

KI-MUSIK4.0

Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0

Festo SE & Co. KG

Teilvorhaben

Überwachung und Diagnose von pneumatischen Antrieben

Zuwendungsempfänger: Festo SE & Co. KG

Förderkennzeichen: 16ME0068

Projektlaufzeit: 1. April 2020 – 31. Dezember 2023

Autoren

Dr. Stefan Saller

Daniel Spies

Inhaltsverzeichnis

1	Kurzdarstellung des Teilvorhabens	3
2	Eingehende Darstellung des Teilvorhabens	5
2.1	Projektplanung und -struktur	5
2.2	Spezifikation und Konzeption des Systems	6
2.3	Systemarchitektur	7
2.4	Generierung einer Datenbasis für das maschinelle Lernen	8
2.5	Entwicklung einer modularen Sensorplattform zur Datenaufnahme und automatisiertem Labeling	9
2.5.1	Datenlogger mit UDP-Schnittstelle	9
2.5.2	Evaluierung von Sensoren und Schaltungen für die Leckagemessung	10
2.5.3	Signalanalyse	11
2.6	Prüfaufbau und messtechnische Datenerfassung	12
2.7	Design of Experiments und Daten-Labeling	13
2.8	Feature-Extraktion und maschinelles Lernen für ein dezentrales Sensor-System	14
2.8.1	Feature-Engineering und Datenvorverarbeitung	14
2.8.2	Maschinelles-Lernen-Modell	15
2.8.3	Ergebnisse	18
2.8.4	Anpassung des Modells für Mikrocontroller	18
2.9	Integrationskonzept und Umsetzung eines dezentralen Leckage-Sensor-Systems mit integriertem Modell maschinellen Lernens	19
2.10	Evaluierung im Demonstrator	20
2.11	Fazit und Ausblick	21

1 Kurzdarstellung des Teilvorhabens

Ausgangslage

Die Analyse hochfrequent abgetasteter Daten im Feld stellt nicht nur hohe Ansprüche an die Messtechnik selbst sondern auch an die nachgelagerte Verarbeitung und Interpretation. Speicherprogrammierbare Steuerungen bieten oft nicht die Rechenleistung, um große Datenmengen kontinuierlich zu verarbeiten und auszuwerten. Die akustische Analyse von Leckage-Geräuschen stellt einen solchen Anwendungsfall in der Automatisierungstechnik dar. Pneumatische Antriebe sind integraler Bestandteil von Automatisierungsanlagen und können bspw. alters- oder beanspruchungsabhängig Schäden aufweisen, die zu Leckagen führen. Im Sinne energieeffizienter Anlagen müssen Leckagen zunächst detektiert, bewertet und folglich behoben werden.



Abbildung 1: Konzept einer Nachrüstlösung für die Leckage-Analyse an pneumatischen Antrieben, basierend auf hochfrequenten Audiodaten und Auswertung durch Methoden maschinellen Lernens

Eine besondere Herausforderung stellt hierbei die Identifikation des Leckagegeräusches im Anlagenumfeld dar. Methoden maschinellen Lernens zeigen sich hier als besonders geeignet, die Signalanteile zu identifizieren und zu bewerten. Für die dezentrale Auswertung großer Datenmengen ist ein solches, komponentennah am pneumatischen Antrieb angebrachtes Sensorsystem, auf soft- bzw. hardwarebeschleunigte Auswertemethoden angewiesen. Mit Kommunikationsprotokollen wie bspw. OPC UA, können solche Systeme Informationen nicht nur Steuerungen, sondern auch an übergeordneten Anlagen übermitteln.

Projektziel

Ziel der Untersuchungen ist die Analyse und Bewertung von Leckagegeräuschen an pneumatischen Antrieben, unterstützt durch Soft- und insbesondere Hardware-basierte Auswertemethoden. Die Basis für hochfrequent abgetastete (200 kSPS) und breitbandige Audiodaten

bilden MEMS-Mikrofone, angebracht in der unmittelbaren Nähe des Leckageortes am pneumatischen Antrieb. Als Integrationslösung wird ein kompaktes System, das an pneumatische Antriebe angebracht werden kann, angestrebt (vgl. Abbildung 1). Das System beinhaltet neben der Signalaufnahme, Algorithmen zur Signalvorverarbeitung, Feature-Extraktion und eine Bewertung der Signale durch Methoden maschinellen Lernens. Die Entwicklung geeigneter Algorithmen ist ebenso zentraler Projektinhalt, wie die Umsetzung der messtechnischen Aufgabe. Das System soll gemäß den Anforderungen an I4.0 sowohl mit der Feldebene als auch übergeordneten Systemen über OPC UA kommunizieren.

Projektergebnisse

Folgende Ergebnisse wurden im Rahmen des Projekts erzielt:

- Definition und Abstimmung von Spezifikationen zur Erforschung eines miniaturisierten Leckage-Sensor-Systems mit KI-Beschleunigung für pneumatische Antriebe in Zusammenarbeit mit den Projektpartnern.
- Erstellung einer System- und Teilarchitektur zur Verortung des Sensor-Systems im Automatisierungsumfeld, dessen Bestandteile und der Machine-Learning-Strategie, auch im Kontext des KI-MUSIK4.0 Konsortiums.
- Herstellung defekter Antriebe zur Erzeugung verschiedener Leckagen und Bereitstellung einer breiten Datenbasis für das maschinelle Lernen innerhalb des Konsortiums.
- Entwurf und Konstruktion von anlagennahen Prüfständen als Testfeld für das Leckage-Sensor-System.
- Untersuchung geeigneter MEMS-Mikrofone und -Sensoren für die Aufnahme hochfrequenter Signale.
- Entwicklung einer modularen Datenaufzeichnungsplattform (Datenlogger) mit automatisiertem Daten-Labeling und PC-Anbindung.
- Entwicklung von Algorithmen zur Vorverarbeitung der Audiodaten, Feature-Engineering und Modellen maschinellen Lernens sowie eine enge Abstimmung der Ergebnisse mit den Partnern des Konsortiums.
- Erfolgreiche, komponentennahe Implementierung von Modellen maschinellen Lernens auf einer miniaturisierten Elektronikplattform zur Auswertung und Bewertung (Regression) von Leckagegeräuschen auf pneumatischen Antrieben.
- Aufbau eines Demonstrators mit mehreren KI-gestützten Leckage-Sensor-Systemen auf pneumatischen Antrieben und OPC UA Anbindung.
- Veröffentlichung der Ergebnisse durch Paper-Beiträge und ein Exponat auf der Hannover Messe 2024

2 Eingehende Darstellung des Teilvorhabens

Die Vorgehensweise und Umsetzung der Ziele des Teilvorhabens werden nachfolgend in der eingehenden Darstellung beschrieben.

