



Testing in the fast lane – Machine Learning accelerates the analysis of measurement data for ASICs several times faster

IMMS has developed a machine-learning-based method for analysing measurement data from ASICs. It delivers the same results as a manual evaluation, but is 10 – 30 times faster. Photo: IMMS.

Motivation and Overview

Whether newly designed integrated circuits (ICs) are operating as intended and can hence be mass-produced is examined in detail with characterisation and test procedures. Automated test setups already exist for this purpose which are applied to mixed-signal chips and MEMS – to check the specified operating conditions. However, if it is necessary to identify where – and how an IC begins to fail, test procedures must be performed outside of the specification. This generates extensive amounts of measurement data. These usually contain a high number of potential faults which have to be examined separately in a manual manner, resulting in a very time-consuming and cost-intensive process. For such test data analyses outside the specification, IMMS and Ilmenau TU developed a new method based on a machine learning algorithm. With this method, similar occurrences of faults and failure symptoms can be grouped automatically. The method was evaluated in a case study with an industrial test data set for a chip from Melexis GmbH. The automatically generated groups efficiently clustered the similar behaviours during potential failure scenarios, provided representative examples as well as data visualisations to the user, and thus reduced the time required by a factor of 10 to 30 compared to that of the expert.

*More on
IntelligEnt at
www.imms.de.*

Annual report
© IMMS 2020

A possible fault is recorded during a measurement if the test system measures signal values that are outside the expected value range. These locations are stored with the time and the triggering measured value, so that this deviation can be analysed manually later by an engineer using transient signal data.

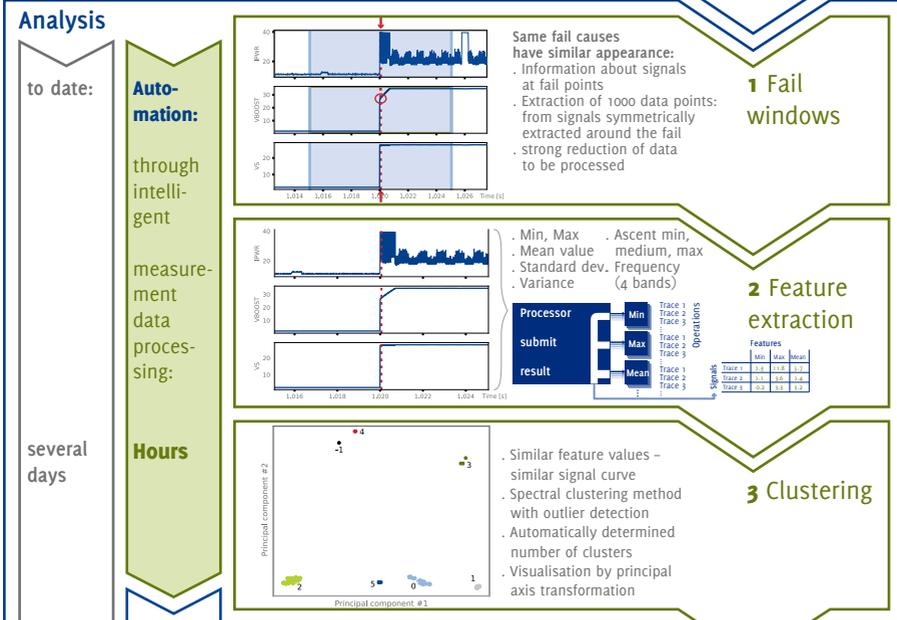
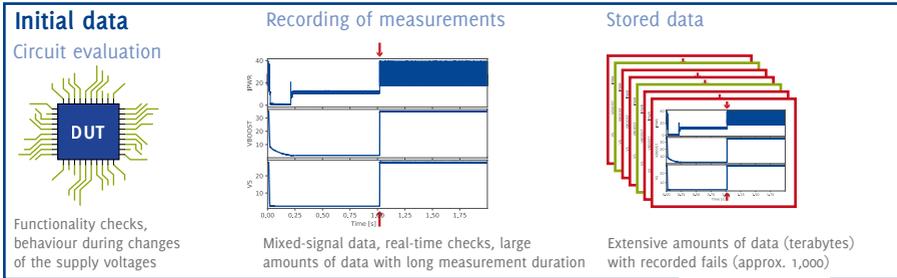
For tests performed within the specification of a circuit, this type of evaluation does not cause any problems, as these usually produce none or only a small number of failures. However, if measurements are also made outside the specification, individual causes of faults are often marked on numerous occasions. Thus, it is quite possible that a series of measurements in its entirety contains several thousand potential failures.

