

Probleme bei der Bestimmung der optimalen Merkmalskombination für die Güteprüfung anhand einer Stichprobe

Dipl. Ing. R. Jahnke * , Dr.-Ing. F. Attia * , Prof. Dr.-Ing. D. Filbert.**

*** Zentralbereich Forschung und Voraentwicklung, Robert Bosch GmbH, Stuttgart**

**** Institut für Meß- und Automatisierungstechnik, TU Berlin.**

Im vorliegenden Beitrag werden Verfahren zur statistischen Bewertung von Einzelmerkmalen und Merkmalskombinationen diskutiert. Die Notwendigkeit der statistischen Bewertung von Merkmalskombinationen wird herausgearbeitet. Schwerpunktmäßig werden die Besonderheiten bei der praktischen Anwendung behandelt. Insbesondere wird die Existenz der 'idealen Merkmalskombination' für ein vorgegebenes Klassifikationsproblem angezweifelt. Der Beitrag basiert auf der Auswertung realer Meßdaten unterschiedlicher Produkte.

Problems by the determination of the best combination of features for the acoustic quality control using a test sample:

In this paper some procedures for the statistical evaluation of a combination of features or a single one are discussed. The necessity of the statistical evaluation is presented and the peculiarities by the practical application are treated. The existence of an ideal combination for a certain classification problem is doubted. This work is based on real data of different products.

Einleitung

Wichtigster Punkt beim Entwurf eines merkmalsbasierten Diagnosesystems ist die Festlegung eines geeigneten Merkmalsatzes. Die (aus einer umfangreichen Bibliothek) ausgewählten Merkmale müssen charakteristische Eigenschaften der zu diagnostizierenden Fehler gut wiedergeben. Die gezielte Auswahl führt zu einer Merkmalsreduktion. Der für die Merkmalsberechnung verwendete Algorithmus ('Merkmalsalgorithmus') bildet die fehlerrelevanten Informationen der gemessenen Zeitsignale in Zahlen ('Merkmalsausprägungen') ab. Anhand der berechneten Merkmalsausprägungen wird das Fehlerobjekt klassifiziert, wobei die Ausdehnungen der Fehlerklassen im Merkmalsraum bekannt sein müssen. Diese Ausdehnungen sollen zur Vereinfachung 'Toleranzbereiche' genannt werden.

Es ist an dieser Stelle sinnvoll, drei Arten von Klassifikationsproblemen zu unterscheiden.

Fall A: Merkmalsatz und Toleranzbereiche bekannt

Ein Experte ist in der Lage, anhand seiner Erfahrungen einen geeigneten Merkmalsatz sowie dessen Toleranzbereiche anzugeben. Ein Beispiel hierfür ist die Bestimmung des Geräuschpegels und der Schalleistung eines Objektes. Die entsprechenden Meßverfahren und Merkmalsalgorithmen sind bekannt. Der Merkmalsatz besteht aus zwei Merkmalen. Liegen sie außerhalb des in der Spezifikation definierten Toleranzbereiches, so ist das Objekt defekt.

Fall B: Merkmalssatz bekannt, Toleranzbereiche unbekannt

Der Experte kann den Merkmalssatz für die Diagnose angeben, die Toleranzbereiche der einzelnen Fehlerklassen sind ihm nicht bekannt. Ein Beispiel hierfür ist die Detektion von Verzahnungsfehlern in einem Getriebe durch Ordnungsanalyse. Durch seine Kenntnisse über den Aufbau des Getriebes ist der Experte in der Lage, einem bestimmten Verzahnungsfehler genau eine Ordnung zuzuordnen. Er kann jedoch nicht den Toleranzbereich (spektrale Energie) der Fehlerklasse angeben. Dieser Fall ist der klassische Einsatzfall für ein lernendes System. Das System wird so konfiguriert, daß es den vom Experten vorgegebenen Merkmalssatz für jedes Objekt einer vorklassifizierten Stichprobe berechnet, um daraus die Toleranzbereiche der einzelnen Fehlerklassen automatisch zu lernen.

Fall C: Merkmalssatz unbekannt, Toleranzbereiche unbekannt

Die physikalischen Eigenschaften der zu diagnostizierenden Fehler sind unbekannt. Dieses Problem tritt in der akustischen Güteprüfung häufig auf. Ein Beispiel hierfür ist die Diagnose unterschiedlicher Rotor-Stator-Kollisionen, z.B. Lüfter-Draht, Lüfter-Isolierung, Lüfter-Gehäuse, etc., an montierten Produkten mittels Körperschall. Hier sind weder die relevanten Frequenzbereiche (Merkmalsalgorithmen) noch deren Toleranzbereiche bekannt. Auch hier kann man ein lernendes System einsetzen. Der Lernvorgang muß auf die automatische Bestimmung eines geeigneten Merkmalssatzes erweitert werden.

