

# Akustische Fehlerdiagnose an industriellen Schallsignalen mit dem Spracherkennungsalgorithmus „Hidden Markov Modell“

C. Danz, F. Attia, Robert Bosch GmbH, Zentrale Forschung, FV/FLP, Stuttgart  
D. Filbert, Technische Universität Berlin, Institut für Meß- und Automatisierungstechnik

## 1. Einführung

Nach der Montage eines Generators, eines Starters oder eines Elektrotriebmotors wird die Qualität des gefertigten Produktes überprüft. Die akustische Qualitätskontrolle nimmt dabei einen hohen Stellenwert zur Sicherung akustischer aber auch funktioneller Eigenschaften ein. Die Prüfung erfolgt in den meisten Fällen durch speziell geschultes Personal in schallgedämmten Kabinen. Problematisch bei dieser subjektiven Qualitätskontrolle sind die Schwankungen in den Entscheidungen der Prüfer. Daher untersucht man Verfahren zur automatischen Bewertung von Schallen. Ein fehlercharakterisierendes Geräusch, z. B. eines Elektrotriebmotors, kann als „Äußerung“ des Motors betrachtet werden. Wenn die akustischen Güteprüfer die „Sprache“ des Motors kennen, gibt ihnen die Interpretation dieser „Äußerungen“ die Möglichkeit, Rückschlüsse auf die Qualität des Motors zu ziehen. Der anschauliche Vergleich von industriellen Schallen und Sprache legt nahe, für die Klassifikation auch Algorithmen zu untersuchen, die sich in der Spracherkennung als robust gegenüber kleinen Störungen erwiesen haben. Spracherkennungssysteme auf der Grundlage von Hidden Markov Modellen (HMM) werden sprecherunabhängig entwickelt. Dabei wird durch das Training mit Datenmaterial verschiedener Sprecher die Variation der Sprache in die Modelle integriert, so daß die Systeme von verschiedenen Sprechern benutzt werden können.

Die Entwicklung eines automatischen Geräuscherkenners für die akustische Qualitätskontrolle kann durch das Training von HMM mit Daten aus einer guten Datenbasis, die eine hohe Anzahl an Beispielsignalen für die entsprechenden Fehlerklassen und die „gut“-Klasse enthält, realisiert werden. Die Integration zeitlicher Varianzen der technischen Geräusche während des Trainings spielt bei der Erkennung ebenfalls eine wichtige Rolle.

## 2. Subjektive vs. objektive Klassifikation von Luftschallsignalen

Im Rahmen der subjektiven Bewertung überprüft ein Facharbeiter am Ende einer Elektromotorenfertigungslinie das akustische Verhalten jedes gefertigten Motors. Die Entscheidung, ob ein Motor „gut“ ist oder an den Reparaturplatz geschickt werden muß, beruht auf der langjährigen Erfahrung des Prüfers. Die Experten sind dabei nicht nur in der Lage, eine Aussage darüber zu treffen, ob der Motor „gut“ oder „schlecht“ ist, sondern welcher Fehlerklasse er angehört.

Bei der subjektiven Klassifikation der aufgezeichneten Schallsignale zur Erstellung einer Lerndatenbasis wurden mehrere Experten befragt. Bei den

durchgeführten Untersuchungen zeigte sich, daß manche Signale eindeutig einer bestimmten Fehlerklasse zugeordnet werden konnten. Bei anderen Signalen zweifelte auch der Experte, ob das entsprechende Signal in die Fehlerklasse A oder B gehört. In einigen Fällen unterschied sich die Expertenentscheidung sogar erheblich voneinander. Mit dem Entwurf des automatischen Fehlerdiagnosesystems kann grundsätzlich erst begonnen werden, wenn man eine zuverlässige Datenbasis vorzuliegen hat.

In der Abbildung 1 sind die Spektrogramme für die „gut“-Klasse und die Fehlerklassen A bis E dargestellt. Man sieht, daß ein Motor mit einem den Fehler A charakterisierenden Geräusch lauter ist als ein guter Motor. Das ist jedoch nicht immer der Fall. Der Schalldruckpegel eines Motors mit einem Fehler A kann ebenso unter dem eines guten Motors liegen. Im Spektrogramm des Fehlers D sieht man deutlich den „Klick“ bei einem Zeitwert von 0.7 sec, die in der Amplitudendarstellung im Rauschen untergeht. Zur Klassifikation der Geräuschsignale müssen also die richtigen klassentrennenden Merkmale der entsprechenden Fehler und der "gut"-Klasse extrahiert werden.

