

FORSCHUNGSZENTRUM
ROSSENDORF e.V.

FZR

Archiv-Ex.

FZR-67

Januar 1995

G. Hessel, W. Schmitt und F.-P. Weiß

Leckdetektion an komplizierten
dreidimensionalen Topologien

Forschungszentrum Rossendorf e.V.

Postfach 51 01 19 · D-01314 Dresden

Bundesrepublik Deutschland

Telefon (0351) 591 3197

Telefax (0351) 591 3651

E-Mail schmitt@fz-rossendorf.de

Forschungszentrum Rossendorf e.V.
Institut für Sicherheitsforschung

Leckdetektion an komplizierten dreidimensionalen Topologien

- Abschlußbericht ¹⁾ -

G.Hessel, W.Schmitt und F.-P.Weiß

¹⁾ Das Forschungsvorhaben wurde durch das Sächsische Staatsministerium für Wissenschaft und Kunst gefördert. Es ist unter dem Förderkennzeichen Nr. 7541.83-FZR/2 registriert. Die Autoren sind für den wissenschaftlichen Gehalt des Berichtes verantwortlich.

Inhaltsverzeichnis

	Seite
1. Stand vor der Durchführung des Vorhabens	1
2. Aufgabenstellung	1
3. Gewählter Weg	1
4. Stand der Wissenschaft und Technik	2
5. Zusammenarbeit	3
6. Ergebnisse	3
6.1 Experimentelles	3
6.2 Leckortung mit Mustererkennungsverfahren	5
6.2.1 Fuzzy-Leckortungsmethode	5
6.2.2 NN-gestützte Leckdetektionsmethode	7
6.3 Leckortung mit Luftschall	8
6.4 Leckortung mit Körperschall	9
6.5 Zuordnung untrainierter Lecks	11
7. Verwertbarkeit der Ergebnisse und Erfahrungen	14
8. Literaturverzeichnis	15

Kurzfassung

Die bekannten Verfahren der akustischen Leckortung (Dämpfungsmethode, Laufzeitdifferenzmessung mittels Korrelationsanalyse) sind an lineare Rohrleitungsgeometrie gebunden, so daß sie bei komplizierten dreidimensionalen Topologien aufgrund von vielfachen Schallreflexionen und verschiedenen Schallmoden (Ausbreitungsgeschwindigkeiten) versagen. Es wurde deshalb eine neue Methode für die Erkennung und Ortung von Lecks an komplizierten geometrischen Strukturen entwickelt und experimentell an einer Originalanlage überprüft.

Die neue Leckortungsmethode basiert auf der Messung des leckinduzierten Körperschalls oder Luftschalls und auf der Anwendung von Mustererkennungsverfahren. Die Leistungsfähigkeit sowohl von Fuzzy Logic als auch von neuronalen Netzen für die akustische Leckortung an komplizierten Topologien konnte experimentell nachgewiesen werden.

Die Methode ist prototypisch für den russischen Druckwasserreaktor WWER-440 entwickelt worden. Sie ist jedoch durch die Lernfähigkeit der benutzten Klassifikatoren auf andere Druckanlagen übertragbar.

Abstract

The well-known methods of the acoustic leak localization using the attenuation differences or propagation time differences (e.g. cross correlation analysis) are restricted to the linear geometry of pipe lines. At complicated three-dimensional topologies they fail because there are several modes of the structure-borne sound that have different propagation velocities and because numerous connecting branches generate multiple sound reflexion.

Therefore, a new method for detecting and localizing the leaks at complicated geometrical structures was developed and experimentally proved at an original facility. This approach is based on the detection of the leak induced airborne sound or structure-borne sound as well as on the application of pattern recognition procedures.

The efficiency both of Fuzzy Logic and neural networks for the acoustic leak localization could be experimentally proved. Though the method has been prototypically developed for Russian pressurized water reactors of VVER-440 type, it can also be used by the self-learning capability of the classifiers at other pressurized facilities.

1. Stand vor der Durchführung des Vorhabens

Anlaß für das Vorhaben waren zahlreiche Leckstörfälle an Druckanlagen mit komplizierten dreidimensionalen Topologien, bei denen die Lecks mit den vorhandenen Überwachungsverfahren nicht erkannt worden sind und dadurch Gefährdungen der Anlagensicherheit und der Umwelt bestanden haben. Aus diesem Tatbestand resultierten auch die Empfehlungen in Sicherheitsberichten (GRS, IAEA), die gefährdeten Anlagen mit Systemen zur Erkennung und Ortung von Leckagen auszurüsten.

Bislang existierte jedoch weltweit keine Detektionsmethode, mit der Lecks an komplizierten dreidimensionalen Strukturen zuverlässig erkannt und geortet werden können.

2. Aufgabenstellung

Ziel des Forschungsvorhabens war es, aufbauend auf den akustischen Verfahren für lineare Rohrleitungsgeometrien [1,2] und auf den fortgeschrittenen Mustererkennungsverfahren, eine neue Detektionsmethode zu entwickeln, mit der die Erkennung und Ortung von Leckagen auch an komplizierten dreidimensionalen Topologien eindeutig möglich ist. Dazu mußten geeignete selbstlernende Klassifikatoren entwickelt werden, die eine große Anzahl sowohl von Merkmalen in den Mustern des Leckschalls als auch von Leckpositionen verarbeiten können. Um die Eigenschaften dieser Klassifikatoren zu untersuchen, sind Lecksimulationsexperimente an einer Originalanlage notwendig.

Hauptergebnis des Vorhabens sollte die prototypische Entwicklung eines Detektions- und Ortungsverfahrens für Lecks an komplizierten dreidimensionalen Strukturen sein, das eine Adaption an andere technische Anlagen ähnlicher Topologie gestattet.

