Big Data in der Fahrzeugakustik – Herausforderungen und Chancen

Dejan Arsić
Müller-BBM VibroAkustik Systeme GmbH, 82152 Planegg, E-Mail: DArsic@muellerbbm-vas.de

Abstract

Mit der steigenden Anzahl an Derivaten und Ausstattungsvarianten steigt die Anzahl an Messungen, die durchgeführt und ausgewertet werden müssen. Um den Entwicklungsprozess zu unterstützen, sollen unterschiedlichste Aussagen automatisch aus den Messungen getroffen werden. Dies könnten beispielsweise Trendanalysen, Zielwerte oder die Prädiktion beim Zusammenspiel von Komponenten sein. An dieser Stelle kommt das Thema Data Analytics bzw. Big Data als neue Methode in der Fahrzeugakustik hinzu und stellt uns vor neue Herausforderungen. Diese sind unter anderem die Aufbereitung der Messdaten und der beschreibenden Daten, die Auswahl der zu extrahierenden Merkmale, und schließlich die Auswahl des Analyseverfahrens. Ferner muss betrachtet werden, ob traditionelles Expertenwissen und bewährte Methoden einfließen sollen bzw. können. An dieser Stelle sollen erste Erkenntnisse aus Projektarbeiten und daraus resultierende Fragen vorgestellt werden.

Motivation

Insbesondere in sehr großen Engineering-Umfeldern werden bisher zahlreiche Messungen an Prüfständen und im mobilen Einsatz durchgeführt. Traditionell werden dabei die Messungen immer problemorientiert ausgerichtet, das Problem hoffentlich gelöst und die Daten anschließend archiviert. Hierbei kommen im alltäglichen Betrieb sehr viele, unterschiedliche Daten zusammen. Die Frage, die sich hier stellt: Wie lassen sich solche Daten nutzen, um evtl. Aussagen zu treffen, und wie müssen diese Daten aufbereitet werden, damit dies möglichst automatisiert laufen kann?

Mit Blick auf andere Disziplinen, wie zum Beispiel Sprach- und Bildbearbeitung [1][2], sollte es möglich sein, aus der schieren Menge an bereits vorhandenen Daten Aussagen zu treffen und Fragestellungen zu beantworten, um den Entwicklungsprozess drastisch zu beschleunigen. Eine dieser Fragestellungen könnte sein, aus dem Verhalten einer einzelnen Komponente an einem Prüfstand auf das Verhalten im eingebauten Zustand zu schließen. Bei der beständig wachsenden Anzahl an Derivaten wäre das durchaus ein sinnvolles Anwendungsszenario, welches beträchtliches Einsparpotential birgt. Konkret wären dies die Prädiktion des Reifenrollgeräusches in verschiedenen Fahrzeugmodellen anhand von Reifenrollgeräusch-messungen am Reifenprüfstand.

Datenaufbereitung

Obwohl in der Vergangenheit sehr viele Daten aufgezeichnet worden sind, ist es dennoch sehr aufwändig bereits bestehende Datensätze zu verwenden. Die meisten Ansätze zur Mustererkennung benötigen sehr strukturierte Daten. Angefangen bei den beschreibenden Daten, Messpositionen, verwendeten Sensoren usw. Hierfür werden sehr

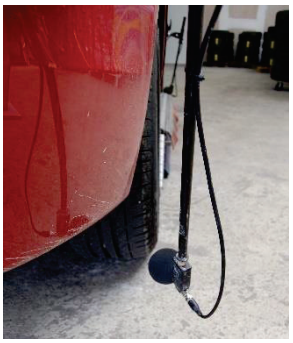

Abbildung 1: Das Big Data Konzept soll an Hand von Reifenmessungen veranschaulicht werden

standardisierte und strukturierte Messdatensätze benötigt. Da bisher meist problemorientiert gearbeitet wurde, sind die Daten oft eher „pragmatisch“ gehalten. Ferner sind oft sowohl proprietäre Datenformate als auch das ATFX-Format nicht als Grundlage für gängige Analysewerkzeuge geeignet. Daher müssen zunächst geeignete Datensätze gefunden werden, die eventuell mit Daten angereichert und vereinheitlicht werden.

Bei der Auswahl der Daten gestaltet sich ein weiterer Punkt als schwierig. Meist existieren kaum Messungen, die das Ergebnis der aktuellen Fragestellung enthalten bzw. ist es im Nachhinein kaum möglich, eine Korrelation zwischen den Messdaten herzustellen. Ausgehend von der Prädiktion von Messungen an Komponentenprüfständen hin zu realen Fahrtmessungen fehlen häufig die Messungen und deren Beurteilung.

