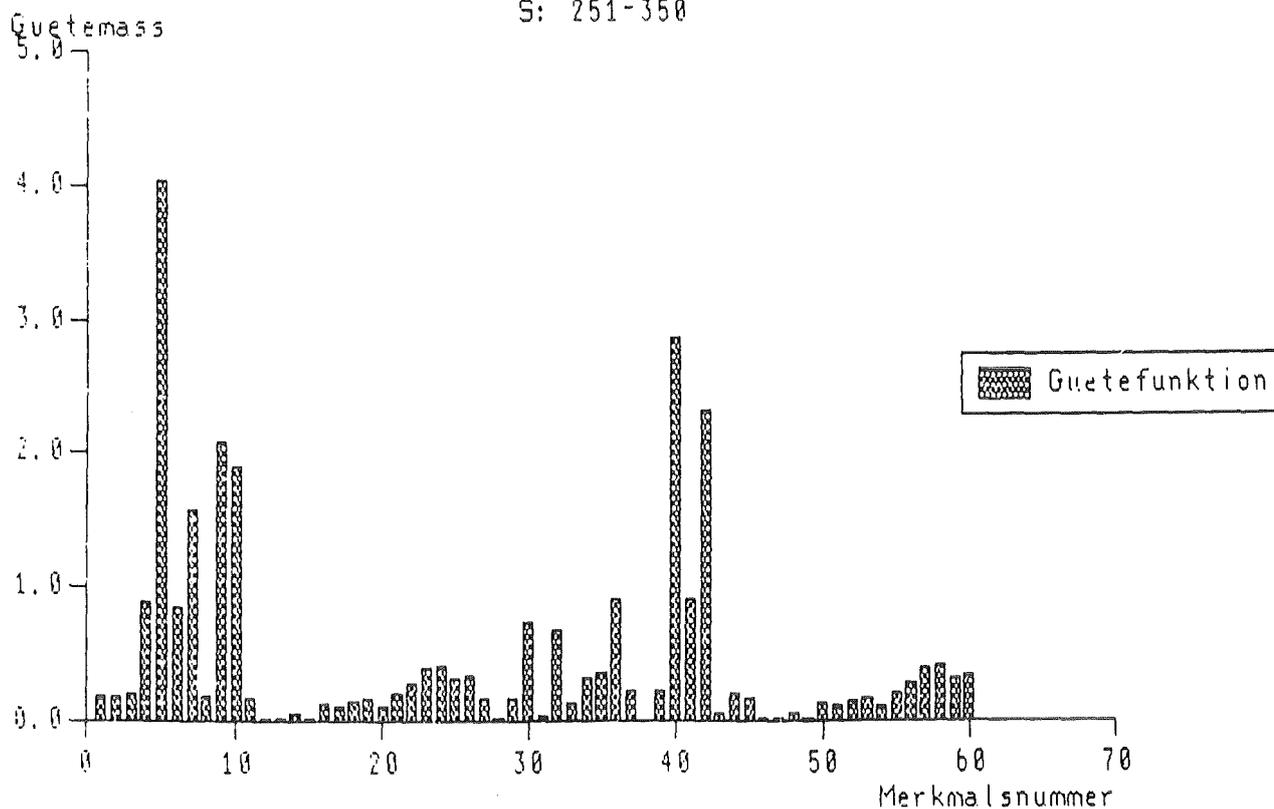
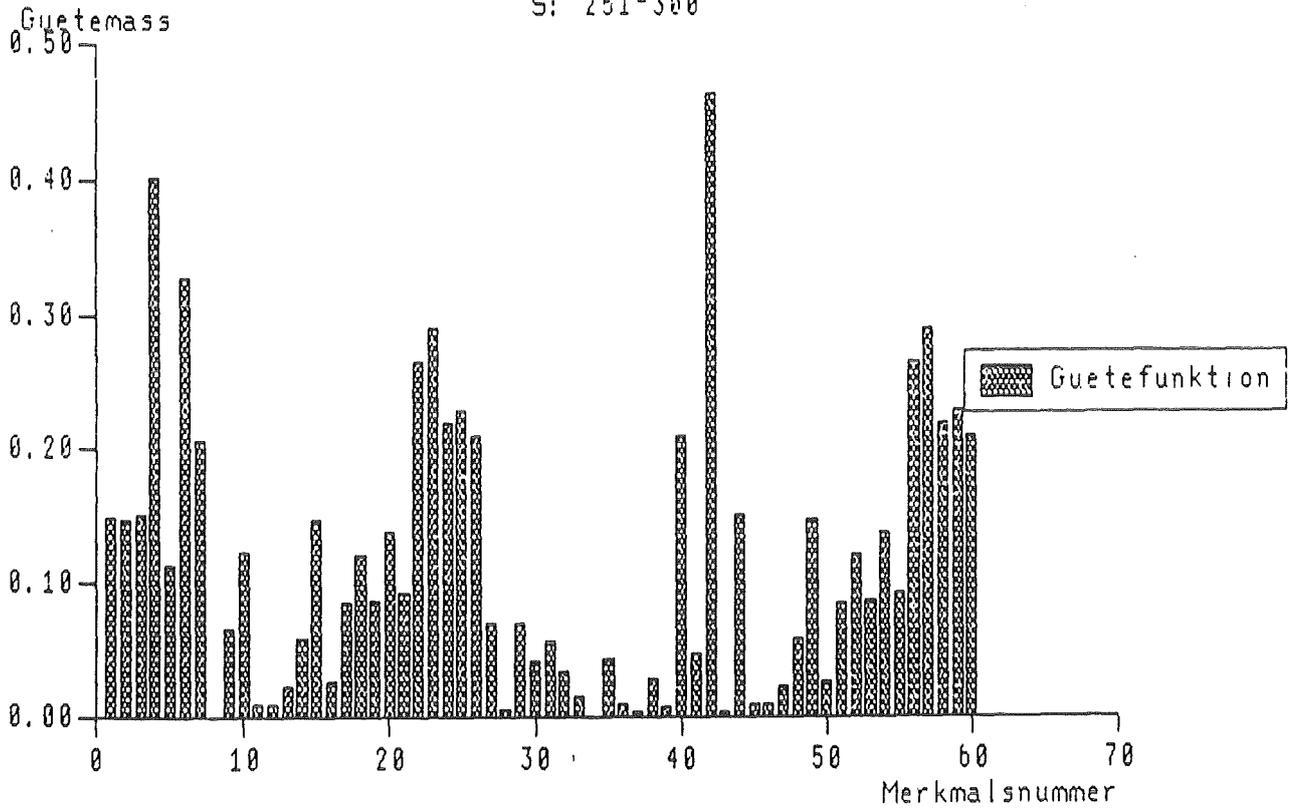


Abb. 6.4: Bewertungsschema; 0 db

-11 db
50 Muster
NS: 31-80
S: 251-300



-11 db
100 Muster
NS: 31-130
S: 251-351

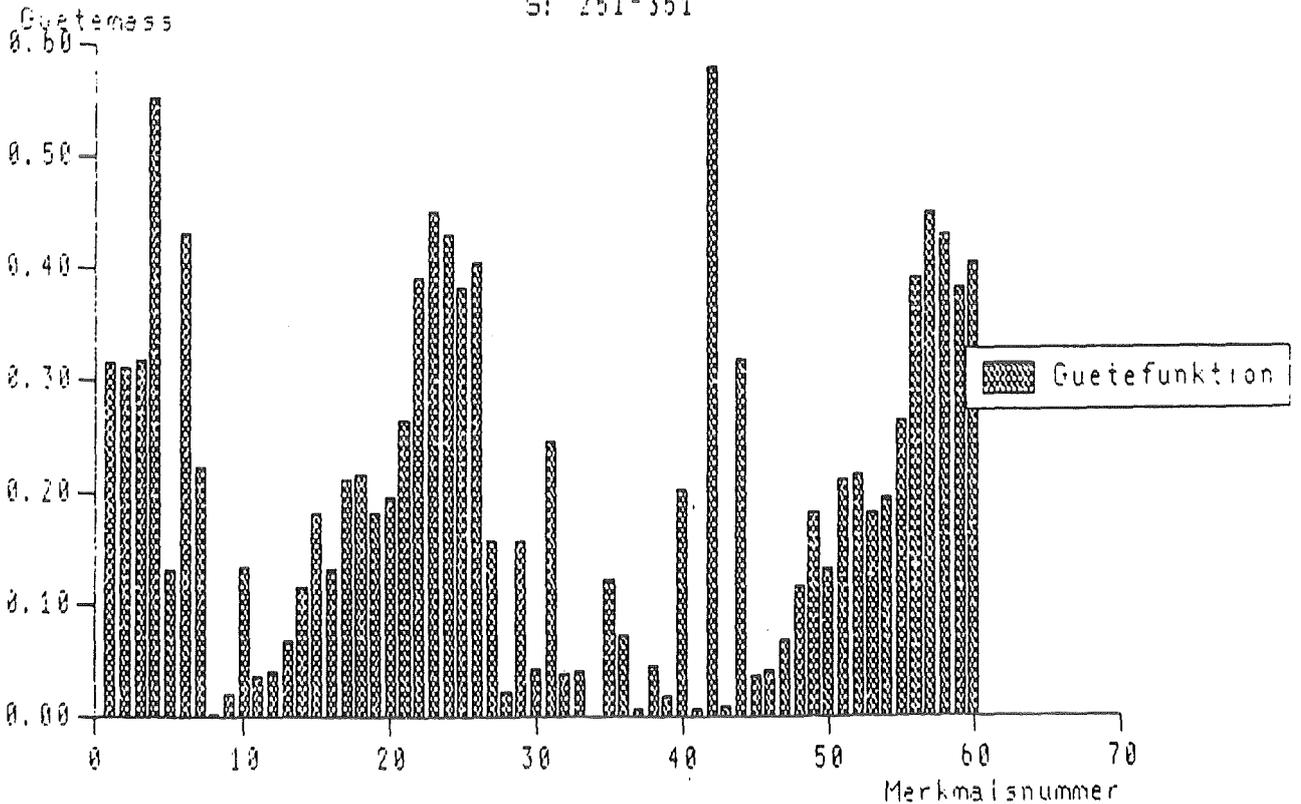
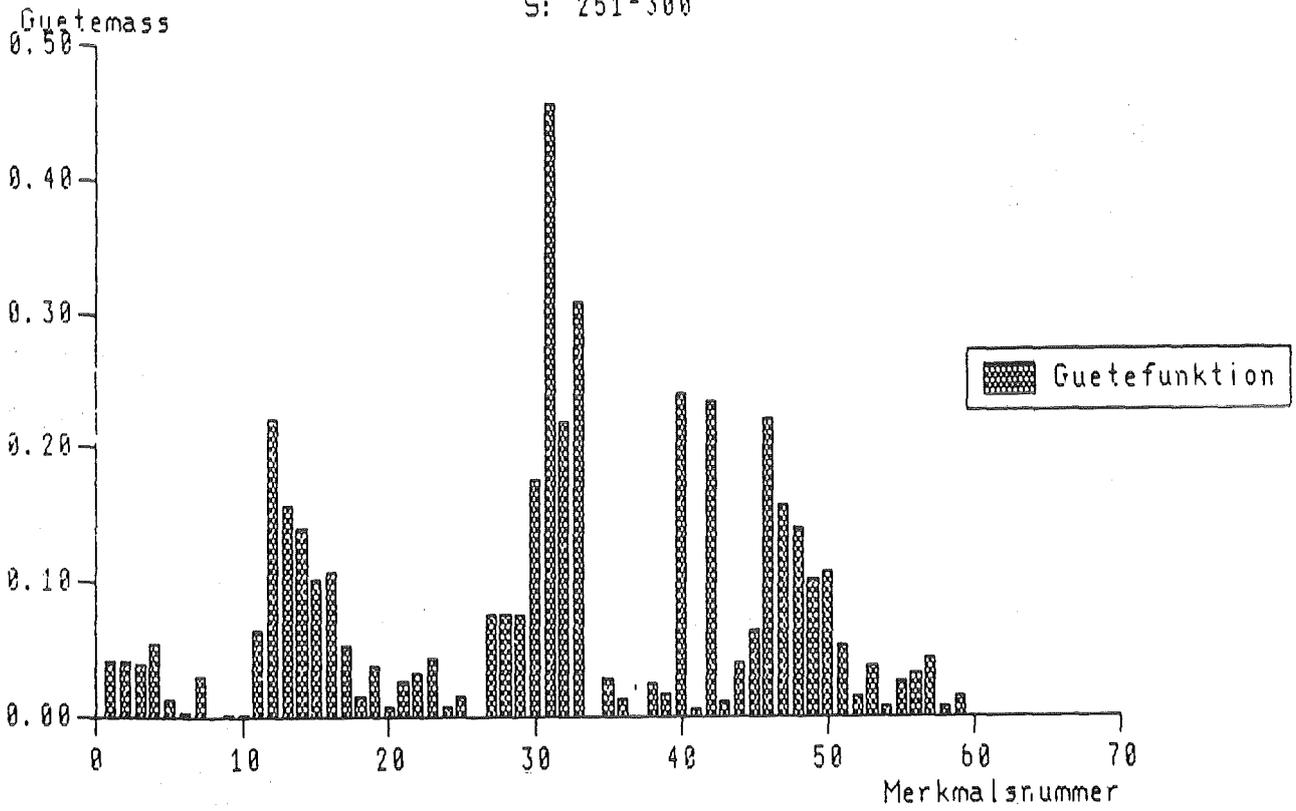


