

Sachbericht zum Verwendungsnachweis

Teil 1 – Kurzbericht

Vorhabenbezeichnung AI4CSM - Automotive Intelligence for/at Connected Shared Mobility Teilvorhaben: KI-basierte Fehlererkennung, -analyse und -minderung für den Antriebsstrang	
Zuwendungsempfänger Fraunhofer IISB, Erlangen	Förderkennzeichen 16MEE0168
Projektleiter Dr.-Ing. Martin Schellenberger	Laufzeit 07.2021 - 04.2024

1. Ursprüngliche Aufgabenstellung

Das Fraunhofer IISB forscht an neuen Hardware- und KI-basierten Steuerungskonzepten für die intelligente elektrische Antriebstechnik (Umrichter und E-Motoren) und für kognitive Batteriesysteme. Ein Projektziel war die Erarbeitung eines datenbasierten, sensorarmen Konzepts zur kostengünstigen Zustandsüberwachung elektrischer Antriebe, mit dem die Effizienz der Wartung von elektrischen Antrieben verbessert und unnötige Reparatur- und Austauscharbeiten vermieden werden. Ein anderes Projektziel war die Verknüpfung von präzisen und schnellen Algorithmen zur Anomalieerkennung mit a-priori Wissen über das Batteriesystem, um die Sicherheit von Batteriesystemen zu erhöhen und potenziell gefährliche Betriebszustände sicher zu erkennen. Mit der eigenen Entwicklungsplattform für Batteriemanagementsysteme „foxBMS“ brachte das Fraunhofer IISB eine Systemplattform in das Projekt mit ein, mit der die neuen Algorithmen zur Anomalieerkennung in Batteriesystemen auf einer Embedded-Plattform demonstriert und validiert werden konnten.

2. Ablauf des Vorhabens

Zustandsüberwachung elektrischer Antriebe:

- Ursprünglich sollte die Degradation der Wicklungsisolierung untersucht werden. Nach ausführlicher Literaturrecherche stellte sich die Machbarkeit aufgrund erheblichen Messtechnikaufwands als nicht realistisch dar. In Abstimmung mit Projektpartnern wurde in der Folge der Fokus auf Demagnetisierungsschäden als relevanten Schadensfall gelegt.
- Es wurden Experimente an Drohnenmotoren durchgeführt, in denen künstlich Demagnetisierungsschäden unterschiedlicher Stärke eingebracht wurden. Diese Datenerhebung wurde durch die Simulation von Demagnetisierungsschäden ergänzt.

- Hervorzuheben ist die gute Übereinstimmung von Experimenten und Simulation, die auch zu neuen Erkenntnisgewinnen z.B. hinsichtlich des nichtlinearen Zusammenhangs zwischen Schadensausmaß und der Total Harmonic Distortion (THD) führte.
- Schließlich wurden erfolgreich Algorithmen zur Erkennung von Demagnetisierungsschäden entwickelt und evaluiert, die nur auf den im Umrichter erfassten Motorströmen basieren und so keine zusätzliche Sensorik zur Schadenserkenung benötigen.

Anomalieerkennung im Batteriesystem:

- Nach der Konzeption und Spezifikation der Algorithmen zur Anomalieerkennung von Temperatursensoren wurden an einem Teststand experimentelle Untersuchungen zur Bestimmung von Temperatureinflüssen durch typische Defekte von Temperatursensoren in Batteriesystemen durchgeführt.
- Algorithmen zur Anomalieerkennung von Temperatursensoren wurden anhand der am Teststand gewonnenen Daten entwickelt und mit historischen Datensätzen eines Testfahrzeugs des Fraunhofer IISB optimiert.
- Schließlich wurden die Algorithmen für die Integration in das Batterie-Managementsystem angepasst und erfolgreich validiert.

3. Wesentliche Ergebnisse

Zustandsüberwachung elektrischer Antriebe:

- FEM-Simulation: Nichtlinearer Zusammenhang zwischen THD und Schadensausmaß bei Demagnetisierungsschäden wurde für die verwendete Motorklasse festgestellt.
- Algorithmenentwicklung: Die Erkennung von Demagnetisierungsschäden mit unterschiedlichen Schadensausmaßen konnte sowohl mit zusätzlicher Sensorik also auch mit den bereits vorhandenen Stromsensoren im Umrichter nachgewiesen werden und in trainierten und validierten Modellen in eine ETL-Pipeline integriert werden.
- Der Nachweis wurde erbracht, dass die Erkenntnisse aus der Simulation mit den Schadensausmaßen aus den Versuchen übereinstimmen.

Anomalieerkennung im Batteriesystem:

- Es wurde erfolgreich ein neues Verfahren zur Anomalieerkennung von Temperatursensoren in Batteriesystemen entwickelt, in ein Batterie-Managementsystem integriert, verifiziert und validiert. Das Verfahren zur Anomalieerkennung ist dabei auf andere Anwendungen übertragbar, in denen Anomalien innerhalb eines Ensembles von Sensoren vorliegen können.
- Ein Edge-Device als Erweiterung des Batterie-Managementsystems wurde mit einer hierfür entwickelten Abschalt- und Startvorrichtung in das Testfahrzeug des Fraunhofer IISB integriert. Software zur Datenvorverarbeitung und eventbasierten Ausführung der Anomalieerkennung wurde entwickelt und unter realen Bedingungen erfolgreich getestet.

Sachbericht zum Verwendungsnachweis

Teil 2 – Eingehende Darstellung

Vorhabenbezeichnung: AI4CSM - Automotive Intelligence for/at Connected Shared Mobility Teilvorhaben: KI-basierte Fehlererkennung, -analyse und -minderung für den Antriebsstrang	
Zuwendungsempfänger: Fraunhofer IISB, Erlangen	Förderkennzeichen 16MEE0168
Projektleiter Dr.-Ing. Martin Schellenberger	Laufzeit 07.2021 - 04.2024

1. Durchgeführte Arbeiten und erzielte Ergebnisse des Teilvorhabens

Die Arbeiten und Ergebnisse sind im Folgenden entlang der technischen Arbeitspakete 1-6 des Projekts dargestellt (das Fraunhofer IISB war nicht am Arbeitspaket 3 beteiligt), und jeweils nach den beiden Projektzielen gegliedert:

1. Sensorarme Zustandsüberwachung elektrischer Antriebe
2. Anomalieerkennung in Batteriesystemen

Arbeitspaket 1: Anforderungen und Spezifikationen

Ad 1: Die Spezifikation für die intelligente Diagnose einer Demagnetisierung der Dauermagneten im elektrischen Antrieb wurde festgelegt. Anforderungen für eine Erweiterung eines FEM-Simulationsmodells wurden erstellt, um diesen Fehler analysieren und bewerten zu können.

Ad 2: Die Spezifikation zur Detektion von sicherheitsrelevanten Anomalien im Temperaturprofile eines Batteriesystems wurde festgelegt, ebenso die Spezifikation der Software- und Hardwarekomponenten für die Entwicklung auf Cloud- und Implementierung auf Edge-Ebene. Ziel der zu realisierenden Anomaliedetektion war, Temperaturabweichungen, die durch Sensorfehler induziert werden, bzw. die Fehlerhaftigkeit des Temperatursensors zu identifizieren.