A test engineer would then have to deal with the very time-consuming process of analysing each of these markings and assigning a cause. The algorithm developed at IMMS for pre-sorting these recorded signal deviations is based on the fact that the captured failure markings of a same cause are very similar to each other in its transient measurement data. To group these similar signals, expressive values must be generated, which can then be used to calculate groupings by a cluster algorithm. In this process, some attributes, also called features, are determined from the signal data for each recorded signal deviation, which together contain essential information about the curve sequences at the possible defect locations.

Sections of the signal data in the region of the fault marks are first separated from the data (Fig. Section 1). The subsequent calculation of statistical features (Fig. Section 2) from these extracted signal section generates the required features for each location of a potential fault. These features consist of variance, standard deviation and frequency components of the sections as well as their minima, maxima, mean values and their derivatives. These values are freely configurable and are calculated for each of the signals. Depending on the number of recorded measurement signals, 50 to 100 features are calculated for each signal mark.

Using clustering algorithms from the field of machine learning, the recorded markings can now be sorted into groups using the data of the calculated features. The evaluation of several methods showed that the cluster algorithm DBSCAN (Density

Overview of the newly developed machine-learning-based method for ASIC measurement data analysis. Diagram: IMMS.



Based Spectral Clustering for Applications with Noise) is best suited for this application of failure analysis. On the one hand, this algorithm does not assume fixed numbers of groups. On the other hand, it is also beneficial due to the noise detection, which automatically marks those recorded markings as noise or as outliers that have an individual appearance in the measurement.

The result of the clustering can then be visualised in various ways. A display of the overlain curves of a group is suitable for causal research. This makes it possible to quickly identify whether all markings assigned to this group originate from a possible cause of error. Another view can be generated by the principal component analysis (PCA) of the 50 to 100 features. The PCA calculation makes it possible to combine all these features in such a way that they are displayed on only two dimensions (Fig. Section 3). Each cluster is assigned a colour. In this way, a clear group differentiation can be recognised.

Furthermore, this representation makes it possible to quickly identify correlations between several groups. For example, faults with similar causes that have been divided into different groups can be quickly identified, as they appear close to each other in this representation.

The possibility of annotating individual markings or entire groupings subsequently also supports and accelerates the documentation and evaluation of the measurement data. The computer-assisted evaluation of chip measurements thus drastically simplifies the effort of manual evaluation.

Evaluation on measurement series from industry

This process was evaluated using several measurement series from Melexis GmbH. One of the results was that a measurement in which 320 failures were recorded was divided into eight groups and three outliers by the cluster algorithm. Due to the structure of the designed algorithm, it is possible in retrospect to easily understand the sorting of the cluster procedure. The manual effort is thus reduced from originally 320 sections of the measurement to be evaluated to eight groups and three outliers, i.e. in total to 11 cases for evaluation. Therefore, for this example, it can be expected that the evaluation will be accelerated by about 10 to 30 times with the help of the presented algorithm.

Machine learning provides the same results as manual evaluation and is 10 – 30 times faster

For a comparison of the new and conventional evaluation procedures, the 320 fails were also examined manually and independently of the presented clustering procedure.

In doing so, it has been evaluated how accurately the grouping of the manual evaluation corresponds to the automated clustering procedure. This can be visualised with the help of a confusion matrix (bottom of figure). This compares the number of matches of the two techniques by adding up the assignment of errors from the evaluation techniques. These are then mapped in a matrix sorted by group size. Horizontally, the result of the automatically created clusters is shown and vertically, the manual grouping is shown.