3. Gewählter Weg

Die Idee der neuen Methode ist es, fortgeschrittene Mustererkennungsverfahren für die Leckortung anzuwenden. Das Arbeitsprinzip dieser Ortungsmethode ist im Bild 1 schematisch dargestellt. Zunächst muß der Klassifikator in einer Trainingsphase (gelbmarkiert) mit den Schallmustern von allen möglichen Leckpositionen angeleert

werden. Hierbei werden mit einer Schallquelle Lecks an allen möglichen Leckpositionen simuliert und das induzierte Schallfeld mit einer Multisensor-Anordnung gemessen, die an der Struktur installiert ist. Für die Leistungsfähigkeit eines Klassifikators ist die Extraktion klassenspezifischer Merkmale aus den gemessenen Signalen von besonderer Bedeutung.

Nachdem der Klassifikator für alle möglichen Positionen angelernt wurde, können mit ihm in der Klassifikationsphase (rotmarkiert) unbekannte Leckagen erkannt und lokalisiert werden.

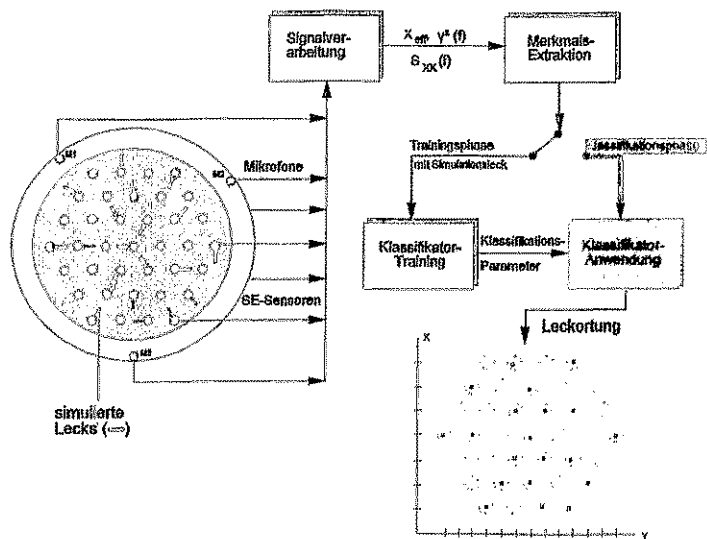


Bild 1 Funktionsprinzip - Leckortung mit Mustererkennungsmethoden

○ Standrohr ○ Standrohr mit SE-Sensor

Im Rahmen des Vorhabens wurden folgende wichtige Arbeitsschritte realisiert:

- Aufbau eines akustischen 1:3-Versuchsmodells für Untersuchungen zur
 - * Körperschallausbreitung der verschiedenen Wellenmoden
 - * Sensoranordnung und Sensorankopplung
 - * Entwicklung intensiver Schallquellen für die Lecksimulation
- Entwicklung von Klassifikatoren auf der Basis von Fuzzy Logic
- Anwendung neuronaler Netze für die Leckortung mittels Luft- und Körperschall
- Experimentelle Erprobung und Vergleich der entwickelten Klassifikatoren an einer Originalanlage

4. Stand der Wissenschaft und Technik

Die Korrelationsanalyse hat sich als empfindlichste und genaueste Leckortungsmethode für Rohrleitungen erwiesen. Die genaue Ortung eines Lecks setzt jedoch voraus, daß die Länge zwischen den beiden Sensoren und die Schallgeschwindigkeiten, die von den Rohrabmessungen, dem Werkstoff und dem Medium abhängen, exakt bekannt sein müssen, um mit Hilfe der aus der Kreuzkorrelationsfunktion ermittelten Laufzeitdifferenz auf den Leckort schließen zu können [2].

Auf zweidimensionalen Topologien glatter Struktur kann das Triangulationsverfahren genutzt werden, das aus den Laufzeitdifferenzen von drei auf einem Dreieck verteilten Sensoren den Leckort bestimmt.

Als eines der fortgeschrittensten Meßsysteme für einfache dreidimensionale Strukturen gilt das Tankboden-Lecküberwachungssystem TB-1000 (Physical Acoustic Corporation) [3]. Es wertet die Laufzeitdifferenzen der direkten Schallwellen zwischen 12 symmetrisch am Behälterumfang verteilten Schallemissionssensoren aus, wobei trotz umfangreicher Hardware (12-Kanal-SPARTAN AE System) und Software bereits einfache dreidimensionale Strukturen Meßzeiten von 1 Stunde und Auswertzeiten von 2 Stunden erforderten. Bei Behältern mit vielen Anschlußstutzen ist eine zuverlässige Leckortung aufgrund der Vielfalt der reflektierten Schallanteile überhaupt nicht mehr möglich.

5. Zusammenarbeit

Zur Realisierung des Forschungsvorhabens wurde mit folgenden Einrichtungen kooperiert:

- Energiewerke Nord GmbH Greifswald, Bereitstellung des Reaktordruckgefäßdeckels (Block 6) für die Lecksimulationsexperimente
- Hochschule für Technik, Wirtschaft und Sozialwirtschaft Zittau/Görlitz (FH), Fachgruppe Physik, Entwicklung eines automatischen Kalibrierungsverfahrens für Multi-Schallemissionssensor-Anordnungen
- Fraunhofer Institut für zerstörungsfreie Prüfverfahren, Außenstelle Dresden, Einrichtung für akustische Diagnose und Qualitätssicherung, Entwicklung spezieller Sensoren und Vorverstärker sowie eines Software-Moduls zur Leckortung

6. Ergebnisse

6.1 Experimentelles

Bild 2 zeigt die Meß- und Auswertetechnik, die für die prototypische Erprobung der neuen Leckdetektionsmethode an einem originalen WWER-440 Druckgefäß im ehemaligen Kernkraftwerk in Greifswald benutzt wurde.