Arbeitspaket 2: Design auf Systemebene

Ad 1: Das Design der ETL-Pipeline für die Erkennung von Demagnetisierungen wurde erstellt und besteht aus folgenden Schritten, die chronologisch abgearbeitet werden. Im ersten Schritt erfolgt nach der initialen Datenbeschaffung die Aufzeichnung des Stromsignals über die zuvor festgelegte Dauer. Die erfassten Daten werden anschließend in einer SQLite-Datenbank auf dem Edge-Gerät gespeichert, um die Nachverfolgbarkeit zu gewährleisten. Im nächsten Pipeline-Schritt wird für jede der gemessenen Stromphasen die Fast Fourier-Transformation (FFT) berechnet, der Mittelwert ermittelt und das resultierende Spektrum normiert. Auch diese Daten

werden in der zuvor beschriebenen Datenbank abgelegt. Im abschließenden Vorhersageschritt kommt das vortrainierte Modell der Kernel Principal Component Analysis (kPCA), das zur Dimensionsreduktion dient, sowie der Anomalieerkennungsalgorithmus der One Class Support Vector Machine (OC-SVM) zum Einsatz, um auf Basis des vorverarbeiteten FFT-Spektrums Vorhersagen zu treffen. Diese Vorhersagen liefern Informationen darüber, ob eine Anomalie, in diesem Fall eine Demagnetisierung, vorliegt. Auch diese Prognosen werden in der Datenbank vermerkt, um eine eindeutige Nachverfolgbarkeit zu gewährleisten. Somit zeigt das Ergebnis der Pipeline an, ob der Motor weiterhin sicher und fehlerfrei betrieben werden kann.

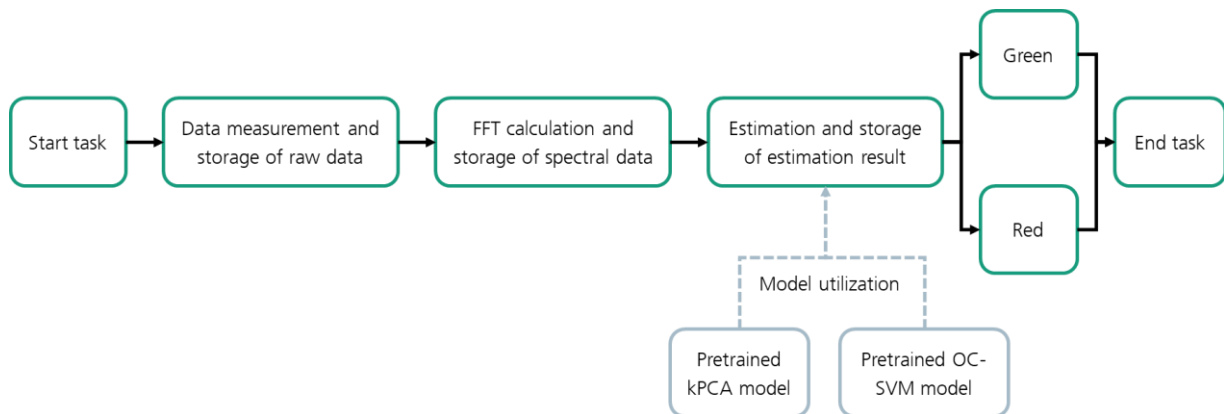


Abbildung 1: ETL-Pipeline zur Erkennung von Demagnetisierungsfehlern in elektrischen Antrieben

Ad 2: Eine Architekturanalyse auf Basis des Inputs des Partners MBAG wurde erstellt. Ein Edge-Device (MOXA MC-1121-E2-T) wurde in einem Systemkonzept als Erweiterung des eigenen foxBMS festgelegt, um den entwickelten intelligenten Algorithmen eine Plattform mit genügen Reichenleistung zu bieten. Entsprechend wurde ein Konzept für die Datenvorverarbeitung der Batteriedaten, sowie deren Speicherung auf dem Edge-Device entwickelt. Das Konzept der Diagnosealgorithmen, welche eine Abweichung zwischen gemessenen und realen Temperaturen im Batteriesystem detektieren sollen, wurde erstellt. Use-Case Szenarien für die Entwicklung und Implementierung von Algorithmen zur Detektion von Sensorfehlern bei der Temperaturüberwachung im Batteriesystem wurden erarbeitet. Aufbauend auf den Use-Case Szenarien wurde ein Versuchsaufbau mit einem Batteriemodule des Fraunhofer IISB Testfahrzeuges umgesetzt, in welchem Temperatursensoranomalien eingebracht werden können, um entsprechende Trainingsdaten für die intelligenten Algorithmen zu generieren. An verschiedenen Positionen auf den Stromschienen des Batteriemoduls wurde jeweils Pärchen aus NTC-Widerständen aufgebracht. NTC-Widerstände besitzen einen definierten temperaturabhängigen elektrischen Widerstand, welcher genutzt werden kann, um die Temperatur des NTCs und der Bauteile im thermischen Kontakt mit dem NTC zu ermitteln. Dementsprechend besteht das oben genannte Pärchen aus einem NTC mit gutem thermischem Kontakt zur Stromschiene und einem NTC mit einer Anomalie hinsichtlich seines thermischen Kontaktes zur Stromschiene. Exemplarisch wird in Abbildung 2 ein Pärchen gezeigt, bei welchem der „gute“ NTC (Nummer 1) durch eine aufgebrachte Wärmeleitpaste einen guten thermischen Kontakt zu der darunter liegenden Stromschiene besitzt.




Abbildung 2: Beispiel eines NTC-Pärchens mit 1 als „guter“ Temperatursensor und 2 als „manipulierten“ Temperatursensor

Die Anomalie des „manipulierten“ NTCs (Nummer 2) zeichnet sich dadurch aus, dass dieser nur einen „losen“ Kontakt mit leichter Anpressdruck durch die rechts anliegende Wärmeleitpaste zu der Stromschiene besitzt. Die im Batteriemodul eingebrachten Temperatursensoranomalien reichen von schlecht gemischter Wärmeleitpaste bis hin zu „losen“ NTCs mit einem variierenden Anpressdruck. Für das Training werden nun jeweils die Werte der „guten“ NTCs als Referenzwert genommen und zum Testen einige Referenzwerte durch Werte der „manipulierten“ NTCs ersetzt.

Arbeitspaket 4: Eingebettete Systeme und Berechnungsalgorithmen

Ad 1: Verschiedene Demagnetisierungszustände eines Motors wurden simuliert (Abbildung 3) und mit Hilfe von Datenanalysen ausgewertet und interpretiert. Dabei wurden unterschiedliche Ausmaße von partiellen Demagnetisierungsschäden untersucht und ein Motordesign-abhängiger, nichtlinearer Zusammenhang zwischen der Total Harmonic Distortion (THD) der elektrischen Größen und dem Grad der Demagnetisierung festgestellt (Abbildung 4). Hierbei ist das vorliegende Schadensbild von entscheidender Bedeutung: Bei partieller Demagnetisierung sind nur einzelne Magneten betroffen, wodurch eine Asymmetrie im magnetischen Kreis und damit ein erhöhter Oberwellengehalt entsteht (Abbildung 4, CD-SM). Wohingegen bei einer gleichmäßigen Demagnetisierung alle Magneten geschwächt sind, sodass anhängig von der Magnetgeometrie der THD sinkt (Abbildung 4, MD-AM).