Abb. 6.5: Bewertungsschema; -11 db

-14 db
50 Muster
NS: 31-80
S: 251-300



-14 db
100 Muster
NS: 31-130
S: 251-351

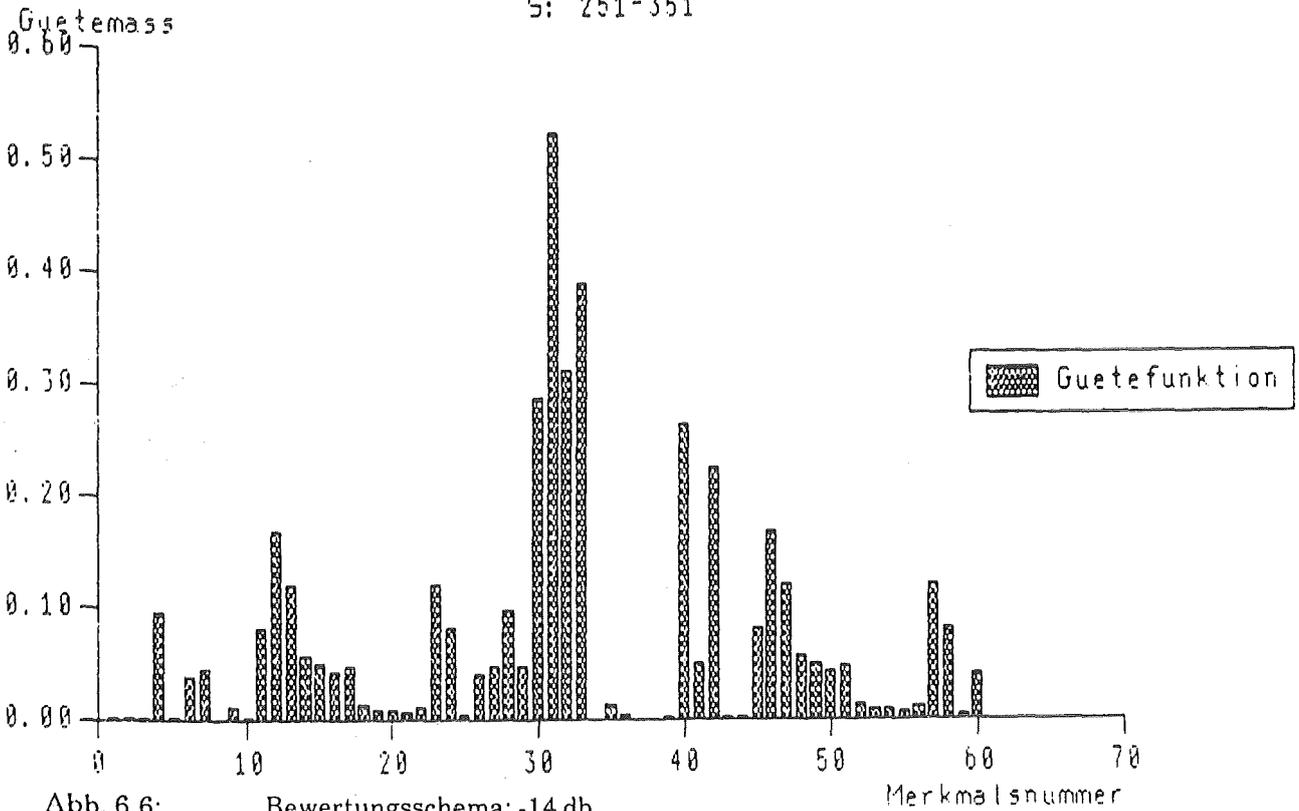
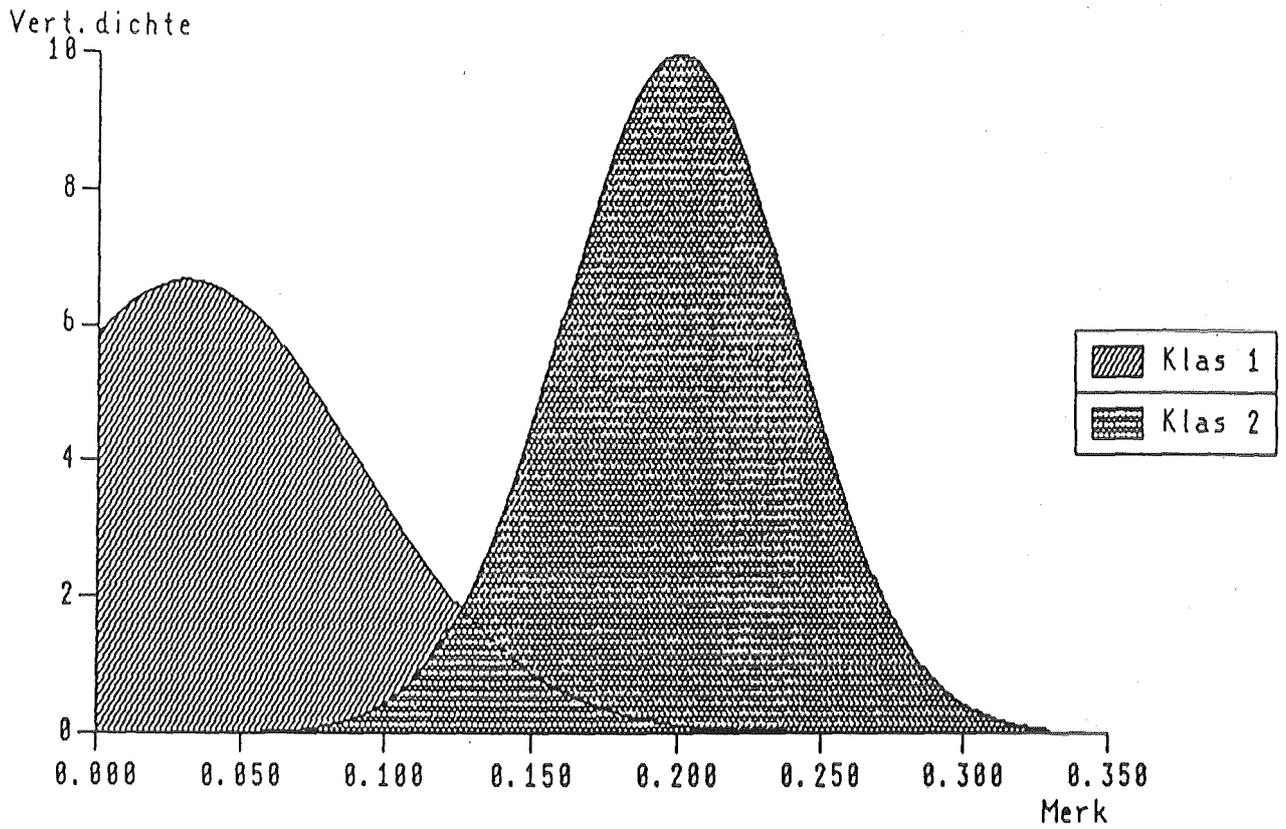


Abb. 6.6: Bewertungschema; -14 db

Gaussvert. des Merkm. 5 bei 0 db.



Gaussvert des opt. Merkm (31) bei -14db

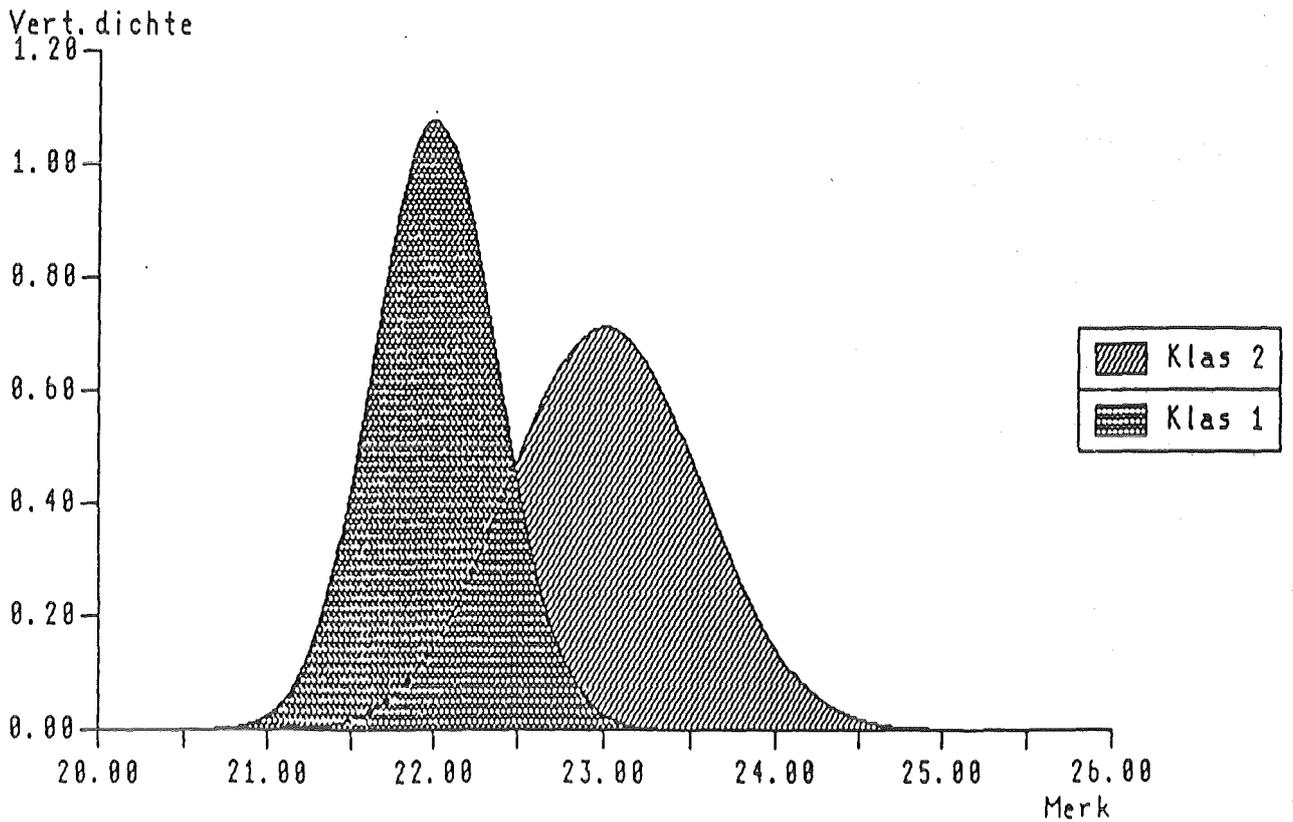


Abb. 6.7: Gaußverteilungen eines Merkmals

7: Lernprozesse

Kapitel 4 hat die Problematik der Merkmalsgenerierung aufgezeigt. Da die Merkmalsfindung im wesentlichen auf Heuristik angewiesen ist, benötigt man Kriterien zu einer Bewertung, um ein Maß für die Güte zu haben.

Diese Bewertung scheint zunächst nur in einem zeitlich lokalen Rahmen zu gelten. Es hat sich bei den Untersuchungen herausgestellt, daß die Güte der Merkmale während der zeitlichen Dauer der Signalüberwachung nicht konstant gut oder schlecht bleibt. Es kann passieren, daß durch Auftreten von neuen S/N Verhältnissen (z.B. bei Änderung von Betriebsgrößen im Reaktor) anfänglich gute Merkmale im Laufe der Zeit schlechter werden, sodaß man dann geeignete Maßnahmen überlegen muß, um eine Separierbarkeit der Musterklassen in ausreichendem Maße zu garantieren.

In diesem Kapitel werden in erster Linie Lernprozesse untersucht. Diese Lernprozesse und Trainingsphasen im Prozeß sind einmal notwendig zur Referenzbildung innerhalb der Klassifizierung, zum andern sollen verschiedene Ausprägungen der Lernphasen untersucht werden, die auch dem Problem einer permanent guten Merkmalsauswahl Rechnung tragen. In diesem Zusammenhang spielen clusteranalytische Verfahren eine bedeutende Rolle. Unter clusteranalytischen Gesichtspunkten werden in den folgenden drei Unterkapiteln die Fragen untersucht, welche Lernprozesse prinzipiell möglich sind, welche Vor- und Nachteile sie haben, wie eine Kombination möglichst die Vorteile verbinden kann und welchen Nutzen sie für die Überwachung innerhalb der Siededetektion haben.

Dabei interessiert beim letzten Fragenkomplex insbesondere, wie man durch einen guten Lernprozeß garantieren kann, daß stets gute Merkmale zur Verfügung stehen aus der Menge der Grundgesamtheit.

7.1. Generierung von Ballungszentren im Merkmalsraum

Dem System stehen a priori zwei Klassen zur Verfügung, Sieden und Nichtsieden, wobei Muster in der Übergangsphase durch die "Nähe" zu der einen oder anderen Klasse ausgedrückt werden. Beide Klassen können als Clusterwolken im n-dimensionalen Merkmalsraum dargestellt werden mit den Parametern \mathbf{m}^A und \mathbf{m}^B als Clusterzentren und σ^A und σ^B als Streuergößen.

Es gilt nun, die Clusterwolken im geometrischen Sinne möglichst weit auseinander und in sich kompakt, also dicht zu halten.

Sowohl in der Trainingsphase (zum Einstellen des Systems,) als auch im späteren Prozeß bei Beobachtung unbekannter Muster müssen die ankommenden Muster nach ihrer Transformation in den Merkmalsraum den einzelnen Clustern zugeteilt werden. Die Zuteilung in der Trainingsphase hängt im wesentlichen davon ab, ob dem System von außen die Klasse und somit das Cluster a priori mitgeteilt wird - wir sprechen dann von einem überwachten Lernprozeß (überwacht durch den Lehrer von außen) - oder ob das System selbst eine Zuordnung vornimmt ohne explizite Überwachung von außen. Wir sprechen dann vom unüberwachten Selbstlernen.

7.2. Überwachtes Lernen - unüberwachtes Selbstlernen

Damit das System bzw. ein Klassifikator überhaupt erst eingestellt werden kann in einer Trainingsphase, bedarf es einer a priori Information über die Klassenzustände von außen. In diesem Sinne ist ein überwachtes Lernen am Anfang sinnvoll. Der Vorteil des überwachten Lernprozesses liegt darin, daß der externe Lehrer Repräsentanten der einzelnen Klassen aussuchen kann um die Klassenstruktur als Referenz vorzugeben. Der Nachteil bei speziell solchen stochastischen Prozessen ist jedoch, daß der externe Lehrer nicht in der Lage ist, reine typische Repräsentanten zu selektieren, da sich die Muster dynamisch im Prozeßverlauf ändern. Bei globaler Zuweisung der Muster in die einzelnen Klassen, wie das bei den stochastischen Signalen in der akustischen Überwachung der Fall ist, können falsche Muster in die vorgegebene Klasse geraten, da man keine abgegrenzten Musterzustände für die eine oder andere Klasse angeben kann. Da viele Zwischenmuster so in die Lernphase einfließen können, da sie von außen nicht zu überwachen sind und somit die Clusterseparierung bzw. die Lage der Clusterwolken verwischen, was einer späteren Klassifizierung unbekannter Muster bestimmt nicht förderlich ist, scheint eine Ergänzung durch eine weitere Lernprozedur, ein unüberwachtes Selbstlernen sinnvoll.

In dieser Arbeit wird eine Kombination beider Lernprozesse eingesetzt.

überwachtes Lernen: globales Herausgreifen der Trainingsmuster aus den intensiven Siede- und Nichtsiedephasen

unüberwachtes Selbstlernen: Selektion von typischen Mustern innerhalb eines Clusters und Bereinigung der Klassen durch hohe Rückweisungsrate.

Durch ein überwachtes Vorlernen stehen dem System zwei Klassen in Form der Cluster (m^A, σ^A) und (m^B, σ^B) zur Verfügung. Das anschließend unüberwachte Selbstlernen dient dann dazu, mit selektierten Mustern neue kompaktere Klassen mit geringerer Streuung zu erzeugen, bzw. falsch zugewiesene Muster in die richtige Clusterwolke zu verschieben. Dabei kann das bekannte Minimaldistanzverfahren als Grundlage dienen mit folgenden Schritten: (/30/ S 107- 118)

- (1) Anfangspartition der Cluster vorgeben (z. B. überwachtes Lernen);
- (2) Klassenschwerpunkte berechnen (m^A, m^B);
- (3) Verschiebung der Elemente in die Klasse gemäß minimalem Abstand z. B.

$$\sum_{k=1}^K \sum_{g_k} | \mathbf{x} - \mathbf{x}_{g_k} |^2 \rightarrow Min \quad (7.2.1)$$

mit K Klassen und \mathbf{x}_{gk} Schwerpunktsvektor der Klasse k;

- (4) Berechnung der neuen Cluster gemäß der neuen Gruppierung;

Man kann zeigen, daß man im Sinne des Varianzkriteriums (/30/ S 107) eine monotone Verbesserung erhält durch diese Strukturierung.

In unserem Anwendungsfall bei der Siededetektion hat sich gezeigt, daß die Cluster der vorgegebenen Siedesignale oft sehr unstrukturiert sind, sodaß weitere spezielle Methoden und Verfahren für die Kompaktifizierung und Bereinigung der Cluster von falschen Mustern angebracht sind.

7.3 Clusterbereinigung und Kompaktifizierung

Hat man im überwachten Vorlernen zwei Cluster für die Klassen generiert, so sind die Gruppenzentroide m^A, m^B und die Streuungen σ^A, σ^B als Vorlage für das anschließende unüberwachte Selbstlernen gegeben. Gerade bei den Siedesignalen können auch beim Lehrer sehr leicht unerwünschte Muster in die falsche Klasse geraten, weil man ganze Bereiche der Siedephase angeben muß und keine partiell isolierten Siedemuster existieren. So sind z.B. in jeder Phase des Siedezustandes (Ansammlung von Bläsenschwingungen und Kollabierungsimpulsen) eine ganze Reihe von Nichtsiedemustern enthalten, umgekehrt können auch im Nichtsiedezustand schon einige Bläsenschwingungen enthalten sein. In einem 2-dimensionalen Merkmalsraum wird das in der Clusterbildung in Abb. 7.3.1. deutlich.

Die beiden Muster M1 und M2 werden vom Lehrer zunächst als den Klassen 1 und 2 entsprechend eingeordnet und demnach die Gruppenzentroide und ihre Streuungen berechnet. Eine gemeinsame Darstellung der beiden Klassen zeigt dann Abb. 7.3.2.

