

# MASCHINELLES LERNEN

## FORTSCHRITTLICHE MUSTERERKENNUNG ZUR AUTOMATISIER- TEN DATENVERARBEITUNG UND ERGEBNISANALYSE

### Stichworte

Big Data, Bildverarbeitung, Mustererkennung, Klassifikation, Maschinelles Lernen

Big Data, Image Processing, Pattern Recognition, Classification, Machine Learning

### Ausgangssituation

Bei der zerstörungsfreien Prüfung von Bauteilen und Komponenten entstehen sehr große Datenmengen unterschiedlicher Modalität, die durch automatische Verarbeitung für den Anwender oft auf eine simple i.O./n.i.O.- Aussage reduziert werden sollen. Je nach Stufe im Produktlebenszyklus muss eine solche Entscheidung mitunter für viele Komponenten in schneller Abfolge getroffen werden, um fehlerhafte Objekte frühestmöglich aus dem Produktionsprozess zu entfernen oder eventuell anfallende Korrekturschritte im entscheidenden Moment anstoßen zu können. Für den Menschen als Anwender sind solche Entscheidungen im modernen Fertigungsprozess oft nicht mehr treffbar.

Wo früher einzelne Exemplare eines Produkts zur Qualitätskontrolle zeit- und kostenintensiv durch einen geschulten Prüfer nachträglich auf ihre Funktionstüchtigkeit geprüft wurden, muss die vollständig digitalisierte Fabrik in allen Fertigungsstufen die Qualität autonom überwachen, steuern und sicherstellen. Dies stellt hohe Anforderungen an die Überwachungs- und Analysesoftware und macht moderne Methoden der Mustererkennung oder des maschinellen Lernens unumgänglich.

### Aufgabenstellung und Durchführung


Hinsichtlich automatischer Datenverarbeitung in der ZfP werden neben Thermographie-, Ultraschall-, Wirbelstrom-, Röntgen- und CT-Daten auch akustische und optische Daten betrachtet. Darüber hinaus können zwei oder mehrere Verfahren bei komplexeren Anwendungsfällen auch miteinander kombiniert werden. Anhand der akustischen Resonanzanalyse wird im Folgenden die Klassifikation mittels maschinellen Lernens dargestellt.

Das Ziel besteht darin, aus den ersten  $N$  Eigenfrequenzen von Pleuelstangen (linke Abbildung) automatisch auf bestimmte Geometrieparameter zurückzuschließen. Mit Hilfe des maschinellen Lernens soll ein Klassifikator entwickelt werden, der ein vorhandenes Testobjekt in die Klassen

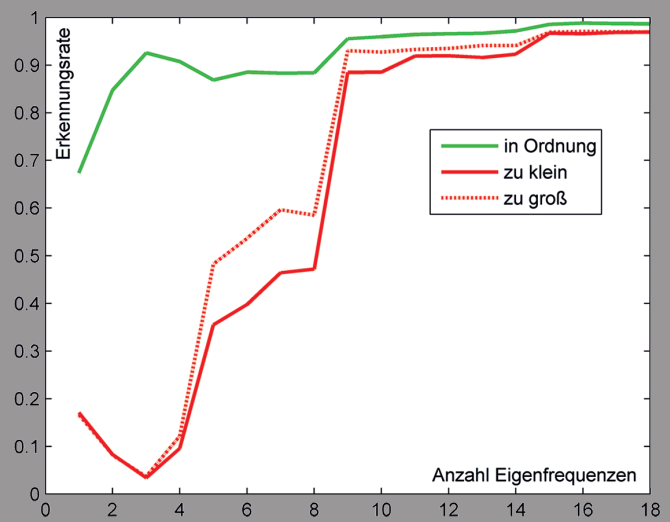
- Stegbreite zu klein
- Stegbreite im Normbereich
- Stegbreite zu groß