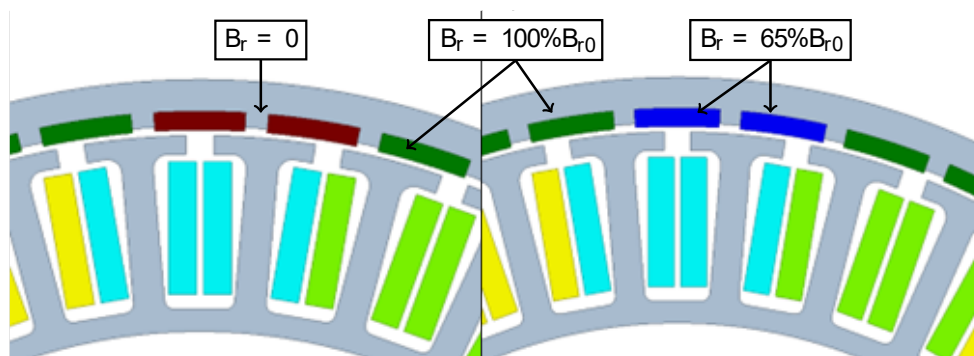


Abbildung 3: Modellierung verschiedener Demagnetisierungsschäden in FEM.

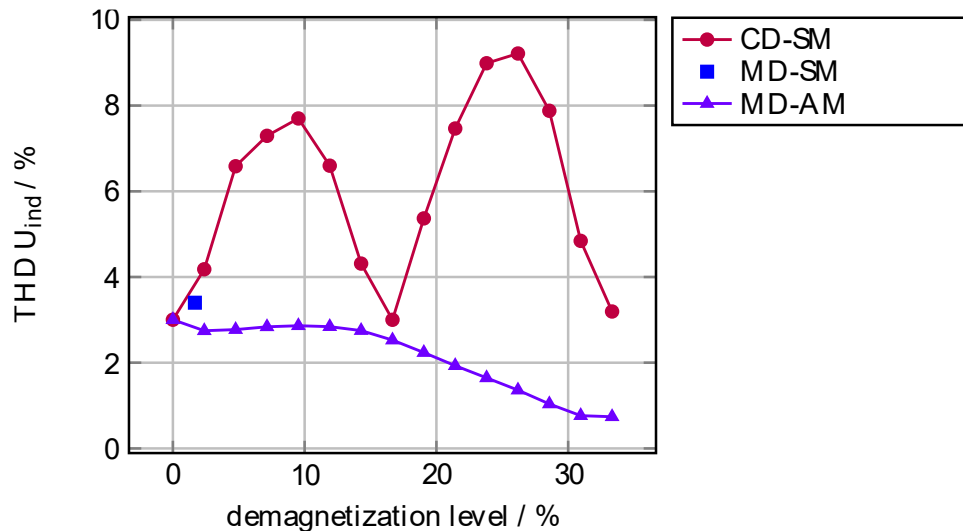


Abbildung 4. THD der induzierten Spannung für verschiedene Grade von Demagnetisierung: einzelne Magnete vollständig demagnetisiert (CD-SM), einzelne Magnete teilweise demagnetisiert (MD-SM), alle Magneten gleichmäßig teilweise demagnetisiert (MD-AM).

Um die Ergebnisse der elektromagnetischen Simulationen zu validieren und weitere Einflüsse auf elektrische Antriebe während der Entmagnetisierung zu erkennen, wurde ein Aufbau im Labor erstellt. Die dreiphasigen Motoren werden von einem Motorcontroller mit einer 24 V, 3 A Stromversorgung betrieben. Die Motorströme wurden dabei mit drei Strommesszangen gemessen (initiale Untersuchung) bzw. aus dem Umrichter ausgelesen (erweiterte Untersuchung). Eine Detailbeschreibung der verwendeten Messtechnik erfolgt im Weiteren. Die Motoren, die bei einer konstanten Drehzahl von 900 U/min betrieben wurden, wurden mit vorgegebenem Drehmoment am Drohnenarm montiert, ebenso der Propeller. Der Testaufbau für das Auslesen der Daten aus dem Umrichter ist in Abbildung 5 dargestellt.




Abbildung 5: Testaufbau der künstlich geschädigten Motoren inkl. Extraktion der Stromsignale aus dem Leistungsteil

Im initialen Versuchsaufbau wurden die Motorströme mit drei Stromzangen gemessen und diese an ein digitales Oszilloskop angeschlossen. Das dreiphasige Stromsignal wurde für 220 s mit einer Abtastrate von 30 kHz und einer Auflösung von 12 Bit aufgezeichnet. Die untersuchten Drohnenmotoren verfügen über 21 Polpaare. Neben drei unbeschädigten Motoren (M1-M3) wurden bei zwei weiteren Motoren Schäden künstlich erzeugt, indem zwei (M4) bzw.

sieben Magnete (M5) pro Motor entnommen, durch hohe Wärme entmagnetisiert und wieder eingebaut wurden, was zu einer Gesamt-Demagnetisierung von 4,8 % bzw. 16,7 % führte. Für eine statistische Aussagekraft wurden pro Motor drei unabhängige Messungen durchgeführt. Die Motoren wurden vor jeder Messung an einer Drohnenarm-Replik montiert und nach der Messung wieder demontiert. Aus den Messungen wurden Samples mit einer festen Frame-länge von 2^{14} Datenpunkten extrahiert und die gemittelten sowie normierten FFT-Spektren berechnet. Diese sind in Abbildung 6 dargestellt.

Im Niederfrequenzbereich bis zur dritten Harmonischen (ca. 950 Hz), wo die leistungsstärksten Harmonischen zu finden sind, wird bereits deutlich, dass sich die Amplituden der beschädigten Motoren erheblich von den gesunden Motoren unterscheiden. Dies zeigt sich besonders in den Frequenzen, die für Demagnetisationsschäden entscheidend sind und mittels physikalischer Formeln berechnet werden können. Zusätzlich zu dem oben genannten Fakt haben auch andere Einschränkungen bei hohen Frequenzen Einfluss auf die Interpretierbarkeit. Neben der Vervielfachung der spektralen Streuung, den frequenzbasierten Inverter-Frequenzen und der hohen Rauschkomponente nimmt die Bedeutung der Demagnetisationsharmonischen bei höheren Frequenzen ab. Eine weitere Betrachtung der FFT zeigt zudem, dass die Amplituden des weniger beschädigten Motors M4 stärkere Ausprägungen haben als die des stärker beschädigten Motors M5. Diese Erkenntnis bestätigt die bereits beschriebenen Untersuchungen aus der simulativen Betrachtung der Motoren. Insgesamt kann aus dem FFT-Signal abgeleitet werden, dass es möglich ist, zwischen schadensfreien Motoren und Motoren mit Demagnetisationsschäden im Frequenzbereich zu unterscheiden.