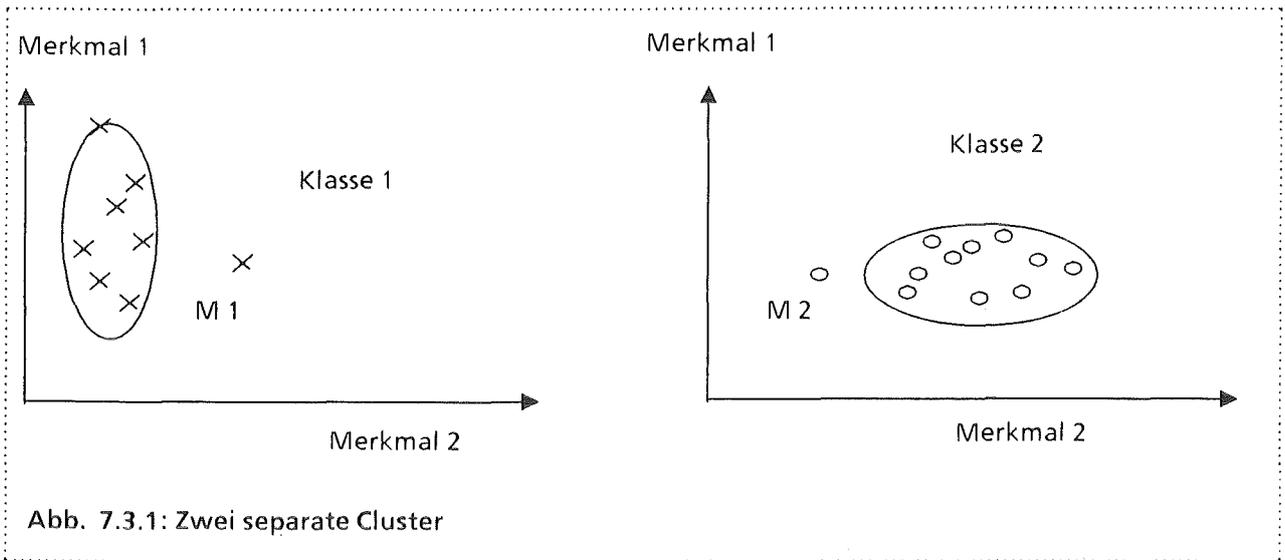


Abb. 7.3.1: Zwei separate Cluster

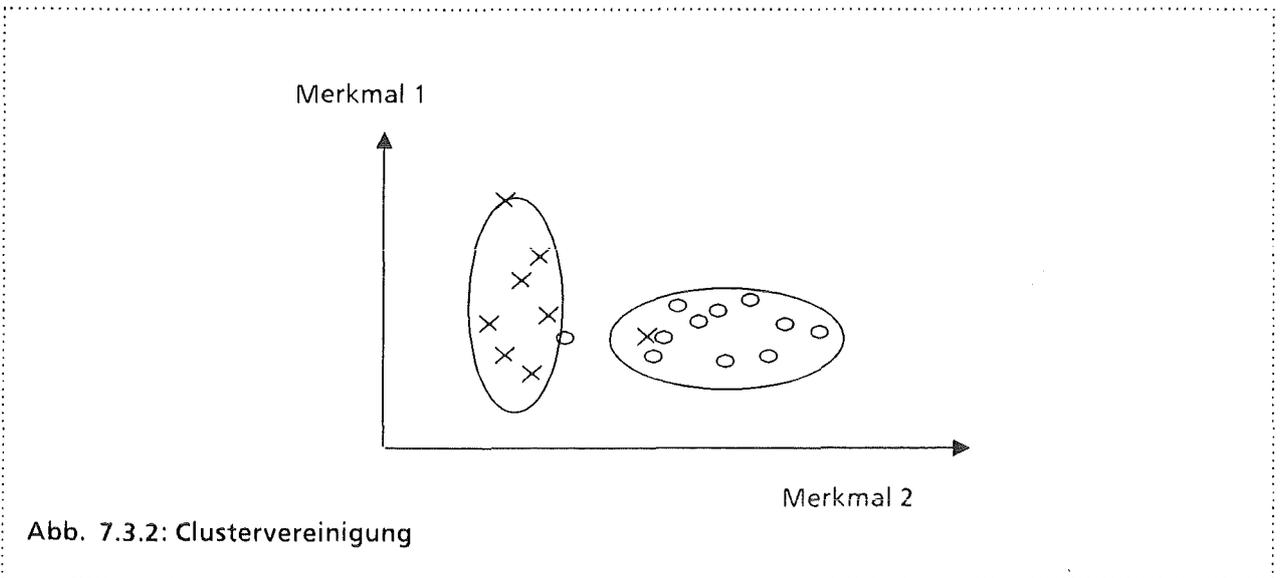


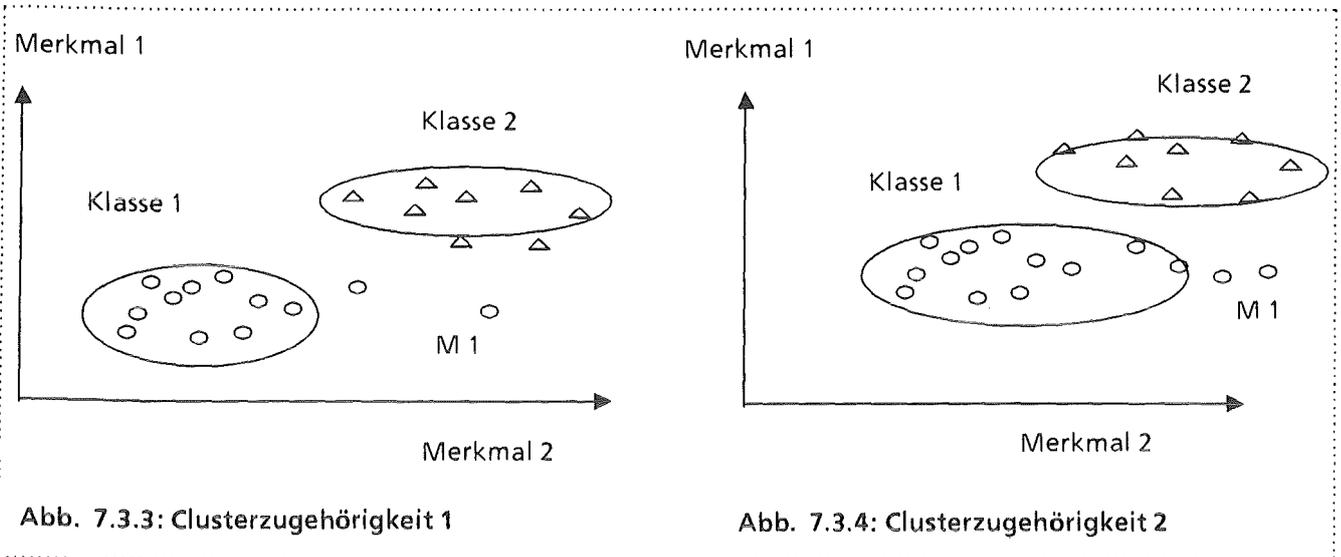
Abb. 7.3.2: Clustervereinigung

Betrachtet man beide Cluster zusammen, so gehört M1 offenbar in die Klasse 2 und M2 in die Klasse 1. Man kann ein Austauschverfahren durchführen, wonach die Gruppenzentroide wieder neu zu berechnen sind.

Eine weitere Möglichkeit, Cluster zu bereinigen und zu kompaktifizieren ist in folgendem Eliminationsverfahren enthalten, wie es auch in dieser Arbeit bei den Siedesignalen Anwendung findet. Die Elimination findet auf der Grundlage statt, daß Muster, die sehr weit abseits vom Cluster liegen, eliminiert werden, unabhängig ob sie bereits einem fremden Cluster zugeordnet wurden

(wie oben gezeigt) oder außerhalb beider Cluster liegen.

Dabei hat sich gezeigt, daß die reine Entfernung des Musters zu den Gruppenzentroiden kein gutes Maß ist. Dies wird in folgenden Abb. 7.3.3 und 7.3.4 verdeutlicht.



Während in Abb. 7.3.3 das Muster M1 eliminiert werden kann, da es weit entfernt ist von beiden Clustern, ist in Abb. 7.3.4 M1 relativ nahe zur Klasse 2 (Der Abstand zum Mittelpunkt der Klasse 2 ist geringer als der zum Mittelpunkt der Klasse 1), darf aber nicht eliminiert werden, da es offenbar zur weitgestreuten Form von Klasse 1 gehört. (Mahalanobisabstand!)

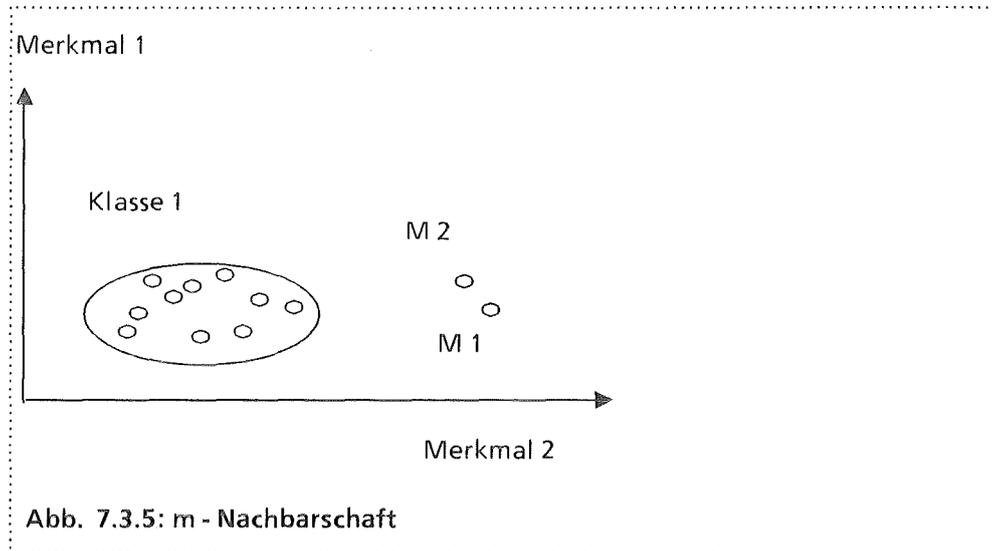
Ein besseres Maß als der absolute Abstand des Musters zum Zentrum ist die Heterogenität des Clusters, d.h. die Isoliertheit des Punktes. Als Maß für die Isoliertheit des Punktes führen wir Abstandsbetrachtungen relativ zu Nachbarpunkten ein.

Kriterium Ein Muster M wird genau dann eliminiert, wenn es zu den übrigen Mustern seines Clusters eine isolierte Lage hat. Dies bedeutet nicht, daß es nur weit entfernt vom Zentrum ist.

Es ist nicht notwendig, diese Betrachtung und Analyse für jeden Punkt des Clusters zu betreiben, sondern es genügt die Berechnung für die Musterpunkte, die außerhalb einer Streubreite (z.B. 1σ) liegen. Damit reduziert sich der Berechnungsaufwand erheblich. Danach ist jedesmal eine Neuordnung der Ballungsgebiete vorzunehmen.

Weiterhin kann nicht nur der Abstand zum nächsten Punkt betrachtet werden, sondern es müssen Gruppennachbarschaften berücksichtigt werden.

Dies wird in folgender Abb. 7.3.5 deutlich:



M1 hat zu seinem nächsten Nachbarn M2 einen geringen Abstand, ebenso M2 zu M1. Erst durch Berücksichtigung der 2-, 3- oder $m > 3$ Nachbarschaft erhalten M1 und M2 große Abstandsbeträge und werden demnach als isoliert angesehen und eliminiert. Für die Elimination wird folgende Strategie festgelegt:

Für jedes Muster x außerhalb des 1σ -Bereichs suche die m nächsten Nachbarn x_1, x_2, \dots, x_m (m fest vorgegeben)

$$\text{Ist } \sum_{i=1}^m d(x, x_i) > m \cdot (\bar{d} + \sigma) \tag{7.3.1}$$

dann eliminiere das Muster x .

Dabei ist N die Anzahl der Muster im Cluster und \bar{d} der mittlere Abstand zweier Nachbarn voneinander.

Beim unüberwachten Selbstlernen werden bei den Siedemustern diejenigen eliminiert, die nach obigem Kriterium als isolierte Gruppe auftreten. Es ist leicht einzusehen, daß eine Elimination aufgrund einer m -Nachbarschaft auch eine Elimination aufgrund einer $(m + 1)$ -Nachbarschaft nach sich zieht, aber umgekehrtes gilt nicht. Dies bedeutet, möglicherweise greift erst ein etwas größeres m , falls mehrere zu eliminierende Punkte in einer engen Nachbarschaft liegen.

Allerdings muß m im Verhältnis zur Clusterelementzahl N klein bleiben. In unserem Anwendungsfall wurde $m=3$ bei $N = 50$ gewählt.

In den Abbildungen 7.3.6 - 7.3.8 sind die Clusterstrukturen vor und nach der entsprechenden Bereinigung dargestellt und zwar für verschiedene Merkmale und für verschiedene Trainingsbereiche, jedoch bei gleicher Anzahl von 50 Mustern pro Klasse in dem 0 db - Signal.

Abb. 7.3.6 zeigt Nichtsiedemuster aus dem Bereich Block 20 - 70 und Siedemuster aus dem Bereich Block 200 - 250. Als Merkmale werden hier die Nr. 20 und Nr.24 benutzt. Der Bereinigungseffekt wirkt offensichtlich.

In Abb. 7.3.7 wurde das gleiche Verfahren eingesetzt. Die Nichtsiedemuster entstammen dem Bereich Block 40 - 90, die Siedemuster dem Bereich 280 - 330. Als Merkmale wurden hier die Nr 1 und Nr.42 benutzt.

In Abb. 7.3.8 wurden die gleichen Merkmale wie in 7.3.7 benutzt, jedoch sind die Muster näher der Übergangsphase entnommen im Bereich Block 120 - 170 für die Nichtsiedemuster und Block 175 - 225 für die Siedemuster. Im Gegensatz zur Abbildung 7.3.7 spielt in diesem Falle der Bereinigungseffekt eine viel bedeutendere Rolle.

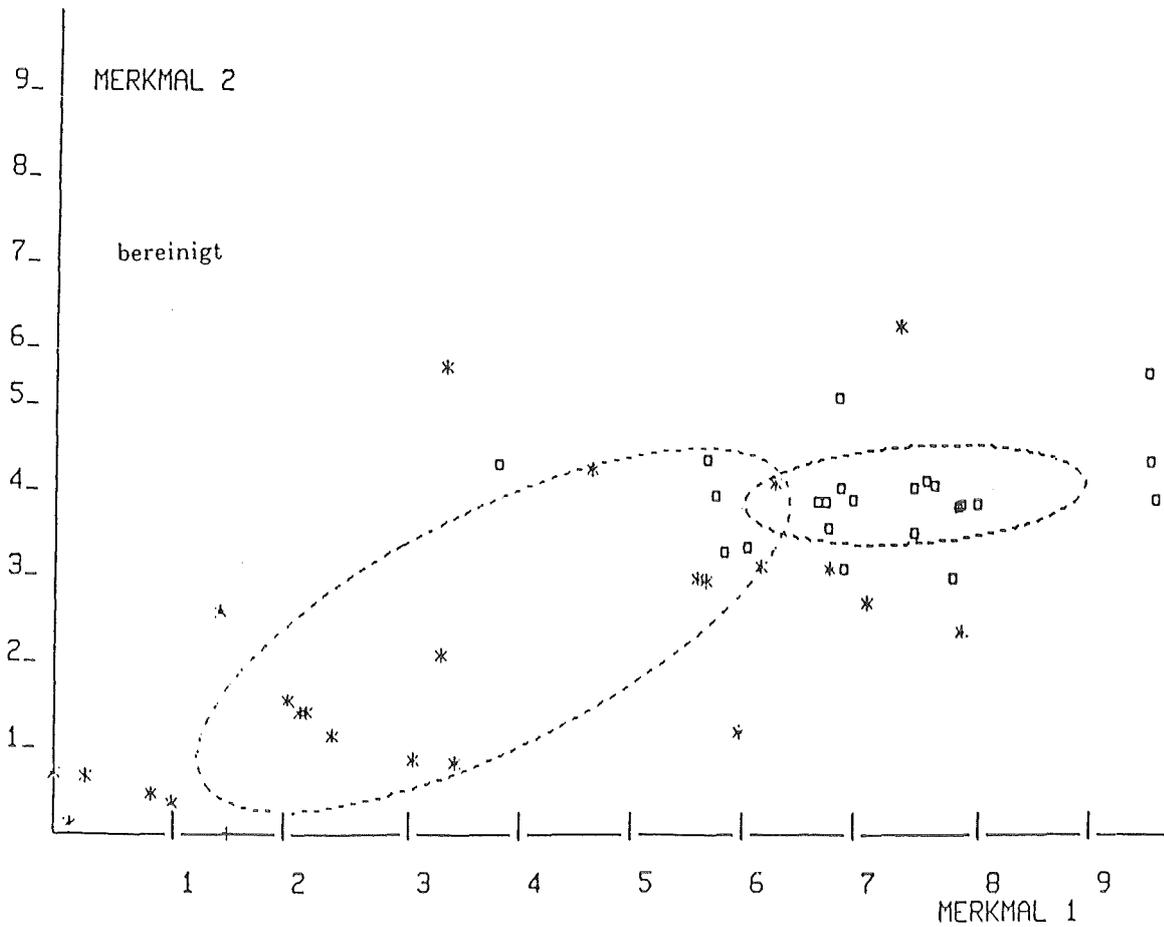
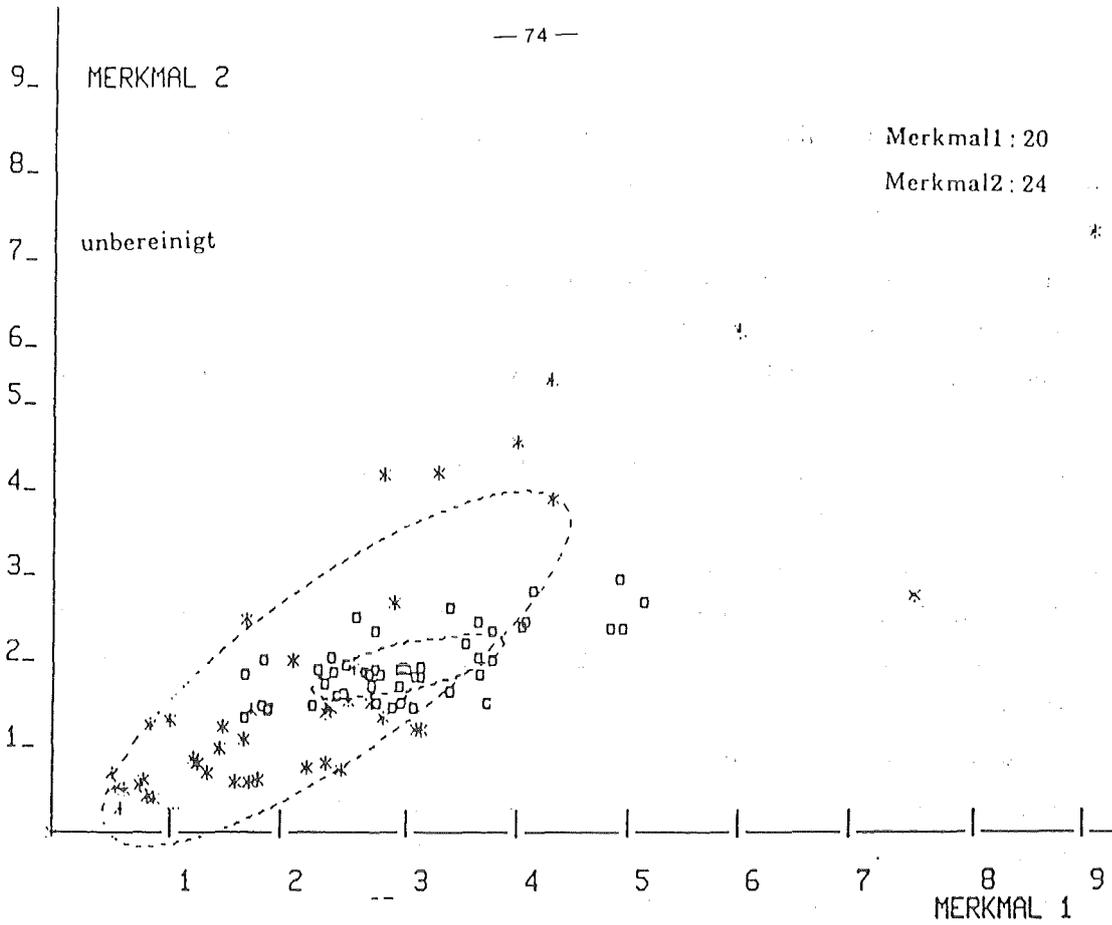