Wir wollen uns in den weiteren Betrachtungen auf Fall C konzentrieren. Es ist offensichtlich, daß in einem ersten Schritt der Merkmalsraum durch Festlegung eines Merkmalssatzes definiert werden muß. Erst anschließend können die Toleranzbereiche im Merkmalsraum gelernt werden. Das Anlernen der Toleranzbereiche ist der klassische Lernvorgang, für den viele unterschiedliche parametrische und nichtparametrische Verfahren entwickelt wurden. Ein parametrisches Lernverfahren ist z.B. die Charakterisierung der Verteilungsfunktionen der Klassen durch die Parameter 'arithmetischer Mittelwert' und 'Standardabweichung'

Bewertung von Einzelmerkmalen

Zur Bewertung der Merkmale soll ein Kriterium herangezogen werden, welches die Klassifikationsergebnisse optimiert. Unabhängig vom verwendeten Klassifikator ist für gute Merkmale eine kleine Streuung der Objekte innerhalb einer Klasse anzustreben (robuste Merkmale). Andererseits soll sich der Wert von einer Klasse zur anderen stark ändern (fehlersensitive Merkmale). Ein mögliches Gütekriterium für Einzelmerkmale ist das folgende :

$$f = \frac{s(\mu_k)}{m(s_k)}$$

Die Gleichung zeigt die Berechnungsvorschrift für das 'F-Ratio' (verallgemeinerte Fischerdiskriminante für mehrere Klassen). Im Zähler wird die Streuung s der Klassenmittelpunkte μ_k für ein Merkmal berechnet, die ein Maß für den mittleren Abstand der Klassenmittelpunkte darstellt. Im Nenner wird der Mittelwert m über die Streuungen s_k des Merkmals innerhalb der Klassen berechnet. Das vorgestellte Maß gibt Auskunft darüber, wie gut ein Merkmal im Mittel alle Klassen voneinander trennt.

Besonderheiten

Es ist davon auszugehen, daß bei einer Merkmalsextraktion die in den Zeitsignalen enthaltene klassentrennende Information mit unterschiedlichen Anteilen in die einzelnen Merkmale abgebildet wird. Bei einer idealen, problemangepaßten Merkmalsextraktion erfolgt die Abbildung in wenigen Merkmalen mit ausgezeichneten Klassentrennungseigenschaften. Demgegenüber entstehen bei einer realen Merkmalsextraktion viele Merkmale, auf die sich die Information verteilt :




Bild 1: Ordnungsspektren für 302 Objekte

Bild 1 zeigt für 242 gute und 60 schlechte Objekte die Ordnungsspektren, 1. bis 256. Wellenordnung. Neben den Spektren guter und schlechter Objekte ist für jede Ordnung das F-Ratio aufgetragen. Interessant sind die Stellen des hohen F-Ratio. Im oberen Frequenzbereich und im Bereich der 50. Ordnung liegen große F-Ratios vor, obwohl in diesen Bereichen keine prägnanten Spektralkomponenten (denen man einzelne Bauteile zuordnen könnte) vorkommen. Ein Experte liefert mit Sicherheit eine andere Bewertung.

Bei der Bewertung von Merkmalen durch einen Experten werden i.a. nur bekannte physikalische Zusammenhänge berücksichtigt, die aus Informationen über das Objekt gewonnen werden (z.B. Bauteilfrequenzen). Unberücksichtigt bleiben oft :

1. Unbekannte physikalische Zusammenhänge

Eine vollständige Beschreibung des Prüfobjektes ist unmöglich. Bei der Diagnose eines Lagerfehlers wird z.B. gern die Überrollfrequenz im Spektrum untersucht. Eine Schadstelle im Lager führt jedoch auch zu Schwankungen der Drehzahl, die sich in (Modula-

tions-) Seitenbändern prägnanter Spektralkomponenten wiederfinden. Beispielsweise kann ein Lagerfehler durchaus in Seitenbänder der Bürstenfrequenz abgebildet werden.

2. Unbekannte Störgrößen

Angenommen, man ist sich über die Klassentrennungswirksamkeit eines bestimmten Merkmals sicher. Durch Störeinstreuungen (dazu kann man auch Rechenfehler der Merkmalsextraktion zählen) kann ein solches Merkmal, trotz seiner physikalischen Bedeutung, für die Klassentrennung ungeeignet sein.

