



**Reduce effort, increase benefit:**

## **anomaly detection with edge AI and unsupervised learning for smart machine monitoring**

IMMS has developed energy-efficient edge AI systems with overall system energy modelling for processes, services and systems that can be automated, for example to retrofit existing systems with wireless sensors for condition monitoring or level detection. Photograph: IMMS.

### **Motivation and overview**

AI and machine learning can increase efficiency in industry and save a lot of time – but also cost a lot of time until they are ready for use. To significantly reduce this initial effort, IMMS has developed methods and implemented them in two demonstrators. For both scenarios, it was shown that not only is it possible to deploy AI-based monitoring solutions quickly, but that they also work without cloud access and can therefore be used to derive lean monitoring applications.

[www.imms.de/  
embeddedai](http://www.imms.de/embeddedai)

[www.imms.de/  
i40](http://www.imms.de/i40)

### **Application area and challenges**

For efficient production processes, it is crucial to detect machine faults at an early stage, minimise downtimes and avoid costly repairs. The key to this is continuous monitoring of machine status by usually vibration signals or power consumption. This allows deviations from normal operating behaviour to be detected at an early stage before an actual failure occurs. Especially in combination with modern ma-

Annual Report  
© IMMS 2024

chine learning methods, complex patterns and small changes can be identified that are not possible with conventional methods.

However, it takes a considerable amount of time and organisation to record sensor data and potential error states with all relevant operating conditions and fault data for training algorithms, especially in industrial applications. In addition, defects on machines occur very rarely or not at all during normal operation while certain error states such as defective bearings and degraded machine parts cannot be easily triggered. Furthermore, the raw data collected usually has to be extensively pre-processed in order to be used for training an AI model.

## Solution approaches

To make AI and machine learning accessible to companies' monitoring applications with as little initial effort as possible, IMMS is focussing on unsupervised learning methods. In these methods, a known state, in this case the error-free good state, is recorded and algorithms are used to recognise deviations and initiate appropriate measures. Various methods were investigated for this purpose. A simple algorithm was implemented directly on a small, energy self-sufficient sensor system with local AI and evaluated with a demonstrator for fan monitoring. More complex, more powerful methods were implemented in an energy-efficient edge AI system. The data is pre-processed locally on the sensor node. More complex algorithms, e.g. for anomaly detection, are executed on the edge system, e.g. on a Raspberry Pi. The application is demonstrated by monitoring vibrations on a shaker. The method and sensor arrangement for monitoring the function of a machine component „Verfahren und die Sensoranordnung zum Überwachen einer Funktion eines Bauteiles einer Maschine“<sup>1</sup> has been patented.

## Unsupervised learning

Unsupervised learning is a sub-area of machine learning in which algorithms are used to identify patterns, structures or correlations in data – without any predefined target values or labels. The aim is to extract valuable information from the pure input data, such as groupings, trends or outliers. In other words, anomalous data and machine error states do not have to be recorded in advance. This is achieved with unsupervised learning.

Typical methods include **clustering algorithms** such as  $k$ -Means to group similar data points, **dimensionality reduction** methods such as principal component analysis or singular value decomposition to simplify complex data sets, and **anomaly detection** to detect unusual or unexpected observations. These methods are particularly useful when no or only limited labelled data is available.

Various data sets, some of which are publicly available such as the Pronostia data set<sup>2</sup> were used for further analyses. This involved recording vibration data from bearings.

## Data clustering

The  $k$ -Means algorithm is a method from the field of unsupervised learning and is primarily used for clustering tasks. Here, data points are divided into  $k$  groups so that points within a group are as similar as possible. At the beginning, the algorithm expects the user to provide  $k$  so-called cluster centres. It then assigns the nearest centre to each data point and then calculates the new centres of the groups. This process is repeated until the groupings no longer change significantly.  $K$ -Means generally works very quickly and is easy to apply to large amounts of data. However, the method can react sensitively to outliers and does not always deliver good results if the data is complex or unevenly distributed.

## Data reduction using singular value decomposition and correlation

Figure 1 shows the recorded vibration signals for a bearing from the Pronostia data set. Individual anomalies or deviations from the “intact” status value can be recognised. These may have been caused by external vibrations or similar events. In the Pronostia data set, the analysed bearings were subjected to additional forces so that the bearing wears more quickly. For industrial machines, normal wear can result in 10,000 – 100,000 operating hours, depending on the application. Recording data in the process and pre-processing it for training AI models usually accounts for around 80% of the total effort. To avoid having to pre-process all the raw data at great expense, data reduction makes sense.

<sup>2</sup> Nectoux, Patrick & Gouriveau, Raïafel & Medjaher, Kamal & Ramasso, Emmanuel & Chebel-Morello, Brigitte & Zerhouni, Nouredine & Varnier, Christophe. (2012). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. *Conference on Prognostics and Health Management*. 1 – 8.

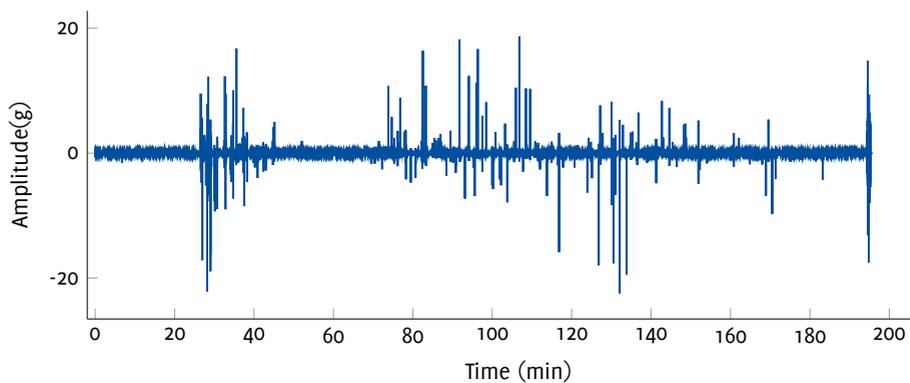


Figure 1: Amplitude curve of a bearing of the Pronostia data set. Graphic: IMMS.

## Singular value decomposition

Singular value decomposition (SVD) is a method in linear algebra which is used to exploit the decomposed recorded data matrix for dimensionality reduction. First, the recorded vibration data is converted row by row into a matrix representation. These are then broken down into three separate matrices. The singular value decomposition of a matrix  $A$  is usually represented as follows:

$$A = U \Sigma V^T$$

These are:

- $U$ : The left-hand singular vector matrix. The columns of  $U$  are the eigenvectors of the matrix  $AA^T$  (covariance matrix).
- $\Sigma$ : The diagonal matrix of the singular values. The singular values represent the importance of the respective eigenvectors and are arranged on the diagonal of  $\Sigma$ . They are always non-negative.
- $V^T$ : The transposed right singular vector matrix. The columns of  $V^T$  are the eigenvectors of the matrix  $A^T A$  (covariance matrix).

A reduced data set is obtained by using only the first  $k$  dominant singular values and the corresponding parts of  $U$ ,  $\Sigma$ , and  $V^T$ . The data points with the largest singular values are shown in Figure 2.