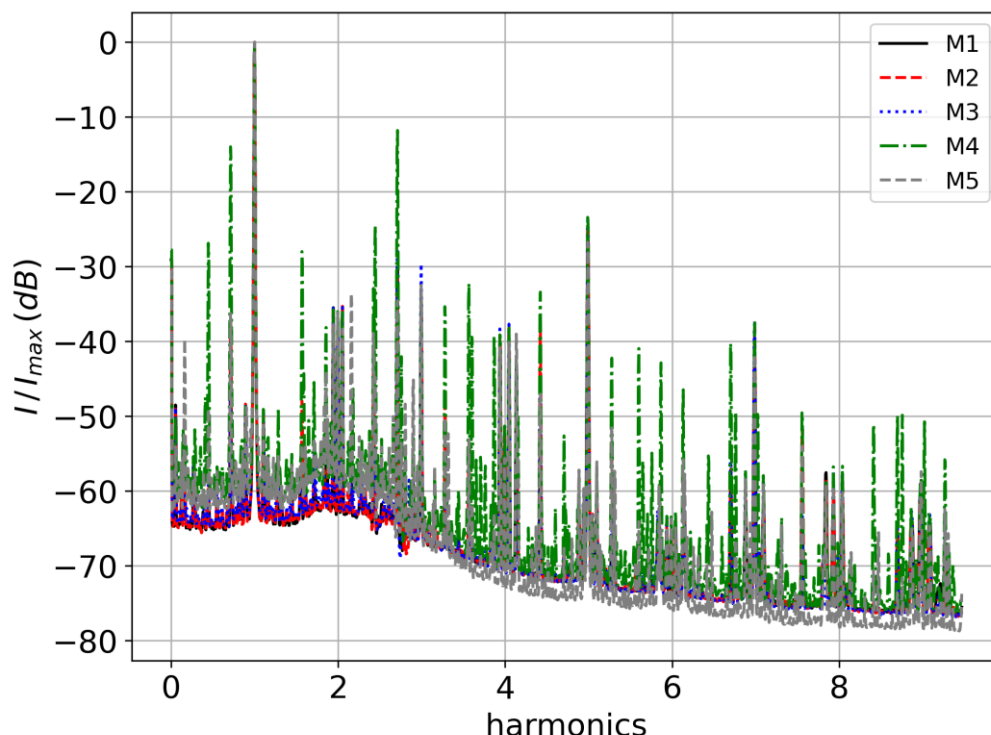


Abbildung 6: Gemitteltes und normiertes FFT-Spektrum der gemessenen Motorströme mit Strommesszangen

Die transformierten Spektren wurden folgendermaßen weiterverarbeitet: Zuerst wurden die Hauptkomponenten mittels kPCA basierend auf zwei schadensfreien Motoren berechnet. Anschließend erfolgte das Training einer One-Class Support Vector Machine (OC-SVM) auf Basis der Hauptkomponenten der beiden schadensfreien Motoren mit zusätzlich generierten

Pseudoanomalien. Somit standen für die Validierung der trainierten Modelle ein schadensfreier und die zwei beschriebenen geschädigten Motoren zur Verfügung.

Nach der Erkennung von Demagnetisierungsschäden mittels zusätzlicher Sensorik (Strommesszangen mit Oszilloskop) lag der Fokus in den weiteren Untersuchungen auf der Analyse von Stromdaten, die aufgrund der bereits vorhandenen Sensorik direkt aus dem Umrichter ausgelesen werden können. Durch diesen Schritt können in praktischen Anwendungen Kosten für zusätzliche Sensortechnik sowie Bauraum gespart werden. Der grundlegende Versuchsaufbau hat sich dahingehend geändert, dass das digitale Oszilloskop und die drei Strommesszangen durch einen J-Link ersetzt wurden. Dieser fungiert als Übertragungswerkzeug für die Daten von der Motorsteuerungseinheit zum Edge-Gerät. Das Gerät liest ein zweiphasiges Stromsignal sowie Informationen über die Zeitpunkte der Messpunkte in Binärdaten mit einer Abtastfrequenz, die der Frequenz der Stromregelung entspricht, aus dem Umrichter aus. Darüber hinaus wurde die Anzahl sowie die Art der geschädigten Motoren ergänzt. Bei den beschädigten Motoren wurde zwischen zwei Arten von Fehlern und dem Schweregrad der beschädigten Magnete unterschieden. Eine Übersicht zu den neuen Notationen und den untersuchten Motoren findet sich in Tabelle 1.

Tabelle 1: Übersicht der Motoren für die erweiterten Untersuchungen

Motor	Demagnetisierte Magneten	Schadensausmaß	Gesamt-Demagnetisierung
H1	0	-	0 %
H2	0	-	0 %
H3	0	-	0 %
CD1	2	Complete demagnetization	4.8 %
CD2	7	Complete demagnetization	16.7 %
MD1	2	Moderate demagnetization	~1.67 %
MD2	2	Moderate demagnetization	~1.67 %

Die Pipeline für die Anomalieerkennung wurde grundsätzlich beibehalten, da diese bereits in den Vorversuchen gute Ergebnisse erzielen konnte. Jedoch wurden im Rahmen dieser erweiterten Untersuchungen verschiedene Ansätze untersucht, um die Detektierbarkeit der Schäden mit geringem Schadensausmaß (MD1, MD2) zu verbessern. Hierbei wurde die Bandbreite des Spektrums beschnitten (bis zur 5., 7. und 11. Harmonischen) oder der Fokus auf bestimmte demagnetisierungstypische Schadensfrequenzen gelegt, die mittels physikalischer Formeln berechnet werden können. Der erfolgversprechendste Ansatz besteht in der Extrahierung aller für die Demagnetisierung typischen Frequenzen mit einer Beschränkung bis zur 11. Harmonischen. Die gemittelten und normierten Spektren mit eingezeichneten Limitierungen sind in Abbildung 7 visualisiert.

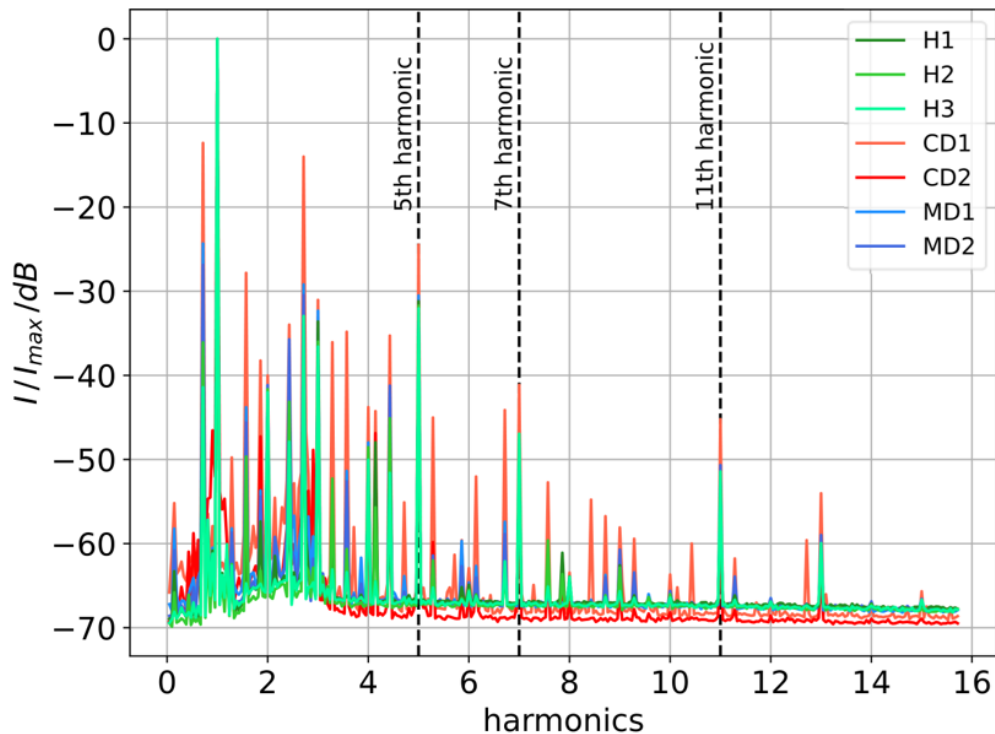


Abbildung 7: Gemittelt und normiertes FFT-Spektrum der aus dem Umrichter ausgelesenen Motorströme