Abb. 7.3.6: unüberwachtes Lernen: Musterbereich: Block 20 - 70 und 200 - 250

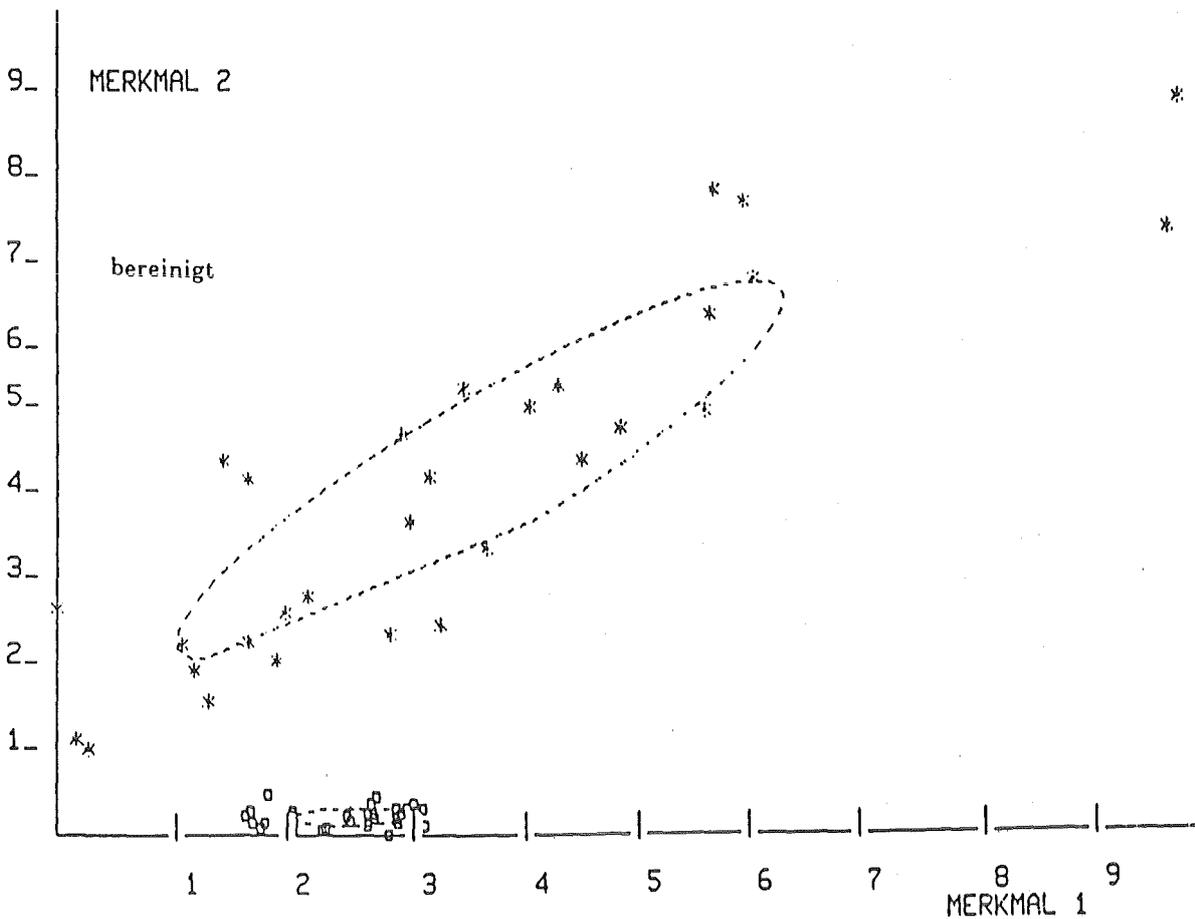
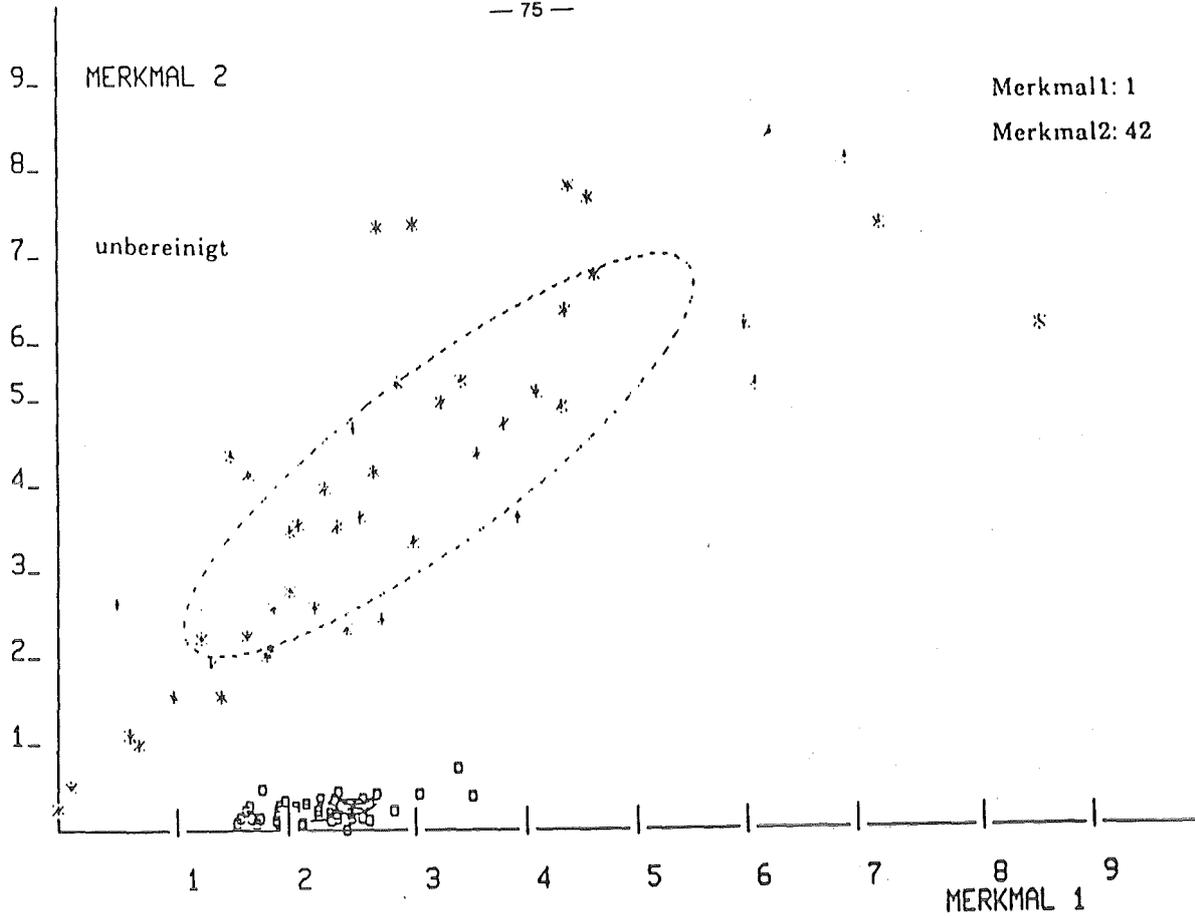


Abb. 7.3.7: unüberwachtes Lernen: Musterbereich: Block 40 - 90 und 280 - 330

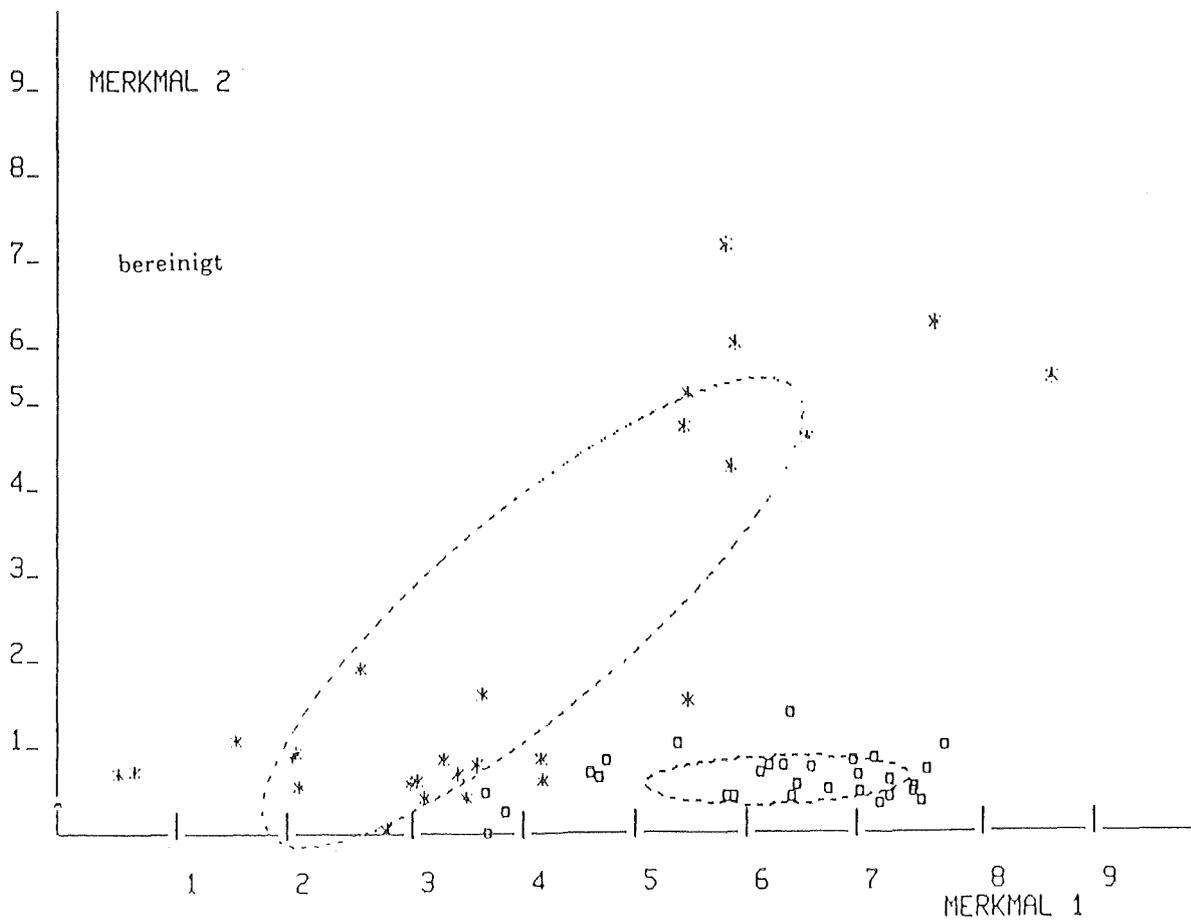
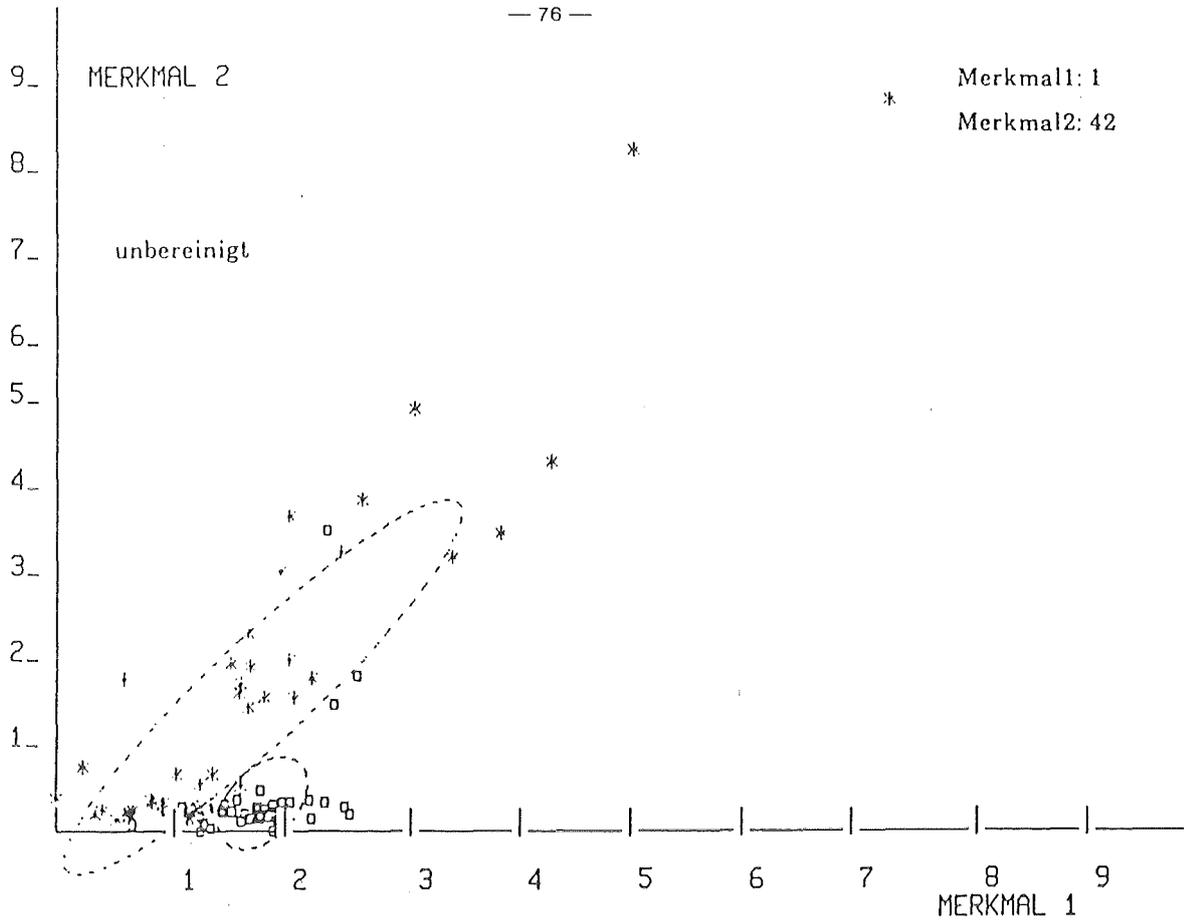


Abb. 7.3.8: unüberwachtes Lernen: Musterbereich: Block 120 - 170 und 175 - 225

8. Gesamtkonzept zur Siededetektion:

Nachdem in den vergangenen Kapiteln wichtige Komponenten der Mustererkennung behandelt wurden, soll jetzt ein Gesamtkonzept formuliert werden, in dem die Einzelkomponenten zu einem System integriert werden. Das System soll schwerpunktmäßig auf den beschriebenen Modellen und Verfahren basieren und auf logischer Ebene eine Überwachungsstruktur für eindimensionale Signale (hier akustische Signale) darstellen.