The standard deviation of the singular values was used to calculate a threshold value ( $\Psi$ ), shown as a dotted line in Figure 2, for the novelty value of the data.

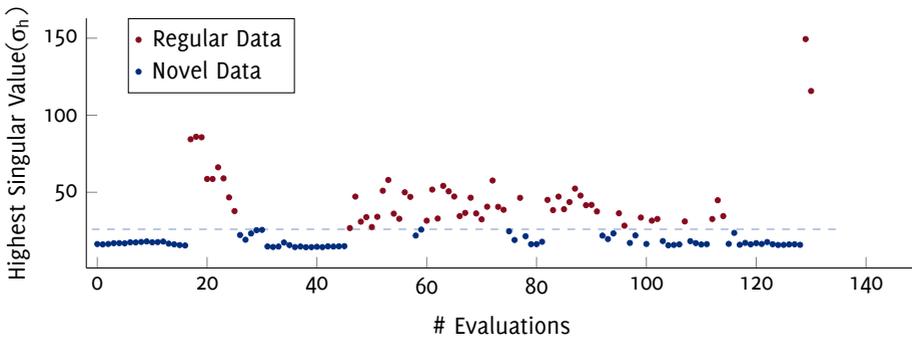


Figure 2: Illustration of the singular values with determined threshold value. Graphic: IMMS.

## Correlation

The singular values can be used to recognise deviations from a learned good state. Canonical Crosscorrelation Analysis (CCA) was used as the correlation algorithm and 3 phases were defined for the implementation, see Figure 3:

- Learning Phase
- Observation Phase
- Deployment Phase

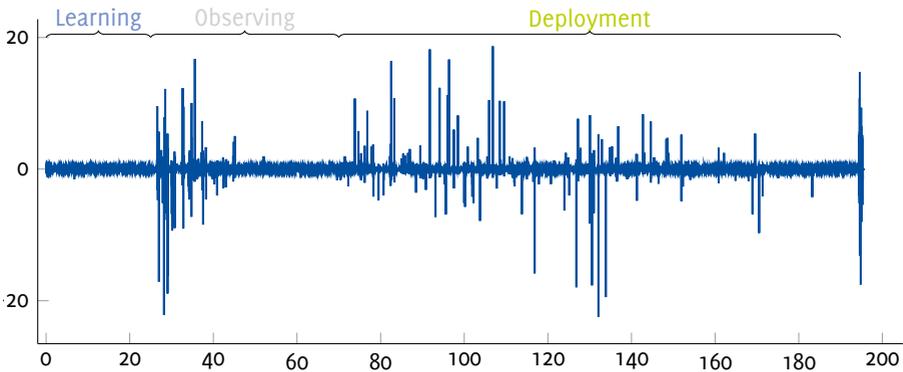


Figure 3: Amplitude curve of a bearing and categorisation into the 3 phases. Graphic: IMMS.

## Learning phase

In the learning phase, it is assumed that the machine is in an intact good state. The singular value decomposition is applied to the recorded vibration signal  $X$ , which is a 2D transformation of the sensor data. The time-discrete signals of the vector of the singular values, decomposed into frequency components by Fast Fourier Transformation (FFT), are used as a feature for the intact state of the machine and stored in a feature matrix  $F$ . Several instances of such a detection and decomposition of the state characteristics are stored in this matrix. The number of features stored in  $F$  is limited by the application and the memory available in the sensor node. The singular vectors corresponding to these feature vectors are also stored and used to calculate a threshold  $\psi$ , as shown in Figure 2.

## Observation phase

The observation phase is optional, but can be useful for learning certain anomalies or states and saving them in feature matrix  $F$ . This leads to the feature matrix  $F$  and the threshold value  $\psi$  being updated.

## Implementation phase

In the implementation phase, new vibration values ( $X$ ) are recorded and decomposed using SVD to obtain the feature vector  $f$  of the newly recorded signal. This feature is then analysed using CCA with the already learned feature matrix  $F$  of the good state. CCA attempts to analyse how different the learned features are compared to the newly recorded feature. The comparison scale is always 0 to 1, where 0 stands for very different and 1 for identical. The result of the CCA analysis is called the degradation coefficient. An example of a deteriorating bearing condition is shown in Figure 4.

## Combination of singular value decomposition and correlation

This combination of feature extraction with SVD and subsequent correlation allows automated feature extraction and subsequent detection of changes in condition. Further details are described in the patent „Verfahren und Sensoranordnung zum Überwachen einer Funktion eines Bauteiles einer Maschine“, DE 10 2024 100 703 B3.<sup>3</sup>

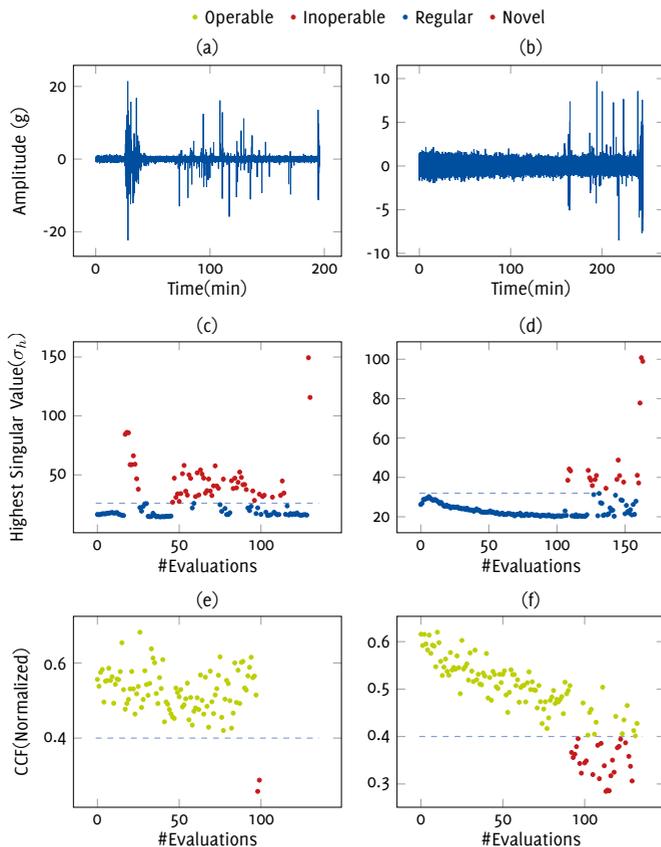


Figure 4:

Example of a deteriorating bearing condition. The columns show signals from two different bearings:

**Top:** vibration signals of the bearings

**Centre:** singular values of the vibration signals

**Bottom:** CCA of the singular values

Graphics: IMMS.

## Anomaly detection with neural networks

Neural network methods have proven to be more efficient at recognising anomalies and distinguishing deviations from the normal state. When applied to unknown data, these methods are able to detect anomalies based on more complex patterns. As a result, this reduces the need to record known error states manually.

Two anomaly detection models were used during the research: LSTM-AD (Long Short-Term Memory Anomaly Detection) and w (Autoencoder Anomaly Detection). Both models were trained with vibration data that represent the normal state, i.e. fault-free, state of a machine. They learn the typical behaviour of the machine on the basis of a defined window size, i.e. a specific time period of the measurement data, and then predict the next set of measured values. This prediction is based on the patterns recognised during training.