It is clearly recognisable that the cluster procedure determines the same groupings as are found in the manual evaluation. The case that in the horizontal direction several clusters (5, 3 and 1) were assigned to one group in the vertical (2) direction shows that a cause of error can also have several appearances in the transient signal course. In a subsequent examination of the fault causes by an expert, these groups could be combined without any problems. In addition, three errors were assigned to the group “-1” or as detected noise in the automated procedure. These three cases are outliers and must subsequently be evaluated separately.

The developed cluster procedure with machine learning can extremely minimise the manual effort for measurement data evaluation of chip tests with large numbers of errors. In the example, only eight groups plus three outliers would now have to be analysed with the evaluated measurement data instead of the complete fail count of 320.

The presented method was developed by IMMS with the support of Ilmenau TU in the "IntelligEnt" research group.[1] Due to the results, which were evaluated with industrial, real measurement data and results of Melexis GmbH, it is only a small step to the actual implementation. In the next step, the fundamental principles will be transferred to industrial applications.

Contact person: Georg Gläser, MSc, georg.glaeser@imms.de



Thuringian Ministry
for Economic Affairs, Science
and Digital Society

The IntelligEnt research group is supported by the Free State of Thuringia, Germany, and the European Social Fund under the reference 2018 FGR 0089.

1 T. REINHOLD, M. SEELAND, M. GRABMANN, C. PAINTZ, P. MAEDER and G. GLAESER, "Ain't got time for this? Reducing manual evaluation effort with Machine Learning based Grouping of Analog Waveform Test Data," *ANALOG 2020; 17th ITG/GMM-Symposium, 2020*, pp. 1-6, <https://ieeexplore.ieee.org/document/9257338>

> *Integrated sensor systems*
> *Distributed measurement + test systems*
> *Mag6D nm direct drives*
> *Contents*
* *Funding*

Services for characterisation and test at www.imms.de.

More on IntelligEnt at www.imms.de.



Testen auf der Überholspur – Machine Learning beschleunigt Messdaten-Analyse für ASICs um ein Vielfaches

Das IMMS hat ein Machine-Learning-basiertes Verfahren für die Messdaten-Analyse von ASICs entwickelt. Es liefert gleiche Ergebnisse wie eine manuelle Auswertung, ist aber 10 – 30 Mal schneller.
Foto: IMMS.

Motivation und Überblick

Ob neu entworfene integrierte Schaltungen funktionieren und sich somit in Masse produzieren lassen, wird mit definierten Charakterisierungs- und Testverfahren eingehend untersucht. Dafür gibt es bei Mixed-Signal-Chips und MEMS bereits automatisierte Testsetups – um die spezifizierten Betriebsbedingungen zu überprüfen. Wenn jedoch identifiziert werden soll, wo und wie die Chips zu versagen beginnen, müssen Testabläufe außerhalb dieser Spezifikation erfolgen. Dabei entstehen umfangreiche Messdaten. Diese enthalten meist eine hohe Anzahl potenzieller Fehler, die individuell und vor allem manuell untersucht werden müssen, was sehr zeit- und kostenintensiv ist. Für derartige Testdaten-Analysen außerhalb der Spezifikation haben IMMS und TU Ilmenau eine neue Methode auf Basis von Machine-Learning-Algorithmen entwickelt. Damit lassen sich ähnliche Fehlerbilder- und Ausfallszenarien automatisch gruppieren. Die Methode wurde in einer Fallstudie mit einem industriellen Testdatensatz für einen Chip der Melexis GmbH evaluiert. Die automatisch generierten Gruppen fassten dabei das Verhalten bei potenziellen Fehlerszenarien effizient zusammen, lieferten dem Anwender repräsentative Beispiele sowie Datenvisualisierungen und verringerten damit den Zeitaufwand im Vergleich mit dem Experten um das 10- bis 30-Fache.

Mehr zu
IntelligEnt auf
www.imms.de.

Jahresbericht

© IMMS 2020

Eine mögliche Fehlfunktion wird bei einer Messung aufgezeichnet, wenn das Testsystem Signalwerte misst, die außerhalb des erwarteten Wertebereiches liegen. Diese Stellen werden mit dem Zeitpunkt und dem auslösenden Messwert gespeichert, sodass diese Abweichung anhand der Signalverläufe später durch einen Ingenieur manuell analysiert werden kann.