Der leckinduzierte Körperschall wird im Frequenzbereich von 50 bis 500 kHz mit 12 Schallemissionssensoren gemessen, die an Standrohrflanschen in der Nähe des Druckgefäßdeckels montiert wurden. Alle Schallemissionssensoren können auch im Sendebetrieb (inverser Betrieb) arbeiten, was für die Kalibrierung des Sensorfeldes benötigt wird (Kooperationsleistungen des Fraunhofer Institutes / EADQ Dresden und der HTWS Zittau).

Zusätzlich wird der leckinduzierte Luftschall mit drei hochfrequenten Mikrofonen (bis 70 kHz) detektiert. Sie wurden an der Wand des Schutzbehälters befestigt, die den

70 kHz) detektiert. Sie wurden an der Wand des Schutzbehälters befestigt, die den Schallraum um den Reaktordeckel mit seinen 37 Standrohren (ca. 7m lang) begrenzt.

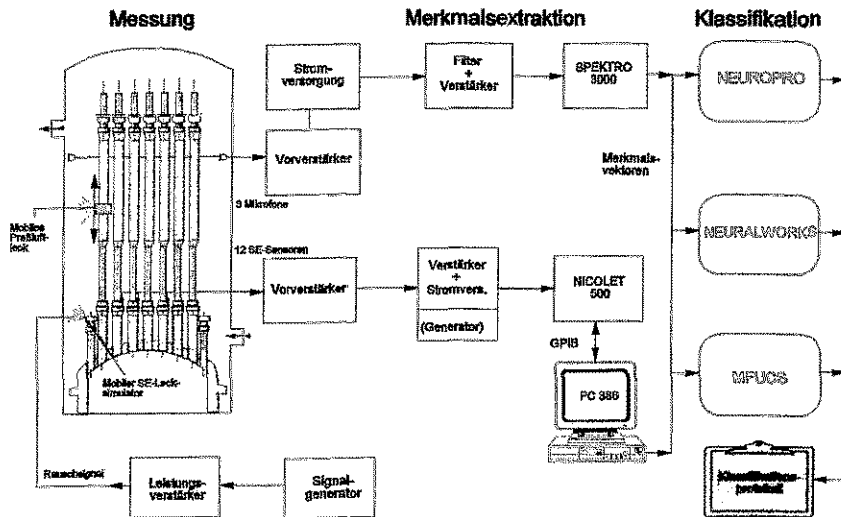


Bild 2 Meß- und Auswertetechnik zur akustischen Leckdetektion an komplizierten dreidimensionalen Topologien

Zur Simulation von Lecks wurden folgende Schallquellen entwickelt:

- dünne Metallblättchen, die durch einen Druckluftstrahl zu intensiven Schwingungen angeregt werden
- Freistrahldüsen, die mit Preßluft arbeiten
- Schallemissionssensoren im inversen Betrieb mit einem Rauschsignalgenerator.

Aus den gemessenen Schallsignalen der Sensorfelder werden im Rahmen der Merkmalsextraktion die Eingangsmuster (Merkmalsvektoren) für die verschiedenen Musterklassifikatoren erzeugt. Die Signalanalytoren SPEKTRO 3000 und NICOLET 500 liefern beispielsweise statistische Kennfunktionen (Effektivwerte, Komponenten von Frequenzspektren, Kohärenzwerte usw.) für die Bildung der Mustervektoren. Diese Vektoren dienen dann zum Training und zur on-line Klassifikation von neuronalen Netzen bzw. Fuzzy-Klassifikatoren. Aufgrund der bei der Leckortung an komplizierten Topologien anfallenden großen Anzahl sowohl von Elementen im Merkmalsvektor (>100) als auch von Leckpositionen (ca. 50) mußten die PC-Software-Tools NEUROPRO [4] und MFUCS [5] für die Leckortung modifiziert werden.

Das Softwarepaket NEURALWORKS [6] wurde für grundlegende Untersuchungen zur Einsatzmöglichkeit neuronaler Netze in nichtlinearen komplexen Systemen insbesondere zur Generalisierung von Mustern untrainierter Klassen genutzt.

6.2 Leckortung mit Mustererkennungsmethoden

6.2.1 Fuzzy-Leckortungsmethode

Im allgemeinen besteht ein Fuzzy-Musterklassifikator (im folgenden als Fuzzy-Klassifikator bezeichnet) aus einem Satz von parametrischen Zugehörigkeitsfunktionen, wobei jede von ihnen eine einzige Klasse (Leckposition) repräsentiert und die Zugehörigkeit eines Merkmals X_i zu der k -ten Klasse bestimmt. Die Unschärfe ist dadurch gegeben, daß die Zugehörigkeit zu den Klassen alle Werte zwischen Null und Eins annehmen kann. Zunächst müssen die Zugehörigkeitsfunktionen in einer Trainingsphase angelehrt werden, d. h. die Parameter der vorgegebenen Zugehörigkeitsfunktionen sind aus den Trainingsmustern zu ermitteln. Als Zugehörigkeitsfunktionen werden Potentialfunktionen benutzt

$$\mu_k(X_i) = \frac{1}{1 + \left| \frac{X_i - \bar{X}_{ik}}{C_{ik\pm}} \right|^{d_{ik\pm}}} \quad (1)$$

wobei die Parameter bedeuten

- \bar{X}_{ik} Lage des (scharfen) Repräsentanten (Schwerpunkt) des i -ten Merkmals bezüglich der k -ten Klasse
- $C_{ik\pm}$ linke (-) und rechte (+) Ausdehnung der Zugehörigkeit vom Schwerpunkt (\bar{X}_{ik})
- $d_{ik\pm}$ Exponent, der den Abfall der Zugehörigkeit auf der linken (-) bzw. rechten (+) Seite des Schwerpunktes definiert.