To test the robustness of the models, the models were evaluated on various datasets, both with error-free data and with erroneous data. Since the models were only trained exclusively on data representing normal state of the machine, they are unable to accurately reconstruct the vibration data if an anomaly is present. This result leads to a “reconstruction error”, defined as the difference between the actual and the predicted signal. An anomaly score is calculated from this error, which can indicate unusual or faulty behaviour. The data from all three vibration axes is first normalised and prepared for model training using a sliding window (moving window approach). The window size represents the input (X-train), while the subsequent time window serves as the target value (Y-train).

The reconstruction error resulting from the model is analysed using change point detection algorithm. This uses a window-based, stepwise approach to identify points in the signal at which the signal behaviour changes significantly, indicating potential anomalies. In a first step, the algorithm identifies possible breakpoints and calculates their error values. In the subsequent prediction step, it selects the optimal change points, taking into account the maximum number of permitted change points and applying a penalty score to discourage excessive segmentation. In this way, changes in the machine status can be recognised automatically and reliably.

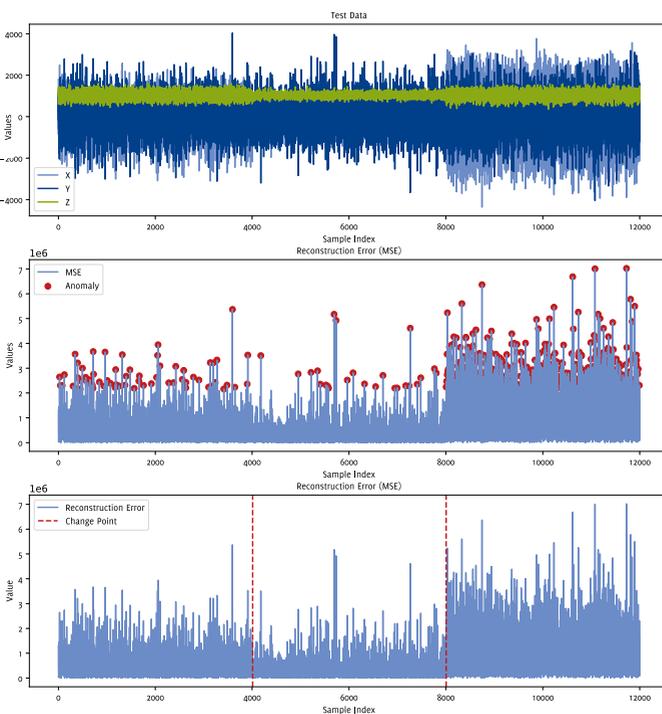


Figure 5:

Top:  
Test data

Centre:  
Reconstruction errors  
(anomalies with static  
threshold value),

Bottom:  
Reconstruction errors  
(change point  
detector).

Graphics: IMMS.

Annual Report

© IMMS 2024

Figure 5 shows the vibration data, the reconstruction error with detected anomalies, once with a static threshold and a change point detection algorithm.

## LSTM-AD (Long short-term memory anomaly detection)

The models analysed allow effective anomaly detection. LSTM-AD is particularly well-suited for analysing time-dependent data, as its feedback structure allows it to capture both long-term and short-term patterns in sequential signals. This makes it a powerful method when machine behaviour is strongly dependent on temporal sequences. However, the use of LSTM-AD requires a larger amount of training data and more complex model tuning making it more computationally intensive compared to other statistical approaches.

## Autoencoder

In contrast, autoencoders offer a more efficient approach to anomaly detection, as it attempts to reconstruct input data as accurately as possible. If the reconstructed signal deviates significantly from the original, this may indicate an anomaly. Autoencoders are well-suited for stationary vibration data, i.e. data with relatively stable patterns over time that may change suddenly. This model is easier to train than an LSTM model, but is less suitable for strongly time-dependent behaviour and gradual changes in machine states.

## Evaluation of the methods

All methods discussed can be used to recognise deviations from normal states in data. Singular value decomposition (SVD) is a robust method for dimension reduction and for identifying novel patterns in linear data. It is particularly suitable if the data structure is relatively simple and the anomalies represent minor deviations in the data structure. Anomaly detection algorithms are more flexible and powerful when analysing complex or non-linear systems. However, they can be more computationally intensive and require careful parametrisation.

To illustrate a possible application in an industrial environment, algorithms for two scenarios were implemented in demonstrators.

The *k*-Means algorithm was implemented directly on a small, energy-autonomous sensor system as a local AI and evaluated with a demonstrator for fan monitoring as an example for monitoring bearings. A more complex and powerful anomaly detection was demonstrated in an energy-efficient edge AI system with local pre-processing on the sensor node and anomaly detection algorithms on the edge device with data processing based on the monitoring of vibrations on a shaker.

### Fan demonstrator

A defective fan can be detected on the demonstrator using a small, energy-autonomous sensor system with local AI. Three fans were used, one had a damaged ball bearing, while the other two are intact. The battery-powered sensor node records vibration data, analyses it and classifies the current status. The system contains a vibration sensor that can detect vibrations up to 6.4 kHz and a microcontroller with an integrated radio transceiver.

The *k*-Means clustering algorithm was implemented on the sensor node. The sensor can be trained on the status of the intact fan. Another “intact” and a “defective” fan can then be recognised and classified accordingly without the data having been recorded beforehand. The result is displayed via a green or red LED, see Figure 6. The data can also be transmitted to an edge device via BLE (bluetooth low energy) with very low power consumption.

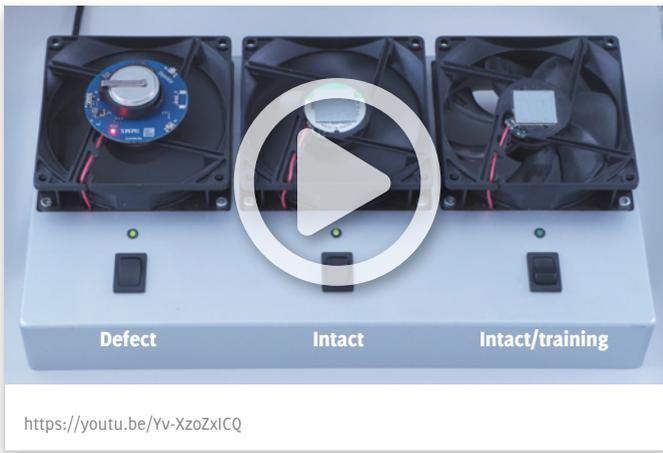


Figure 6:

Fan demonstrator: The fans can be switched on and off individually. The sensor system is placed in the centre of one of the fans and is attached using a magnet. The status is indicated by an LED, green = intact, red = defective.

Photograph: IMMS.

Figure 7: Demonstrator system with: (1) vibration generator, (2) wireless sensor nodes, (3) edge device and (4) tablet. Photograph: IMMS.



## Energy-efficient edge AI system

This demonstrator shows how vibration data can be recorded using a wireless sensor node and transmitted via BLE (Bluetooth Low Energy) to an edge device, where an LSTM-AD algorithm for anomaly detection is implemented.