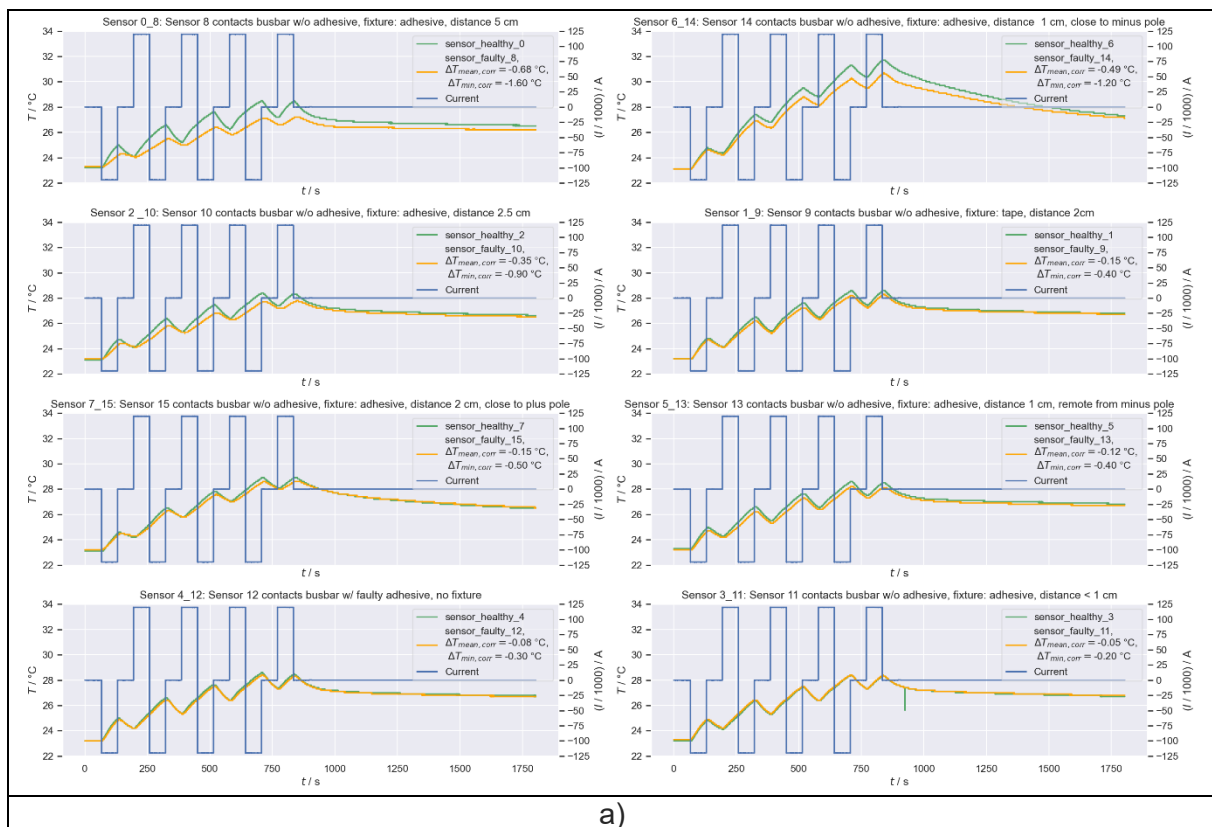
Die Weiterverarbeitung der Spektren ist identisch mit dem Vorgehen aus der ersten Untersuchung: Zunächst wurden die wesentlichen Merkmale mithilfe der kPCA aus den Daten von zwei gesunden Motoren extrahiert. Anschließend wurde ein OC-SVM Modell trainiert, das diese Hauptmerkmale der beiden schadensfreien Motoren zusammen mit künstlich erzeugten Pseudoanomalien nutzte. Für die Validierung der trainierten Modelle standen somit ein intakter Motor und die vier defekten Motoren zur Verfügung.

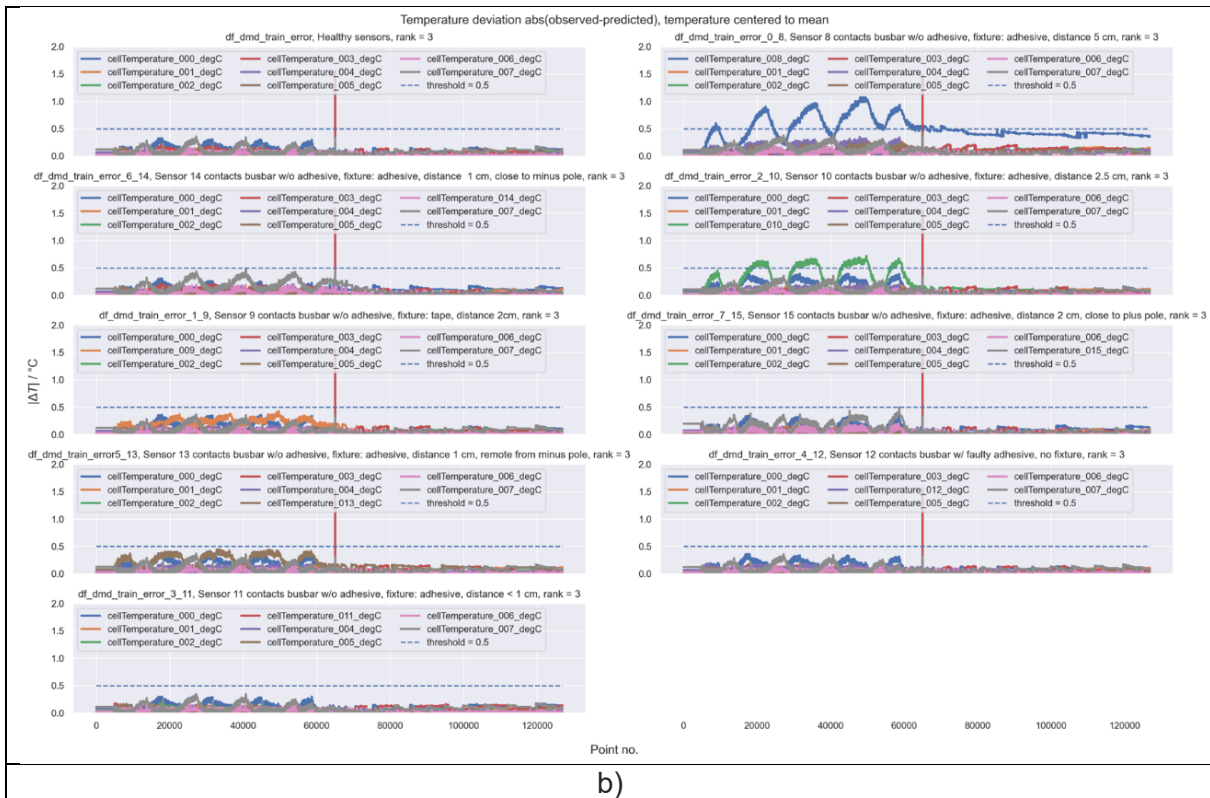
Ad 2: Eine ETL-Pipeline zur Verarbeitung von anwendungsnahen BMS-Daten wurde implementiert. Ein experimenteller Teststand (basierend auf einem Batteriemodul des Fraunhofer IISB Demonstratorfahrzeugs) für die Untersuchung von Temperaturabweichungen wurde aufgebaut. Alle in der Spezifikation festgelegten Temperatursensoranomalien wurden mit anwendungsnahen Leistungsprofilen charakterisiert.