einordnet. Die Berechnung des Klassifikators findet mit Hilfe eines Trainingsdatensatzes statt, der aus einer großen Anzahl von Proben bekannter Klassenzugehörigkeit besteht. Dazu wurden mehrere tausend Datensätze mit einer Finite-Elemente-Simulation erzeugt. Entscheidend für die Größe des benötigten Trainingsdatensatzes ist die Anzahl der verwendeten Eigenfrequenzen. Ist diese zu niedrig, können keine sicheren Rückschlüsse auf die Stegbreite gezogen werden. Ist sie zu hoch, bleibt eine Klassifizierung zwar möglich, allerdings müssen dann wesentlich mehr Datensätze zum Training verwendet werden. Nach Abschluss des Trainings ist der Klassifikator in der Lage, in kürzester Zeit die Zuordnung der gewünschten Klassen vorzunehmen. Die Komplexität des Klassifikationsschritts ist dabei in der Regel um mehrere Größenordnungen kleiner als der Aufwand für das vorangegangene Training und daher perfekt geeignet für den Einsatz bei hoher Stückzahl.





Eigenschwingung einer Pleuelstange



Erkennungsraten des Klassifikators für die Klassen: Pleuelstange zu klein, zu groß oder im Normbereich

## Ergebnisse

Zur Evaluation des berechneten Klassifikators wird er auf eine größere Probenanzahl angewendet und bestimmt, wie hoch die Erkennungsraten für die einzelnen Klassen sind. Es zeigte sich, dass die 15 niedrigsten Eigenfrequenzen ausreichen, um eine zuverlässige Zuordnung herzustellen. Im vorliegenden Beispiel wurde für alle Klassen eine Erkennungsrate von über 95 Prozent erreicht.

## Ihr Vorteil

Der wesentliche Fortschritt durch Mustererkennung oder maschinelles Lernen besteht darin, dass für den Menschen komplexe und aufwändige Prüfaufgaben in kürzester Zeit automatisch gelöst werden können. Prüfergebnisse werden deterministisch und exakt wiederholbar und sind beispielweise nicht mehr davon abhängig, ob Prüfer A oder Prüfer B die Entscheidung getroffen hat. Erst durch die schnelle automatische und robuste Entscheidung wird es möglich, große Stückzahlen eines Prüfobjekts zu testen oder sogar eine Hundertprozent-Prüfung aller Teile zu erreichen. Zudem sind Verfahren des maschinellen Lernens in der Lage, auch in hochdimensionalen Messdaten Zusammenhänge zu erfassen, die dem menschlichen Auge verborgen blieben. Durch all diese Eigenschaften zusammen werden sie zu einem integralen Bestandteil der digitalisierten Fabrik.

## Auftraggeber

htw saar (Projekt MERKUR)  
RTE Akustik + Prüftechnik GmbH  
SHW Automotive GmbH

Das Projekt MERKUR wird vom Bundesministerium für Bildung und Forschung unter dem Förderkennzeichen O3FH029PX4 gefördert.

## Summary

In the nondestructive testing of assemblies and components, very large data sets of different modality accrue, which for the user are often reduced to a simple okay / not okay statement generated through an automatic process. Particularly in the digital factory, such statements have to be made as early as possible, in fast succession and both, sturdily and reliably. Procedures of machine learning or pattern recognition fulfill these requirements, thus offering ways to qualify themselves for even complex test tasks by means of fitting training.

In this project, piston rod geometric patterns were analyzed using acoustic resonance. Using the lowest ( $N$ ) resonant frequency as a basis, the web width was estimated with a machine learning classification method in order to detect and categorize defects. With a recognition rate of more than 95 percent when using the 15 lowest resonant frequencies, all defect classes were allocated, thus ensuring a reliable distinction between defective and functional components.

## Ansprechpartner

Prof. Dr.-Ing. Ahmad Osman  
+49 681 9302 3628  
ahmad.osman@izfp.fraunhofer.de