Vibration data exhibits complex patterns that vary depending on the machine and process. Therefore, the required algorithms demand computational resources beyond what the sensor node can provide. However, the sensor node is capable of performing pre-processing on the vibration data. To increase energy efficiency and extend battery life, data compression techniques such as Singular Value Decomposition (SVD) are applied.

For this demonstrator, a vibration exciter (shaker) is used to generate vibrations similar to those found in industrial environments. The sensor node is mounted on the exciter system. The system is first used to train the model on a healthy (“good”) state. The sensor node records the vibration signal cyclically – configurable from once per second to once per hour – and transmits the data to the edge device, in this case a Raspberry Pi with no cloud connectivity. Deviations from the trained good state are detected on this device and visualised through a dashboard displayed in a browser on a tablet. If the generated vibration signal changes, these changes are detected and displayed graphically.

In its work on adaptive edge AI systems, IMMS is focussing on researching and implementing the determination and prediction of machine and tool states in the application field of predictive maintenance with the help of AI.

The results presented on unsupervised learning help to reduce the effort and costs involved in implementing AI for monitoring. The focus was on vibration sensors, as these are mostly used in practice to monitor machine states. Simple algorithms such as clustering were implemented on a microcontroller to show that they can be executed directly on ultra-low-power sensors. For more complex tasks, data must be transferred from the sensor node to an edge device on which the AI algorithms are executed. For this purpose, compression algorithms were analysed and implemented on the sensor node to send only the required data to the edge device and thus achieve the longest possible battery lifetime for the sensor node. It was shown that both the training and the inference, i.e. the AI-based classification, can be implemented directly on the sensor node or, in the case of more complicated algorithms, on edge devices such as a Raspberry Pi without any cloud access.

On the basis of these solutions for monitoring machine states and automatically detecting deviations from good states, IMMS is endeavouring to advance further developments and is looking for application partners.

**Contact person:** Dipl.-Ing. Sebastian Uziel, [sebastian.uziel@imms.de](mailto:sebastian.uziel@imms.de)



The solutions presented were developed in the internal AI research group at IMMS, which is funded by the German Land of Thüringen, and in the HoLoDEC project.

In 2024, the HoLoDEC project on which this report is based was funded by the German Federal Ministry of Education and Research (BMBF) under the reference 16ME0703. The author is responsible for the content of this publication.

- > *Integrated sensor systems*
- > *Distributed measurement + test systems*
- > *nm-precise 6D direct drives*
- > *Contents*
- \* *Funding*

[www.imms.de/](http://www.imms.de/)  
*embeddedai*

[www.imms.de/](http://www.imms.de/)  
*i40*

[www.imms.de/](http://www.imms.de/)  
*holodec*

[Annual Report](#)  
© IMMS 2024

A close-up photograph of a person's hand adjusting a precision tool on a machine. A neural network overlay with white nodes and connecting lines is superimposed on the scene. The machine has a green light and a small circular component being adjusted. The background is blurred, showing industrial equipment.

**Aufwand senken, Nutzen steigern:**

## **Anomalie-Detektion mit Edge-KI und unüberwachtem Lernen für smartes Maschinenmonitoring**

Für automatisierbare Prozesse, Dienstleistungen und Anlagen hat das IMMS energieeffiziente Edge-KI-Systeme mit Gesamtsystem-Energiemodellierung entwickelt, um beispielsweise Bestandsanlagen mit kabellosen Sensoren für Condition Monitoring oder Füllstandserfassung nachrüsten zu können. Foto: IMMS.

### **Motivation und Überblick**

KI und Machine Learning können in der Industrie die Effizienz steigern und viel Zeit einsparen – aber auch viel Zeit kosten, bis sie einsatzbereit sind. Um diesen Initialaufwand deutlich zu senken, hat das IMMS Methoden entwickelt und diese in zwei Demonstratoren implementiert. Für beide Szenarien konnte gezeigt werden, dass nicht nur ein schneller Einsatz von KI-basierten Monitoring-Lösungen möglich ist, sondern dieser auch ohne Cloud-Zugang funktioniert und sich somit schlanke Monitoring-Anwendungen ableiten lassen.

[www.imms.de/  
embeddedai](http://www.imms.de/embeddedai)

[www.imms.de/  
i40](http://www.imms.de/i40)

### **Einsatzbereich und Herausforderungen**

Für effiziente Produktionsprozesse ist es entscheidend, Störungen von Maschinen früh zu erkennen, Ausfallzeiten zu minimieren und kostspielige Reparaturen zu vermeiden. Der Schlüssel dafür ist ein kontinuierliches Monitoring von Maschinenzuständen, meistens von Vibrationssignalen oder auch von der Stromaufnahme. Damit kann man frühzeitig vor einem tatsächlichen Ausfall Abweichungen vom normalen

[Jahresbericht](#)

© IMMS 2024

Betriebsverhalten erkennen. Insbesondere in Kombination mit modernen Machine-Learning-Verfahren lassen sich komplexe Muster und kleine Veränderungen identifizieren, die mit konventionellen Methoden nicht möglich sind.

Allerdings ist es ein erheblicher zeitlicher und organisatorischer Aufwand, Sensordaten aufzunehmen und potenzielle Fehlerzustände mit allen relevanten Betriebs- und Stördaten für ein Training von Algorithmen zu erfassen, vor allem in industriellen Anwendungen. Zudem treten im Normalbetrieb Defekte an Maschinen sehr selten bis gar nicht auf und bestimmte Fehlerzustände, wie z.B. defekte Lager und Maschinenteile, lassen sich nicht einfach hervorrufen. Hinzu kommt, dass die gesammelten Rohdaten in der Regel umfangreich vorverarbeitet werden müssen, um sie für das Training eines KI-Modells nutzen zu können.

## Lösungsansätze

Um KI und Machine Learning mit möglichst geringem Initialaufwand für Monitoring-Anwendungen von Unternehmen zu erschließen, fokussiert sich das IMMS auf unüberwachte Lernmethoden. Bei diesen wird ein bekannter Zustand, hier der fehlerfreie Gutzustand, erfasst und Algorithmen eingesetzt, um Abweichungen zu erkennen und entsprechende Maßnahmen einleiten zu können. Dazu wurden verschiedene Methoden untersucht. Ein einfacher Algorithmus wurde direkt auf einem kleinen, energieautarken Sensorsystem mit lokaler KI implementiert und mit einem Demonstrator zum Lüftermonitoring evaluiert. Komplexere, leistungsfähigere Methoden wurden in einem energieeffizienten Edge-KI-System implementiert. Die Daten werden auf dem Sensorknoten lokal vorverarbeitet. Komplexere Algorithmen, z.B. für die Anomalie-Detektion, werden auf dem Edge-System, z.B. auf einem Raspberry Pi, ausgeführt. Die Anwendung wird anhand der Überwachung von Vibrationen auf einem Shaker demonstriert. Das Verfahren und die Sensoranordnung zum Überwachen einer Funktion eines Bauteiles einer Maschine wurden patentiert.<sup>1</sup>

[www.imms.de/  
embeddedai](http://www.imms.de/embeddedai)

[www.imms.de/  
patent](http://www.imms.de/patent)

## Unüberwachtes Lernen

Unüberwachtes Lernen ist ein Teilbereich des maschinellen Lernens, bei dem Algorithmen eingesetzt werden, um Muster, Strukturen oder Zusammenhänge in Daten zu identifizieren – ganz ohne vorab definierte Zielwerte oder Labels. Ziel ist es, aus den reinen Eingabedaten wertvolle Informationen zu extrahieren, wie etwa Gruppierungen, Trends oder Ausreißer. Das heißt, Stördaten und Fehlerzustände müssen beim unüberwachten Lernen nicht mit viel Aufwand im Vorfeld erfasst werden.