Ein trainierter Fuzzy-Klassifikator ist dann in der Lage, unbekannte Merkmalsvektoren \underline{X} mit Hilfe des Sympathievektors $\underline{\mu}(\underline{X})$ zu bestimmen

$$\underline{\mu}(\underline{X}) = [\mu_1(\underline{X}), \mu_2(\underline{X}), \dots, \mu_k(\underline{X})]^T \quad (2)$$

Die Elemente des Sympathievektors enthalten die Zugehörigkeit des Merkmalsvektors \underline{X} zu den k Klassen. Z. B. ergibt sich die Zugehörigkeit zur k -ten Klasse aus

$$\mu_k(\underline{X}) = \frac{1}{1 + \sum_i \left| \frac{X_i - \bar{X}_{ik}}{C_{ik\pm}} \right|^{d_{ik\pm}}} \quad (3)$$

Da im allgemeinen Sympathiewerte zu mehreren Klassen im Sympathievector vorhanden sein können, wird das minimale Sympathieverhältnis S bestimmt

$$S = \frac{\max_{k \neq j} [\mu_k(\underline{X})]}{\mu_j(\underline{X})} \leq S_0 \quad (4)$$

$$\text{mit } \mu_j(\underline{X}) = \max_k \mu_k(\underline{X}) \quad , \quad (5)$$

um die Klasse j zu identifizieren, zu der der unbekannte Merkmalsvector \underline{X} gehört.

Durch geeignete Wahl eines maximal zulässigen Schwellwertes S_0 kann die Fehlklassifikationsrate beeinflußt werden. Damit wird ein erforderlicher Abstand zwischen dem höchsten und zweithöchsten Sympathiewert definiert, um eindeutige Zuordnungen zu erhalten und das Risiko einer Fehlklassifikation bewerten zu können.

Beim Fuzzy-Klassifikator besteht die Möglichkeit, die Parameter der Potentialfunktion ohne Training durch den Experten festzulegen. Beispielsweise können bei normalverteilten, bekannten Meßdaten deren statistische Kennwerte wie Mittelwerte und Streuungen als Parameter für die Potentialfunktionen genutzt werden. Im Gegensatz zu den trainierten Zugehörigkeitsfunktionen werden sie als künstliche Fuzzy-Klassifikatoren bezeichnet.

Im Bild 3 sind sowohl trainierte als auch künstliche Zugehörigkeitsfunktionen dargestellt. Der künstliche Fuzzy-Klassifikator (Fuzzy S) ist dadurch charakterisiert, daß die Ausdehnung $c_{ik+} = c_{ik-} = 3\sigma$ für jede Klasse der jeweiligen dreifachen Standardabweichung entspricht, der Schwerpunkt mit dem Mittelwert $\bar{X}_{ik} = \bar{X}_i$ identisch ist und daß der Exponent $d_{ik+} = d_{ik-} = 2$ wie bei allen anderen Zugehörigkeitsfunktionen gewählt wurde. In diesem Fall werden mit dem künstlichen Fuzzy-Klassifikator

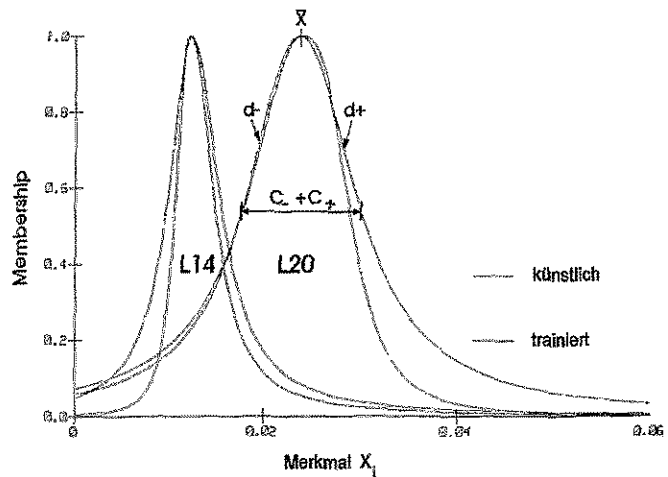


Bild 3 Zugehörigkeitsfunktionen von Fuzzy-Klassifikatoren für zwei Leckpositionen (L14, L20)

keine wesentlich schlechteren Klassifikationsergebnisse erzielt, wie bei den Vergleichsmessungen festgestellt wurde (siehe Tab. 1, 98,6% Klassifikationsrate für den trainierten "Fuzzy T" und 95,9% für den künstlichen Fuzzy-Klassifikator "Fuzzy S").

6.2.2 NN-gestützte Leckdetektionsmethode

Im folgenden sollen einige Grundprinzipien der auf neuronalen Netzen (NN) basierenden Leckdetektionsmethode erläutert werden. Die Topologie eines typischen mehrschichtigen neuronalen Netzes ist im Bild 4 dargestellt. Die Neuronen (Rechenelemente) sind in einer Eingangsschicht (In), einer verdeckten Schicht (Hidden 1) und einer Ausgangsschicht (Out) angeordnet. Die Schichten sind miteinander über die sogenannten Gewichte verbunden. Die Verbindungen zwischen einzelnen Neuronen besitzen unterschiedliche Stärken, was durch unterschiedliche Farben angezeigt wird. In den Gewichten wird das anzulernende Wissen gespeichert. Die Anzahl der Neuronen in der Eingangsschicht ist identisch mit der Anzahl der Elemente X_i des Merkmalsvektors \underline{X} , während die Anzahl der Ausgangsneuronen der Anzahl K der Klassen entspricht, die zu klassifizieren sind. Die verschiedenen Klassen repräsentieren in dieser Anwendung die unterschiedlichen Leckpositionen $L_1 \dots L_k$. Im allgemeinen kommt noch die Klasse $L_0 =$ "kein Leck" hinzu.




Bild 4 Topologie eines neuronalen Netzes

Das neuronale Netz muß in einer Trainingsphase mit Paaren von Eingangsmustern (Merkmalsvektoren) \underline{X} und Ausgangsmustern (Klassifikationsvektoren) \underline{O} konfrontiert werden, um die Verbindungsstärken (Gewichte) zwischen den Neuronen der verschiedenen Schichten anzulernen. Diese Prozedur wird als überwachtes Lernen bezeichnet.