Anwendungsbeispiel

Um sich dem Thema „Big Data“ anzunähern, wurde in einem Kundenprojekt festgelegt, dass es interessant wäre an-

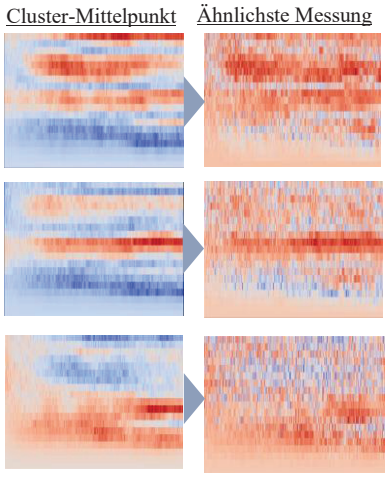

Abbildung 2: Clusterbildung an Hand der Spektren von Reifenrollgeräuschmessungen

hand von Reifenmessungen an dedizierten Reifenprüfständen auf das Verhalten in eingebautem Zustand in verschiedenen Derivaten und auf verschiedenen Messstrecken schließen zu können. Hierfür wurde zunächst ein Datenpool mit 2000 Messungen eines Reifenprüfstands sondiert. Schnell wurde sichtbar, dass es sehr schwierig ist, diese Menge an Daten manuell zu klassifizieren und zu sortieren. Ferner fehlten häufig eindeutig zuordenbare Paare von Prüfstand und Messstrecke. Daher wurde sich darauf beschränkt, die Daten möglichst automatisiert zu clustern und zu sortieren.

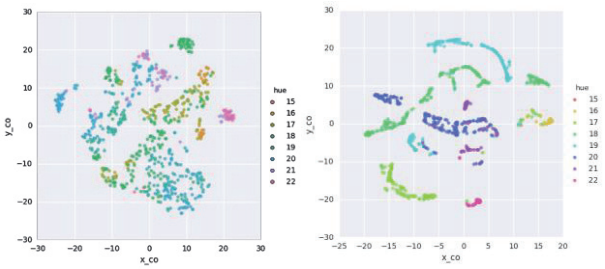

Abbildung 3: Ergebnisse für spektrale Cluster links und Cluster basierend auf Neuronalen Netzen rechts

In einem ersten Schritt wurde versucht, einfach anhand der FFT von bestehenden Daten einfache Datencluster zu berechnen, was den Merkmalsraum deutlich reduzieren würde. Es wurden insgesamt 10 Cluster berechnet, die zumindest eine Teilmenge an Reifen möglichst umfassend repräsentiert. Somit kann versucht werden, die FFT einer Reifenrollgeräuschmessung einem dedizierten Cluster zuzuordnen. Dies ist in Abbildung 2 dargestellt. Die resultierende Zuordnung in einzelne Cluster ist in Abbildung 3 dargestellt. Zwar ist eine Clusterbildung bereits sichtbar, aber eine eineindeutige Zuordnung ist nicht immer möglich.

Im nächsten Schritt konnte sich von den bereits bekannten und in der Fahrzeugakustik etablierten Methoden gelöst und ein „Deep Learning“ auf Basis der Zeitrohdaten ausgeführt werden. Mithilfe eines Neuronalen Netzes NN, siehe Abbildung 4, wurde hier mit verschiedenen Verfahren zur Merkmalsextraktion experimentiert, wobei die aus der Sprachverarbeitung bekannten MFCC-Koeffizienten zunächst sehr vielversprechende Ergebnisse aufweisen konnten.

Auch hier wurden Cluster gebildet, die am Ende die Reifengröße repräsentieren sollen. Im Vergleich zum einfachen Clustering in Abbildung 3 auf der linken Seite, ist eine deutlich bessere Zuordnung zur Reifengröße sichtbar. Hierbei hat sich der Aufwand kaum vergrößert.

Prozessoptimierung

Um die vorangehenden Punkte zu adressieren und in Zukunft die Daten „Big Data“-fähig abzulegen, ist es wahrscheinlich notwendig, die Fahrzeugakustik deutlich prozessorientierter zu betreiben. Ob dabei mobile Messtechnik oder Prüfstandstechnik eingesetzt wird, ist zunächst zweitrangig.

In einem ersten Schritt ist es notwendig, die Messdaten soweit wie möglich zu vereinheitlichen. Hierzu gehört das Datenmodell mit den beschreibenden Messdaten, welches nach Möglichkeit einheitlich sein sollte, um eineindeutige Bezüge zu den verbauten Komponenten herstellen zu können. Messpositionen sollten nicht nur in der Position, sondern auch in der Bezeichnung vereinheitlicht werden. Die Messgrößen ebenso. Um dies zu erreichen, bietet sich ein cloudbasierter Ansatz an. So können die Daten zentral verwaltet und an die relevanten Stellen verteilt werden.