Jahresbericht

© IMMS 2024

<sup>1</sup> DE 10 2024 100 703 B3, <https://register.dpma.de/DPMAreger/pat/register?AKZ=1020241007036>

Zu den typischen Methoden zählen **Clustering-Algorithmen** wie  $k$ -Means zur Gruppierung ähnlicher Datenpunkte, Verfahren zur **Dimensionalitätsreduktion** wie Hauptkomponentenanalyse oder Singulärwertzerlegung zur Vereinfachung komplexer Datensätze sowie **Anomalieerkennung**, um ungewöhnliche oder unerwartete Beobachtungen zu entdecken. Diese Verfahren sind besonders nützlich, wenn keine oder nur begrenzt gelabelte Daten vorliegen.

Für die weiteren Untersuchungen wurden unterschiedliche Datensätze, zum Teil öffentlich verfügbare wie z.B. der Pronostia-Datensatz<sup>2</sup>, verwendet. Dabei wurden Vibrationsdaten von Lagern aufgezeichnet.

## Clustering von Daten

Der  $k$ -Means-Algorithmus ist ein Verfahren aus dem Bereich des unüberwachten Lernens und wird vor allem für Clustering-Aufgaben eingesetzt. Hierbei werden Datenpunkte in  $k$  Gruppen unterteilt, sodass Punkte innerhalb einer Gruppe möglichst ähnlich sind. Zu Beginn wählt der Algorithmus zufällig  $k$  sogenannte Clusterzentren. Anschließend ordnet er jedem Datenpunkt das nächstgelegene Zentrum zu und berechnet danach die neuen Mittelpunkte der Gruppen. Dieser Vorgang wird so lange wiederholt, bis sich die Gruppierungen nicht mehr wesentlich ändern.  $k$ -Means arbeitet in der Regel sehr schnell und lässt sich gut auf größere Datenmengen anwenden. Allerdings kann das Verfahren empfindlich auf Ausreißer reagieren und liefert nicht immer gute Ergebnisse, wenn die Daten komplex oder ungleichmäßig verteilt sind.

## Datenreduktion mittels Singulärwertzerlegung und Korrelation

In Abbildung 1 ist der aufgenommene Amplitudenverlauf der Vibrationsignale für ein Maschinen-Lager aus dem Pronostia-Datensatz dargestellt. Darin sind einzelne Anomalien oder Abweichungen vom „intakten“ Zustandwert zu erkennen. Diese können aufgrund von äußeren Erschütterungen oder ähnlichen Ereignissen entstanden sein. Bei dem Pronostia-Datensatz wurden die untersuchten Lager mit zusätzlichen Kräften beaufschlagt, damit das Lager schneller verschleißt. Für industrielle Maschinen können bei normalem Verschleiß je nach Anwendung 10.000 – 100.000

<sup>2</sup> Nectoux, Patrick & Gouriveau, Raïfael & Medjaher, Kamal & Ramasso, Emmanuel & Chebel-Morello, Brigitte & Zerhouni, Noureddine & Varnier, Christophe. (2012). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. *Conference on Prognostics and Health Management*. 1 – 8.

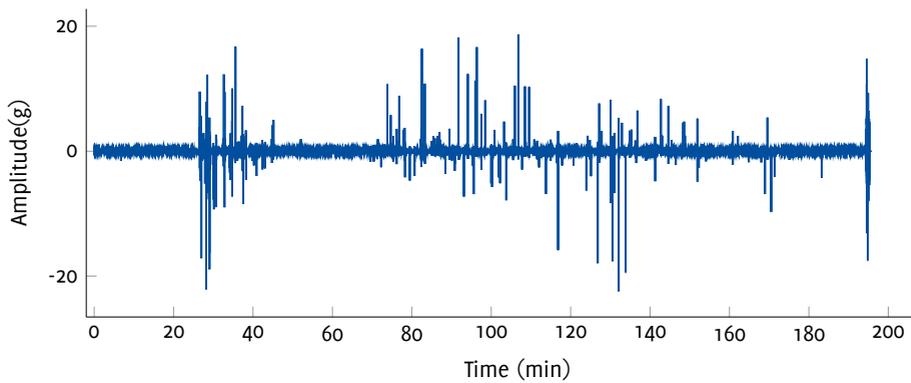


Abbildung 1: Amplitudenverlauf eines Lagers des Pronostia-Datensatzes. Grafik: IMMS.

Betriebsstunden vergehen. Daten im Prozess aufzunehmen und für ein Training von KI-Modellen vorzuverarbeiten, macht in der Regel etwa 80% des Gesamtaufwandes aus. Um somit nicht alle Rohdaten aufwändig vorverarbeiten zu müssen, ist eine Datenreduktion sinnvoll.

## Singulärwertzerlegung

Die Singulärwertzerlegung (Singular Value Decomposition, SVD) ist eine Methode der linearen Algebra, um die Dimensionalität von Daten zu reduzieren. Zuerst werden die aufgenommenen Vibrationsdaten zeilenweise in eine Matrixdarstellung überführt. Dann werden diese in drei separate Matrizen zerlegt. Die Singulärwertzerlegung einer Matrix  $A$  wird in der Regel wie folgt dargestellt:

$$A = U\Sigma V^T$$

Hierbei sind:

- **$U$** : Die linke singuläre Vektormatrix. Die Spalten von  $U$  sind die Eigenvektoren der Matrix  $AA^T$  (Kovarianzmatrix).
- **$\Sigma$** : Die Diagonalmatrix der Singulärwerte. Die Singulärwerte repräsentieren die Wichtigkeit der jeweiligen Eigenvektoren und sind auf der Diagonalen von  $\Sigma$  angeordnet. Sie sind immer nicht-negativ.
- **$V^T$** : Die transponierte rechte singuläre Vektormatrix. Die Spalten von  $V^T$  sind die Eigenvektoren der Matrix  $A^T A$  (Kovarianzmatrix).

Einen reduzierten Datensatz erhält man, indem nur die ersten  $k$  dominanten Singulärwerte und die entsprechenden Teile von  $U$ ,  $\Sigma$  und  $V^T$  verwendet werden. Die Datenpunkte mit den größten Singulärwerten sind in Abbildung 2 dargestellt.