2.1 Projektplanung und -struktur

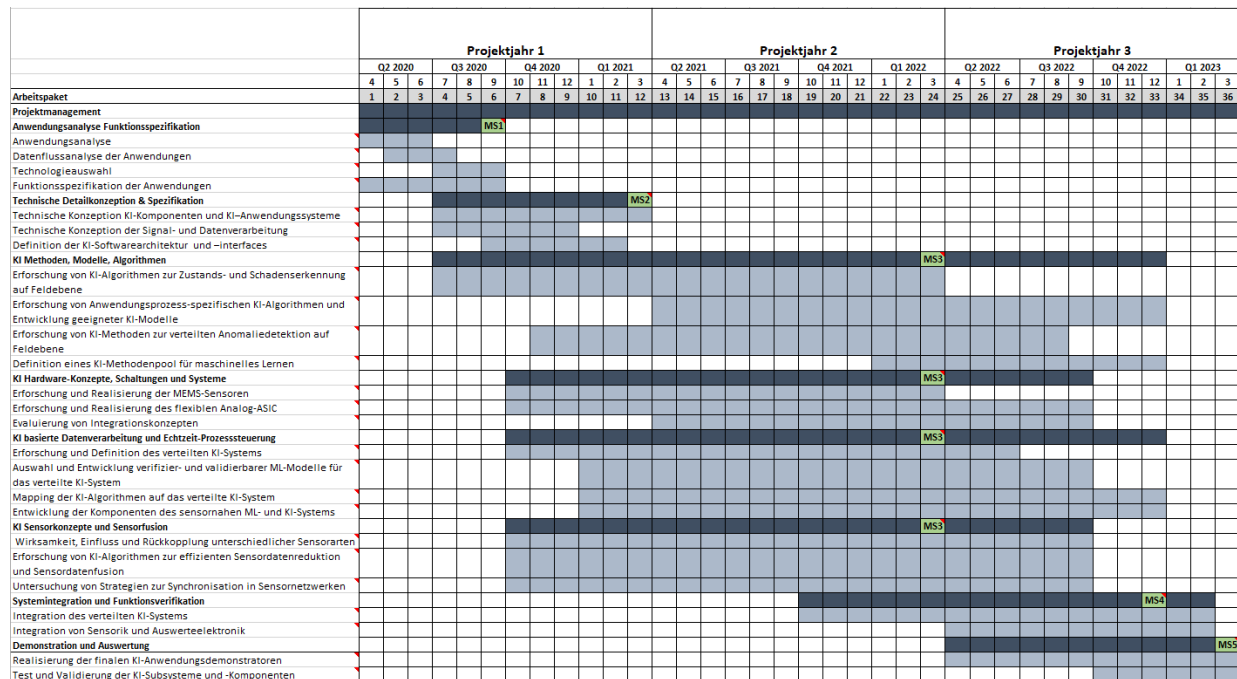


Abbildung 2: Gant-Plan des Teilvorhabens

Die frühzeitige Erkennung und Bewertung von Leckagen an pneumatischen Antrieben spielt nicht nur aus energetischen Gesichtspunkten eine zentrale Rolle im Automatisierungsumfeld. Relevante Schädigungen am Antrieb können zu Veränderungen von Prozesszeiten und erforderlichen Kräften führen. Die wesentlichen Anforderungen an eine KI-basierte Nachrüstlösung zur Identifikation von Leckagen an pneumatischen Antrieben wurden in der Anwendungsanalyse (AP1) und Detailkonzeption (AP2) identifiziert und definiert. Die KI-basierte Auswertung von breitbandigen akustischen Sensordaten setzt eine breite Datenbasis voraus, auf der Methoden maschinellen Lernens trainiert werden können. Die Aufnahme von Daten defekter Antriebe, ebenso deren Vorverarbeitung und eine geeignete Feature-Extraktion sind notwendig, um Modelle zu trainieren (AP3). Die hierfür eingesetzte Sensorik, ebenso wie das Integrationskonzept des Nachrüstsystems wurden im Rahmen von AP4 untersucht. Die Modellierung der Algorithmen zur Bewertung der Leckage, sowie deren Portierung von leistungsfähigen Rechnern auf Mikrocontroller-Ebene ist Gegenstand von AP5. In AP6 wurde eine weitere Optimierung der sensorischen Erfassung und Betrachtung effizienter Algorithmen betrachtet. Die Systemintegration sowohl konstruktiv, elektronisch als auch algorithmisch wurde in AP7 in Form eines Demonstrators am pneumatischen Antrieb umgesetzt und in AP8 nachgewiesen.

2.2 Spezifikation und Konzeption des Systems

Abhängig vom Schädigungsmechanismus können Leckagen an pneumatischen Antrieben an verschiedenen Dichtungsstellen auftreten. Abbildung 3 illustriert dies exemplarisch. Die Kolbenstangendichtung spielt hierbei eine besondere Rolle, da sie externen Einflüssen, bspw. Partikeln auch in Kombination mit Querkräften im Produktionsprozess ausgesetzt sein kann. Auch die QS-Verschraubungsstellen können beim Montageprozess durch eine mangelnde Fixierung ungenügend abgedichtet sein. Das Überströmen der Kolbendichtung ist nur während des Verfahrens relevant und ist weiterhin durch das abschirmende Zylinderrohr mit den eingesetzten Sensoren messtechnisch kaum zu erfassen.




Abbildung 3: Ableitung der Funktionsspezifikation aus dem Konzept. Darstellung möglicher Leckagestellen, Sensorsystem (Mitte), Aufbau eines pneumatischen Antriebs (halb-transparente Darstellung)

Im Sinne einer vollintegrierten kompakten Nachrüstlösung bieten sich bestückbare MEMS-Mikrofone an. Hauptsächlich aus dem Consumer-Bereich kommend, werden mittlerweile auch Varianten in robuster Ausführung für den industriellen Einsatz angeboten, die einen höheren AOP-Wert (Acoustic Overload Point) aufweisen. Zusammen mit einem leistungsfähigen Mikrocontroller, bspw. auch im Zusammenspiel mit einem dedizierten ASIC für die Vorverarbeitung und Analyse von hochfrequent abgetasteten Audiosignalen, können Methoden maschinellen Lernens effektiv auf der Komponente ausgeführt werden. Das Nachrüstkonzept sieht eine Ethernet-basierte Kommunikationsschnittstelle mit OPC UA für die Anbindung

an die Automatisierungsumgebung vor. Die hochfrequent abgetasteten Daten können auf der Komponente ausgewertet werden und die extrahierte Information über den Komponentenzustand kann übergeordnet bewertet werden. Die nachfolgende Auflistung enthält die wesentlichen Anforderungen an das System.

- Identifikation der Kolbenstangenleckage durch eine Nahfelderfassung der schwingungsbasierten Signale
- Integration eines breitbandigen schwingungsbasierten Sensorsystems am pneumatischen Antrieb
 - Luftschall bis 100 kHz und hohem AOP
 - Körperschall bis 6 kHz
- Entwicklung und Einsatz von Algorithmen mit entsprechender Signalvorverarbeitung und Feature-Extraktion auf pneumatischen Antrieben
- Kompaktes und energieeffizientes Design der Elektronik und Algorithmik mit geeigneter Datenschnittstelle zur Anbindung an I4.0-Systeme
- Kommunikations- und Konfigurationschnittelle für das Sensor-System
- Robuste Auswertung im Hinblick auf Anomalien im Produktionsprozess

Das Nachrüstsystem muss mit einer mechanischen Schnittstelle so orientiert sein, dass die sensorische Überwachung der in Abbildung 3 dargestellten Leckage möglich ist und eine optimale Sensorankopplung am Antrieb erfolgen kann.