Für Testabläufe, die innerhalb der Spezifikation eines Schaltkreises stattfinden, stellt diese Art der Auswertung auch kein Problem dar, da diese zumeist keine oder nur wenige Fails erzeugen. Wird jedoch auch außerhalb der Spezifikation gemessen, so werden einzelne Fehlerursachen häufig vielfach markiert. So ist es durchaus möglich, dass eine Messreihe in ihrer Gesamtheit mehrere tausend potenzielle Fehlstellen beinhaltet. Ein Testingenieur müsste sich anschließend mit dem sehr zeitaufwändigen Prozess beschäftigen, jede dieser Markierungen zu analysieren und einer Ursache zuzuordnen.

Ähnliche Signalverläufe werden automatisch vorsortiert

Der am IMMS entwickelte Algorithmus zur Vorsortierung dieser gespeicherten Signalabweichungen basiert auf der Grundlage, dass die aufgezeichneten Markierungen der gleichen Ursache im Signalverlauf einander stark ähneln. Um diese ähnlichen Signalverläufe zusammenzufassen, müssen aussagekräftige Werte erzeugt werden, mit denen anschließend eine Gruppierung durch einen Clusteralgorithmus errechnet werden kann. Dabei werden für jede aufgezeichnete Stelle aus den Signaldaten einige Merkmale, auch Features genannt, ermittelt, die zusammen wesentliche Informationen über die Kurvenverläufe an den möglichen Fehlerstellen beinhalten.

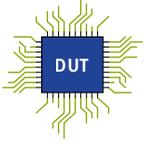
Ausschnitte der Signaldaten im Bereich der Fehlermarkierungen werden zunächst aus den Daten separiert (Abb. Abschnitt 1). Die anschließende Berechnung statistischer Merkmale (Abb. Abschnitt 2) in diesen Signalbereichen erzeugt die benötigten Features für jede Stelle eines potenziellen Fehlers. Diese Features bestehen aus Varianz, Standardabweichungen und Frequenzanteilen der Signalausschnitte sowie aus deren Minima, Maxima, Mittelwerten und deren Ableitungen. Sie sind frei konfigurierbar und werden für jedes der Signale errechnet. Je nach Anzahl der aufgezeichneten Messsignale werden damit 50 bis 100 Features für jede Signalmarkierung errechnet.

Durch Clusteralgorithmen aus dem Machine-Learning-Bereich können die aufgezzeichneten Markierungen mit den Daten der ermittelten Features nun in Gruppen sortiert werden. Die Evaluation mehrerer Verfahren ergab, dass sich der Clusteralgorithmus DBSCAN (Density Based Spectral Clustering for Applications with Noise) für

Überblick zu dem neuentwickelten Machine-Learning-basierten Verfahren für die Messdaten-Analyse von ASICs. Grafik: IMMS.

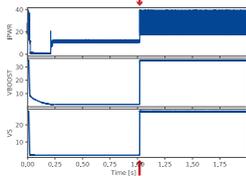
Ausgangsdaten

Schaltungsevaluation



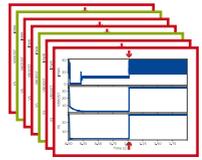
Funktionalitätschecks, Verhalten bei Änderungen der Versorgungsspannungen

Aufzeichnung: Messungen



Mixed-Signal-Daten, Echtzeit-Checks, große Datenmengen bei langer Messdauer

Gespeicherte Daten



umfangreiche Datenmengen (Terabyte) mit aufgezeichneten Fehlern (ca. 1.000)

bisher:

mehrere Tage

Automatisierung:

durch intelligente Messdatenverarbeitung:

Stunden

1 Fail-Fensterung

Gleiche Fail-Ursachen haben ähnliches Aussehen:

- Informationen über Signale an Fallsstellen
- Extraktion von 1000 Datenpunkten: aus Signalen symmetrisch um die Fallstelle extrahiert
- starke Datenreduktion zu verarbeitender Daten