Hardwaremäßig sind alle Berechnungsmodelle auf einer IBM 3090 installiert. Als Peripherie der zentralen Großrechenanlage IBM 3090 des KfK wurden ein Versatec Matrixdrucker und ein IBM Graphik-Terminal 3179 eingesetzt. Außerdem standen zur Verfügung die mathematisch statistische Library "IMSL" (International Mathematical and Statistical Library) und als Graphiksoftware "GDDM" (Graphik Display Data Management). Mit Hilfe dieser Werkzeuge wurden die Modelle erstellt und die Untersuchungen durchgeführt. Die akustischen Meßsignale des IRE standen auf Magnetband zur Verfügung und wurden im Massenspeicher der IBM gehalten. Heuristische Voruntersuchungen wurden zum Teil interaktiv im Teststadium durchgeführt. In der Abbildung 8.0 ist die Hardware - Software - Konfiguration der Überwachungssimulation dargestellt.

8.1 Simulation der Siedeüberwachung

Bevor die bereitgestellten KNS - Signale über ihre jeweilige Gesamtdauer von etwa 10 Sekunden überwacht werden, wird ein Training durchgeführt. Der Merkmalsgenerator wird durch einen externen Lehrer mit Mustern aus beiden Klassen, der Siedephase und der Nichtsiedephase in ihrer ausgeprägten Form trainiert. Nach der Merkmalsbildung wird eine separate Bewertung der Einzelmerkmale vorgenommen und die Merkmale mit der besten Gütebewertung werden in den späteren Klassifikator eingesetzt. Verschiedene Prozeßzustände werden insofern berücksichtigt, daß für jedes Signal (welches im Realfall zum Beispiel einer Betriebszustandsänderung aufgrund geänderter S/N Verhältnisse entspricht) eine erneute Trainings- und Lernphase stattfindet. Auch eine neue Bewertung ist dann wieder notwendig, wie Kapitel 6 gezeigt hat. Die Cluster werden zum Teil bereinigt, um gute Referenzen zu erhalten (Kapitel 7) .

Nach dieser Klassifikatoreinstellung wird die on-line -Überwachung simuliert. Ein Fenster einer bestimmten Länge (hier FLEN = 750 msec) wird über das Signal verschoben. Eine nichtdisjunkte Verschiebung des Fensters (hier VERSCH = 125 msec) gewährleistet, daß lokal vergangene Muster das gegenwärtige Fenster mitbeeinflussen. Diese Überwachungsparameter FLEN und VERSCH können auch anders gewählt werden, jedoch sind mit dieser Einstellung bei unserem Anwendungsfall

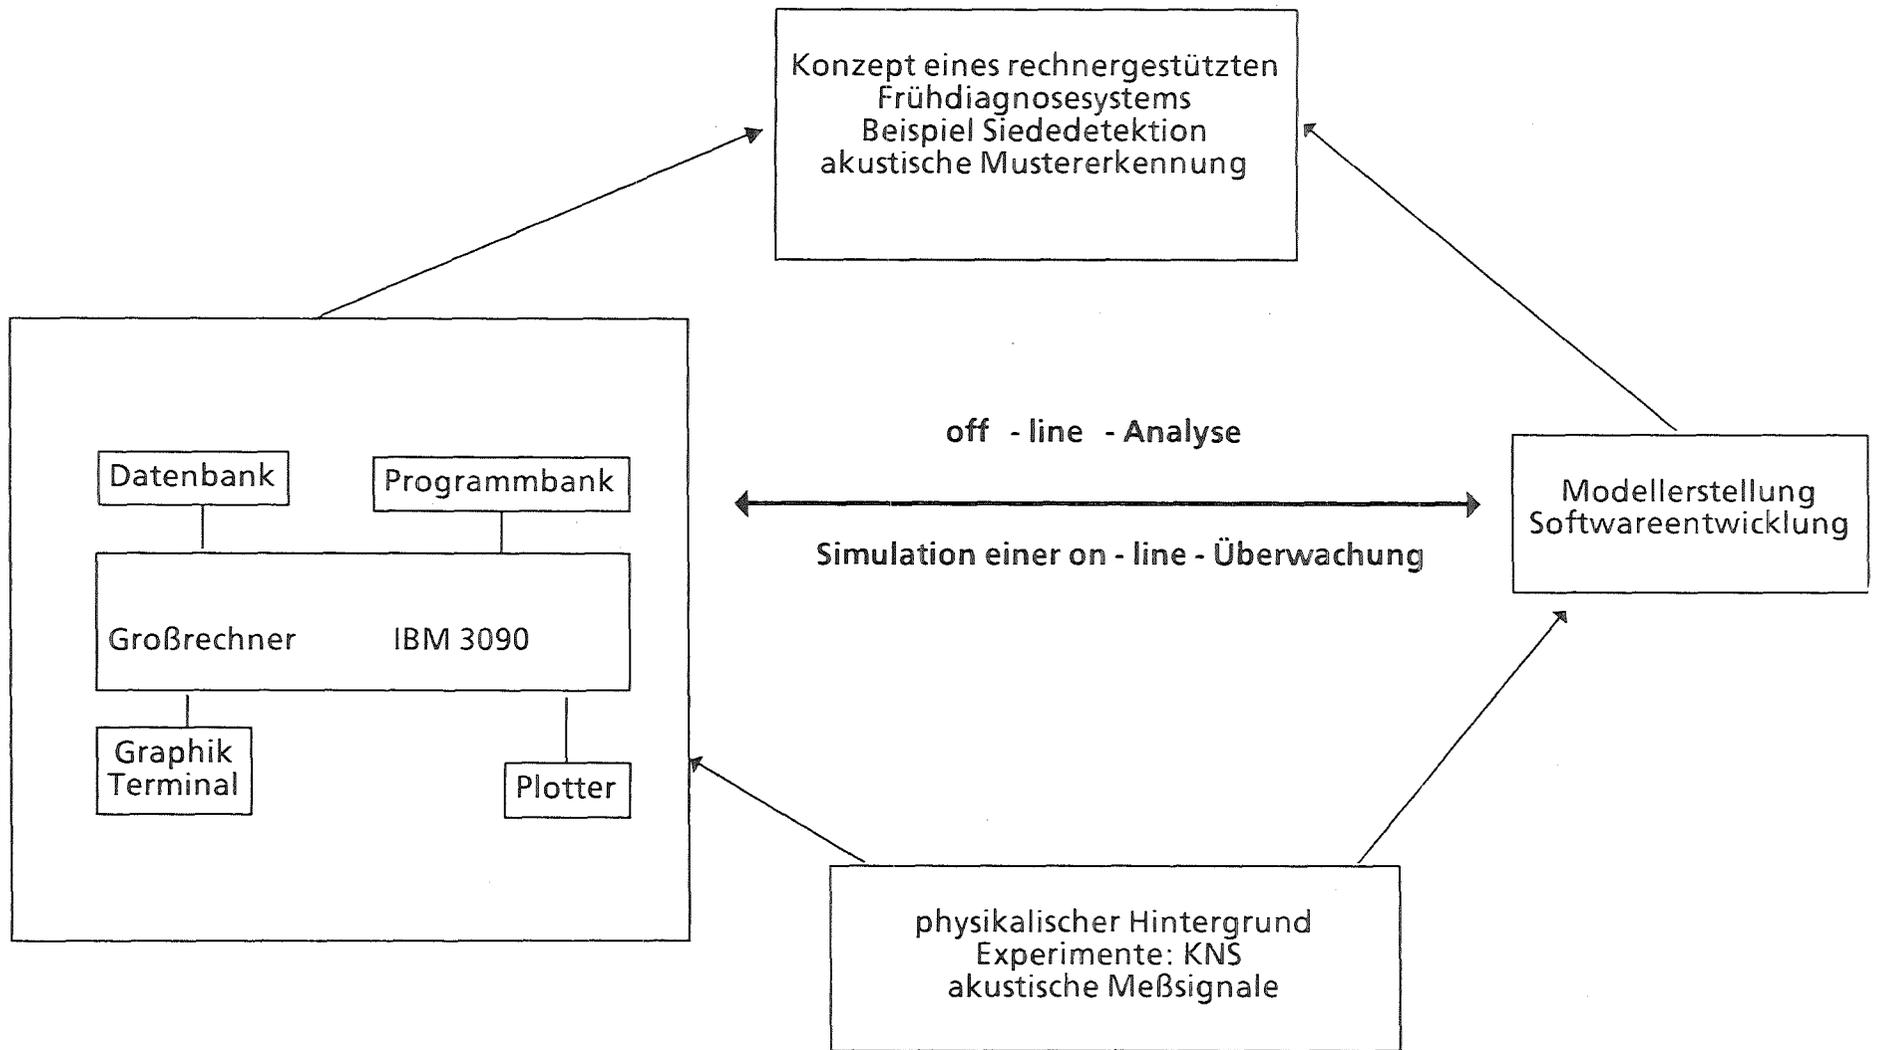


Abb. 8.0: Hardware-Software- Konfiguration

gute Ergebnisse erzielt worden.

Bemerkungen zur Festlegung der Überwachungskomponenten FLEN und VERSCH

Bei der Festlegung der Fensterlänge FLEN muß darauf geachtet werden, daß zum einen das Fenster genügend viele Stützstellen besitzt, um eine aussagenkräftige Modellbildung über die statistischen Parameter vornehmen zu können. Dabei muß es auf der anderen Seite aber auch kurz genug sein, um plötzlich auftretende Störungen früh genug erfassen zu können, ohne daß über die Gesamtlänge durch Glättungsalgorithmen die Störungen verloren gehen. Ebenso ist bei der Wahl des Verschiebungsparameters VERSCH ein Kompromiß zu finden zwischen einer zu großen Verschiebungszeit (bei disjunkten Verschiebungen reicht die Aussagekraft des früheren Fensters nicht mehr in das gegenwärtige Modell) und einer zu kleinen (immenser Rechenaufwand, da die Anzahl der Modellbildungen umgekehrt proportional zur Anzahl VERSCH sich ändert).

Auf logischer Ebene wird eine Überwachung über den gesamten Prozeß von der Aufnahme der Rohdaten bis hin zur partiellen Entscheidung über den Siede- bzw. Nichtsiedezustand durchgeführt (Abb. 8.1). Die digitalisierten Rohdaten werden nach Vorverarbeitungsroutinen zunächst in den Merkmalsraum zu Merkmalen transformiert (im Zeit- und Frequenzbereich). Die Fensterbildung vollzieht sich ausschließlich im Merkmalsraum, also nicht auf der ursprünglichen Signalebene. Die eigentliche Klassifikation geschieht dann mit den optimal bewerteten Merkmalen für ein Fenster in paralleler Weise mit einem geometrischen Abstandsklassifikator, basierend auf dem Mahalanobisabstand. Dabei bedeutet Paralleleinsatz des Klassifikators folgendes:
Zu einem festen Zeitpunkt t_0 wird das momentan anliegende Muster klassifiziert. Weiterhin sind aus den 4 Modellansätzen, die über das letzte Fenster erstellt wurden, vier Schätzmuster für den Zeitpunkt t_0 entstanden, welche aufgrund der unabhängigen Modelle selbst unabhängig sind und die charakterisiert sind durch die Modellparameter, die zeitlich lokal im letzten Fenster angepaßt wurden. Somit hat man eine stets adaptive Schätzung. Man beachte, daß die Adaptivität sich nicht dahingehend auswirkt, daß die Klassen verwischt werden, sondern die angepaßten Modellparameter sind lediglich verantwortlich für die Schätzung der Merkmale vor ihrer Klassifikation. Für diese prognostizierten Schätzwerte werden ebenfalls die Klassifikatoren eingesetzt und man erhält so für jeden Zeitpunkt eine fünfstufige Klassifikation, wobei die Einzelklassifikationen hier gleichstark ins Gewicht fallen, da keinem Modell aufgrund mangelnder Kenntnisse über physikalische Signalstrukturen eine Priorität eingeräumt werden kann. In die Klassifikation der Muster, die durch die vier vorhandenen Schätzmodelle entstehen, gehen also indirekt noch eine Menge von Sekundärmerkmalen ein, die bei der ursprünglichen Klassifikation nicht im Merkmalsgenerator vorhanden sind. Diese Sekundärmerkmale sind die Parameter, die durch Erstellen des Modells über