2.3 Systemarchitektur

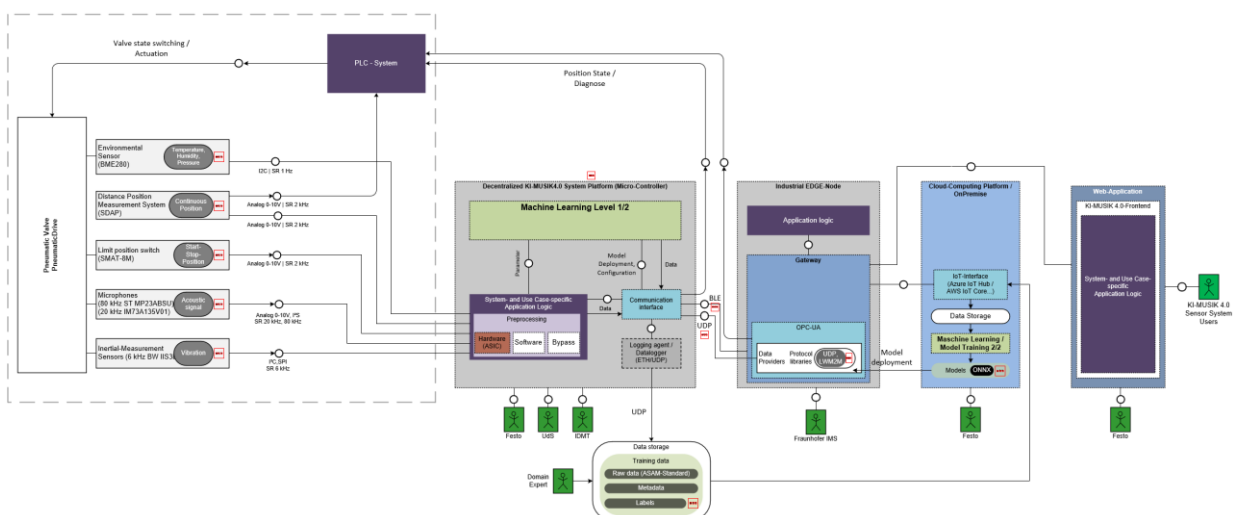


Abbildung 4: Systemarchitektur Teilvorhaben Festo

In Zusammenarbeit mit dem Konsortium und insbesondere der Schaeffler AG wurde eine Gesamt-System-Architektur für das Projekt KI-MUSIK4.0 entworfen, an das sich die System-

Architektur des Teilvorhabens angliedert. In Abbildung 4 sind die Komponenten, Sensoren, der Datenfluss, die Machine-Learning-Pipeline sowie die Verortung des Systems im Kontext Industrie 4.0 darstellt. Der pneumatische Antrieb ist mit mehreren Sensoren, insbesondere für die Leckagedetektion mit Mikrofonen ausgestattet und an das PLC-System über Endschalter zur Überwachung der Position angebunden. Das Machine-Learning Level I stellt ein zentrales Element der Architektur dar, in dem sowohl die Datenaufnahme über einen Datenlogger, sowie die Integration und Ausführung von Modellen in Soft- und Hardware stattfinden können. Als geeignete Mikrocontroller-Plattform wurde hierfür die STM32-Familie (STMicroelectronics) ausgewählt. Angebunden über Ethernet findet die Kommunikation mit einem EDGE-Rechner oder auch PLCs über OPC UA statt. Übergeordnet gliedert sich das Machine-Learning Level II an, das Zugriff auf größere Hardware-Ressourcen für das Training von Modellen besitzt. Mit einer Web-Applikation können Systemzustände abgerufen aber auch Applikationen gestartet und konfiguriert werden. Der KI-MUSIK4.0 – Datenlogger, der weiterführend in Abschnitt 2.5 beschrieben wird, kann entsprechend konfiguriert und für die Aufnahme der Trainingsdaten verwendet werden. Das Labeln der Daten erfolgt zunächst manuell sowie im Fortlauf des Projekts automatisiert. Anschließend wurden mehrere Parametervariationen für ein optimales Modell und eine Modellreduktion für die Lauffähigkeit auf einem dezentralen System vorgenommen.

2.4 Generierung einer Datenbasis für das maschinelle Lernen

Die Voraussetzung für das Training und die Leistungsfähigkeit des Modells, bzw. die Vorhersage und quantitative Bewertung der Leckage ist eine breite Datenbasis, die relevante Informationen über die Leckage enthält. Hierfür wurden systematisch die Kolbenstangendichtungen im Lagerdeckel modifiziert, um eine breite Abdeckung von Leckagen von 0 bis etwa 300 l/h zu erhalten.




Abbildung 5: Vorrichtung für die Dichtringmodifikation mit einem Laser, Schädigung an einer Lagerdeckeldichtung mittels Laserablation, Mechanischer Schnitt sowie Riefe mittels Laserablation, Vorrichtung zur Erzeugung verschiedener Schnittwinkel an Druckluftschläuchen (v.l.n.r.)

Bei den Modifikationen handelt es sich um bewusste Schädigungen an der Dichtungsinnenseite, hin zur Kolbenstange (vgl. Abbildung 3). Die Schädigungen wurden mechanisch und durch Laserablation hervorgerufen (vgl. Abbildung 5). Neben der Kolbenstangendichtung wurden auch die Lagerdeckeldichtungen modifiziert, die insgesamt jedoch für diese Aufgabenstellung

eine geringere Relevanz besitzen. Eine weitere Leckagemöglichkeit kann sich aufgrund des Schnittwinkels am Ende des Druckluftschlauches und der Dichtung im QS-Anschluss des Antriebs einstellen (vgl. Abbildung 1 und Abbildung 5). Es hat sich gezeigt, dass die Leckagen bei einem Schnittwinkel von etwa 45° Leckagen sehr schnell zunehmen. Der dafür notwendige Schnittwinkel stellt jedoch im Vergleich zur Kolbenstangeleckage im Rahmen des Projekts ein untergeordnetes Szenario dar. Aufgrund der Breitenwirkung wurde der DSBC-32-100 bzw. DSBC-32-160 Antrieb für alle weiteren Experimente und zur Demonstration der Ergebnisse ausgewählt.

2.5 Entwicklung einer modularen Sensorplattform zur Datenaufnahme und automatisiertem Labeling

Als Ausgangspunkt der Leckageerkennung dient die Analyse des Luftschalls im Bereich der Leckageöffnung. Es hat sich herausgestellt, dass der Aufnahmequalität eine ganz wesentliche Bedeutung bei der Feature-Extraktion und der letztlichen Interpretation zukommt. Basierend auf der ST32-Mikrocontroller-Familie wurde ausgehend von einem NUCLEO F429ZI Board in mehreren Iterationsschritten ein Datenlogger entworfen, eine geeignete Sensorik identifiziert und die Signalübertragungsstrecke optimiert. Die Qualität der aufgezeichneten Daten wurde dabei fortlaufend verbessert und den Partnern zur Verfügung gestellt.