Ein trainiertes neuronales Netz ist dann in der Lage, angebotene unbekannte Eingangsmuster einer Leckposition zuzuordnen oder gegebenenfalls als unbekannt zurückzuweisen.

Es wurden insgesamt 7 neuronale Netztypen untersucht. Als besonders geeignet für

die akustische Leckortung haben sich dabei Perceptron-Netze mit Fehler-Back-propagation und Radial-Basis-Function-Netze (RBFN) erwiesen [7]. Der prinzipielle Unterschied zwischen beiden Netztypen ergibt sich aus der Form des angelernten, gespeicherten Wissens, das i. allg. durch die Werte der Verbindungsstärken (Gewichte) gespeichert ist. Im Gegensatz dazu ist das gespeicherte Wissen der verdeckten Neuronen im RBFN nicht mehr durch Verbindungsstärken (Skalare) sondern durch Gewichtsvektoren (Prototypen der Trainingsvektoren) repräsentiert. Außerdem besitzt jedes verdeckte Neuron neben diesem Koordinatenvektor einen zweiten Gewichtsvektor, der das radialsymmetrische Rezeptive Feld in der Umgebung des gespeicherten Prototypen charakterisiert. Ein Abstandsmaß zum Soll / Ist-Vergleich zwischen Merkmalsvektoren und dem Prototypzentrum (z. B. das Euklidische Abstandsmaß oder City- Abstandsmaß) wird als Eingang der Transferfunktion des verdeckten Neurons benutzt, um die Abbildung dieser Abstandswerte auf die Ausgangsschicht vorzunehmen. Dabei gewährleistet die Transferfunktion, daß ein verdecktes Neuron immer nur dann voll aktiviert wird, wenn ein Merkmalsvektor innerhalb seines Rezeptiven Feldes liegt.

Mit Hilfe seiner Prototypvektoren sind RBFNe in der Lage, topologieerhaltende Abbildungen zu erzeugen. Das bedeutet, daß Neuronen von Klassen mit ähnlichen Eigenschaften durch Selbstorganisation benachbart angeordnet werden. Diese Eigenschaften sind im benutzten Kohonen-Netz implementiert.

6.3 Leckortung mit Luftschall

Für Leckortungsprozeduren, die den Luftschall zur Merkmalsgewinnung benutzen, haben sich Kohärenzfunktionen zwischen zwei hochfrequenten Mikrofonsignalen als geeignete Merkmalsvektoren zur Charakterisierung des Quellortes erwiesen. Die normierte Kohärenzfunktion $\gamma^2(f)$ wird durch die folgende Beziehung definiert

$$\gamma^2(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f) \cdot P_{yy}(f)} \quad (6)$$

wobei f die Frequenz,
 $P_{xy}(f)$ das Kreuzleistungsspektrum und
 $P_{xx}(f), P_{yy}(f)$ die Autoleistungsspektren der beiden Mikrofonsignale bedeuten.

Die Ursache für die besondere Eignung dieser statistischen Kennfunktion liegt sicherlich darin, daß jede Leckposition zu einer typischen nichtlinearen Schallausbreitung von einem zum anderen Mikrofon führt. Und die spezielle Übertragung bestimmt die Kohärenzfunktion. Außerdem beeinflussen zeitliche spektrale Änderungen des leckinduzierten Luftschalls die Kohärenzfunktionen nicht.

Um Lecks in verschiedenen Höhenniveaus an den Standrohren unterscheiden zu können, wurde ein erweiterter Merkmalsvektor mit 600 Elementen angewendet. Hierbei wurden zusätzlich zur Kohärenzfunktion weitere Merkmale aus den Autoleistungsspektren der beiden Mikrofonsignale gewonnen.

Die Unterscheidung zwischen den geodätischen Höhenniveaus wird durch den steileren Abfall der Autoleistungsspektren mit wachsender Frequenz bei zunehmender Höhe ermöglicht. Im Bild 5 ist dieser Abfall in den Autoleistungsspektren (APS) des Lecks LR46 deutlich erkennbar, das sich ca. 7m oberhalb des Reaktordeckels befindet. Das Leck L40 liegt in der Nähe des Reaktordeckels.

Mehrschichtige Perceptron-Netze mit Fehler-Backpropagation erwiesen sich am besten geeignet für sehr große Merkmalsvektoren. Allerdings zeigte auch dieser Netztyp bei mehr als etwa 15 trainierten

Leckpositionen mangelnde Konvergenz, wenn 600 oder mehr Merkmale angelernt wurden. Deshalb mußte die Anzahl der Merkmale deutlich reduziert werden, wenn mehr als etwa 50 verschiedene Leckpositionen erkannt werden sollten.




Bild 5 Erweiterter Merkmalsvektor

6.4 Leckortung mit Körperschall

Bei der Anwendung von Körperschallsignalen zur Leckortung wurden die Trainings- und Klassifikationseigenschaften der neuronalen Netze und der Fuzzy-Klassifikatoren mit den Daten einer großen Anzahl von Klassen (44) untersucht, wobei der Merkmalsvektor aus den RMS-Werten der 12 AE-Sensorsignale gebildet wurde.

Die Ergebnisse des Vergleiches sind in der Tab. 1 zusammengestellt [8]. Es ist offensichtlich, daß die Fuzzy-Klassifikatoren wesentlich schneller als neuronale Netze angelernt werden können, sie aber andererseits nur bei der Reklassifikation eine Genauigkeit von 100% erreichen, während die Klassifikationsraten für den trainierten Fuzzy-Klassifikator Fuzzy T 98,6% und für die beiden künstlichen Fuzzy-Klassifikatoren Fuzzy S und Fuzzy C 95,9% bzw. 95,4% betragen.