3. Unbekannte statistische Beziehungen zwischen Merkmalen

Bei Klassifikation mit Merkmalskombinationen erlangt dieser Aspekt große Bedeutung. Wählt man aus einer Gesamtheit von zwei 'guten' Merkmalen und einem 'schlechten' Merkmal die guten zur Klassifikation aus, so ist das Klassifikationsergebnis u.U. schlechter als bei Kombination eines guten und eines schlechten Merkmals. Dies ist insbesondere dann der Fall, wenn sich die guten Merkmale besonders ähnlich sind (Korrelation). In diesem Fall führt die Kombination der Merkmale nicht zu einem Informationsgewinn.

Die aufgeführten Punkte bestätigen die Notwendigkeit statistischer Merkmalsauswahlverfahren. Die Ergebnisse dieser Auswahl können dann durch gezielte Untersuchungen verifiziert werden. Nach der F-Ratio-Bewertung kann man z.B. die Klassentrennungswirksamkeit der Seitenbänder der Bürstenfrequenz experimentell untersuchen. Dabei werden evtl. bisher nicht beachtete physikalische Effekte (z.B. Modulation) entdeckt.

Der umgekehrte Weg, die Merkmale zunächst mit Expertenwissen zu bewerten und die so erhaltene Merkmalsbasis anschließend durch statistische Verfahren zu reduzieren, ist demgegenüber falsch. In diesem Fall wird die Fähigkeit des statistischen Verfahrens, alle statistischen Beziehungen zwischen den Merkmalen zu bewerten, nicht genutzt. Die beschriebenen Seitenbänder würden, wenn ein Experte das Modulationsphänomen nicht beachtet, niemals zur Klassifikation benutzt werden.

Die beste Methode ist, genügend Rechenkapazität und -zeit vorausgesetzt, eine vollständige statistische Bewertung der möglichen Merkmalskombinationen.

Bewertung von Merkmalskombinationen

Im allgemeinen ist die Bewertung aller Merkmalskombinationen (vollständige Permutation) aus Zeitgründen unmöglich. Es wird ein Auswahlverfahren benötigt. Bei der Add-On Methode wird, ausgehend vom besten Einzelmerkmal, die Merkmalskombination sukzessiv aufgebaut. Nach der Bestimmung des besten Einzelmerkmals wird dieses zunächst in Zweierkombinationen mit allen übrigen Merkmalen kombiniert. Die beste Zweierkombination wird festgehalten und nach dem gleichen Schema wird die beste Dreierkombination ermittelt. Hat die Kombination die gewünschte Mächtigkeit erreicht, so wird der Algorithmus abgebrochen. Zur Bewertung der Merkmalskombinationen wird ein Gütekriterium ähnlich dem F-Ratio [s.0] benutzt. Dieses Verfahren führt äußerst schnell zum Ziel, wenn mit kleinen Kombinationen klassifiziert werden soll.

Einfluß des 'Startmerkmals' bei der Add On Methode

Hintergrund:

Es soll gezeigt werden, daß es viele gleich gute Merkmale und Merkmalskombinationen gibt. Bereits eine kleine Änderung im System, wie die Änderung des Startmerkmals, führt zu erheblichen Veränderungen in den errechneten Merkmalskombinationen ohne die Klassifikationsergebnisse zu beeinträchtigen.

Vorgehen :

- a) verschiedene Startmerkmale wählen
- b) modifizierten Add On Algorithmus anwenden
- c) klassifizieren
- d) Merkmalskombinationen und Klassifikationsergebnisse vergleichen

Ziel :

Es soll die Annahme widerlegt werden, es gäbe die optimale Merkmalskombination. Weiterhin sollen Unterschiede der Bewertung von Merkmalskombinationen durch verschiedene Bewertungssysteme gerechtfertigt werden. Es muß betont werden, daß eine Beurteilung der Einzelmerkmale einer Kombination keine Aussagekraft über die Güte dieser Merkmalskombination besitzt.

Ergebnis :

Für eine Merkmalsbasis von 100 Merkmalen (302 Objekte, 6 Fehlerklassen) wurde die Add On Methode 100-mal durchgeführt, wobei für jeden Durchlauf das Startmerkmal variiert wurde. In der folgenden Tabelle sind exemplarisch einige Merkmalskombinationen dargestellt. Die Nummer der Merkmale enthält die direkte Information über die Güte der Einzelmerkmale. Merkmal 100 ist das beste Einzelmerkmal, Merkmal 1 ist das schlechteste Einzelmerkmal nach F-Ratio:

Merkmal-kombin.	M 1	M 2	M 3	M 4	M 5	M 6	M 7	M 8	M 9	M 10	Klassifikations- ergebnis in %
K1	64	94	<u>62</u>	<u>55</u>	<u>92</u>	<u>14</u>	8	24	6	98	64,24
K2	86	76	<u>85</u>	9	96	<u>46</u>	<u>100</u>	73	87	40	62,9
K3	99	76	<u>85</u>	9	94	8	<u>92</u>	15	<u>100</u>	<u>79</u>	60,26
K4	68	94	<u>62</u>	<u>55</u>	<u>14</u>	24	96	50	<u>46</u>	25	63,91
K5	100	85	46	90	62	92	4	76	55	14	63,25