2 Merkmalsextraktion

Min, Max, Mittelwert, Stdabw., Varianz, Anstieg, mittel, max, Frequenz (4 Bänder)

Processor

submit

result

Min	Max	Mean
Trace 1	Trace 2	Trace 3
Trace 1	Trace 2	Trace 3
Trace 1	Trace 2	Trace 3

3 Clustering

ähnliche Feature-Werte – ähnlicher Signalverlauf

- Spectral-Clustering-Verfahren mit Ausreißerkennung
- automatisch bestimmte Clusteranzahl
- Visualisierung durch Hauptachsentransformation

Endauswertung

Bisher (vollständig manuell):

- Analyse jedes einzelnen Fehlers: stark repetitiv, fehleranfällig, viele Fehler = große Datensätze, extremer manueller Aufwand

Jetzt: KI-Clusterverfahren

- manuelle Inspektion nur für wenige Clustergruppen
- bei vielen Fehlern: gute Separation der Fehlergruppen, bessere Performance bei mehr Daten

sehr guter Match	Konfusionsmatrix										Automatic clustering										Match [%]
	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	8	9	
1	94.2%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	100
2	0.0%	0.0%	50.4%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	80
3	0.0%	0.0%	0.0%	100.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	60
4	0.0%	0.0%	0.0%	0.0%	100.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	40
5	5.8%	0.0%	19.6%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	20
6	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0

diese Anwendung der Fehlerauswertung am besten eignet. Zum einen geht dieser Algorithmus nicht von festgelegten Gruppenanzahlen aus. Zum anderen ist er auch aufgrund der Rauscherkennung vorteilhaft, welche automatisch jene aufgezeichneten Stellen als Rauschen oder als Ausreißer markiert, die in der Messung ein individuelles Erscheinungsbild aufweisen.

Das Ergebnis des Clusters kann anschließend auf verschiedene Weise visualisiert werden. Zur Ursachenforschung eignet sich eine Darstellung der überlagerten Kurvenverläufe einer Gruppe. Damit kann man schnell identifizieren, ob alle Markierungen, die dieser Gruppe zugeordnet wurden, einer möglichen Fehlerursache entstammen. Eine weitere Ansicht kann durch die Hauptachsentransformation (PCA = Principal Component Analysis) der 50 bis 100 Merkmale erzeugt werden. Die PCA-Berechnung ermöglicht es, alle diese Merkmale so zusammenzufassen, dass sie auf nur zwei Dimensionen dargestellt werden (Abb. Abschnitt 3). Jedem Cluster wird dabei eine Farbe zugewiesen. So ist eine deutliche Gruppenabgrenzung zu erkennen. Weiterhin lassen sich durch diese Darstellung Zusammenhänge mehrerer Gruppen schnell identifizieren. So könnten beispielsweise auch Fehler gleicher Ursachen, die in verschiedene Gruppen unterteilt wurden, schnell erkannt werden, da sie in dieser Darstellung dann nah beieinander liegen.

Durch die Möglichkeit der Annotation einzelner Markierungen bzw. ganzer Gruppierungen wird im Anschluss auch die Dokumentation und Auswertung der Messdaten unterstützt und beschleunigt. Die Computer-unterstützte Auswertung von Chipmessungen vereinfacht damit den Aufwand der manuellen Auswertung drastisch.

Evaluation an Messreihen aus der Industrie

Dieser Prozess wurde anhand mehrerer Messreihen der Melexis GmbH evaluiert. Eines der Ergebnisse daraus war, dass eine Messung, in der 320 Fails aufgezeichnet wurden, durch den Clusteralgorithmus in acht Gruppen sowie drei Ausreißer unterteilt wurde. Aufgrund der Struktur des entworfenen Algorithmus ist es im Nachhinein gut möglich, die Sortierung des Clusterverfahrens nachzuvollziehen. Der manuelle Aufwand wird somit von ursprünglich 320 auszuwertenden Bereichen der Messung auf acht auszuwertende Gruppen und drei Ausreißer, also in Summe auf 11 Fälle, verringert. Daher ist für dieses Beispiel zu erwarten, dass die Auswertung mithilfe des präsentierten Algorithmus um ca. das 10- bis 30-Fache beschleunigt wird.