Die fehlenden Reklassifikationsraten der beiden künstlichen Fuzzy-Klassifikatoren sind Ergebnis der Tatsache, daß sie nicht trainiert wurden, sondern ihre Parameter aus a priori Informationen z. B. aus den statistischen Kennfunktionen normalverteilter, bekannter Meßdatensätze ermittelt wurden.

Da mit den künstlichen Fuzzy-Klassifikatoren noch relativ korrekte Klassifikationsraten erreicht werden können, bietet sich ihr Einsatz an, wenn aus sicherheitstechnischen oder ökonomischen Gründen zunächst kein Training der Klassifikatoren möglich ist.

Die gegenüber der Reklassifikationsrate geringere Klassifikationsgenauigkeit zeigt, daß der trainierte Fuzzy-Klassifikator eine schlechtere Generalisierungsfähigkeit als die besten neuronalen Netze (P2) bezüglich Merkmalsvektoren besitzt, die nicht beim Training repräsentiert wurden.

Das dreischichtige Perceptron-Netz (P2) und das Reduced-Nearest-Neighbour-Netz (RNNN) liefern sowohl eine 100% richtige Reklassifikation als auch eine korrekte Klassifikationsrate von 100%. Allerdings muß erwähnt werden, daß das RNNN und das Kohonen-Netz (KN) über eine erheblich schlechtere Separabilität zwischen den verschiedenen Klassen verfügen als die P1- und P2-Netze. Zum Beispiel ordnet das P2-Netz die Merkmalsvektoren zu den richtigen Klassen mit einer Ausgangsaktivität (Zugehörigkeit) von 1.00 in allen Fällen zu, während die Werte der anderen Ausgangsneuronen unter 0.05 bleiben.

Die Klassifikationsrate von 61% deutet daraufhin, daß das zweischichtige Perceptron-Netz P1 alle 44 Klassen nicht linear trennen kann, wenn nur 12 Merkmale benutzt werden.

Tab. 1 Trainings- und Klassifikationseigenschaften verschiedener Klassifikatoren

Netzname	P1	P2	KN	RNNN	Fuzzy T	Fuzzy S ¹⁾	Fuzzy C ²⁾
Parameter	12/44	12/25/44	12/132/44	12/106/44	12/44	12/44	12/44
Trainingszeit	7h	20h	3h	12min	<5s	<5s	<5s
Reklassifikation	65%	100%	92%	100%	100%	-	-
Klassifikation	61%	100%	91%	100%	98,6%	95,9%	95,4%

Parameter der künstlichen Fuzzy-Klassifikatoren:

$$1) x_{ik} = \bar{x}_{ik}, d_{ikt} = 2, c_{ikt} = 3\sigma_{ik}$$

$$2) x_{ik} = \bar{x}_{ik}, d_{ikt} = 2, c_{ikt} = 0,3 \max(\bar{x}_{ik})$$

k


Die Eigenschaft des Kohonen-Netzes, die Topologie zu erhalten, kann genutzt werden, um die erforderliche Sensoranzahl und ihre günstigsten Positionen zu bestimmen. In Tabelle 2 sind die Klassifikationsraten des KN und RNNN für einige ausgewählte Sensoranordnungen zusammengestellt. Obwohl die Separabilität mit sinkender Sensoranzahl abnimmt, klassifiziert das RNNN auch noch richtig, wenn nur 3 Sensoren verfügbar sind. Die Abnahme der Separabilität des RNNN führt allerdings

zu kleineren Unterschieden zwischen den Werten der verschiedenen Ausgangsneuronen. So war z. B. für 3 Sensoren der Wert des richtigen Ausgangsneurons zwar noch 1.00, aber die Werte anderer Ausgangsneuronen kamen diesem Wert sehr nahe (0.98).

Tab. 2 Klassifikationsrate als Funktion der Sensoranordnung

Sensoranzahl	12	9	8	7*	6	3
Konfiguration	0-11	0-8	1-8	0-6	1-6	4-6
RNNN	100%	100%	100%	100%	100%	100%
KN	92.2%	97.8%	97.8%	100%	96.4%	90.1%

* Anordnung der 7 Sensoren (◦):



Das Kohonen-Netz erreicht die besten Klassifikationsergebnisse mit 7 Schallemissionssensoren, wenn die in der Legende dargestellte Anordnung gewählt wird (Tab.2). Es wird vermutet, daß die Abnahme der richtigen Klassifikationsrate trotz anwachsender Sensoranzahl durch das Euklidische Distanzmaß verursacht wird. Die 5 zusätzlichen Sensoren tragen nicht zur Separabilität bei, sondern sie rufen ein Untergrundrauschen in der Distanz hervor, das schließlich zu schlechteren Klassifikationsergebnissen führt.

6.5 Zuordnung untrainierter Lecks

Im allgemeinen können Klassifikatoren nur Muster von trainierten Klassen erkennen, andere Musterklassen werden zurückgewiesen. Die Fähigkeit eines neuronalen Netzes sogar Muster von untrainierten Klassen zu klassifizieren, ist jedoch von praktischem Interesse, weil in einigen Anwendungen nicht von allen möglichen Fehlerklassen Merkmalsvektoren für die Trainingsphase zur Verfügung stehen.

Um die Generalisierung bezüglich der Muster untrainierter Klassen zu untersuchen, wurden alle eingesetzten Klassifikatoren mit demselben Trainingsdatensatz einer

reduzierten Anzahl von Leckpositionen (31 von 37) angelernt, während sie in der Klassifikationsphase mit dem Datensatz der 6 nicht trainierten Leckpositionen konfrontiert wurden. Hierbei handelt es sich um eine "erweiterte Generalisierung", weil in der Literatur der Begriff "Generalisierung eines Netzes (Generalisierungsfähigkeit)" für die Klassifikation von Testdaten bereits vergeben ist, die aus der Menge der trainierten Klassen stammen, aber deren Meßdaten nicht beim Training präsentiert wurden.