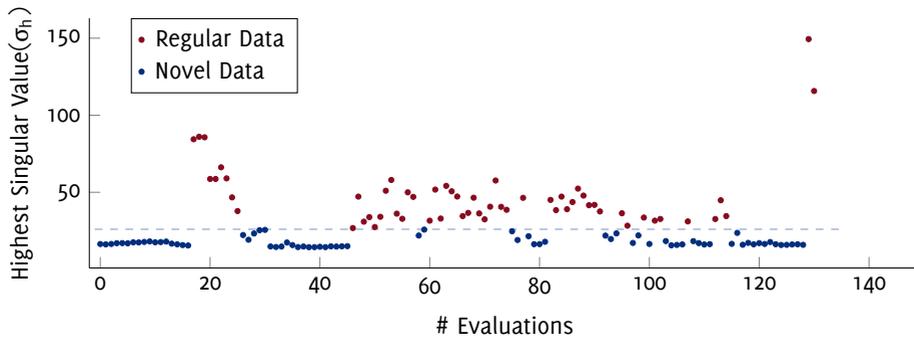


Abbildung 2: Darstellung der Singulärwerte mit ermitteltem Schwellwert. Grafik: IMMS.

Die Standardabweichung der Singulärwerte wurde genutzt, um einen Schwellwert ( $\Psi$ ), dargestellt als gestichelte Linie in Abbildung 2, für den Neuigkeitswert der Daten zu berechnen.

## Korrelation

Die Singulärwerte können dazu genutzt werden, um in einem weiteren Schritt mittels Kreuzkorrelation Abweichungen von einem gelernten Gutzustand zu erkennen. Als Korrelationsalgorithmus wurde die Canonical Crosscorrelation Analysis (CCA) verwendet und für die Umsetzung 3 Phasen definiert, vgl. Abbildung 3:

- Learning Phase – Lernphase
- Observation Phase – Beobachtungsphase
- Deployment Phase – Implementierungsphase

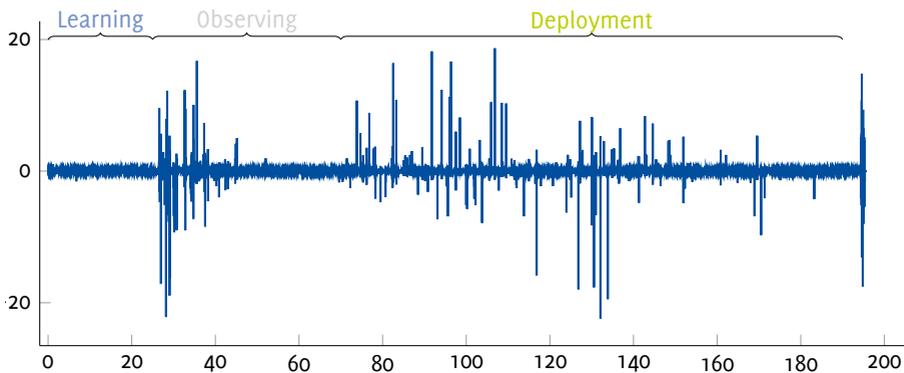


Abbildung 3: Amplitudenverlauf eines Lagers und Einteilung in die 3 Phasen. Grafik: IMMS.

## Lernphase

In der Lernphase wird davon ausgegangen, dass sich die Maschine in einem intakten Gutzustand befindet. Die Singulärwertzerlegung wird auf das erfasste Vibrationssignal  $X$  angewendet, das eine 2D-Transformation der Sensordaten ist. Die für eine Analyse per Fast-Fourier-Transformation (FFT) in Frequenzanteile zerlegten zeitdiskreten Signale des Vektors der Singulärwerte wird als Merkmal für den intakten Zustand der Maschine verwendet und in einer Merkmalsmatrix  $F$  gespeichert. In dieser Matrix werden mehrere Instanzen einer solchen Erfassung und Zerlegung der Zustandsmerkmale gespeichert. Die Anzahl der in  $F$  gespeicherten Merkmale ist durch die Anwendung und dem im Sensorknoten verfügbaren Speicher begrenzt. Die Singulärvektoren, die diesen Merkmalsvektoren entsprechen, werden ebenfalls gespeichert und zur Berechnung eines Schwellenwerts  $\psi$  verwendet, wie in der Abbildung 2 dargestellt.

## Beobachtungsphase

Die Beobachtungsphase ist optional, kann aber nützlich sein, um bestimmte Anomalien bzw. Zustände zu lernen und als Merkmal  $F$  zu speichern. Dies führt zur Aktualisierung der Merkmalsmatrix  $F$  und des Schwellenwertes  $\psi$ .

## Implementierungsphase

In der Implementierungsphase werden neue Vibrationswerte ( $X$ ) aufgezeichnet und mit SVD zerlegt, um den Merkmalsvektor  $f$  des neu aufgezeichneten Signals zu erhalten. Dieses Merkmal wird dann mittels CCA mit der bereits erlernten Merkmalsmatrix  $F$  des Gutzustandes analysiert. CCA versucht zu analysieren, wie unterschiedlich die gelernten Merkmale im Vergleich zu dem neu aufgenommenen Merkmal sind. Die Vergleichsskala ist immer 0 bis 1, wobei 0 für sehr unterschiedlich und 1 für identisch steht. Das Ergebnis der CCA-Analyse wird als Degradationskoeffizient bezeichnet. Ein Beispiel für einen sich verschlechternden Lagerzustand ist in Abbildung 4 dargestellt.

## Kombination aus Singulärwertzerlegung und Korrelation

Diese Kombination aus Merkmalsextraktion mit SVD und nachfolgender Korrelation erlaubt eine automatisierte Merkmalsextraktion und anschließende Detektion von Zustandsänderungen. Weitere Details sind im Patent „Verfahren und Sensoranordnung zum Überwachen einer Funktion eines Bauteiles einer Maschine“, DE 10 2024 100 703 B3, beschrieben.<sup>3</sup>

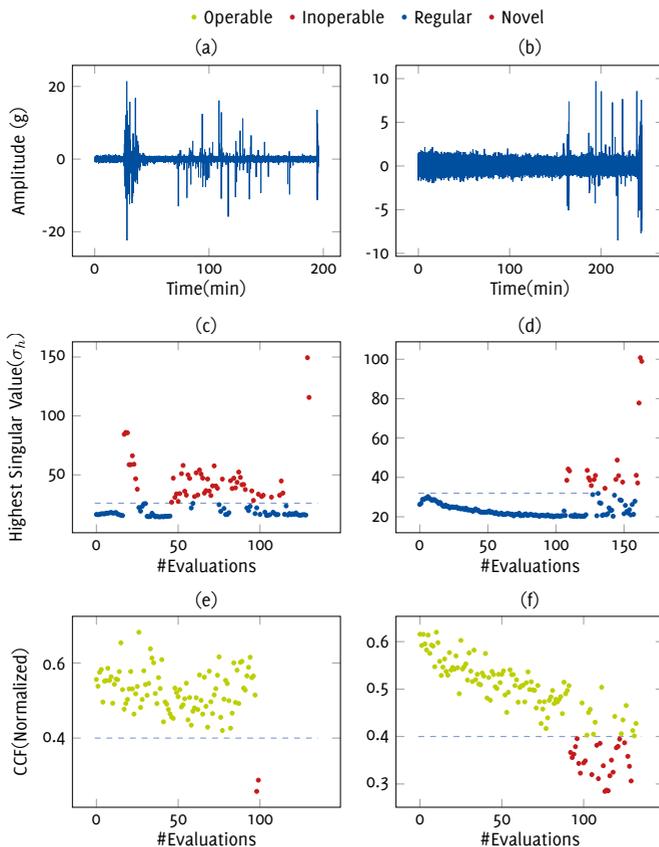


Abbildung 4:

Beispiel für einen sich verschlechternden Lagerzustand. Die Spalten zeigen Signale von zwei unterschiedlichen Lagern:

oben: Vibrations-  
signale der Lager,

Mitte: Singulärwerte  
der Vibrations-  
signale

unten: CCA der  
Singulärwerte

Grafik: IMMS.