2.5.1 Datenlogger mit UDP-Schnittstelle

Der Datenlogger basiert auf einem STM32 NUCLEO-F429ZI Board, das einen Header mit PIN-Out für verschiedene Sensorschnittstellen bereitstellt und eine Ethernet-Schnittstelle für die Übertragung der Sensordaten per UDP bietet (vgl. Abbildung 6). Innerhalb des Konsortiums wurde ASAM MDF für Datenaustausch festgelegt. Das Format ermöglicht die Speicherung von Sensordaten mit zugehörigen Zeitachsen in jeweils separaten Kanälen.




Abbildung 6: Datenlogger Architektur

Die Datenübertragung lässt sich über ein Python-Skript starten, das eine Socket-Verbindung zwischen PC und Datenlogger öffnet. Durch eine initiale Konfiguration wird die Anzahl der aufzunehmenden Sensoren festgelegt. Die Samplerate ist jeweils in der Firmware des ST-Board konfiguriert. Durch ein eigenentwickeltes Protokoll werden die Daten jeweils mit Kanal-

und Sensorinformationen, Paket-ID und Sensordaten, aufgeteilt in Frames, übertragen. Hierdurch können die Pakete entsprechend identifiziert und Paketverluste vermieden werden. Die Daten werden anschließend im ASAM MDF abgelegt.

2.5.2 Evaluierung von Sensoren und Schaltungen für die Leckagemessung

Die hohe Dynamik des Leckagegeräusches macht es erforderlich, dass Geräusche gleichzeitig mit sehr geringen und sehr hohen Lautstärken aufgenommen werden können. Während der Projektlaufzeit wurden mehrere Sensorelemente evaluiert, die nachfolgend aufgelistet sind:

- Digital IMP34DT05 (I²S)
- Digital SPH0645 (I²S)
- Analog MP23ABS1
- Analog IMP23ABSU (Ultrasonic 80 kHz)
- IIS3DWB (Körperschall 6 kHz)

Als geeignet hat sich das IMP23ABSU herausgestellt, das eine hohe Bandbreite aufweist und somit Messungen bis in den Ultraschallbereich ermöglicht. Neben der Bandbreite gibt der Acoustic Overload Point Aufschluss über die Eignung in lauten Umgebungen. Abbildung 7 zeigt als Reaktion auf Impulslärm eine kurzfristige Abweichung des normalerweise um den Nullpunkt schwingenden Ausgangssignals. Für die Abtastung durch einen 16 Bit-ADC wurde der Nullpunkt entsprechend auf den halben Eingangsmessbereich angehoben.




Abbildung 7: Exemplarisches Zeitsignal (l.) und Spektrogramm (r.) jeweils 5 Sekunden bei Impulslärm. Mikrofonsignal (l.) mit Offset von 15 Bit für eine symmetrisch Aussteuerung

Die hohe Bandbreite des Mikrofons erfordert für die spektrale Analyse des Signals eine geeignete Anti-Aliasing Schaltung, die in diesem Zuge entworfen wurde (vgl. Abbildung 8). Der Frequenzgang des Filters sowie die dessen messtechnische Evaluierung sind in Abbildung 9 dargestellt. Weiterhin wurde das Mikrofonsignal entsprechend der Leckagedynamik verstärkt.

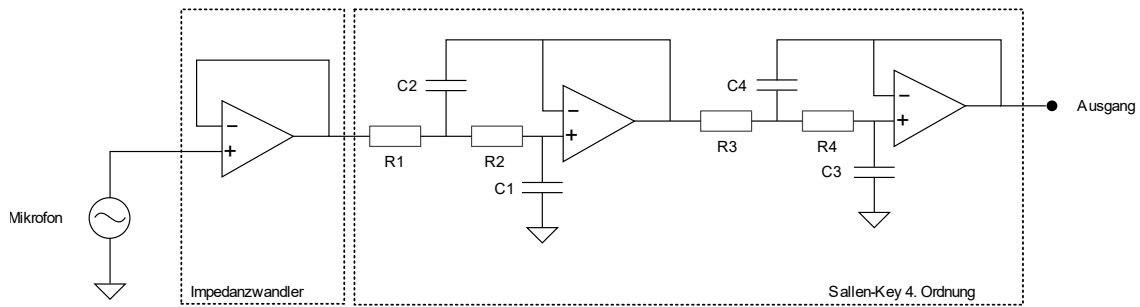


Abbildung 8: Mikrofon mit Anti-Aliasing-Filter Sallen-Key 4. Ordnung




Abbildung 9: Simulation des Frequenzgangs Anti-Aliasing-Filter Sallen-Key 4. Ordnung (l.), Vermessung der Schaltung mit dem Oszilloskop (r.)

2.5.3 Signalanalyse

Die Relevanz des Acoustic Overload Point bzw. der Dynamikbereich der eingesetzten Mikrofone zeigt sich vor allem bei der Betrachtung des Geräuschcharakteristik eines verfahrenenden pneumatischen Antriebs bzw. von Schalldämpfern und Ventilen in der messtechnischen Nähe.

Waveform

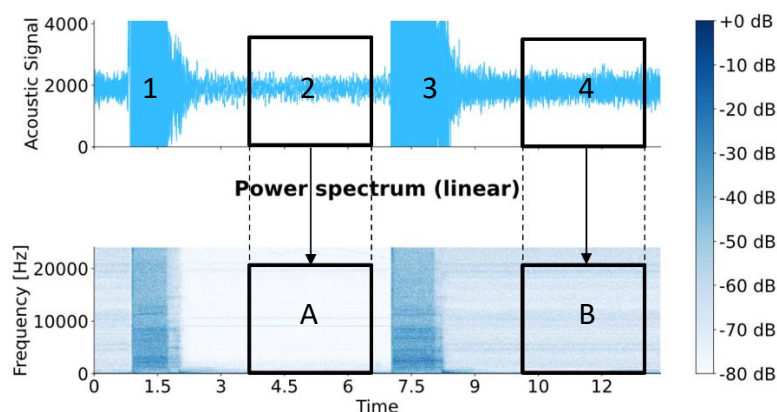


Abbildung 10: Zeitsignal und Spektrogramm eines verfahrenen Antriebs, Darstellung der Signaldynamik und von Clipping-Effekten

In Abbildung 10 sind in zeitlicher Abfolge das Ausfahren des Antriebs (1), eine definierte Wartezeit von etwa drei Sekunden (2), sowie das Einfahren (3) und eine erneute Wartezeit

von etwa drei Sekunden (4) dargestellt. Das Mikrofon ist nahe des Lagerdeckels, in unmittelbarer Nähe der Kolbenstangendichtung montiert (vgl. Abbildung 3). Verschiedene Positionierungen auf dem Antrieb zeigen erwartungsgemäß die größten Pegel für den geringsten Abstand von Mikrofon und Leckagestelle. Während der Bewegungsphase führt die Lautstärke auch aufgrund der Verstärkung am Mikrofon zu entsprechendem Clipping. Während des ausgefahrenen Zustands werden ausschließlich Umgebungsgeräusche aufgenommen. Nach dem Einfahren (3) zeigt sich die Leckage an der Kolbenstange, in Folge der unter Druck stehenden Kammer und der an der Kolbenstangendichtung entweichenden Luft. Der Unterschied im Spektrogramm zwischen A und B zeigt für die Leckage charakteristische Frequenzanteile. Diese Charakteristika werden als Feature für das maschinelle Lernen verwendet und in Abschnitt 2.8.1 eingehend diskutiert.