Bevor die Netze auf ihre Generalisierungsfähigkeit untersucht wurden, erfolgte die Anpassung der Netze an die gestellte Klassifikationsaufgabe durch die Optimierung der Neuronenanzahl in der verdeckten Schicht. Bild 6 zeigt, wie die Anzahl der verdeckten Neuronen die Klassifikationseigenschaften eines Perceptron-Netzes (P2) beeinflusst. Der minimale Klassifikationsfehler wird für die Anordnung von 7 Sensoren bei einer Anzahl von 15 bis 20 Neuronen in der verdeckten Schicht und für die Anordnung von 12 Sensoren bei etwa 25 erreicht.

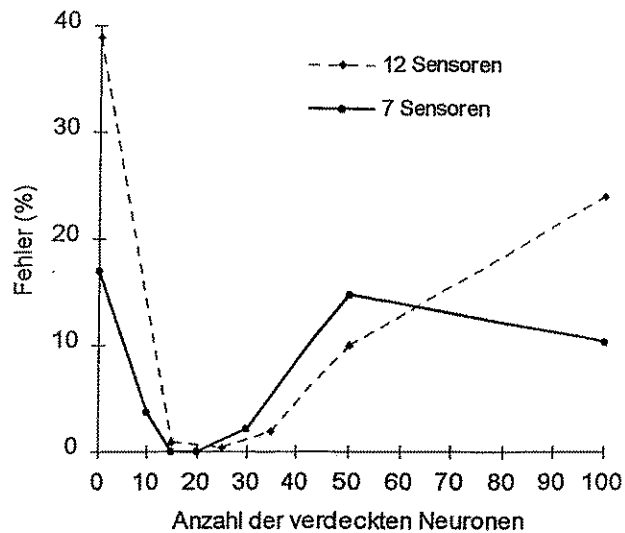


Bild 6 Klassifikationsfehler eines Perceptron-Netzes für 2 Sensoranordnungen als Funktion der verdeckten Neuronenanzahl

Die Zuordnung von 8 untrainierten Lecks für ein Perceptron-Netz (P2) ist in Abhängigkeit von der verdeckten Neuronenanzahl durch Balkendiagramme im Bild 7 dargestellt. Die höchsten Zuordnungswerte der untrainierten Lecks zu trainierten Positionen werden durch die Netze mit 15, 20 und 30 Neuronen in der verdeckten Schicht erzielt. Aufgrund der verwendeten Ausgangsschicht des neuronalen Netzes (jedes Ausgangsneuron entspricht einer bestimmten trainierten Leckposition) kann natürlich auch von einem optimal angepaßten neuronalen Netz bestenfalls eine Zuordnung der untrainierten Lecks zu einer benachbarten Leckposition oder gegebenenfalls zum gleichen Standrohr erwartet werden, wenn dort ein Leck in einer anderen Lage (Höhe) angelernt wurde.

In allen Fällen wurden die untrainierten Lecks eindeutig zum gleichen Standrohr z. B. LR50/Lr53 und L41/L40 oder zu einem benachbarten Standrohr z. B. L39/L42 und L22/L28 zugeordnet. Weiter muß bemerkt werden, daß die Ausgangsaktivität für entferntere Standrohre geringer als 0.05 waren.

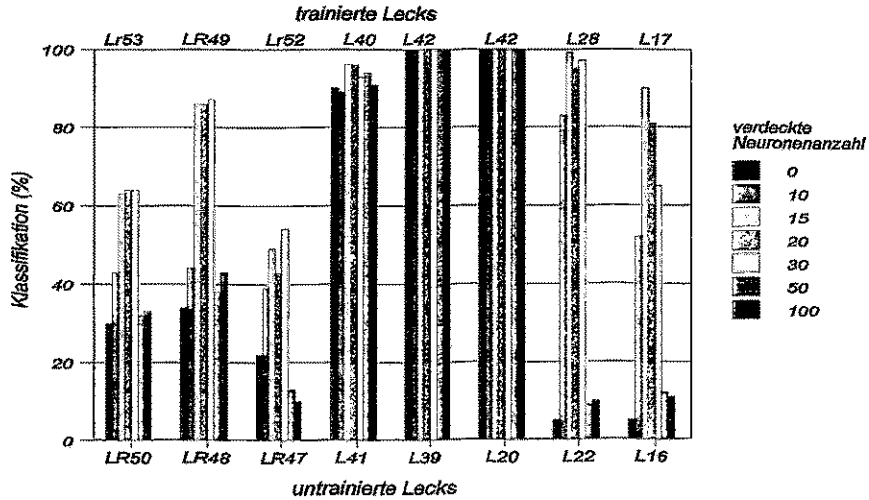


Bild 7 Klassifikation von untrainierten Lecks als Funktion der verdeckten Neuronenanzahl (Perceptron-Netz)

Die Anwendung von RNNN und KN auf die untrainierten Lecks führte dagegen zu mehrdeutigen Ergebnissen, weil sie ähnliche Zuordnungswerte zu verschiedenen Positionen erzeugten.

Im Rahmen der Untersuchung zur Klassifikation untrainierter Lecks wurden auch mehrschichtige neuronale Netze getestet, deren Ausgangsschichten aus nur 2 Neuronen bestanden und die mit den (x, y) -Koordinaten der Leckpositionen angelernt wurden.