Machine-Learning liefert gleiche Ergebnisse wie manuelle Auswertung und ist 10 – 30 Mal schneller

Für einen Vergleich der neuen und herkömmlichen Auswertungsverfahren wurden die 320 Fails auch manuell und unabhängig von dem vorgestellten Gruppierungsverfahren untersucht.

Dabei wurde evaluiert, wie gut die Gruppierung der manuellen Auswertung mit dem automatisierten Gruppierungsverfahren übereinstimmt. Visualisieren lässt sich das mithilfe einer Konfusionsmatrix (unten in Abb.). Diese stellt die Anzahl der Übereinstimmungen der zwei Verfahren gegenüber, indem die Zuordnung der Fehler von den Auswertungsverfahren zusammengezählt werden. Diese werden anschließend in einer Matrix mit Sortierung nach Gruppengrößen abgebildet. In horizontaler Richtung ist das Ergebnis der automatisch erstellten Cluster und vertikal ist die manuelle Gruppierung zu sehen.

Die klar erkennbare Übereinstimmung zeigt, dass das Clusterverfahren gleiche Gruppierungen ermittelt, wie sie bei der manuellen Auswertung zu finden sind. Der Fall, dass in horizontaler Richtung mehrere Cluster (5, 3 und 1) einer Gruppe in vertikaler (2) Richtung zugeordnet wurden, zeigt, dass eine Fehlerursache auch mehrere Erscheinungsbilder im transienten Signalverlauf aufweisen kann. Bei einer anschließenden Untersuchung der Fehlerursachen durch einen Experten konnten diese Gruppen problemlos zusammengefasst werden. Außerdem wurden in dem automatisierten Verfahren drei Fehler der Gruppe „-1“ bzw. als erkanntes Rauschen zugewiesen. Diese drei Fälle sind Ausreißer und müssen anschließend separat ausgewertet werden.

Das entwickelte Clusterverfahren mit Machine Learning kann den manuellen Aufwand zur Messdatenauswertung von Chip-Tests mit großen Fehlerzahlen extrem minimieren. Im Beispiel müssten mit den evaluierten Messdaten nur noch acht Gruppen plus drei Ausreißer ausgewertet werden, anstatt der kompletten Fail-Anzahl von 320.

Das vorgestellte Verfahren wurde vom IMMS mit Unterstützung der TU Ilmenau in der Forschergruppe „IntelligEnt“ entwickelt.¹ Durch die grundlegenden Ergebnisse, welche mit industriellen, realen Messdaten und Ergebnissen der Melexis GmbH evaluiert wurden, ist es nur noch ein kleiner Schritt bis zur praktischen Implementierung. Die Grundlagen werden im nächsten Schritt in die industrielle Praxis überführt.

Kontakt: Georg Gläser, MSc, georg.glaeser@imms.de

> Integrierte

Sensorsysteme

> Intelligente ver-

netzte Mess- u.

Testsysteme

> Mag6D-nm-

Direktantriebe

> Inhalt

* Förderung



EUROPÄISCHE UNION
Europäischer Sozialfonds



Ministerium
für Wirtschaft, Wissenschaft
und Digitale Gesellschaft

Die Forschergruppe IntelligEnt wurde gefördert durch den Freistaat Thüringen aus Mitteln des Europäischen Sozialfonds unter dem Kennzeichen 2018 FGR 0089.

¹ T. REINHOLD, M. SEELAND, M. GRABMANN, C. PAINTZ, P. MAEDER and G. GLAESER, “Ain’t got time for this? Reducing manual evaluation effort with Machine Learning based Grouping of Analog Waveform Test Data,” *ANALOG 2020; 17th ITG/GMM-Symposium, 2020*, pp. 1-6, <https://ieeexplore.ieee.org/document/9257338>

Leistungen für

Charakterisie-

rung und Test:

www.imms.de.

Mehr zu

IntelligEnt auf

www.imms.de.