Weitere Messungen mit ebenfalls breitbandigen Beschleunigungssensoren (IIS3DWB, 6 kHz) haben gezeigt, dass nur sehr hohe Leckagen zu messbaren Vibrationen auf dem Antrieb führen und folglich eine zu geringe Sensitivität für niedrige Leckagen und damit die Messaufgabe besitzen.

2.6 Prüfaufbau und messtechnische Datenerfassung

Für Untersuchung der Antriebe im Feld und Erhebung der Messdaten dient ein Prüfstand. Dieser ist gleichzeitig vorgesehen, um Leckagemessungen durchzuführen und ein mögliches Umgebungsumfeld zu simulieren.



Gesamter Prüfaufbau (2m x 1m x 2m)



Prüfebene



Versorgungsebene

Abbildung 11: Prüfaufbau für die messtechnische Untersuchung pneumatischer Antriebe

Abbildung 11 zeigt die Realisierung des Aufbaus bestehend aus:

- 2 Ebenen – 16 pneumatische Antriebe – 4 elektrische Achsen
- Einzeln messbarer Versorgungsdruck für jeden pneumatischem Antrieb
- Einstellbarer Versorgungsdruck pro Ebene

- Mehrere Datenlogger und angebundene Sensoren
- SPS-Programm mit Webinterface zur Ansteuerung individueller Bewegungszyklen

Im Prüfstand wurden Antriebe mit einer frühen Variante eines „Sensorknotts“ aus Datenlogger und Mikrofon (MP23ABS1) und Beschleunigungssensor (IIS3DWB) aufgebaut (vgl. Abbildung 12).




Abbildung 12: Datenlogger mit Sensoren (l.), Beschleunigungssensor und Mikrofon (r.)

Steuerungsseitig wurde ein Webserver zur Ansteuerung des Prüfstands programmiert. Hierdurch können die Antriebe ebenfalls überwacht und in einer frühen Iteration die Ergebnisse der Leckageregression abgerufen werden, die durch die Ausführung erster Modelle PC-seitig ermittelt wurden (vgl. Abschnitt 2.8).

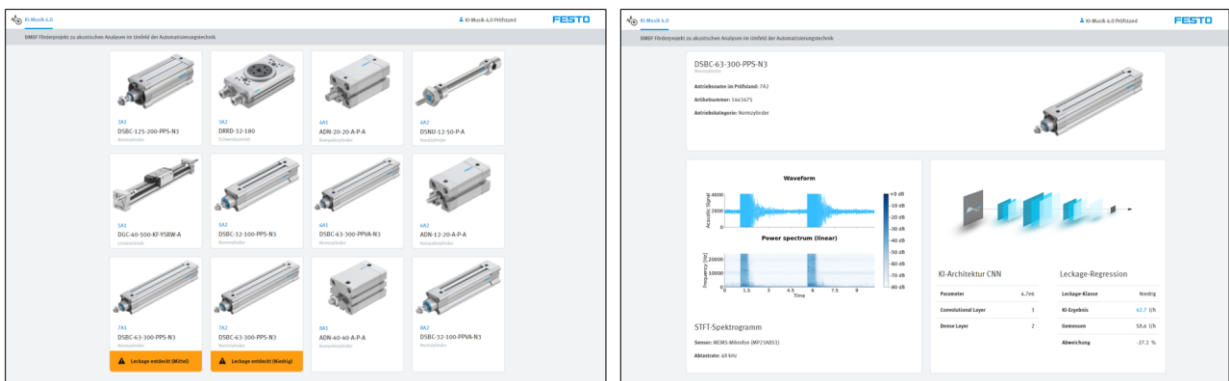


Abbildung 13: Webinterface zur Überwachung der Antriebe

2.7 Design of Experiments und Daten-Labeling

Zum Training der Modelle ist eine Vielzahl an gelabelten Messdaten notwendig. Um eine hohe Effizienz bei der Datenerfassung zu gewährleisten, wurden die Experimente in Zusammenarbeit mit der Universität des Saarlandes mittels einer statistischen Versuchsplanung erstellt. Die Verteilung der Messparameter, in der Hauptsache der Betriebsdruck zwischen 4 und 8 bar, erfolgte mittels Latin hypercube Sampling. Im Rahmen des Projekts wurden über 200 GB an kurzen Audio- bzw. MDF-Dateien mit < 10 Sekunden an Aufnahmezeit erfasst.

Basierend auf dem Antriebstyp DSBC-32-100 wurden final die Kolbenstangendichtung von 13 Antrieben modifiziert, um unterschiedliche Leckagebereiche abdecken zu können. Grundsätzlich zeigt sich, dass sich die Leckage druckabhängig verhält und nicht jede Modifikation den gewünschten Bereich von 0 – 300 l/h innerhalb der definierten 4 – 8 bar Betriebsdruck abdeckt. Weiterhin hat sich herausgestellt, dass die Leckagewerte und Mikrofondaten zeitgleich aufgenommen werden müssen, da sich die Leckagewerte über der Zeit verändern können. Durch diese Erkenntnis konnte die Vorhersagegenauigkeit verbessert werden. Hierfür wurde eine entsprechende Schnittstelle in Python zwischen Datenlogger und einer Referenz-Messeinrichtung für die Leckagemessung programmiert.

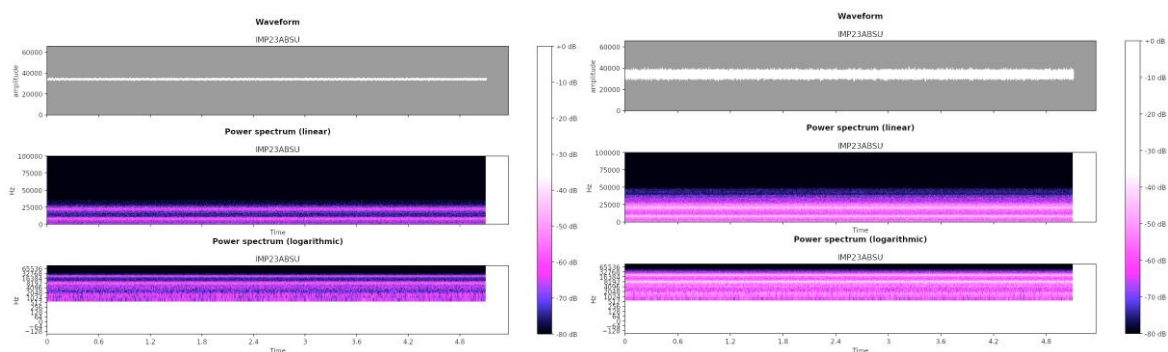


Abbildung 14: Leckage-Messungen 37,3 l/h (l.), 183,9 l/h (r.); Farbdarstellung überhöht
Zeitsignal (oben), Spektrogramm linear (Mitte),
Spektrogramm logarithmisch (unten)

Abbildung 14 zeigt den Vergleich von Messdaten für zwei Leckagewerte von ca. 38 l/h (l.) und 184 l/h (r.) in einer überhöhten Farbdarstellung zur besseren Sichtbarkeit. Es konnte beobachtet werden, dass mit zunehmender Leckage die Amplitude des Signals zunimmt und höherfrequente Anteile auftreten. Insgesamt zeigt sich eine rauschähnliche Verteilung.