Im Bild 8 sind die Klassifikationsergebnisse als eine Projektion der beiden Netzausgabewerte (x, y) auf die Topologie der Standrohrorte dargestellt. Wie die leeren 6 Standrohrdurchmesser zeigen, wurde das Perceptron-Netz (12/20/2) mit nur 31 Leckpositionen angelernt. Das Klassifikationsergebnis für jeden Merkmalsvektor wird durch einen Punkt gekennzeichnet. Im Bild 8 sind die Ergebnisse der Testdatei abgebildet, d.h. 10 Punkte für jede der 31 trainierten Leckpositionen. Alle Zuordnungen liegen innerhalb des durch den Kreis markier-

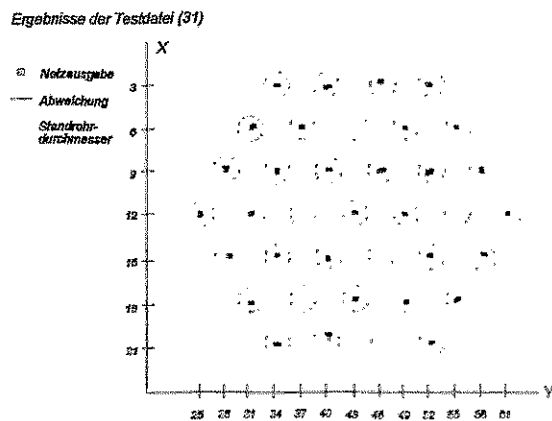


Bild 8 Generalisierung der Testdatei durch das Perceptron-Netz (X, Y-Ausgänge)

ten zugehörigen Standrohrdurchmessers, so daß diesem Perceptron-Netz eine sehr gute Zustandserkennung bestätigt werden kann (Bild 8).

Die Klassifikationsergebnisse von 6 untrainierten Leckpositionen zeigt Bild 9. Dieses Perceptron-Netz klassifiziert 3 untrainierte Leckpositionen (L21-42, L18-37, L12-37) richtig, 2 Lecks nahe der gewünschten Position (L15-46, L12-55) und nur ein Leck (L6-43) zum benachbarten Standrohr (L6-49).

Wie diese Ergebnisse zeigen, ist ein optimiertes Perceptron-Netz mit 2 Koordinaten-Ausgangsneuronen in der Lage, auch untrainierte Lecks (Leckpositionen) teilweise richtig zuzuordnen.

Ergebnisse der untrainierten Lecks




Bild 9 Generalisierung untrainierter Lecks durch das mit 31 Leckpositionen trainierte Perceptron-Netz (X,Y-Ausgänge)

7. Verwertbarkeit der Ergebnisse und Erfahrungen

Die Leistungsfähigkeit von Fuzzy-Klassifikatoren und neuronalen Netzen für die akustische Leckdetektion an komplizierten dreidimensionalen Topologien konnte experimentell bewiesen werden. Geeignete Merkmale für die Erkennung und Ortung von Lecks sind die RMS-Werte des Körperschalls. Bis zu 50 verschiedene Leckorte konnten durch Reduced-Nearest-Neighbour-Netze, dreischichtige Perceptron-Netze und trainierte Fuzzy-Klassifikatoren identifiziert werden. Kohonen-Netze sind besonders geeignet, um die Sensoranordnung für die jeweilige komplizierte Struktur zu ermitteln und die optimale Anzahl der Sensoren zu bestimmen.

Die Leckdetektion mit Luftschall ist eine komplementäre Methode und wird insbesondere benötigt, wenn die Strukturkomponenten, an denen Lecks auftreten können, in verschiedenen geodätischen Höhenniveaus liegen.

Mehrschichtige Perceptron-Netze sind am besten für die Leckortung an komplizierten dreidimensionalen Topologien geeignet, weil sie 100% richtige Klassifikationen liefern, eine exzellente Separabilität und eine vorteilhafte Generalisierungsfähigkeit besitzen.

Perceptron-Netze mit 2 Koordinaten-Ausgangsneuronen scheinen für die Klassifikation auch von untrainierten Lecks besonders nützlich zu sein.

Durch die Anwendung selbstlernender Klassifikatoren kann die neue akustische Leckdetektionsmethode an andere komplizierte Topologien einfach angepaßt werden.

Weitere Forschung ist notwendig, um Klassifikatoren für die Leckraten-Abschätzung zu entwickeln und die Methodik an anderen Anlagengeometrien zu erproben.

Die im Rahmen des Forschungsvorhabens entwickelten Musterklassifikationsverfahren auf der Basis von Fuzzy und neuronalen Netzen sind nicht nur für die akustische Lecküberwachung nutzbar, sondern können bei der Anwendung von geeigneten Merkmalsvektoren prinzipiell auch für andere Diagnoseaufgaben genutzt werden. Die gewonnenen Erfahrungen sollen deshalb zukünftig insbesondere zur Identifizierung von gefährlichen Betriebszuständen in Chemieanlagen eingesetzt werden, wozu ein BMFT-Forschungsvorhaben am 1.1.1995 als Verbundprojekt mit einem Partner aus der chemischen Verfahrenstechnik begonnen wird.

8. Literaturverzeichnis

- [1] Jax, P., K. Ruthrof; Acoustic Emission Inspections of Nuclear Components Considering Recent Research Programmes, Nuclear Engineering and Design 113 (1989) 71-79
- [2] Fuchs, H.V., R. Riehle; Ten Years of Experience with Leak Detection by Acoustic Signal Analysis, Applied Acoustic 33 (1991) 1-19
- [3] Physical Acoustic Corporation; TB-1000 Manual, 1989
- [4] Loos, M.; Bedienhandbuch NEUROPRO, MEDAV Schrift Nr. 394, Uttenreuth, 1992
- [5] Kretschmar, W.; Programmbeschreibung MICRO FUCS - Fuzzy Classification System, Institut für Mechanik, Chemnitz, 1992
- [6] NeuralWare, Inc.; Neural Computing - A Technology Handbook for Professional II/Plus and NeuralWorks Explorer, Pittsburgh, 1993
- [7] Hessel, G., W. Schmitt, and F.-P. Weiß; A New Method for Acoustic Leak Detection at Complicated Geometrical Structures, Proc. of IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS '94, June 13-16, 1994, Espoo, Finland, pp. 153-158
- [8] Schmitt, W., G. Hessel, and F.-P. Weiß; Acoustic Leak Detection at Complicated Topologies Using Fuzzy Classifiers and Neural Networks, Proc. of IMEKO XIII World Congress, September 5-9, 1994, Torino, Italy, pp. 1259-1264