Neben der Standardisierung der Mess-Setups und der Daten, die eine Messung zu enthalten hat, muss eine Orientierung von der eher problemorientierten Arbeitsweise hin zu Prozessen erfolgen, zumal die Aufgaben heute deutlich arbeitsteiliger ausgeführt werden und Fehler in der Prozesskette vermieden werden sollten. Ein solcher Prozess könnte, wie in Abbildung 5 dargestellt, aussehen:

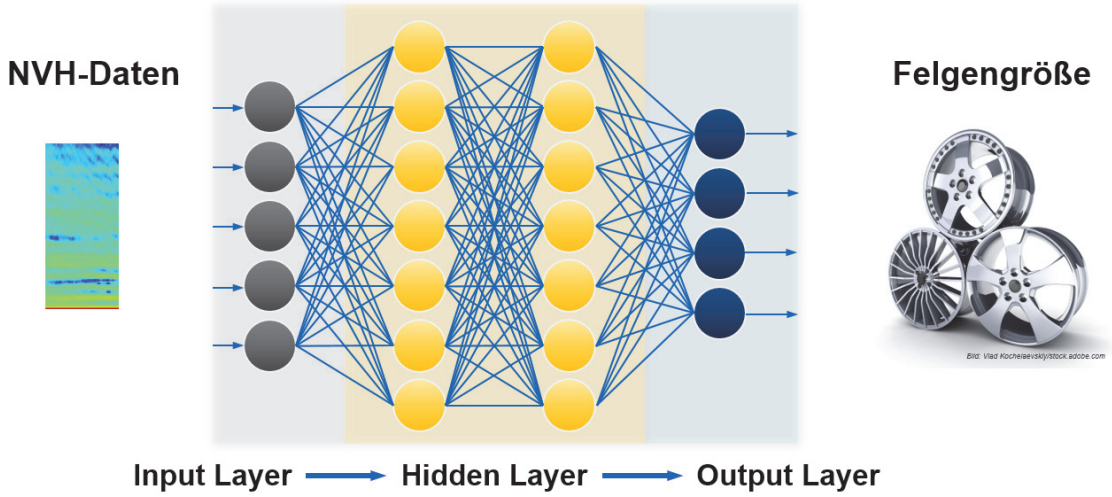

Abbildung 4: Beispielhafte Implementierung mit einem Neuronalen Netz

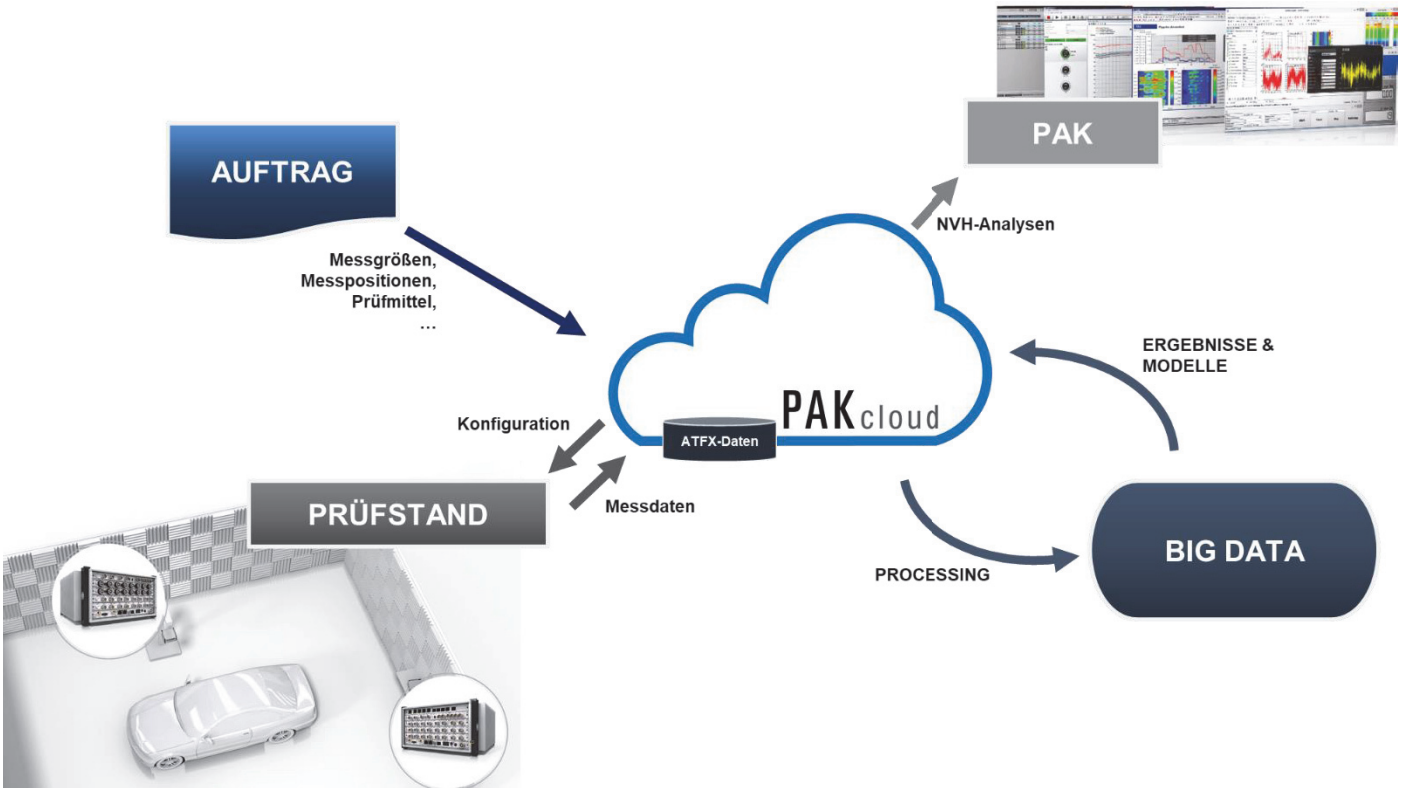

Abbildung 4: Beispielhafte Implementierung eines Prozesses in der Messtechnik

Anhand der in der Cloud befindlichen Daten kann eine Order erstellt werden. Diese enthält alle beschreibenden Daten, die dedizierten Messpunkte und die zu verwendende Messtechnik. Die Order wird über die Cloud an den Prüfstandstechniker versendet. Nach dem Laden der Order werden die vorhandenen PAK MKII Frontends automatisch konfiguriert, sodass hier kaum mehr Fehler unterlaufen können.

Werden nun die Messungen durchgeführt und als ATFX-Datei gespeichert, können diese im Anschluss in die entsprechenden Datendepots geladen werden. Zur Gewährleistung der Datenqualität werden die Daten auf Vollständigkeit überprüft. Im Zweifelsfall müssen die Daten nochmals nachbearbeitet werden. Sind die Daten in der Cloud angekommen, kann eine Data Clearance erfolgen. Es können alle relevanten Messdaten automatisiert extrahiert werden. Die Messdaten werden so aufbereitet, dass die verwendeten Algorithmen des Deep Learning mit den Daten weiterarbeiten können. Die „Big Data"-Instanzen und die PAK cloud sind miteinander verbunden, sodass ein Austausch von Messdaten und Modellen erfolgen kann. Somit können die Auswertungen auch direkt in der Cloud erfolgen.