2.8 Feature-Extraktion und maschinelles Lernen für ein dezentrales Sensor-System

Basierend auf den ersten Messdaten und Experimenten wurde eine Vielzahl an Modellen trainiert. Als Grundlage des Trainings dienen die Spektrogramme der gesampelten Mikrofondaten, versehen mit dem jeweils ermittelten Leckagewert als Label. In mehreren Iterationschleifen wurden neben den Features, die Parameter des Maschinellen-Lernen-Modells (ML-Modell), sowie die Verteilung von Test- und Trainingsdaten variiert.

2.8.1 Feature-Engineering und Datenvorverarbeitung

In der ersten Iteration wurden aus den Mikrofondaten mittels des Short-Time-Fourier-Transform-Algorithmus (STFT) und einer anschließenden Filterung MEL-Spektrogramme erzeugt und diese als Input-Features verwendet. MEL-Spektrogramme finden zwar in der Literatur häufig Anwendung, haben jedoch eine teilweise logarithmische Skalierung, da sie das menschliche Hörvermögen möglichst detailgetreu nachzubilden versuchen. Da dies im

Gegensatz zur Vermutung stand, in höheren Frequenzbereichen wichtige Informationen über die Leckage finden zu können, wurde auf die MEL-Skalierung verzichtet. In späteren Iterationen wurde eine reine logarithmische Skalierung der Spektrogramme eingeführt, da sich eine besondere Relevanz der hochfrequenten Anteile nicht herausstellte. Um eine bestmögliche Genauigkeit und Generalisierung des Modells zu ermöglichen, wurden bei Trainingsläufen verschiedene Kombinationen von Hyperparametern (hier: lineare, und logarithmische Skalierung) miteinander auf den gleichen Daten verglichen.

Ein Hyperparameter mit direktem Einfluss auf die Input-Features ist die Länge der Zeitfenster, die als Eingabe für die STFT dienen. Hier wurde ein fester Wert von 100 ms empirisch ermittelt: Die Zeitfensterlänge ist einerseits groß genug, um relevante Informationen über die Leckage zu enthalten und andererseits kurz genug, um mehrere Inferenzen schnell nacheinander durchführen zu können, zur Bildung eines statistischen Mittels.

Final wurden die in den Frequenzbereich transformierten Input-Daten ins Intervall [0,1] normiert (Min-Max-Skalierung). Dies ist notwendig, um die Leistungsfähigkeit des ML-Algorithmus sicherzustellen¹.

2.8.2 Maschinelles-Lernen-Modell

Über das Projekt hinweg wurden verschiedene ML-Modell-Ansätze gewählt. Für die erste Evaluation wurde ein einfaches CNN mit zwei versteckten Schichten (engl. *hidden layer*) und einer Parameterzahl von knapp 500.000 gewählt.

Tabelle 1: Im ML-Training verwendete Hyperparameter. Nicht alle Hyperparameter kamen in vollem Umfang in allen Studien zum Einsatz.

Hyperparameter	Mögliche Werte	Beschreibung
Aktivierungsfunktion	ReLU, LeakyReLU, Tanh	Aktivierungsfunktion aller Layer im Modell
Batch-Size	16, 32, 64, 128	Batch-Größe der Verarbeitung beim Training
Epochen	150, 250, 400, 700, 1000	Anzahl der Durchläufe, vor Trainingsende
Input-Stride	1, 2, 4	Sprungweite der Faltungsoperation im CNN
Kernel-Größe	3, 5	Größe der Kernel für die Faltungsoperation
Lernrate-Skalierung	[1, 10 ⁻⁹]	Skalierungswert der Lernrate
Anzahl der Filter	8, 16, 32	Anzahl der Filter pro Layer im CNN
Optimierer	Adam, AdaDelta, AdaGrad	Optimierer für den Gradientenabstieg
Bias	Wahr, falsch	Verwendung von Bias in den Layern des Modells
Hochpass-Frequenz	0, 500, 1000	Input-Features nur oberhalb der Grenzfrequenz
Daten-Skalierung	Linear, logarithmisch	Skalierung des Spektrogramms als Input

¹ Cabello-Solorzano, K. et al. (2023), The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis, https://doi.org/10.1007/978-3-031-42536-3_33

Nachdem gute Ergebnisse erzielt werden konnten, wurde das Modell erweitert und eine erweiterte CNN-Architektur basierend auf ResNet², bzw. MobileNet³ entwickelt. Die Definition der Architektur wurde dynamisch implementiert, sodass sie durch Parameter flexibel angepasst werden kann. Dies erlaubt die Optimierung der Architektur basierend auf Hyperparameter-Studien und somit das automatisierte Finden des besten Modells. Die verschiedenen Hyperparameter und deren Beschreibung finden sich in Tabelle 1.



Abbildung 15: Verteilung der Trainings- und Testdaten im LODO-Verfahren.

Um die Generalisierung des Modells über mehrere Antriebe hinweg sicherzustellen, wurden die Inputdaten nach dem Prinzip *Leave-One-Drive-Out* (LODO) in Trainings- und Testdaten aufgeteilt. Tatsächlich wurden meist mehrere Antriebe komplett dem Testdatensatz zugeordnet, sodass, gemessen am Gesamtdatensatz, eine ungefähre Aufteilung von 80 % Training und 20 % Test eingehalten wurde, sowie eine möglichst große Abdeckung der gemessenen Leckagewerte erreicht wurde. Je nach Messdatensatz wurden so auch verschiedene Antriebe dem Testdatensatz zugeordnet. Abbildung 15 zeigt die Verteilung der Trainings- und Testdaten im Vergleich zu den in den Messdaten vorkommenden Leckagewerten.

Die verwendete Architektur ist exemplarisch in Abbildung 16 dargestellt. Die tatsächliche Architektur hängt von verschiedenen Hyperparametern ab (Tabelle 1) und variiert entsprechend. Insbesondere der Hyperparameter *Anzahl der Filter* beeinflusst die Anzahl der Parameter im Modell und damit den Speicherbedarf. Diese Vorgehensweise erlaubt zu evaluieren, ob das Problem auch mit kleinen oder nur mit großen Modellen gelöst werden kann (bzw. überhaupt nicht).

Das Training der Modelle erfolgte mit Hyperparameter-Studien, iterativ immer dann, wenn neue Messungen durchgeführt wurden. Erkenntnisse aus vorhergehenden Studien konnten so auch in die Wahl des Hyperparameterraums fließen. Die Parameter für die einzelnen Modelle wurden durch einen Bayes-Algorithmus statistisch bestimmt. Abbildung 18 zeigt exemplarisch den Gradientenabstieg des ML-Algorithmus in Form der Loss-Funktion. Ziel der Optimierung

² Kaiming He et al. (2015), Deep Residual Learning for Image Recognition, <https://doi.org/10.48550/arXiv.1512.03385>

³ Andrew G. Howard et al. (2017), MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications, <https://doi.org/10.48550/arXiv.1704.04861>

ist es, den Loss-Wert der Validierungsdaten (ein zufälliger Teil der Trainingsdaten) zu minimieren, wobei dem Trainings-Algorithmus immer nur die Trainingsdaten zur Verfügung stehen. Nach Abschluss einer Hyperparameter-Studie wird aus der Menge der Modelle der beste Kandidat entsprechend der Metriken (niedrigster Fehler) und der Parameter ausgewählt.