Es wurden Algorithmen für die Detektion von Sensorfehlern bei der Temperaturüberwachung entwickelt, untersucht und im Hinblick auf Genauigkeit und Integrierbarkeit in das Batteriemanagementsystem bewertet. Ein Verfahren basierend auf Dynamic Mode Decomposition (DMD) wurde anstelle eines Deep-Learning Verfahrens auf Basis von Temporal Convolutional Networks (TCN) aufgrund besserer Genauigkeit und Integrierbarkeit ausgewählt. Die Algorithmen wurden dabei anhand der Daten des experimentellen Teststands und eines historischen Datensatzes (erzeugt über drei Jahre am Testfahrzeug des Fraunhofer IISB) untersucht.

Anhand der Daten, die an dem experimentellen Teststand gewonnen wurden, wurde der Basisalgorithmus zur Anomalieerkennung eines defekten Temperatursensors unter Nutzung der DMD entwickelt. Weiterhin wurde abgeschätzt, welche der mit unterschiedlicher Schwere eingebrachten Anomalien noch erkannt werden können. Hierbei hatten in allen Fällen der Temperatursensor noch Kontakt mit der Stromschiene der Batterie, und ein loser Sensor ohne

Kontakt zur Stromschiene wurde nicht betrachtet. Abbildung 8 a) zeigt die Versuchsdurchführung zur Untersuchung der Temperaturabweichung von intakten und defekten Temperatursensoren für verschiedene Fehlerfälle durch gepulstes Laden, Entladen und einem Ruhezustand eines Batteriemoduls. Bei dem Verfahren zur Anomaliedetektion wird zunächst mittels DMD ein Modell zur zeitreihenbasierten Vorhersage der auf den Mittelwert im jeweiligen Zeitschritt zentrierten Temperaturwerte in einem Ensemble mehrerer intakter Temperatursensoren erstellt. Ein defekter Sensor führt zu einer geänderten gemessenen Temperatur gegenüber der Vorhersage für die intakten Sensoren, so dass durch einen Vergleich der gemessenen und der vorhergesagten Temperaturen der Defekt eines Sensors erkannt werden kann. Hierzu ist bei der Erstellung des DMD-Vorhersagemodells der Rang der Zerlegung anzupassen. Bei zu hohem Rang werden die Temperaturen auch für defekte Sensoren nahezu richtig, dem Messwert entsprechend vorhergesagt. Bei niedrigem Rang werden die Vorhersagen für alle Sensoren ungenau, so dass der defekte Sensor nicht mehr unterschieden werden kann. Abbildung 8 b) zeigt, dass für den Aufbau mit einem optimierten DMD-Modell mit Rang 3 defekte Temperatursensoren erkannt werden können, die zu einer absoluten Abweichung der Vorhersage von mehr als $0.5\text{ }^{\circ}\text{C}$ führen, welche einer realen Temperaturabweichung von ca. -0.8°C durch die fehlerhafte Messung eines defekten Sensors entspricht.

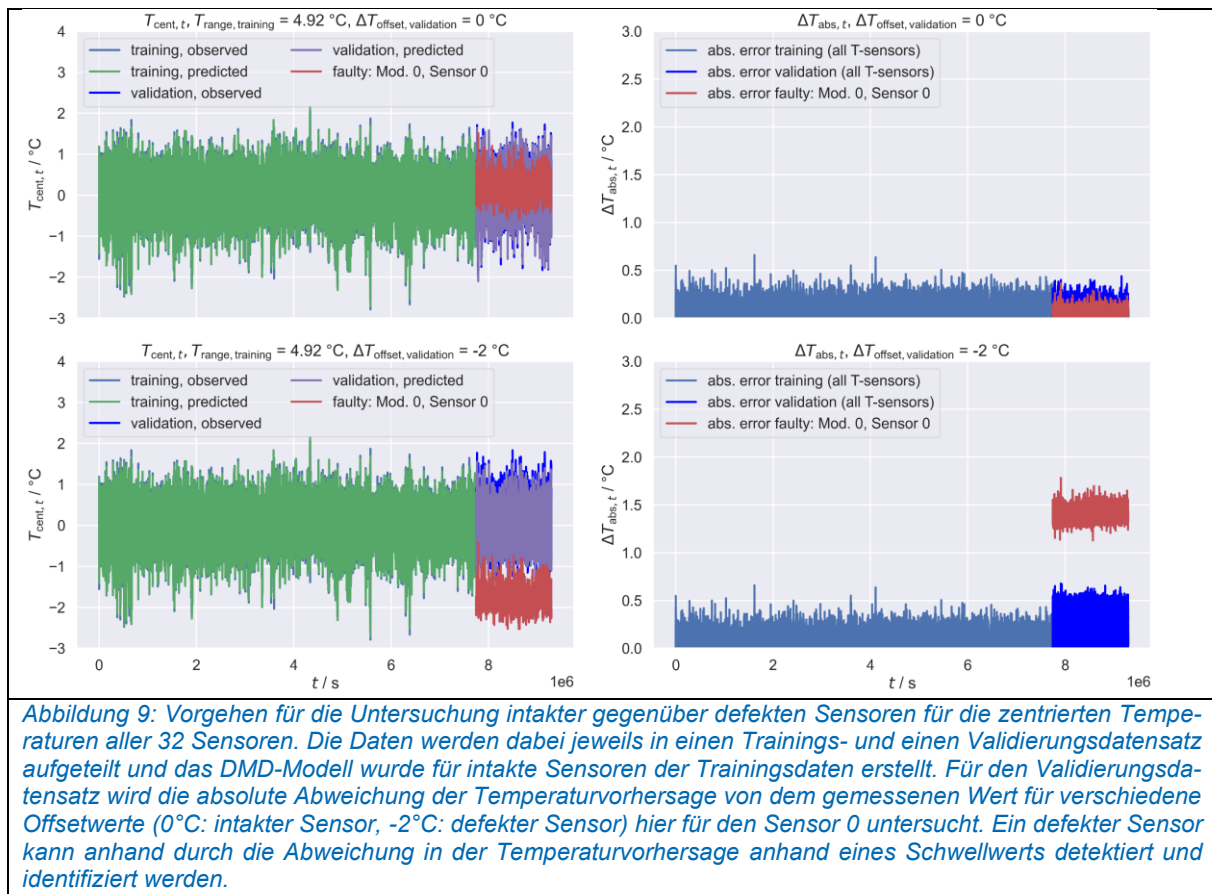




b)

Abbildung 8: Untersuchung der Temperaturabweichung von intakten und defekten Temperatursensoren für verschiedene Fehlerfälle durch gepulstes Laden, Entladen und einem Ruhezustand eines Batteriemoduls a). Absolute Fehler der Vorhersagen der zentrierten Temperaturen für ein DMD-Vorhersagemodell mit Rang 3 für die intakten Sensoren und die Temperaturabweichungen durch die defekten Sensoren b). Die absoluten Fehler für die Vorhersage an den intakten Sensoren liegen unterhalb einer absoluten Temperaturabweichung von 0.5 °C. Die Temperaturabweichung der fehlerhaften Sensoren 9 und 14 überschreiten diesen Schwellwert und können als defekt identifiziert werden.