## Anomalie-Detektion mit neuronalen Netzen

Neuronale Netze sind eine Methode, um Abweichungen vom Normzustand, d.h. Anomalien in den Daten, anhand wesentlich komplexerer Muster zu erkennen und somit ein zeitaufwändiges Erfassen bekannter Fehlerzustände überflüssig zu machen.

In dieser Untersuchung wurden zwei Modelle zur Anomaliedetektion verwendet: LSTM-AD (Long Short-Term Memory Anomaly Detection) und Autoencoder. Beide Modelle wurden mit Vibrationsdaten trainiert, die ausschließlich den normalen, also fehlerfreien Zustand einer Maschine repräsentieren. Sie lernen auf Basis einer festgelegten Fenstergröße, also eines bestimmten Zeitabschnitts der Messdaten, das typische Verhalten der Maschine und sagen anschließend die nächsten Messwerte voraus. Diese Vorhersage basiert auf den Mustern, die während des Trainings erkannt wurden.

Um die Robustheit der Modelle zu testen, wurden sie mit verschiedenen Testdaten evaluiert, sowohl mit fehlerfreien als auch mit fehlerhaften Daten, die bereits Anomalien enthalten können. Da die Modelle jedoch nur auf Gutzustände trainiert wurden, gelingt ihnen die Rekonstruktion der Vibrationsdaten bei Vorliegen einer Anomalie nicht mehr präzise. Es entsteht ein sogenannter Rekonstruktionsfehler, also die Differenz zwischen dem tatsächlichen und dem vorhergesagten Signal. Aus diesem Fehler wird ein Anomalie-Score berechnet, der Hinweise auf ungewöhnliches Verhalten liefern kann. Zuvor werden die Daten aller drei Schwingungsachsen normalisiert und mithilfe eines gleitenden Fensters (Moving-Window-Ansatz) für das Modelltraining vorbereitet. Dabei stellt die Fenstergröße die Eingabe (X-Train) dar, während das nachfolgende Zeitfenster als Zielwert (Y-Train) dient.

Der aus dem Modell resultierende Rekonstruktionsfehler wird anschließend einem Change-Point-Detection-Algorithmus übergeben. Dieser sucht mithilfe eines fensterbasierten, schrittweisen Verfahrens nach Punkten im Signal, an denen sich das Verhalten signifikant ändert, also potenziellen Anomalien. In einem ersten Schritt identifiziert der Algorithmus mögliche Haltepunkte und berechnet deren Fehlerwerte. Im anschließenden Vorhersageschritt wählt er unter Berücksichtigung einer maximalen Anzahl erlaubter Change Points sowie einer Strafbewertung für übermäßige

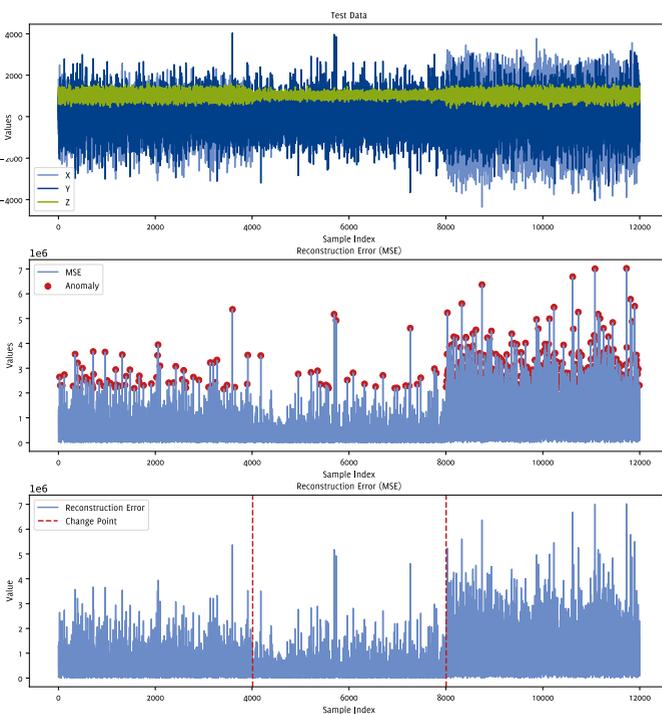


Abbildung 5:

oben:  
Testdaten

Mitte:  
Rekonstruktions-  
fehler (Anomalien  
mit statischem  
Schwellwert),

unten:  
Rekonstruktions-  
fehler (Change Point  
Detector).

Grafik: IMMS.

Unterteilungen die optimalen Punkte aus. Auf diese Weise lassen sich Veränderungen im Maschinenzustand automatisiert und zuverlässig erkennen.

In Abbildung 5 sind die Vibrationsdaten, der Rekonstruktionsfehler mit erkannten Anomalien, einmal mit einem statischen Schwellwert und einem Change Point Detektion Algorithmus dargestellt.

### LSTM-AD (Long Short-Term Memory Anomaly Detection)

Die untersuchten Modelle erlauben eine Detektion von Anomalien. LSTM-AD ist besonders geeignet für die Analyse zeitabhängiger Daten, da es durch seine rückgekoppelte Struktur sowohl langfristige als auch kurzfristige Muster in sequenziellen Signalen erfassen kann. Das macht es zu einer besonders leistungsfähigen Methode, wenn Maschinenverhalten stark von zeitlichen Verläufen abhängt. Allerdings erfordert der Einsatz von LSTM-AD eine größere Menge an Trainingsdaten sowie eine aufwendigere Modellanpassung und ist damit auch rechenintensiv.

### Autoencoder

Im Gegensatz dazu bieten Autoencoder einen effizienteren Ansatz zur Anomaliedetektion, da sie versuchen, Eingabedaten möglichst originalgetreu zu rekonstruieren. Weicht das rekonstruierte Signal stark vom Original ab, kann dies auf eine Anomalie hinweisen. Autoencoder sind besonders gut geeignet, wenn es sich um stationäre Vibrationsdaten handelt, also Daten, deren Muster sich über die Zeit wenig verändern. Sie sind einfacher zu trainieren als LSTM-Modelle, eignen sich jedoch weniger für stark zeitabhängige oder dynamisch veränderliche Zustände.

### Bewertung der Methoden

Mit allen Methoden lassen sich Abweichungen von Normalzuständen in Daten erkennen. Die Singulärwertzerlegung ist eine robuste Methode zur Dimensionsreduktion und zur Identifikation neuartiger Muster in linearen Daten. Sie ist besonders geeignet, wenn die Datenstruktur relativ einfach ist und die Anomalien geringfügige Abweichungen in der Datenstruktur darstellen. Algorithmen zur Anomaliedetektion sind flexibler und leistungsfähiger bei der Analyse komplexer oder nichtlinearer Systeme. Sie können jedoch rechenintensiver sein und erfordern eine sorgfältige Parametrierung.