Abbildung 16: Finales CNN-basiertes Modell




Abbildung 17: Übersicht einer Hyperparameter-Studie und die Ergebnisse verschiedener Kombinationen von Hyperparametern. Der äußerst rechte Wert beschreibt den *Root-Mean-Squared-Error (RMSE)*.




Abbildung 18: Trainingsvorgang und Entwicklung der Loss-Funktion (logarithmisch).




Abbildung 19: Spektrogramme ansteigender Leckagen (l.), zugehörige GradCAM Darstellung (r.)

2.8.3 Ergebnisse

Abbildung 20 zeigt die Ergebnisse der Regression für zwei Messdatensätze, für Aufnahmen mit und ohne Störgeräusche. Es konnte beobachtet werden, dass trotz einer quantitativ gleichen Leckage, die spektralen Anteile und damit auch der akustische Eindruck variieren können. Eine mögliche Ursache hierfür ist die Geometrie der Leckageöffnung. Dies hat zur Folge, dass die Prognosen der Modelle abhängig von der Schädigung vom tatsächlichen Wert deutlicher abweichen.




Abbildung 20: Regression mit Störgeräusch (l.), Ergebnisse ohne Störgeräusch (r.)

In Abbildung 20 zeigen die Antriebe D4, D21 und D23 eine deutliche Abweichung von gemessener und prognostizierter Leckage. Es wurde zudem beobachtet, dass laute Umgebungsgeräusche zu einer Verschlechterung der Prognosen führen. Die Vorhersagegenauigkeit lässt sich vermutlich nur durch eine sehr breite Datenbasis mit einer Vielzahl an Antrieben mit entsprechenden Leckagen verbessern. Aufgrund der limitierten Ressourcen im Projekt stand jedoch nur eine eingeschränkte Anzahl zur Verfügung.

2.8.4 Anpassung des Modells für Mikrocontroller

Durch den begrenzten Speicher des Mikrocontrollers kommen nur sehr kompakte Modelle mit Größen unter 100 kB in Frage. Um diese Einschränkung zu erfüllen, wurde bei der Wahl der Hyperparameter darauf geachtet, besonders auch Kombinationen mit aufzunehmen, die sehr kleine Modelle erzeugen. Nach einer abgeschlossenen Hyperparameterstudie (siehe Abschnitt 2.8.2) konnte so aus der Menge aller Modelle eine Untermenge der kleinen, bzw. passenden Modelle erzeugt werden.

Mithilfe der Software *X-CUBE-AI* des Herstellers STMicroelectronics wurde dann das gewählte Modell in C-Code übersetzt, und konnte so auf dem Akustikmodul mit KI zum Einsatz kommen. Zusätzlich zum Modell, wurde die Vorverarbeitung (siehe Abschnitt 2.8.1) manuell in C-Code repliziert.

2.9 Integrationskonzept und Umsetzung eines dezentralen Leckage-Sensor-Systems mit integriertem Modell maschinellen Lernens

Mit dem Ziel einen modularen Aufbau und somit eine hohe Flexibilität im Forschungsprojekt vorzuhalten, wurde das Leckage-Sensor-System in ein Hauptmodul und angebundene Sensoren aufgeteilt (vgl. Abbildung 21). Im Hauptmodul kommt ein leistungsfähiger Prozessor der STM32 Familie für die Ausführung des trainierten Modells und folglich zur Regression der Leckage zum Einsatz. Das H723-Nucleo Board stellt hierfür folgende Eigenschaften bereit:

- Inferenz auf dem Mikrocontroller (X-CUBE-AI) H743-XI 1 MB RAM | 2 MB Flash
- Support für Keras and TensorFlow™ Lite
- Sensorik und integrierte Kommunikation in einem Modul




Abbildung 21: Konzeptioneller Aufbau des Retrofit Systems

In Abbildung 22 ist die konstruktive Umsetzung des kompakten Systems dargestellt. Das Ultraschall-Mikrofon mit Anti-Aliasing-Filter (vgl. Abbildung 23) ist in der Nähe der Kolbenstangendichtung platziert. Das Hauptmodul besitzt weiterhin ein Display sowie Taster für den lokalen Abruf von Informationen (bspw. IP-Adresse) und Messwerten. Über die M12-LAN Verbindung wird das System mittels OPC UA in das Automatisierungsnetzwerk eingebunden.




Abbildung 22: Antrieb mit Sensor-System (l.), Explosionsdarstellung des Sensor-Systems (r.)




Abbildung 23: IMP23ABU mit SPI ADC und Anti-Aliasing-Filter mit 80 kHz Grenzfrequenz

2.10 Evaluierung im Demonstrator



Abbildung 24: DSBC-32-100 Antrieb mit dezentraler Intelligenz (l.), Demonstrator mit drei Sensor-Knoten, Leckage-Referenz-Messsystem, Steuerungstechnik (OPC UA) und Webinterface (r.)

Das auf Methoden maschinellen Lernens basierende Leckage-Sensor-System wurde in Form eines Demonstrators evaluiert. Drei Antriebe, die als „Sensor-Knoten“ fungieren, sind steuerungstechnisch an ein Referenz-Leckage-Messsystem angebunden (vgl. Abbildung 24). Über ein Webinterface (vgl. Abbildung 25) kann die Leckage durch den Versorgungsdruck variiert bzw. gesteuert werden. Durch die Initiierung einer Messung wird der Antrieb mehrmals verfahren, um die Dichtungen gängig zu machen und anschließend im eingefahrenen Zustand unter Druck gehalten.



Abbildung 25: Webinterface zur Initiierung einer Messung mit geregeltm Druck, Darstellung der Referenz- und Inferenz-Leckage-Werte

Die sich ausbildende Leckage wird gleichzeitig durch eine Inferenz im Hauptmodul sowie durch das Referenz-Leckage-Messsystem ermittelt. Beide Werte, prognostizierte und die gemessene Leckage, werden im Webinterface der SPS in einem x-y-Diagramm dargestellt. In Abbildung 26 (r.) sind die am PC ermittelten Ergebnisse des Modells dargestellt. Im linken Teil der Abbildung sind die Ergebnisse der drei Sensorknoten des Demonstrators abgebildet. Das Modell zeigt eine ausreichend gute Vorhersage, die auch für die Bewertung einer fortschreitenden Leckage herangezogen werden kann.