Die Weiterentwicklung der Vorhersagealgorithmus zielte auf die Anpassung und robuste Auslegung der Algorithmen anhand der im Realbetrieb am Testfahrzeug des Fraunhofer IISB über drei Jahre erfassten Messdaten. Hier wird die Temperatur in der Batterie mit 32 Temperatursensoren erfasst. Da in diesem Testbetrieb keine Anomalien der Temperatursensoren auftraten, wurden Temperaturabweichungen durch defekte Sensoren durch ein Addieren von Offsetwerten untersucht, wobei untersucht wurde, dass jeder Sensor diese Temperaturabweichung aufweisen könnte, d.h. einen defekten Sensor darstellt. Abbildung 9 zeigt das Vorgehen für die Untersuchung intakter gegenüber defekter Sensoren für die zentrierten Temperaturen aller 32 Sensoren. Die Daten wurden dabei jeweils in einen Trainings- und einen Validierungsdatensatz aufgeteilt. Das DMD-Modell wurde für die intakten Sensoren der Trainingsdaten erstellt. Für den Validierungsdatensatz wurde die absolute Abweichung der Temperaturvorhersage von dem gemessenen Wert für verschiedene Offsetwerte untersucht (Abbildung 9, links). Abbildung 9, rechts zeigt die Auswertung für den intakten Sensor 0 (Offset ist 0 °C) und einen angenommenen Offset von -2 °C. Bei diesem Wert ist der Temperaturverlauf noch im Bereich der halben Spanne der Temperaturen, die mit allen Sensoren gemessen werden. Mit dem Algorithmus zur Anomalieerkennung kann die Abweichung der Vorhersage für den defekten Sensor deutlich von den intakten Sensoren abgegrenzt werden. Die Detektionsgrenze von -2 °C ermöglicht dabei eine robuste Erkennung ohne Falsch-Positiv- oder Falsch-Negativwerte und für das Szenario, dass diese Abweichung für alle Sensoren auftreten könnte.



Da die auftretenden Temperaturänderungen durch mögliche Sensorfehler im Realbetrieb unbekannt sind, und die Vorhersagefehler mit steigenden Temperaturabweichungen zunehmen, wurden verschiedene Temperatur-Offsetwerte untersucht und eine Schwellwertverfahren entwickelt, dass eine Identifikation der defekten Sensoren auch bei unbekanntem Temperaturerhöhungen ermöglicht. Mit den hier zusammengefassten Ergebnissen wurde die grundlegende Algorithmenentwicklung und Schwellenableitung abgeschlossen.

In einem nächsten Schritt wurden die Algorithmen von einer recheneffizienten, matrixbasierten Ausführung für die Entwicklung in eine schleifenbasierte Ausführung überführt, welche die Datenübernahme aus dem BMS und die Inferenz in der entwickelten ETL-Pipeline vorbereitet. Auf dem Batteriemanagementsystem foxBMS® werden die Daten sequenziell gesammelt, und der Algorithmus wird in definierten Zeitintervallen ausgeführt, um Alarmsignale zu generieren, wenn ein defekter Temperatursensor erkannt wird. Daher waren im Code zur Echtzeitausführung insbesondere die folgenden Anpassungen notwendig:

1. Aggregation der Daten aus dem foxBMS®, die mit einer durchschnittlichen Abtastrate von ca. 14 ms abgetastet werden, auf eine Probenahme- und Ausführungsintervall von ein bis zwei Sekunden. Dieser Schritt wurde für Code-Validierung anhand der historischen Daten implementiert und getestet, die Funktionalität in der Implementierung aber durch die Azure IOT-Runtime übernommen.
2. Ausführung des Algorithmus im Sekundenbereich, wenn neue Daten verfügbar sind, einschließlich Temperaturvorhersage für die Sensoren für Schritt t aus Daten, die bei $t-1$ aufgezeichnet wurden, Vergleich mit den tatsächlichen Sensortemperaturen bei t und Erzeugung eines Alarmsignals, wenn vordefinierte Schwellenwerte für einen Sensor überschritten werden. Dieser Codeteil wurde als Kernfunktionalität in die Azure IOT-Runtime übernommen.

Der Code wurde gegenüber den bei der matrixbasierten Auswertung erhaltenen Ergebnissen verifiziert und validiert und die benötigte Ausführungszeit ermittelt, die auf einem Laptop-PC in der Größenordnung von 100 ms liegt und ausreichend für eine Analyse im Sekundenbereich ist. Die so optimierten und getesteten Algorithmen standen somit für die weitere Integration in das Fraunhofer IISB Testfahrzeug (Demonstrator 2) bereit.

Auf Grundlage der Microsoft Azure IoT Edge-Runtime wurden Softwarekomponenten für das Edge Device entwickelt, um die Algorithmen zur Detektion von Sensorfehlern ereignisgesteuert ausführen zu können. Softwarekomponenten zur Aufbereitung der foxBMS CAN-Nachrichten, welche die Sensordaten des Batteriesystems enthalten, wurden fertiggestellt. Hierbei handelt es sich um ein CAN-Modul, welches um eine Filterfunktion erweitert wurde, sowie ein angepasstes Upload-Module zur Speicherung der Modellausgabe.

Arbeitspaket 5: Systemintegration

Ad 1: Die Algorithmen zur Demagnetisierungserkennung wurden in einer Inferenz-Pipeline auf ein Edge-Gerät für die lokale Auswertung übertragen. Hierbei wurde der bereits beschriebene experimentelle Testaufbau, der in Abbildung 5 gezeigt ist, herangezogen. Die Steuerung der Motoren erfolgt dabei über eine Motorsteuerungseinheit, wobei die Geschwindigkeit konstant gehalten wird. Die Daten zur Auswertung des trainierten KI-Modells zur Anomalieerkennung von Entmagnetisierungsschäden wurden direkt von den Strommesszangen und dem digitalen Oszilloskop bzw. der MCU unter Verwendung eines J-Link übertragen, um die Daten auf das Edge-Gerät zu transferieren. Der trainierte Algorithmus erfordert Batch-Eingaben, um eine Vorhersage zu treffen. Während der Entwicklung des Algorithmus wurde eine Batch-Länge von 2^{14} Datenpunkten festgelegt, um eine zuverlässige Leistung zu gewährleisten. Zusammen mit der erforderlichen Abtastfrequenz von 30 kHz (Strommesszangen + digitales Oszilloskop) ergibt dies eine Batch-Länge von etwa 0,546 Sekunden, bei der vom Umrichter vorgesehenen Frequenz von 20 kHz beträgt die Messdauer 0,8192 Sekunden. **Fehler! Verweisquelle konnte nicht gefunden werden.** Die verwendete ETL-Pipeline wurde bereits in [Arbeitspaket 2: Design auf Systemebene](#) beschrieben.

Ad 2: Das Edge-Device (MOXA MC-1121-E2-T) wurde mit einem eigens hierfür entwickelten Abschalt- und Startmechanismus in das Fraunhofer IISB Testfahrzeug integriert. Für den Abschalt- und Startmechanismus wurden zwei Relais (K1 und K2) mit dem Edge-Device in das Fraunhofer-Testfahrzeug integriert, welche sich in Anhängigkeit des Spannungslevels der autointernen Klemme 15 schließen oder öffnen. Das geschlossene Relay K1 stellt die benötigte Versorgungsspannung für das Edge-Device über die autointerne 12 V Batterie zur Verfügung. Das geschlossene Relay K2 wiederum hebt das Potential am digitalen Eingang des Edge-Devices, welches zwingend notwendig für das Hochfahren des Betriebssystems ist. Ist das Spannungslevel an Klemme 15 niedrig, öffnen sich beide Relais und initiieren den Abschaltmechanismus. Zusätzlich wurde das Edge-Device via CAN mit dem foxBMS verbunden, worüber das Edge-Device Batteriedaten der im Fraunhofer IISB Testfahrzeug verbauten Batterie empfangen und auswerten kann. Damit das Edge-Device sich mit der Cloud verbinden kann, wurde eine 2,4 GHz RF-Antenne angebracht. Eine schematische Darstellung der kompletten Verkabelung des Edge-Device ist in Abbildung 10 zu sehen.