Tabelle 1: 5 verschiedene 10-er Kombinationen

Die letzte Kombination K5, deren Startmerkmal das beste Einzelmerkmal (100) ist, wird von der nicht modifizierten Add On Methode automatisch ermittelt. In den übrigen Kombinationen sind die Merkmale, die in K5 enthalten sind, unterstrichen. Die Gesamtauswertung hat ergeben, daß jede ermittelte Merkmalskombination mindestens 2 Merkmale aus der Kombination K5 enthält, der Großteil enthält weitaus mehr Merkmale aus K5 (Durchschnitt über alle 99 Kombinationen : 6,08 Merkmale aus K5).

Trotzdem lassen sich disjunkte Kombinationen finden, die in keinem Merkmal übereinstimmen. Die erste und die zweite Kombination sind z.B. disjunkt. Die erste Merkmalskombination klassifiziert geringfügig besser¹ als K5, die zweite Kombination ist nur unwesentlich schlechter als K5. Es stehen somit zwei disjunkte Merkmalskombinationen mit gleichen Klassifikationseigenschaften zur Verfügung.

Bei der Gesamtauswertung fällt auf, daß einige Merkmale sehr häufig auftreten (Maximum wäre 100, also das Merkmal tritt in allen Kombinationen auf) :

Merkmal	35	14	55	94	90	100	62	46	92	85
Häufigkeit	35	41	42	49	50	77	79	84	88	98

Tabelle 2: die 10 häufigsten Merkmale

Es gibt nur zwei Merkmalskombinationen von 100, die das Merkmal 85 nicht enthalten. Es fällt auf, daß fünf Merkmale (100 62 46 92 85) sehr häufig auftreten, mehr als zwei Drittel aller Kombinationen enthalten diese Merkmale. Man muß diesen Merkmalen überdurchschnittliche Klassentrennungseigenschaften bescheinigen.

Die 10 häufigsten Merkmale enthalten vier Merkmale der schlechteren Hälfte (<50), sogar Merkmal 14 tritt 41-mal auf.

Zusammenfassung

Die Untersuchungen haben gezeigt, daß der physikalische Klassentrennungsmechanismus durch viele unterschiedliche Merkmalskombinationen in annähernd gleicher Qualität nachgebildet werden kann. Die benutzten Einzelmerkmale waren für diese Stichprobe teilweise stark korreliert. Die Untersuchungen der modifizierten Add On Methode haben ergeben, daß sich bei gleichem Klassifikationsergebnis eine Merkmalskombination durch eine andere ersetzen läßt. Dies gilt jedoch nicht für die Einzelmerkmale: bei Änderung eines Merkmals muß i.allg. eine völlig neue Kombination bestimmt werden.

Die statistische Bewertung von Merkmalskombinationen ist notwendig, da weder aus den Klassentrennungseigenschaften, noch aus den Korrelationen der Einzelmerkmale auf deren Tauglichkeit für die Klassifikation innerhalb einer Merkmalskombination geschlossen werden darf. Die Merkmalskombinationen sind überwiegend inhomogen aus guten und schlechten Einzelmerkmalen zusammengesetzt. Die Auftrittshäufigkeit der Einzelmerkmale ist ein Maß für deren Bedeutung, wenngleich sie sich als Einzelmerkmale für die Klassifikation nicht immer eignen.

Die oft praktizierte manuelle 'Vorauswahl' von Einzelmerkmalen durch Experten ist bei Klassifikation mit einer Merkmalskombination nicht gerechtfertigt, die Merkmale sollten vollständig statistisch bewertet und anschließend verifiziert werden. Aufgrund der Gleichwertigkeit unterschiedlicher Merkmalskombinationen können sowohl zwei Merkmalsbewertungen nach unterschiedlichen Verfahren unter gleichen Bedingungen als auch zwei Merkmalsbewertungen nach dem glei-

¹ Die sinnvolle Genauigkeit ergibt sich jeweils aus der Anzahl der klassifizierten Beispielobjekte

chen Verfahren unter leicht modifizierten Bedingungen zu völlig unterschiedlichen Merkmalskombinationen gleicher Klassentrennungsfähigkeit führen.

4 Literatur (Überschrift 1)

- [Filbert 1995] Diagnose von Lagerfehlern in Elektromotoren durch nichtlineare Modellierung des Motorstroms, Forum Akustische Qualitätssicherung 1995, Heidelberg,
- [Lewien 1995] Erkennung von Beschädigung an rotierenden Teilen, Forum Akustische Qualitätssicherung 1995, Heidelberg