Die Aufgabe des akustischen Güteprüfungssystems ist es, gute Motoren zu identifizieren, jedoch keinen einzigen schlechten Motor als „gut“ auszuweisen. Einen guten Motor als „schlecht“ zu klassifizieren, ist zwar unerwünscht (Pseudofehler), aber nicht kritisch, da der Motor am Reparaturplatz noch einmal subjektiv bewertet wird.

## 3. Fehlerdiagnose von Geräusch-Signalen mit Hidden Markov Modellen

Zuerst werden die Daten an einem Prüfstand in einem schallisolierten Raum aufgenommen. Anschließend werden sie subjektiv klassifiziert. Danach erfolgt die Berechnung der Merkmale und die Definition von Prototyp-HMM für jede Fehlerklasse und die „gut“-Klasse. Dabei gibt man die Anzahl der möglichen Zustände des HMM vor, sowie Anfangswerte für die Mittelwerte und Varianzen der Zustandsbeobachtungswahrscheinlichkeiten und Startwerte für die Zustandsübergangsmatrix. Weiterhin müssen ein Wörterbuch und ein Netzwerk entworfen werden. Im Wörterbuch erfolgt die Zuweisung des Fehlernamens zu einer gefundenen Sequenz von Fehleranteilen. Im Netzwerk können mögliche Schleifen oder Sprünge in den Fehlersequenzen in das HMM implementiert werden.

Es wurden Signale mit einer Länge von 1 sec. bewertet. Zur Modellierung der Signale wurden HMM mit 2 Zuständen definiert. Die Fensterlänge betrug 50 ms, d.h. es wurden zur Berechnung eines Merkmalsvektors 1100 Abtastwerte benutzt. Als Merkmale wurden 24 gehörangepaßte spektrale Filterbankwerte berechnet, sowie die Energie- und Delta-Werte zweier

aufeinanderfolgender Vektoren. Jeder Merkmalsvektor setzte sich somit aus 50 Werten zusammen. Pro Klasse wurde ein HMM trainiert. Die Zuordnung der Motorengeräusche zur entsprechenden Klasse richtete sich danach, welches HMM die maximale Wahrscheinlichkeit für die vorliegende Beobachtungssequenz lieferte.

#### 4. Ergebnisse der Fehlerdiagnose mit HMM

In Tabelle 1 sind die Klassifikationsergebnisse der Bewertung der Motorengeräuschsignale mittels HMM sowie die Anzahl der Trainings- und Testsignale gegeben. In der Diagonale der Tabelle erkennt man die richtig klassifizierten Signale.

	A	D	B	Gut	C	E	ER [%]	Train	Tes.
A	3	0	0	0	0	0	100	11	3
D	0	1	2	0	0	0	33,3	6	3
B	0	0	4	0	0	0	100	13	4
Gut	3	3	0	68	0	6	85	392	80
C	0	0	0	0	1	0	100	3	1
E	2	0	0	0	0	1	33,3	7	3

Tabelle 1: Ergebnisse der Fehlerdiagnose

Die letzte Spalte beinhaltet die Erkennungsrate (ER) pro Signal-Klasse. Es wurde kein „schlecht“-Signal in die „gut“-Klasse eingeordnet. Die „gut“-Erkennungsrate liegt bei 85%. Die Fehler A, B und C werden sehr gut erkannt. Die Fehler D und E hingegen bereiten bei der Klassifikation noch einige Schwierigkeiten. Trotzdem ist die Erkennung aller fehlerbehafteten Geräusche prinzipiell als erfolgreich zu bezeichnen, da bei Verwendung von konventionellen Klassifikationsverfahren immer einige „schlecht“-Signale in die „gut“-Klasse sortiert wurden. Aufgrund der geringen Besetzung der Fehlerklassen mit Lern- und Testobjekten können die Klassifikationsergebnisse allerdings noch nicht verallgemeinert werden.