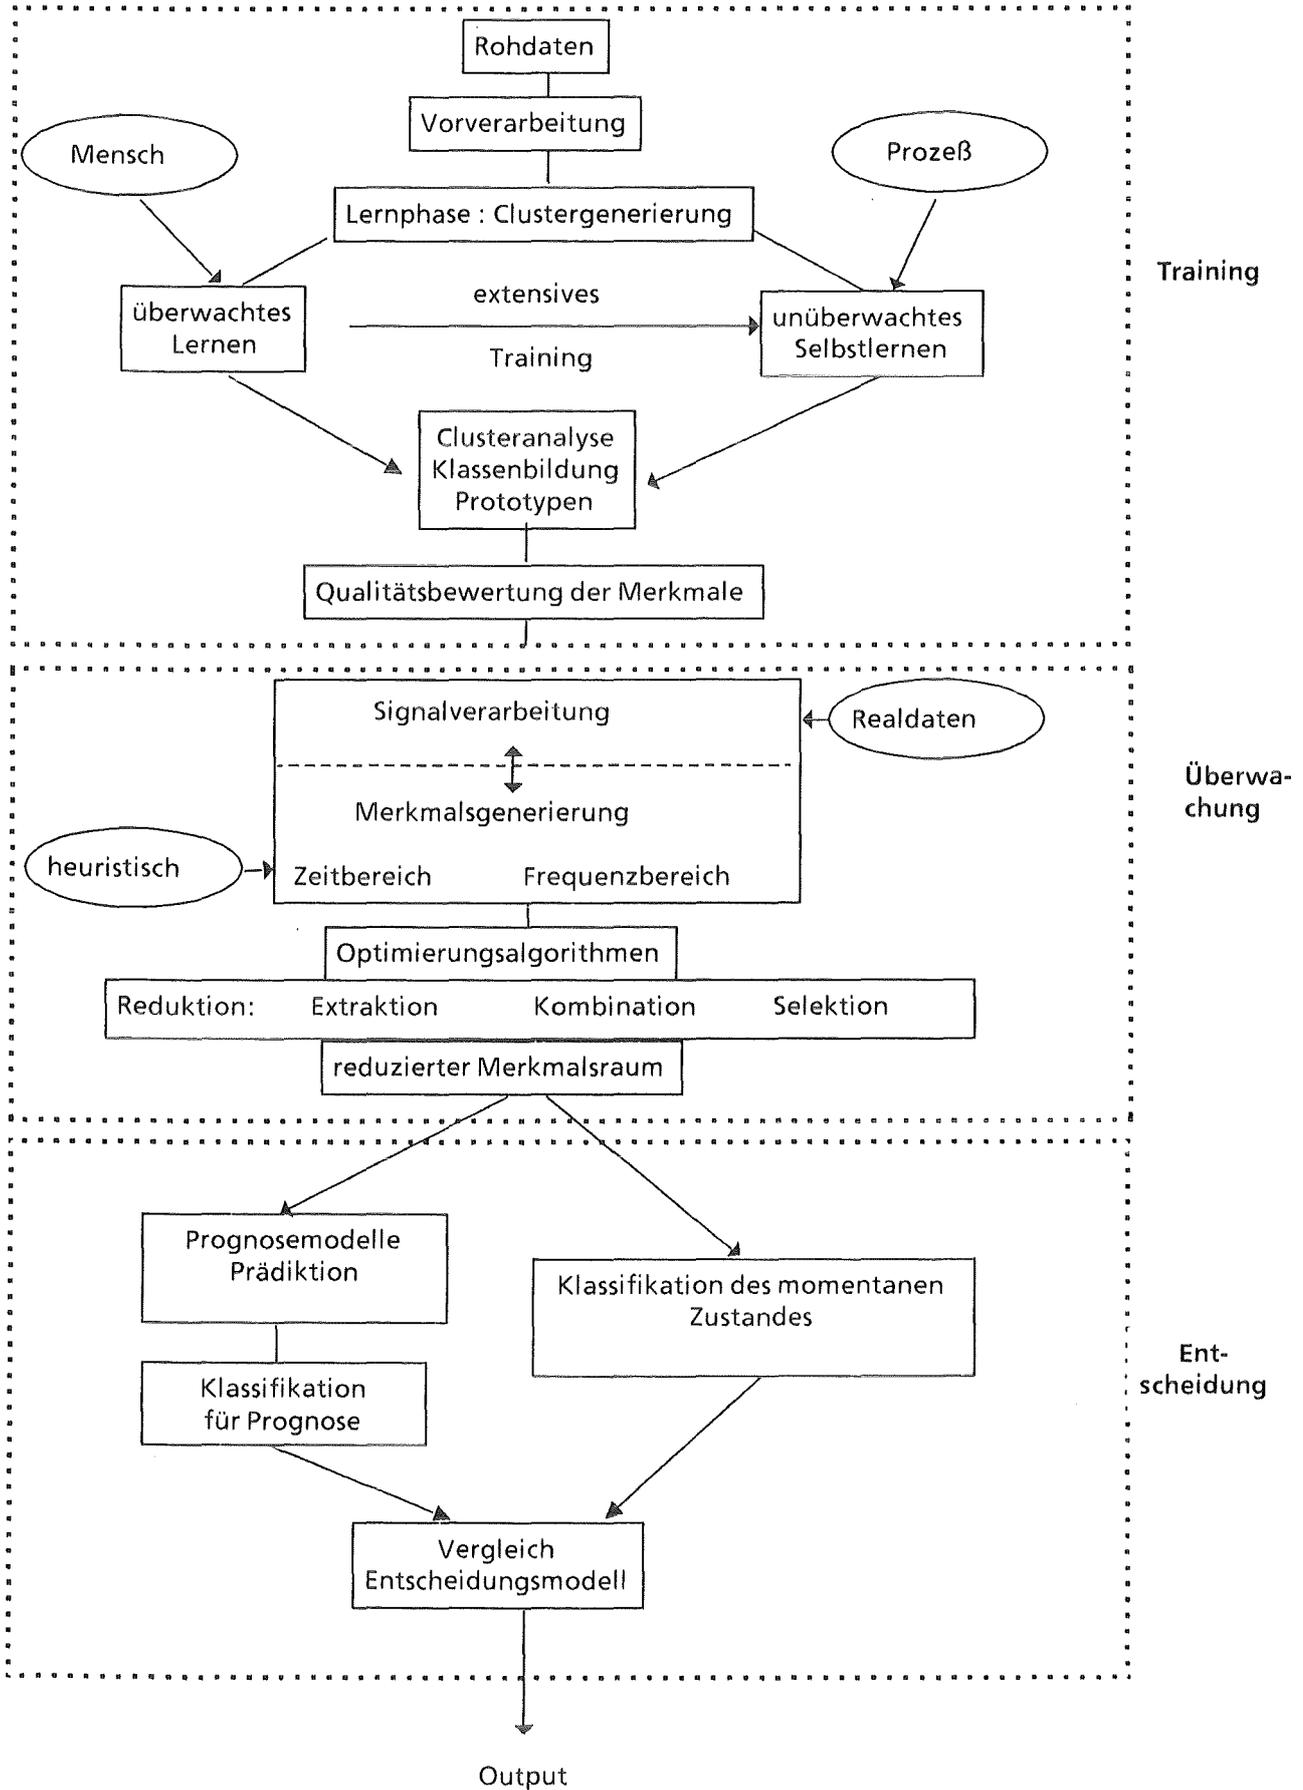


Abb. 8.1: Mustererkennung - Überwachungsmodell

ein bestimmtes Fenster berechnet und mit denen dann die zukünftigen Muster geschätzt werden.

8.2 Klassifikationsergebnisse

Die vorliegenden Klassifikationsergebnisse für die drei KNS - Signale wurden mit einem Abstandsklassifikator erzielt. Als Abstandskriterium wurde der Mahalanobisabstand gewählt.

Eine wesentliche Verbesserung des Informationsgehaltes der Klassifikation wird durch die Parallelauswertung der Prognosemodelle erzielt, die in unserem Falle dem gleichen Klassifikator unterliegen.

Nach einer Trainingsstufe, in der sowohl Siede- als auch Nichtsiedemuster aus dem Prozeß abgegriffen wurden in der jeweiligen intensiven Phase, wurden alle Merkmale bewertet und die besten für den Klassifikationsprozeß eingesetzt. Mit dieser Strategie wurden zum ersten wesentliche Verbesserungen gegenüber normalen Schwellwertverfahren erzielt, die meist (wenn überhaupt rechnergestützt eingesetzt) eine Amplitudenüberwachung bzw. eine gemittelte RMS-Wert Überwachung durchführen. Ein Leistungsvergleich wird im Nächsten Kapitel 8.3 gezeigt. Der Einsatz der Prognoseverfahren und der damit verbundene Einsatz einer parallelen Klassifikation ermöglicht eine erhebliche Verbesserung der Aussagen in folgendem Sinne:

Die Entscheidung Sieden oder Nichtsieden ist in dieser extremen Alternative für viele nachfolgenden Entscheidungen nicht aussagekräftig genug, zumal es keine strenge Abgrenzung zwischen beiden Zuständen gibt, wenn man das physikalische Phänomen betrachtet. Zur Gesamtüberwachung des Cores beim Schnellen Brüter soll in den nächsten Jahren ein Expertensystem eingesetzt werden, in welches die partiellen Entscheidungsprozesse (z.B. Temperaturüberwachung, Neutronenflußrauschen oder hier akustische Rauschprozesse) in Form von Zustandsbeschreibungen einfließen. Auf der übergeordneten Entscheidungsebene werden diese Aussagen verknüpft. Eine Aussage mit Wahrscheinlichkeitsdichten zu belegen scheint aufgrund mangelnder Strukturkenntnisse des Signals nicht so geeignet wie solche Bewertungsaussagen, die ein Maß angeben, wie stark sich der Klassifikator für den Zustand Sieden entschieden hat.

In diesem Sinne wird der für die Prognosemodelle parallel eingesetzte Klassifikator die Aussagekraft erhöhen. Dabei sind folgende Aspekte zu bedenken:

1. Durch die Modellerstellung bei den Prognosemodellen werden lokal vergangene Zustände (innerhalb des Zeitfensters während der Überwachung) mitberücksichtigt und machen eine Aussage darüber, ob zur Zeit in Abhängigkeit von der zeitlich lokalen Vergangenheit ein gewisser Zustand (Sieden oder Nichtsieden) erwartet wird.

2. Die Prognosemodelle basieren auf prinzipiell unterschiedlichen Modellaspekten. Während zum Beispiel das Differentialgleichungsverfahren mehr auf eine Detektion im exponentiellen Sinne abzielt, sind beim Verfahren der Linearen Vorhersage mehr die linearen autoregressiven Parameter maßgeblich beteiligt. Beim Berliner - Verfahren werden durch den polynomialen Ansatz im wesentlichen solche Tendenzen (bis zu einem vorgegebenem Grad) berücksichtigt. Das ARIMA - Modell liefert mit einem leider nicht unerheblichen Aufwand eine Abschätzung der stochastischen Parameter (sowohl die autoregressiven - als auch die moving - average - Anteile), die dieses Modell beschreiben. Allerdings lassen sich mit diesem Modell auch instationäre Prozesse (wie es beim Sieden der Fall ist) beschreiben.

3. Bei zeitlich trägen Prozessen können die Prognosewerte bereits als Eingabe in einen Klassifikator dienen, ohne daß der Prozeß soweit vorangeschritten ist. Dies würde eine vorgezogene Klassifikation bedeuten und würde bei solchen trägen Prozessen für eine Frühwarnung erhebliche Zeitprobleme lösen helfen.

4. Da beim Siedeprozess nicht das eine oder andere Prognosemodell bevorzugt werden kann, da man keinerlei a priori Wissen über die Modellanpassung an die Prozeßentwicklung hat, sollten alle Modelle gleichberechtigt eingesetzt werden.

Die partiellen Klassifikationsergebnisse Sieden(Zustand 1) und Nichtsieden (Zustand 0) werden für jedes Modell separat berechnet und der aktuellen Klassifikation (zeitlich verschoben) überlagert. Die Summe der Entscheidungsbewertungen (zwischen 0 und 5) drückt somit die Stärke der Entscheidung zugunsten des einen oder anderen Zustandes aus. In diesem Sinne kann man von einem adaptiven System reden, da die aktuelle Modellbildung stets für eine Bewertung aus der momentanen Sicht sorgt.

Im folgenden sind die Parameter aufgeführt, unter welchen das System die vorliegenden Ergebnisse erzielt hat:

Trainingsstufe:

50 Merkmalsvektoren zu je einem Block von 25 msec. Dies entspricht einer Blocklänge von 5120 Werten. Es wurden jeweils aus dem Siedebereich wie aus dem Nichtsiedebereich 50 Muster abgegriffen. Jeder dieser Merkmalsvektoren hat 60 Komponenten (im wesentlichen statistische Parameter) gemäß der Auflistung in Kapitel 4.

Verschiebungslänge VERSCH :

Die Überwachung des Signals geschieht dadurch, daß ein Fenster einer bestimmten Fensterlänge zeitlich diskret versetzt um die Verschiebungslänge über das Signal

geschoben wird. Die Verschiebungslänge beträgt hier 5 Blöcke zu je 5120 Mustern. Dies entspricht einer Zeit von 125 msec.

Fensterlänge FLEN :

Zur Modellbildung werden alle Muster innerhalb eines Fensters berücksichtigt. Die Fensterlänge ist im System zur Zeit auf 30 Blöcke = 750 msec festgelegt. Über diesen Zeitraum werden die Parameter berechnet, die dann eine Aussage über den zukünftigen Prozeßzustand machen.

Prognoselänge PROG:

Die Prognose auf zukünftige Merkmalsvektoren, basierend auf dem über das Fenster erstellte Modell, bezieht sich auf diskrete Blöcke. Es sind hier 5 Blöcke = 125 msec.

Diese Parameter scheinen eine sinnvolle Größenordnung darzustellen. Betrachtet man die zeitlichen Angaben über Prognosezeitraum (125 msec), Zeitraum zur Modellerstellung (750 msec), adaptive Modellanpassung (125 msec), so sind hier schon immense Vorteile gegenüber einer Temperaturüberwachung registrierbar. Unabhängig von Rechenzeiten, die beim realen Einsatz noch zu optimieren sind, die aber in beiden Fällen anfallen, hat man bei der Temperaturüberwachung mit Zeiten im Sekundenbereich zu rechnen, bis überhaupt der physikalische Prozeß am Sensor registriert werden kann. Erst dann kann da eine Modellbildung vorgenommen werden. Alle oben beschriebenen Parameter sind im Programm frei wählbar, jedoch wurden die Ergebnisse mit den hier aufgeführten erzielt.

Abbildung 8.2.1 zeigt einen Extrakt aus einem Listing, welches die berechneten und geschätzten Merkmale darstellt. Der Extrakt bezieht sich auf drei Fensterverschiebungen. Es wurden hier drei Merkmale beim 0 db - Signal überwacht. Unter Verschnr. ist die Verschiebungsnummer angegeben, die angibt, um wieviel 125 msec - Einheiten das Fenster verschoben ist. Für jeweils ein um 5 Blöcke (zu je 25 msec) verschobenes Fenster werden unter einem Merkmal in einer Zeile für ein Modell die nächsten fünf Prognosemerkmale geschätzt, bevor das Fenster gerade um diese fünf Blöcke weiter geschoben wird.

VERSCH.NR	1	UEBERW.BEGINN 0.75 SEC+			1 *125	MSEC
1. TES SELEKTIERTES MERKMAL						
AKTUELL	0.20	0.14	0.20	0.19	0.16	
LIN.PR.	0.23	0.21	0.23	0.22	0.21	
BERL.	0.22	0.22	0.22	0.22	0.22	
DIFFGL.	0.15	0.23	0.21	0.21	0.21	
ARIMA	0.21	0.21	0.21	0.21	0.21	
2. TES SELEKTIERTES MERKMAL						
AKTUELL	0.09	0.06	0.06	0.06	0.06	
LIN.PR.	0.12	0.10	0.11	0.12	0.11	
BERL.	0.10	0.10	0.10	0.11	0.11	
DIFFGL.	0.05	0.06	0.08	0.08	0.08	
ARIMA	0.10	0.07	0.08	0.08	0.08	
3. TES SELEKTIERTES MERKMAL						
AKTUELL	0.25	0.21	0.22	0.25	0.20	
LIN.PR.	0.25	0.23	0.23	0.23	0.23	
BERL.	0.24	0.23	0.23	0.23	0.23	
DIFFGL.	0.27	0.25	0.24	0.25	0.25	
ARIMA	0.25	0.25	0.25	0.25	0.25	
VERSCH.NR	2	UEBERW.BEGINN 0.75 SEC+			2 *125	MSEC
1. TES SELEKTIERTES MERKMAL						
AKTUELL	0.24	0.24	0.16	0.26	0.19	
LIN.PR.	0.19	0.18	0.17	0.18	0.17	
BERL.	0.17	0.16	0.15	0.14	0.14	
DIFFGL.	0.21	0.24	0.19	0.21	0.20	
ARIMA	0.21	0.21	0.21	0.20	0.20	
2. TES SELEKTIERTES MERKMAL						
AKTUELL	0.09	0.09	0.11	0.04	0.13	
LIN.PR.	0.06	0.06	0.05	0.05	0.05	
BERL.	0.07	0.07	0.07	0.07	0.06	
DIFFGL.	0.12	0.07	0.09	0.08	0.08	
ARIMA	0.08	0.08	0.08	0.08	0.08	
3. TES SELEKTIERTES MERKMAL						
AKTUELL	0.37	0.28	0.23	0.26	0.20	
LIN.PR.	0.23	0.23	0.21	0.23	0.22	
BERL.	0.22	0.21	0.21	0.21	0.20	
DIFFGL.	0.31	0.23	0.24	0.25	0.24	
ARIMA	0.26	0.24	0.24	0.24	0.24	
VERSCH.NR	3	UEBERW.BEGINN 0.75 SEC+			3 *125	MSEC
1. TES SELEKTIERTES MERKMAL						
AKTUELL	0.21	0.20	0.22	0.21	0.26	
LIN.PR.	0.19	0.23	0.19	0.20	0.21	
BERL.	0.20	0.20	0.20	0.20	0.20	
DIFFGL.	0.24	0.20	0.21	0.21	0.21	
ARIMA	0.21	0.21	0.21	0.21	0.21	
2. TES SELEKTIERTES MERKMAL						
AKTUELL	0.07	0.16	0.07	0.07	0.06	
LIN.PR.	0.10	0.09	0.08	0.10	0.10	
BERL.	0.08	0.07	0.07	0.07	0.07	
DIFFGL.	0.03	0.09	0.08	0.08	0.08	
ARIMA	0.07	0.08	0.08	0.08	0.08	
3. TES SELEKTIERTES MERKMAL						
AKTUELL	0.26	0.23	0.23	0.29	0.26	
LIN.PR.	0.22	0.23	0.21	0.22	0.21	
BERL.	0.26	0.26	0.26	0.26	0.26	
DIFFGL.	0.32	0.22	0.25	0.25	0.25	
ARIMA	0.24	0.24	0.25	0.25	0.25	

Abb. 8.2.1: Modellergebnisse (Extrakt)

Die Klassifikationsergebnisse in Form von Maßzahlen sind in den folgenden Klassifikationstabellen 8.2.2 - 8.3.3 aufgeführt.