## Demonstratoren

Um eine mögliche Anwendung im industriellen Umfeld zu veranschaulichen, wurden Algorithmen für zwei Szenarien in zwei Demonstratoren implementiert. Der einfache  $k$ -Means-Algorithmus wurde direkt auf einem kleinen, energieautarken Sensorsystem als lokale KI implementiert und mit einem Demonstrator zum Lüftermonitoring als Beispiel für die Überwachung von Lagern evaluiert. Eine komplexere, leistungsfähigere Anomalie-Detektion wurde in einem energieeffizienten Edge-KI System mit lokaler Vorverarbeitung auf dem Sensorknoten und Anomalie-Detektions-Algorithmen auf dem Edge-Device mit einer Datenverarbeitung anhand der Überwachung von Vibrationen auf einem Shaker demonstriert.

### Lüfter-Demonstrator

Am Lüfter-Demonstrator kann ein defekter Lüfter mit einem kleinen, energieautarken Sensorsystem mit lokaler KI erkannt werden. Dazu wurden drei Lüfter verwendet, bei einem wurde das Kugellager beschädigt, die anderen beiden sind intakt. Der batteriebetriebene Sensorknoten erfasst Schwingungsmessdaten, wertet sie aus und klassifiziert den aktuellen Zustand. Das System enthält einen Schwingungssensor, der Schwingungen bis 6,4 kHz erfassen kann, und einen Mikrocontroller mit integriertem Funktransceiver.

Auf dem Sensorknoten wurde der Clustering Algorithmus  $k$ -Means implementiert. Der Sensor kann auf den Zustand des einen intakten Lüfters trainiert werden. Ein weiterer „intakter“ und ein „defekter“ Lüfter können dann entsprechend erkannt und klassifiziert werden, ohne dass die Daten vorher aufgezeichnet wurden. Angezeigt wird das Ergebnis über eine grüne bzw. rote LED, siehe Abbildung 6. Die



<https://youtu.be/Yv-XzoZxlCQ>

Abbildung 6:

Lüfterdemonstrator: Die Lüfter können einzeln an- und abgeschaltet werden. Das Sensorsystem wird mittig auf einem der Lüfter platziert und ist mittels eines Magneten befestigt. Der Status wird über eine LED angezeigt. Grün entspricht intakt, Rot defekt.

Foto: IMMS.

Abbildung 7: Demonstratorsystem mit (1) Vibrationserzeuger, (2) drahtlosen Sensorknoten, (3) Edge-Device und (4) Tablet. Foto: IMMS.

Daten können auch energiesparend mittels BLE (bluetooth low energy) zu einem Edge-Device übertragen werden.

### Energieeffizientes Edge-KI-System

Dieser Demonstrator zeigt, wie sich mit einem drahtlosen Sensorknoten Vibrationsdaten aufnehmen und mit BLE (bluetooth low energy) zu einem Edge-Device übertragen lassen, auf dem ein LSTM-AD-Algorithmus zur Anomalie-Detektion implementiert ist.



Vibrationsdaten weisen je nach Maschine und Prozess komplexere Muster auf. Die dafür notwendigen Algorithmen benötigen daher Rechenkapazitäten außerhalb des Sensorknotens. Die Vibrationsdaten können jedoch auf dem Sensorknoten schon vorverarbeitet werden. Dazu wurden Methoden zur Datenkompression wie die Singulärwertzerlegung eingesetzt, um die Energieeffizienz und somit Batterielaufzeit des Sensorknotens zu erhöhen.

Für diesen Demonstrator wurde ein Schwingungserreger (Shaker) genutzt, um Vibrationen ähnlich zum industriellen Umfeld zu erzeugen. Der Sensorknoten ist auf dem Erregersystem montiert. Mit dem System kann nun ein Gutzustand trainiert werden. Der Sensorknoten erfasst zyklisch das Vibrationssignal, was von 1x pro Sekunde bis zu 1 x pro Stunde einstellbar ist, und überträgt es zu dem Edge-Device, in dem Fall ein Raspberry Pi ohne Cloud-Zugang. Auf diesem werden dann Abweichungen vom Gutzustand detektiert und per Dashboard im Browser auf einem Tablet visualisiert. Wird nun das erzeugte Schwingungssignal verändert, werden diese Änderungen detektiert und grafisch angezeigt.

Das IMMS fokussiert sich bei seinen Arbeiten zu adaptiven Edge-KI-Systemen darauf, die Bestimmung und Vorhersage von Maschinen- und Werkzeugzuständen im Applikationsfeld der vorausschauenden Wartung mithilfe von KI zu erforschen und umzusetzen.

Die vorgestellten Ergebnisse zum unüberwachten Lernen helfen, den Aufwand und die Kosten bei der Implementierung von KI beim Monitoring zu reduzieren. Der Schwerpunkt lag auf Vibrationssensoren, da diese meist in der Praxis eingesetzt werden, um Maschinenzustände zu erfassen. Einfache Algorithmen wie ein Clustering wurden in einem Mikrocontroller implementiert, um zu zeigen, dass diese sich direkt auf Ultra-Low-Power-Sensorik ausführen lassen. Für komplexere Aufgaben müssen Daten vom Sensorknoten zu einem Edge-Device übertragen werden, auf dem die KI-Algorithmen ausgeführt werden. Dafür wurden Kompressionsalgorithmen untersucht und auf dem Sensorknoten implementiert, um nur die benötigten Daten an das Edge-Device zu senden und so eine möglichst hohe Batterielaufzeit des Sensorknotens zu erreichen. Es wurde gezeigt, dass sowohl das Training als auch die Inferenz, also die KI-basierte Schlussfolgerung, direkt auf dem Sensorknoten oder bei komplizierten Algorithmen auf Edge-Devices wie einem Raspberry Pi ohne Cloud-Zugang implementiert werden können.

Auf der Basis dieser Lösungen zur Erfassung von Maschinenzuständen und zur automatischen Detektion von Abweichungen von Gutzuständen ist das IMMS bestrebt, Weiterentwicklungen voranzubringen und sucht dafür nach Anwendungspartnern.

**Kontakt:** Dipl.-Ing. Sebastian Uziel, [sebastian.uziel@imms.de](mailto:sebastian.uziel@imms.de)



GEFÖRDERT VOM



Die vorgestellten Lösungen wurden in der internen, vom Freistaat Thüringen geförderten KI-Forschungsgruppe des IMMS und im Projekt HoLoDEC entwickelt. Das diesem Bericht zugrunde liegende Vorhaben HoLoDEC wurde 2024 mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 16ME0703 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

- > Integrierte Sensorysysteme
- > Intelligente vernetzte Mess- u. Testsysteme
- > nm-präzise 6D-Direktantriebe
- > Inhalt
- \* Förderung

[www.imms.de/embeddedai](http://www.imms.de/embeddedai)

[www.imms.de/i40](http://www.imms.de/i40)

[www.imms.de/holodec](http://www.imms.de/holodec)

Jahresbericht  
© IMMS 2024