Zusammenfassung und Ausblick

In dieser Arbeit sollte ein kleiner Überblick über erste Erfahrungen mit „Big Data"-Projekten in der Fahrzeugakustik gegeben werden. Wie gezeigt wurde, können teils aus anderen Disziplinen bekannte Algorithmen die Messdaten clustern und die Komplexität deutlich verringern. Es hat sich allerdings auch gezeigt, dass die Daten deutlich standardisierter und sauberer aufgezeichnet und abgelegt werden müssen, damit diese nutzbar sind. Ferner kann es sein, dass bisher bewährte Methoden aus der Fahrzeugakustik bei der Merkmalsextraktion bzw. Merkmalsselektion eventuell außen vorgelassen und durch auf den ersten Blick nicht passende Analysen ersetzt werden. Zusammenfassend kann gesagt werden, dass die gesamte Fahrzeugentwicklung derzeit einem starken Wandel unterliegt und dieser auch den Messalltag verändern wird.

Literatur

[1] B. Schuller: "Intelligent Audio Analysis", Signals and Communication Technology, Springer, ISBN: 978-3642368059, 2013.

[2] Dejan Arsić, Björn Schuller: Real Time Person Tracking and Behavior Interpretation in Multi Camera Scenarios Applying Homography and Coupled HMMs" in Analysis of Verbal and Nonverbal Communication and Enactment: The Processing Issues, Springer, Heidelberg, Lecture Notes on Computer Science (LNCS), Vol. 6800/2011, pp. 1-18, 2011