Eine Tabelle besteht aus jeweils 380 Maßzahlen (entweder 0 und 1 oder 0 bis 5), welche die Siedezustände im überwachten Block (insgesamt 380 Blöcke zu je 25 msec) zeilenweise von oben nach unten) angeben.

In der oberen Hälfte der Abbildung. 8.2.2 wird das 0 db - Gesamtsignal über die 10 sec klassifiziert. Der gleiche Klassifikator wird eingesetzt bei den einzelnen Prognosemodellen; siehe hierzu die Abb. 8.2.3 für die Lineare Vorhersage und das Dgl.verfahren und die Abb.8.2.4 für das Berliner Verfahren und die ARIMA - Modellierung.

In der zweiten Hälfte in Abb. 8.2.2 sind alle vier Verfahren zusammen mit der aktuellen Klassifikation durch Summierung der Erkennungsmaße zusammengefaßt. Die Maßzahl zwischen 0 und 5 gibt an, wieviele Modelle bei diesem Fenster für den Zustand Sieden entscheiden. Man sieht bei dem 0 db - Signal eine deutliche Entscheidung für den Zustand Sieden ab den Blocknummern 200 - 220. Dieser Klassifikationstabelle liegen die Merkmale 5 und 42 (vgl. auch Abb. 6.4) zugrunde.

In Abb. 8.2.5 wurde die aktuelle und die zusammengefaßte Klassifikation zum Vergleich dargestellt mit schlechten Merkmalen 20 und 21 beim gleichen 0 db - Signal.

Abb. 8.2.6 bezieht sich auf das -11 db - Signal mit den Merkmalen 4 und 42.

Abb. 8.2.7 bezieht sich auf das -14 db - Signal mit den Merkmalen 31 und 33.

Interessant ist nun, daß selbst bei diesen stark verrauschten Signalen von -11 db und -14 db noch signifikante Klassifikationsaussagen möglich sind.

Zwar kann man keinen exakten Zeitpunkt t angeben, ab wann es siedet (dies ist in dieser Form auch nicht beim 0 db - Signal möglich), aber die Tabelle zeigt deutlich die starken Maßzahlen zugunsten des Siedens, was beim RMS Signal, wie es herkömmlich zur Aussage herangezogen wird, nicht möglich ist (Abb. 3.5) .

Abb. 8.2.6: Klassifikationslabellen: -11 db; Merkmale: 4, 42; (aktuell u. Summe)

AKTUELL

0	0	1	0	1	0	0	1	0	0	0	0	0	1	1	0	0	1	0	1
0	0	1	1	0	1	1	1	0	0	1	0	0	0	0	1	1	1	0	0
1	1	0	1	0	1	1	1	0	1	1	0	1	0	1	0	0	0	0	1
0	0	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0
0	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	0	0	0
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	1	0	1	0
1	0	0	1	1	0	0	1	1	0	0	0	0	0	0	0	1	0	0	1
0	0	0	0	0	1	1	1	0	0	0	0	1	0	0	0	1	0	1	0
0	1	0	1	1	0	0	0	0	0	1	1	1	1	0	1	1	1	1	0
1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0
0	0	1	1	0	1	0	0	0	1	1	1	1	1	1	0	1	0	1	0
1	0	0	0	0	1	0	1	0	0	1	0	1	1	1	0	0	1	1	1
1	0	0	1	0	0	1	1	1	1	1	0	0	0	1	1	0	0	0	0
0	1	0	0	1	0	0	1	0	1	1	1	0	1	1	1	1	1	1	1
1	1	1	1	0	1	1	1	1	1	1	0	0	1	1	1	1	1	1	0
0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	0	1	0
1	1	1	1	0	0	1	1	0	1	1	1	0	0	0	1	0	1	1	1
1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	0	1	1	0	1
1	1	1	0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1

ERKENNUNGSSUMME ALS GEWICHT FUER DECISION MAKING LEVEL

0	0	1	0	1	0	0	1	0	0	0	0	0	1	1	0	0	1	0	1
0	0	1	1	0	1	1	1	0	0	3	2	2	2	2	2	1	1	0	0
2	1	1	3	2	2	2	2	1	2	2	0	1	1	2	1	1	1	1	2
1	0	0	1	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0
0	1	0	2	2	3	2	3	2	2	0	0	0	1	0	1	1	1	1	1
0	0	0	0	1	1	0	0	0	0	0	0	0	1	1	1	1	0	1	0
2	0	0	1	2	2	1	2	2	1	0	0	0	0	0	1	0	0	1	1
1	1	0	0	0	2	1	1	0	0	1	0	1	0	0	1	1	0	1	0
0	1	0	1	1	1	0	1	0	1	3	2	2	2	1	2	3	3	2	2
5	3	2	2	2	1	0	0	0	1	1	0	1	0	1	3	0	2	1	1
1	0	1	1	0	3	1	1	2	2	4	4	4	4	3	5	4	5	4	4
2	1	2	3	3	4	4	4	5	5	2	3	4	3	2	3	3	5	5	5
4	3	4	5	4	2	3	2	2	3	3	4	3	4	4	2	1	1	1	1
0	2	1	1	2	1	2	3	2	3	5	3	4	4	3	5	4	4	4	4
5	5	5	5	4	5	5	5	5	5	4	3	3	4	5	4	4	5	5	4
4	5	4	5	5	5	5	4	5	5	5	5	5	5	5	5	5	4	5	4
4	3	3	4	3	4	4	4	2	3	5	3	3	3	3	3	2	3	3	3
5	5	5	5	5	4	5	5	5	5	3	4	4	4	4	4	5	5	4	5
5	5	5	4	5	5	5	5	5	5	4	5	5	5	5	5	4	5	4	5

Abb. 8.2.7:

Klassifikationstabellen: -14 db, Merkmale: 31,33; (aktuell u. Summe)

AKTUELL																				
1	0	0	0	0	1	1	0	1	1	1	1	0	1	0	1	0	0	0	1	
0	1	0	0	0	1	0	0	1	0	1	1	1	0	0	1	1	1	1	1	
1	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	1	0	
0	0	1	0	0	1	1	1	1	1	1	1	1	1	0	0	0	0	1	0	
0	0	0	1	1	0	1	1	0	0	0	0	0	0	0	1	1	0	1	1	
1	0	1	1	1	0	0	0	1	1	0	0	0	0	0	1	0	0	1	0	
1	1	1	0	0	0	0	0	0	0	0	0	0	1	0	1	0	1	1	0	
1	0	1	1	1	0	0	0	0	0	0	0	0	0	1	0	0	1	0	1	
1	1	1	1	0	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	
0	1	0	0	0	0	0	1	1	1	1	1	1	1	1	1	1	1	0	1	
1	0	0	0	0	1	0	1	1	0	1	1	0	1	1	1	1	0	1	1	
0	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	
1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	0	1	1	1	
1	0	1	1	1	1	1	1	1	1	1	1	0	0	1	0	1	1	1	0	
0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	
1	1	1	1	1	1	1	1	1	1	1	1	0	0	1	1	1	1	1	1	

ERKENNUNGSSUMME ALS GEWICHT FUER DECISION MAKING LEVEL																				
1	0	0	0	0	1	1	0	1	1	1	1	0	1	0	1	0	0	0	1	
0	1	0	0	0	1	0	0	1	0	1	1	1	0	2	2	2	2	2	2	
2	1	2	2	2	3	2	1	1	1	1	0	0	0	0	0	0	1	0	1	
0	0	1	0	0	1	1	1	1	1	1	5	4	3	2	2	1	0	1	1	
1	1	1	2	2	0	1	1	0	0	1	1	2	1	3	1	0	2	2	2	
3	3	4	4	4	1	1	1	2	1	1	0	0	0	1	1	0	1	0	1	
2	0	0	1	1	2	1	2	2	1	1	1	0	0	1	1	2	1	1	1	
4	4	4	3	3	1	2	1	1	1	1	1	0	0	1	0	1	1	1	1	
2	0	1	2	2	3	2	3	1	1	0	0	1	0	1	0	0	1	0	1	
4	3	3	3	2	3	3	2	3	3	4	2	3	3	3	2	2	3	3	2	
1	2	1	1	1	1	1	0	1	1	1	2	1	2	1	1	3	3	2	2	
3	1	1	1	1	1	1	0	1	1	0	2	2	1	2	2	3	1	1	1	
2	2	2	1	2	1	1	1	1	1	1	5	4	5	4	3	5	4	4	5	
5	5	5	4	5	5	5	4	4	3	4	4	5	5	5	5	4	5	5	5	
3	3	3	3	3	4	5	5	5	5	5	4	5	5	4	4	5	4	4	5	
5	5	5	4	5	5	5	5	5	5	5	4	5	5	5	5	4	5	5	5	
5	4	5	5	5	4	4	4	4	4	4	5	4	4	5	4	4	5	4	5	
2	5	5	5	5	4	5	5	5	5	5	5	5	5	5	5	2	2	2	2	
5	5	5	5	5	4	4	4	4	4	4	5	5	4	3	4	5	5	5	5	

8.3 Vergleich zu Schwellwertverfahren

Die Vorteile der akustischen Mustererkennung gegenüber herkömmlichen Verfahren liegen zum einen in der schnellen Meßtechnik a priori und zum anderen in guten Entscheidungskriterien. Da es überhaupt noch keine rechnergestützte Klassifikation für solche Siedeereignisse gibt, sondern die Siedevorgänge bislang nur visuell rückwirkend beurteilt werden, scheint es nicht ganz leicht, die Leistungsfähigkeit der aufgeführten Verfahren zu messen. Aus diesem Grunde wurde als Vergleichsreferenz ein Schwellwertverfahren eingesetzt, welches die gemittelten RMS - Werte über die Schalldrücke nach bisherigem Muster überwacht.

Die Simulation dieses Schwellwertverfahrens wird folgendermaßen durchgeführt:

Zunächst wird in einer Art Trainingsstufe der Normalzustand über eine genügend große Trainingsstichprobe ermittelt. Nach Berechnung der mittleren Streuung σ wird beim Überwachungsvorgang ein Zustand genau dann als Sieden anerkannt, wenn der RMS - Wert den Referenzwert um 1σ bzw. in einer zweiten Version um 2σ übersteigt. Die Schwachstellen dieses Verfahrens liegen auf der Hand und werden auch durch die Klassifikationsergebnisse im nachfolgenden belegt.

Schon in den RMS - Signalverläufen 3.3 - 3.5 erkennt man, daß in der Siedephase viele RMS - Werte wieder Normalniveau erreichen, was bedeutet, daß diese Muster als Merkmale schlichtweg untauglich sind für optimale Entscheidungen. Dies sieht man auch am Gütefaktor des 1. Merkmals in den Gütetabellen 6.4 - 6.6.

In den Abbildungen 8.3.1, 8.3.2 und 8.3.3 sind die Klassifikationstabellen für das Schwellwertverfahren angegeben. 8.3.1 überwacht das 0 db - Signal, 8.3.2 das -11 db - Signal und 8.3.3 das -14 db - Signal. In der oberen Tabelle wird Sieden genau dann als erkannt gemeldet, wenn der RMS - Wert den Nichtsiedereferenzwert um mehr als 1σ überschreitet, die untere Tabelle bezieht sich auf 2σ als Überschreitungsschwelle.

Ein Vergleich dieser Erkennungsraten mit denen der modernen ME - Verfahren nach einer Merkmalsoptimierung zeigt sehr deutlich, daß die ME - Verfahren zwar mehr Aufwand bedeuten, aber erheblich die Klassifikationsaussagekraft erhöhen. Beim Einsatz des Schwellwertverfahrens für die verrauschten Signale mit -11 db und -14 db erhält man überhaupt keine Aussagekraft mehr. Die Daten - und Programmstruktur, die zur Beurteilung der Leistungsfähigkeit der ME - Verfahren im Vergleich zu den herkömmlichen Schwellwertverfahren führt, ist in Abb. 8.3.4 dargestellt.

Abb. 8.3.2: Klassifikationstabellen: -11 db; Schwellwertverfahren

SCHWELLE =			1SIGMA																	
1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	0	0	1	1	1	1
0	1	1	1	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0
0	1	0	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0
0	0	0	0	1	0	0	0	0	0	0	1	0	0	1	0	1	1	0	0	0
0	0	0	0	0	0	1	0	0	1	1	1	1	1	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	1	1	1	1	1	0	0	0	0	0	0
0	0	0	0	0	0	1	1	1	1	1	0	1	0	0	0	0	0	0	0	0
0	0	1	0	0	0	0	0	1	0	1	1	0	1	0	1	0	0	0	0	0
0	1	1	1	1	1	1	0	0	1	1	1	0	0	1	0	0	1	1	0	0
0	1	1	1	1	1	1	1	0	1	1	1	1	1	1	0	0	0	0	0	1
1	1	1	0	1	0	1	1	1	1	0	0	0	0	1	1	1	1	1	1	1
SCHWELLE =			2SIGMA																	
1	1	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	1	0
0	1	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	1	1	1	1	0	0	1	1	1	0	0	0	0	0	0	0	0	0	0
0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
0	1	1	1	1	0	1	0	1	0	1	0	1	0	0	0	0	0	0	0	1
1	1	1	0	1	0	1	1	0	0	0	0	0	0	1	1	1	1	1	1	1