#### 5. Zusammenfassung und Ausblick

In dem vorliegenden Artikel wurden Ergebnisse der Untersuchung von Spracherkennungsmethoden zur Fehlerdiagnose an technischen Schällen vorgestellt. Erste Ergebnisse zeigen, daß Hidden Markov Modelle zur Klassifikation akustisch relevanter Fehler eingesetzt werden können. Dabei werden einige Fehlerklassen besser erkannt, als andere. Allerdings fand keine Verwechslung von fehlercharakterisierenden Signalen in die „gut“-Klasse statt. Das ist die Grundvoraussetzung für den Einsatz von HMM in einem akustischen Güteprüfungssystem in der Fertigung. Um die Fehlerdiagnoseergebnisse verallgemeinern zu können, ist es von grundlegender Bedeutung, weitere Daten zu sammeln, diese subjektiv zu bewerten und neue HMM zu trainieren. Bei der anschließenden Klassifikation wird erwartet, daß sich die Erkennungsrate für die „gut“-Klasse erhöht.

#### Quellenverzeichnis:

1. C. Couvreur, et.al. *Automatic Classification of environmental noise events by hidden markov models*. Applied Acoustics. Vol 54. No. 3. pp187-206,1998
2. C. Couvreur, Y. Bresler. *Automatic Classification of environmental noise sources by statistical methods*. Noise Control Eng. J. 46 (4), 1998
3. S. Young, et.al. *The HTK BOOK*, 1997
4. L. Rabiner. *A tutorial on hidden Markov models and selected applications in speech recognition*, proceedings of the IEEE. Vol. 77. No.2. pp. 257-285,1989
5. J. Kolerus. *Zustandsüberwachung an Maschinen*. Expert-Verlag, 1995
6. E.-G. Schukat-Talamazini. *Automatische Spracherkennung*. Vieweg-Verlag, 1995

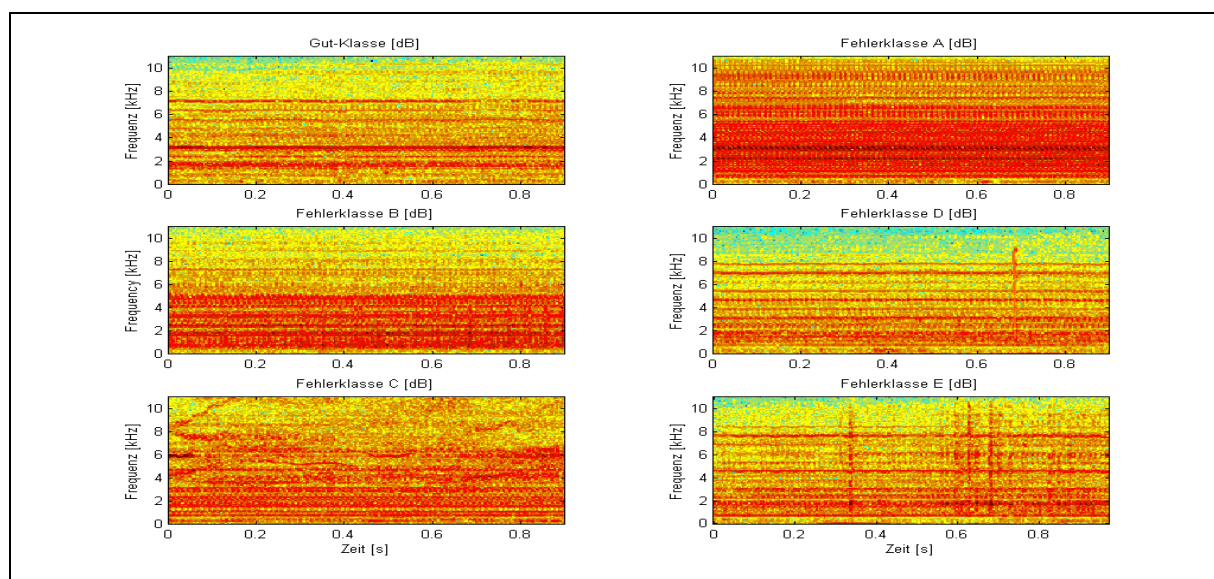


Abbildung 1: Spektrogramme der Beispiel-Signale