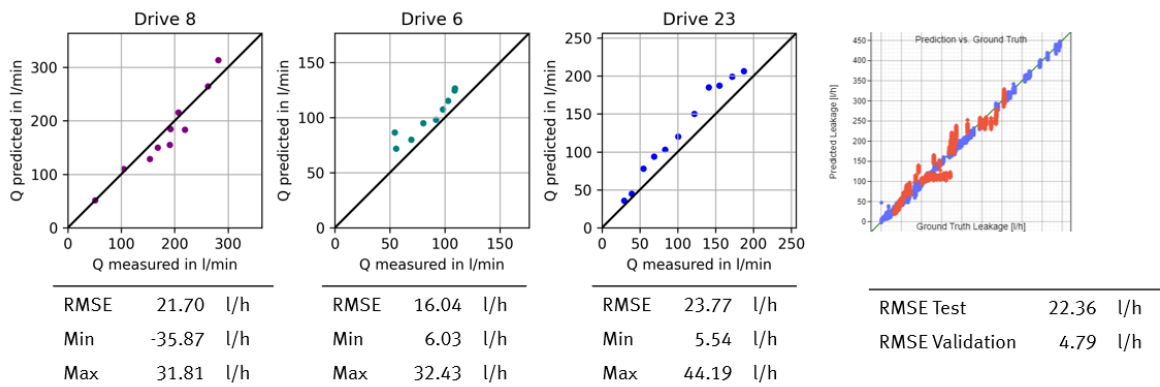


Abbildung 26: Vergleich der Ergebnisse der Sensorknoten (l.) mit den PC-seitig ermittelten Ergebnissen (r.), Antrieb 23 ist dem Modell nicht bekannt.

2.11 Fazit und Ausblick

Die erarbeiteten Ergebnisse tragen insgesamt zu einer Weiterentwicklung des Einsatzes von KI-basierten Methoden in Komponenten bei. Die Miniaturisierung von Systemen und deren Integrationsfähigkeit steigt somit weiter an und neue Lösungsräume für Produkte in der Automatisierungstechnik können dadurch erschlossen werden. Es konnte gezeigt werden, dass Modelle maschinellen Lernens dezentral in Komponenten erfolgreich eingesetzt werden können und eine akustische Leckage-Erkennung und Prognose möglich ist. In weiterführenden Arbeiten muss die Robustheit gegenüber akustischen Störeinschlüssen aus der Umgebung erhöht werden. Der Einsatz von vibrationsbasierten Sensoren zeigt für diesen Anwendungsfall eine insgesamt zu geringe Empfindlichkeit.

Künftige KI-basierte Lösungen werden insbesondere von einer anwendungsspezifischen und vor allem breiten Datenbasis, der Weiterentwicklung von Algorithmen und dedizierter Hardware profitieren. Letztere wird im Nachgang des Projekts in Form eines energieeffizienten ASICs von der Infineon AG bereitgestellt. Vor dem Hintergrund der Leckagedetektion und damit der Verarbeitung hochfrequenter Daten soll der ASIC evaluiert werden.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel KI-MUSIK4.0 - Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0	
4. Autor(en) [Name(n), Vorname(n)] Dr. Saller, Stefan Spies, Daniel	5. Abschlussdatum des Vorhabens 31.12.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation
8. Durchführende Institution(en) (Name, Adresse) Festo SE & Co. KG Ruiter Str. 82 73734 Esslingen am Neckar	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 16ME0068
	11. Seitenzahl 21
12. Fördernde Institution (Name, Adresse) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. Literaturangaben 3
	14. Tabellen 1
	15. Abbildungen 26
16. Zusätzliche Angaben keine	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung Im Rahmen des Förderprojekts wurden KI-basierte Methoden erforscht, die sich energiesparend und effizient, v.a. aber dezentral auf Mikrocontrollern bzw. ASICs ausführen lassen, um den Zustand pneumatischer Antriebe im Anlagenumfeld zu beurteilen. Ein wesentliches Ziel des Projekts ist es, die Leckage pneumatischer Antriebe, die durch Schädigungen an der Kolbenstangendichtung auftreten kann, durch eine hochfrequente Abtastung (200 kHz) des Luftschalls komponententennah aufzunehmen, zu verarbeiten und entsprechend zu interpretieren. Hierdurch können Produktionsprozesse vorausschauend beurteilt werden und die Stabilität aufrechterhalten werden. Zur Erreichung der Ziele wurde zunächst ein breiter Datenpool für das Training des maschinellen Lernens generiert. Hierzu wurden mangels vorliegender defekter Komponenten, die Kolbenstangendichtungen pneumatischer Antriebe gezielt manipuliert, um ein breites und repräsentatives Feld an Daten für das Training des maschinellen Lernens bereitzustellen. Durch das Feature-Engineering sowie Parametervariationen wurden Modelle Maschinellen Lernens neben Ihrer Vorhersagegenauigkeit auch hinsichtlich ihrer Größe und Portierbarkeit auf einen Mikrocontroller optimiert. Der final entstandene Demonstrator erfüllt in Form einer kompakten Sensor-Einheit die gestellten Anforderungen an Nachrüstbarkeit, Recheneffizienz und Kommunikation. Durch das implementierte Modell konnte gezeigt werden, dass Leckagen an pneumatischen Antrieben hochfrequent gemessen und beurteilt werden können. Die Daten können durch einen integrierten OPC UA-Server im dezentral agierenden kompakten Sensor-System im Sinne von Industrie 4.0 an angebundene Steuerungen, EDGE-Rechner aber auch an übergeordnete Systeme übermittelt werden.	
19. Schlagwörter Leckage, Automatisierungstechnik, pneumatische Antriebe, Maschinelles Lernen, KI, Feature-Engineering, Industrie 4.0, OPC UA	
20. Verlag	21. Preis

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Report
3. title KI-MUSIK4.0 - Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0	
4. author(s) (family name, first name(s)) Dr. Saller, Stefan Spies, Daniel	5. end of project 31.12.2024
	6. publication date
	7. form of publication
8. performing organization(s) (name, address) Festo SE & Co. KG Ruiter Str. 82 73734 Esslingen am Neckar	9. originator's report no.
	10. reference no. 16ME0068
	11. no. of pages 21
12. sponsoring agency (name, address) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. no. of references 3
	14. no. of tables 1
	15. no. of figures 26
16. supplementary notes none	
17. presented at (title, place, date)	
18. abstract As part of the funded project, AI-based methods were researched that can be executed in an energy-saving and efficient, but above all decentralized manner on microcontrollers or ASICs in order to assess the condition of pneumatic drives in the automation environment. A key aim of the project is to record, process and interpret the leakage of pneumatic drives, which can occur due to damage to the piston rod seal, by means of high-frequency sampling (200 kHz) of the airborne sound close to the component. This allows production processes to be assessed in advance and stability to be maintained. To achieve the objectives, a broad data pool was first generated for training machine learning. In the absence of defective components, the piston rod seals of pneumatic drives were specifically manipulated in order to provide a broad and representative field of data for machine learning training. Through feature engineering and parameter variations, machine learning models were optimized in terms of their size and portability to a microcontroller in addition to their prediction accuracy. The final demonstrator, in the form of a compact sensor unit, meets the requirements for retrofittability, computing efficiency and communication. The implemented model was able to show that leakages on pneumatic drives can be measured and assessed at high frequency. The data can be transmitted to connected controllers, EDGE computers and also to higher-level systems via an integrated OPC UA server in the decentralized compact sensor system in line with Industry 4.0.	
19. keywords Leakage, automation, pneumatic drives, machine learning, AI, feature engineering, Industry 4.0, OPC UA	
20. publisher	21. price