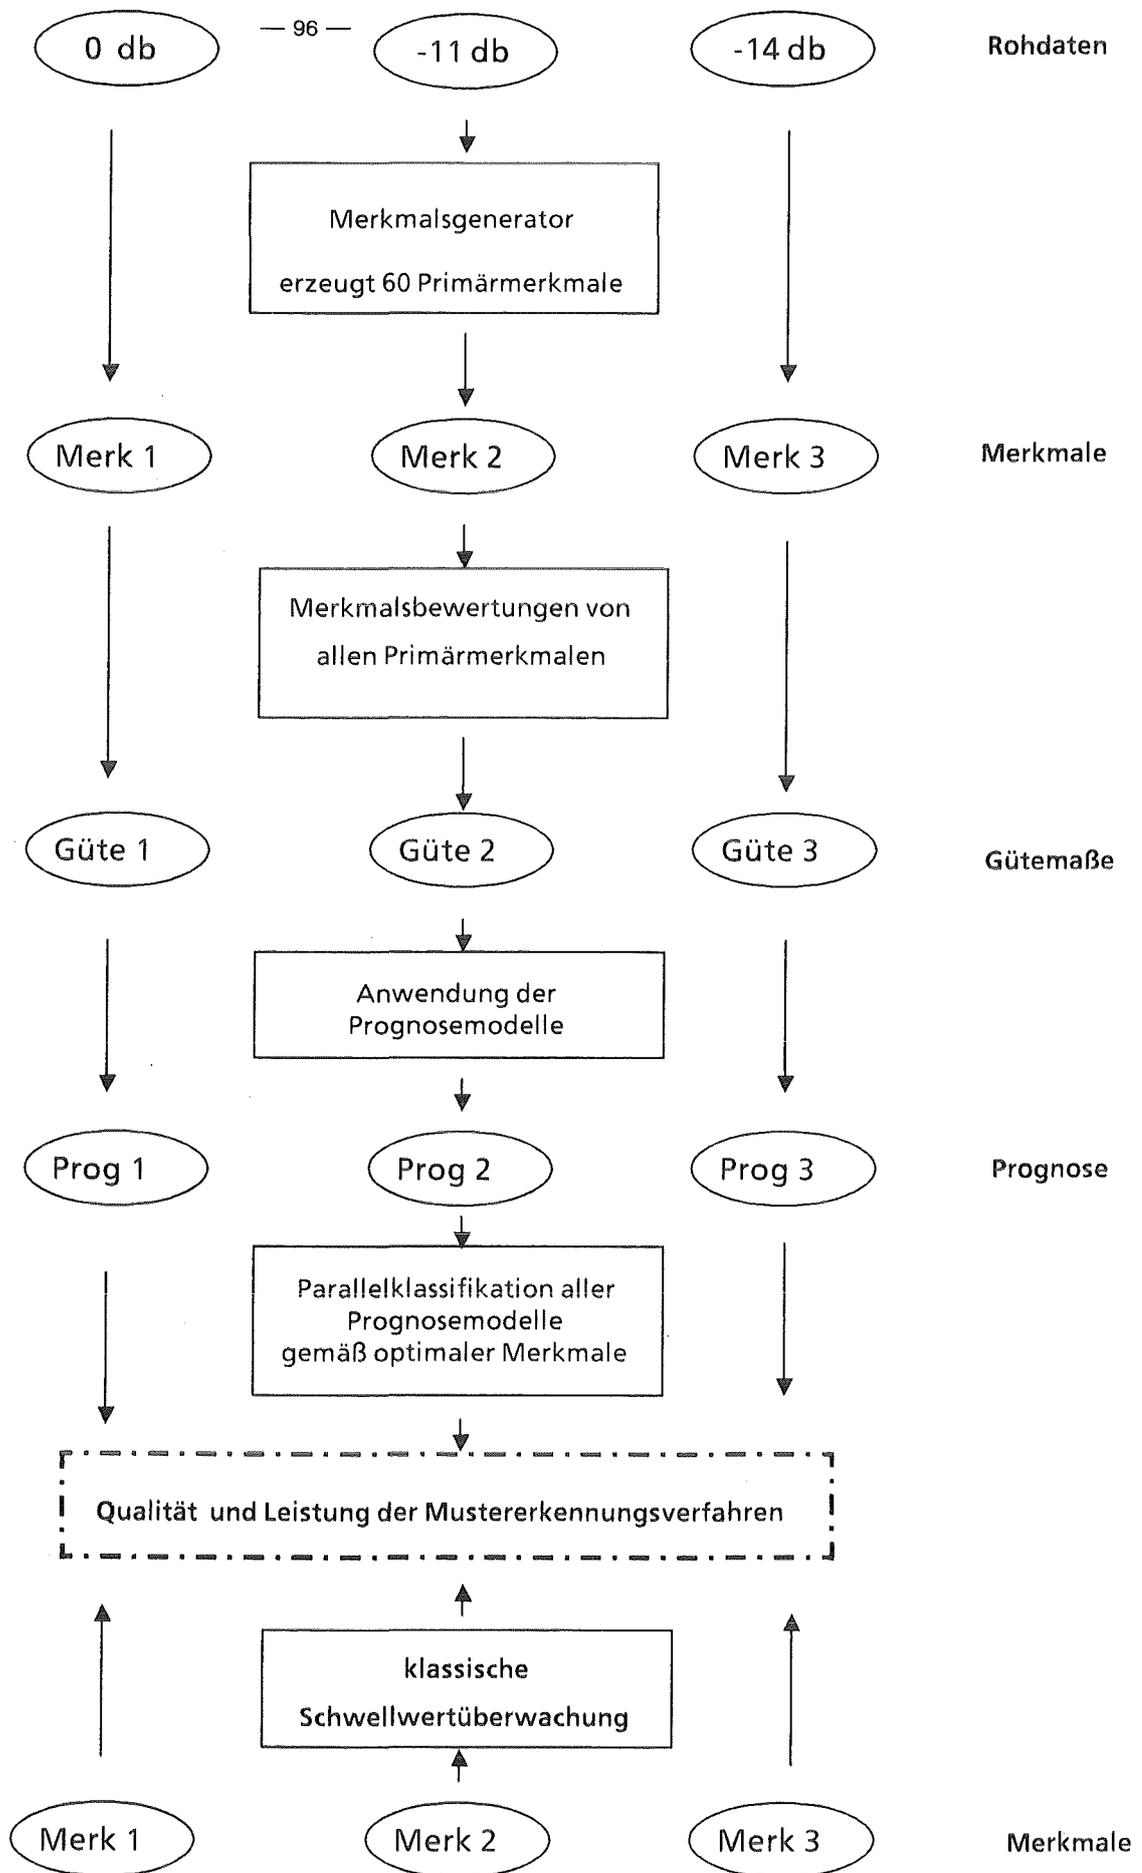


Abb. 8.3.4: Daten - und Programmstruktur

9. Ausblick

Ausgehend von den untersuchten Mustererkennungsverfahren im Einsatz zur Siededetektion und den erzielten Ergebnissen bei der simulierten Siedeüberwachung stellen sich im Anschluß folgende Fragen:

- 1) In welchen Punkten liegt das Anwendungsinvariante innerhalb dieser Mustererkennung?
- 2) Inwieweit sind die entwickelten Schwerpunkte verwertbar für weitere Anwendungsbereiche, und wo sind welche Spezifikationen in Abhängigkeit von der jeweiligen Problematik zu machen?

Greifen wir uns zunächst die erste Frage heraus. Das Gebiet der Mustererkennungsverfahren, welches in seiner Bedeutung immer größeren Zuwachs erhält, ist zunächst in den einzelnen Schwerpunktkomponenten wie Training, Lernen, Merkmalsfindung und Klassifikation zu untersuchen, wo problemspezifische Verfahren entwickelt wurden und wo allgemein übertragbare Ideen eingingen.

- a) Die Merkmalsgenerierung war vor allem im Hinblick auf die stochastische Natur der eindimensionalen Signale so ausgerichtet, daß als Primärmerkmale (das sind die im Merkmalsgenerator erzeugten) im wesentlichen statistische Parameter benutzt wurden, die ein charakteristisches Muster des Prozeßsignals über einen zeitlich begrenzten Abschnitt lieferten. Das zur Verfügungstellen einer Obermenge von statistischen Merkmalen ist natürlich problemorientiert. Hier geht die Heuristik in vollem Umfange ein. Es wird also bei jeder Anwendung zu fragen sein, mit welcher Art von Signalen oder allgemeiner von Mustern wir es zu tun haben, um danach eine a priori Obermenge von Merkmalen als heuristisch sinnvoll zu generieren.
- b) Die Problematik der Lernprozesse, des Trainings und der Merkmalsbewertung ist jedoch völlig unabhängig vom Anwendungsfall durchgeführt. Hier gehen generelle Überlegungen ein, die abstrakt gewissen Optimierungsansprüchen genügen.
- c) Zur eigentlichen Klassifikation stehen prinzipiell eine Menge von Klassifikatorstrukturen zur Verfügung. Es gibt numerische (darunter statistische, verteilungsfreie, nichtparametrische) und nichtnumerische. Da man es in diesem Falle der Signalüberwachung mit stochastischen Prozessen zu tun hat, schien ein geometrischer Abstandsklassifikator für den Anwendungsfall geeignet.
- d) Eine weitere wichtige Komponente der Überwachungsstrategie ist mit der Einführung der Prognosemodelle geschehen. Sie sind zunächst unabhängig vom Prozeß entwickelt und können auf jegliche anderen Anwendungsfälle bei eindimensionalen Signalen übernommen werden. Wesentlich ist die Modellierung und Parametrisierung der meßbaren Signale , wobei die aus der Beobachtung zu schätzenden Parameter als Sekundärmerkmale in spätere Verarbeitungsroutinen eingehen. Sie garantieren eine gewisse

Adaptivität der Modelle zur Schätzung lokal künftiger Merkmale. Wie diese Weiterverarbeitung der Modellparameter erfolgt und welche Aussagekraft ihnen vom Modell her zugestanden wird, ist allein problemspezifisch. Z. B. können die Parameterkonstanten **A** und **b** beim Differentialgleichungsverfahren unmittelbar für weitere Aussagen benutzt werden, wenn der Prozeß einigermaßen glatt verläuft und zeitlich träge ist. Exponentielle Propagationen (eventuell bei chemischen Prozessen) sind für solch eine Beschreibung prädestiniert. Diese Modelle sind insbesondere dann gut einsetzbar, wenn nähere Kenntnisse über die Signalstrukturen vorhanden sind (z.B. in Form physikalischer Gesetzmäßigkeiten analytisch beschreibbar).

Somit kommen wir zur 2. Frage, welche die Übertragbarkeit der Verfahren auf andere Einsatzgebiete betrifft.

Generell lassen sich diese Methoden auf alle eindimensionalen Signale anwenden, wobei von der Mustererkennungsseite das problemorientierte Anliegen bleibt, jeweils eine entsprechende Obermenge von nützlichen Merkmalen zu finden und einen adäquaten Klassifikator einzusetzen (je nach a priori Wissen). Vom modellorientierten Ansatz ist zu untersuchen, welches Modell möglicherweise aufgrund gewisser Gesetzmäßigkeiten in der Signalstruktur das Problem am besten beschreibt. In diesem Sinne kann also eine Übertragung der Verfahren zu einer Anomaliedetektion im weitesten Sinne eingesetzt werden.

10. Zusammenfassung

Mustererkennungsverfahren finden in immer mehr Bereichen der Qualitätssicherung, der Schadenserkenkung und insbesondere der Fehlerfrühdiaagnose ihre Anwendung. In dieser Arbeit ist gezeigt, wie man diese Verfahren in Verbindung mit parametrischen Signalmodellen einsetzen kann, um eindimensionale Signale on -line überwachen zu können. Es ist exemplarisch am Beispiel der Siededetektion vorgeführt, wie das System rechnergestützt intelligente Signalverarbeitung betreibt, um zu partiellen Entscheidungen zu kommen, die eventuell einem Expertensystem oder einer anderen weiterverarbeitenden Instanz zugeführt werden. Das entwickelte ME - Verfahren zeichnet sich durch hohe Erkennungsraten aus. Eine weitere Steigerung wurde noch erzielt durch den Einsatz von parametrischen Prognosemodellen, die zur Beurteilung des momentanen Prozeßzustandes lokal vergangene Zustände mit in die Klassifikation einfließen lassen. Selbst "versteckte" gefährliche Muster können vom System detektiert werden, was bei einer visuellen Inspektion nicht mehr möglich ist. In diesem Sinne hat man einen mehrschichtigen Klassifikationsprozeß, woraus ein gutes Bewertungsmaß für die Aussagesicherheit der Klassifikation resultiert. Dies wird am Beispiel der stark verrauschten Signale sehr deutlich. Man kann grob folgende Leistungssteigerungen festhalten:

1. visuelle Auswertung von Signalen
2. rechnergestützte Schwellwertverfahren
3. rechnergestützte Verfahren der Mustererkennung
4. rechnergestützte Verfahren der Mustererkennung unter Einbeziehung von parallel arbeitenden parametrischen Signalmodellen.

Die hohe Leistungsfähigkeit unter Punkt 3 und 4 wird im wesentlichen erreicht durch die ME - Komponenten

Training:	optimale Referenz- und Klassenprototypenbildung
Merkmalsgenerator:	Gewinnung von optimalen Merkmalen
Klassifikation:	dem Problem angepaßtes Entscheidungsmodell

Neben diesen wesentlichen ME - Komponenten wird durch die Überwachung innerhalb eines zeitlich zu verschiebenden Fensters die Modellbildung zu einer adaptiven Modellierung. Neben diesen Leistungsmerkmalen der intelligenten Signalverarbeitungsmethoden kommt noch die a priori Schnelligkeit der akustischen Signale von der meßtechnischen Seite hinzu.

Über Rechenzeiten lassen sich hier keine Aussagen machen, da die Verfahren auf dieser Maschine nicht zum Einsatz für die Reaktorüberwachung kommen. Auf einer Zielmaschine, die im System einmal eingesetzt wird, müssen dann noch entsprechende zeitoptimierende Programmieretechniken eingesetzt werden.

Eine rechnergestützte on-line Überwachung mit diesen Methoden, wie es sie zur Zeit noch nicht im Einsatz gibt, die aber gerade bei solch gefährlichen Prozessen äußerst sinnvoll scheinen, könnte sich an diesen Prinzipien und Methoden orientieren.

10.Literaturverzeichnis

- /1/ G.E.P.Box, G.M. Jenkins
Time Series Analysis, forecasting and control
Holden Day, San Francisco, 1970
- /2/ L.Fahrmeir, H. Kaufmann, F. Ost
Stochastische Prozesse
Carl Hanser Verlag München, Wien, 1981
- /3/ W.G. Schneeweiß
Zufallsprozesse in dynamischen Systemen
Springer Verlag Berlin, Heidelberg, 1974
- /4/ H.W. Knobloch, F. Kappel
Gewöhnliche Differentialgleichungen
in Mathematische Leitfäden
Teubner Verlag Stuttgart, 1974
- /5/ P. Mertens
Prognoserechnung
Physica Verlag Würzburg, Wien, 1981
- /6/ M. Brown
Smoothing, Forecasting and Prediction of Discrete Time Series
Prentice Hall, 1963
- /7/ J. Aberle, L.Krebs, K. Schleisiek, G. Weinkoetz,
unveröffentlichter Bericht, KfK, 1979
- /8/ G. Le Guillou, J.P.Parcy,C. Berlin
Application of artificial intelligence to the detection and diagnosis of core faults in fast
reactors
IAEA-SM--265/54
Proceedings of an international symposium on nuclear power plant control and
instrumentation ,Munich, 11-15 October 1982, p. 173-186

- /9/ H. Schuler
Frühzeitige Erkennung gefährlicher Reaktionszustände in chemischen Reaktionen
Regelungstechnik, Vol. 32(6) 1984, S. 190
Oldenburg Verlag München, Juni 1984
- /10/ M. Brunet
Pattern recognition techniques applied to acoustic detection of liquid-metal fast breeder
reactor cooling defects
nuclear science and engineering, vol 84, 1983, S. 373-379
- /11/ B.O.Wey, R.S.Overeton, G.Hughes
The evaluation of automatic decision making systems using a temperature noise
dataset
17. informal meeting on reactor noise, Karlsruhe 1984
- /12/ E.Tuerkcan, R.Oguma
Improved Noise analysis methods for on line determination of in core instrumentations
and power reactor parameters
ECN--148
Netherlands Energy research foundation, Januar 1984
- /13/ T.S. Huang
Image sequence Analysis
Springer Series in Information Sciences 5
Springer Verlag Berlin,Heidelberg, New York 1981
- /14/ L.N. Kanal, A. Rosenfeld
Progress in pattern recognition
North Holland Publishing Company, 1981
- /15/ H. Niemann, G. Winkler
Eine Theorie zur quantitativen Beschreibung von Mustern
Nachrichtentechnische Zeitschrift Bd. 22, S. 94
VDE Verlag GmbH Berlin, 1969
- /16/ F. Fukunaga, W. Koontz
Application of the Karhunen-Loeve Expansion to Feature selection and ordering
IEEE Transactions on Computers, Vol. C 19, Mo. 4, April 1970, S. 311
- /17/ H. Niemann
Klassifikation von Mustern
Springer Verlag Heidelberg, New York, Tokio, 1983

- /18/ J. Ehrhardt
Detekton oszillatorischer Komponenten in verrauschten Signalen und Anwendung
zum schnellen Nachweis von Kühlmittelsieden in natriumgekühlten Reaktoren
Dissertation Karlsruhe, September 1975
- /19/ L. Gmeiner
Microprozessor-based Integrated LMFBR core surveillance
KfK Bericht Nr. 3749, 1. und 2. Teil, Karlsruhe 1984
- /20/ W.M. Carey et al.
The detection of Sodium Vapor Bubble Collapse in a Liquid Metal Fast Breeder Reactor
Progress in Nuclear Energy , Vol. 1, 2-4, New Series 1977
- /21/ D. Schulz
Lineare und nichtlineare Verarbeitung von amplitudenmodulierten stochastischen
Prozessen zur akustischen Qualitätskontrolle und Schadenfrüherkennung
Dissertation TU Karlsruhe, 1976
- /22/ J.Aberle, R.Bartholomay, H. Rohrbacher, K.Schleisiek
Potential and Problems of Acoustic Boiling Detection
10.Meeting of the Liquid Metal Boiling Working Group
Karsruhe, 27-29. Oktober 1982
- /23/ H.Niemann
Methoden der Mustererkennung
Akad. Verlagsgesellschaft Frankfurt a.M., 1974
ISBN 3-400-00213-5
- /24/ H.Niemann
Pattern analysis
Springer Verlag , New York, 1981
- /25/ W. A: Lea
Trends in Speech Processing
Prentice Hall, Inc., Englewood Cliffs, 1980
- /26/ W.K. Pratt
Digital Image Processing
J.Wiley & Sons, New York, Chichester, Brisbane, Toronto, 1978
ISBN 0-471-01888-0

- /27/ K. Fukunaga
Introduction to statistical pattern recognition
Academic Press, New York, San Francisco, London, 1972
- /28/ G. Winkler
Stochastische Systeme: Analyse und Synthese
Akademische Verlagsgesellschaft Wiesbaden, 1977
- /29/ W. Marth
Das Projekt Schneller Brüter -Stand und Zielsetzung
KfK Nachrichten, Jahrgang 15, Karlsruhe, Februar 1983, S.61
- /30/ D. Steinhausen, K. Langer
Clusteranalyse: Einführung in die Verfahren der automatischen Klassifikation
Walter de Gruyter Verlag Berlin, New York 1977
- /31/ M. Brunet, A. Despret
Acoustic Detection of A Cavitation Noise in the French Breeder Reactor Phenix;
Specialist's Meeting on boiling noise detection
Risley, GB, 9.-11. Juni 1981, CEA - Conf 5920
- /32/ private Mitteilung, KfK interner Bericht