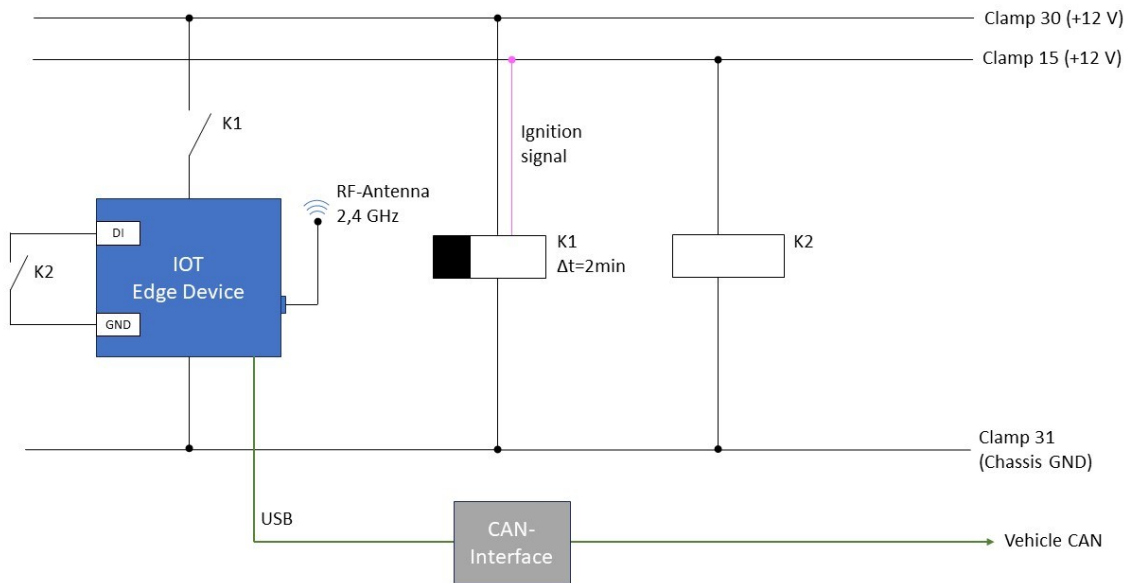


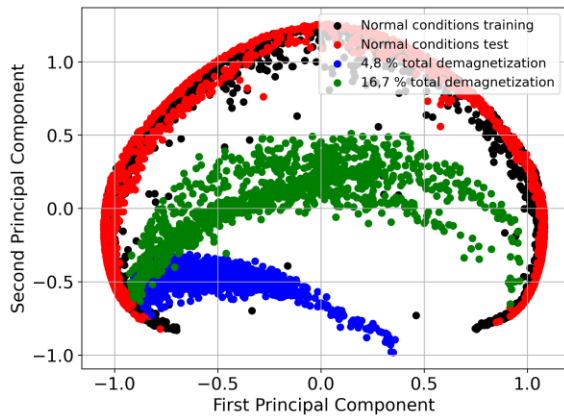
Abbildung 10: Schematische Darstellung der Edge-Device Verkabelung

Dem Projektpartner AVL wurden die benötigten Systemintegrationsanforderungen des Edge-Devices zur Überwachung des Batteriesystems übergeben.


Die Algorithmen zur Detektion der Temperatursensoranomalien wurden in die ETL-Pipeline integriert und für die Ausführung auf dem Edge-Device in Bezug auf das Laden und Konfigurieren des Modells und dessen zeitlicher Ausführung weiter optimiert.

Arbeitspaket 6: Validierung und Tests

Ad 1: Eine experimenteller Teststand mit künstlich demagnetisierten Testmotoren für die Validierung der entwickelten ETL-Pipeline und Algorithmen wurde aufgebaut. Wie bereits in Arbeitspaket 4 wird auch hier zwischen den beiden Ansätzen in der Messtechnik (Strommessungen und digitales Oszilloskop bzw. Auslesen der Stromdaten aus dem Umrichter) unterschieden. Abbildung 11 zeigt in a) zwei der drei Dimensionen innerhalb der kPCA mit farblichen Hervorhebungen und in b) die getätigten Vorhersagen der OC-SVM, wobei der gesunde Test-Motor als True Negative und die geschädigten Motoren als True Positive gekennzeichnet sind. In den Abbildungen wird ersichtlich, dass die entwickelten Algorithmen basierend auf unbekanntem Daten hervorragend performen und deren Einsatz für die Anomalieerkennung von Demagnetisierungsschäden in Frage kommen können.



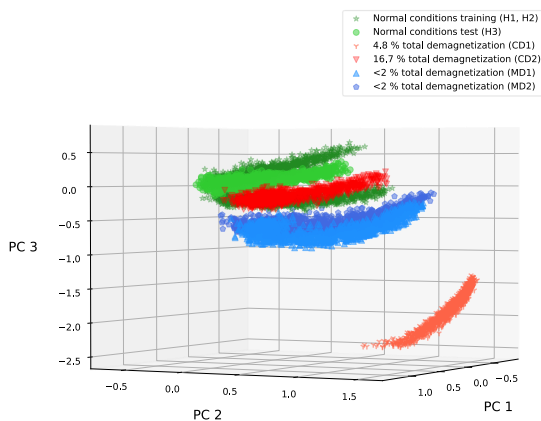
a)



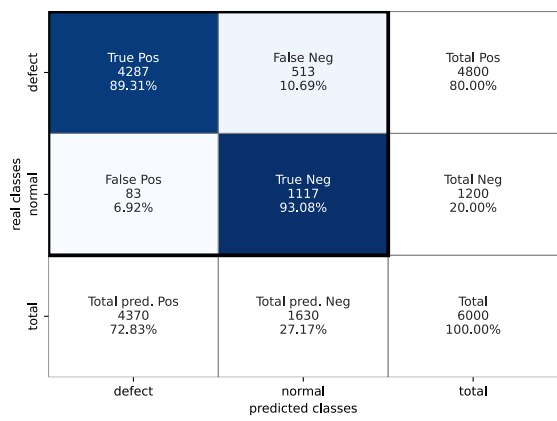
b)

Abbildung 11: Ergebnisse der trainierten Machine Learning Modelle basierend auf die mittels Strommesszangen gemessenen Stromdaten: Abhängigkeiten zwischen den ersten zwei Hauptkomponenten der kPCA a), Confusion Matrix der OC-SVM Vorhersagen b).

Bei der erweiterten Untersuchung der ausgelesenen Motorströme aus dem Umrichter mussten im Rahmen der Datenvorverarbeitung weitere Schritte für eine bessere Merkmalsextraktion durchgeführt werden. Die Beschränkung auf die für die Demagnetisierung relevanten Harmonischen, die mittels physikalischer Zusammenhänge berechnet werden konnten, sowie die Begrenzung des Spektrums auf die niederfrequenten Bereiche bis zur 11. Harmonischen, führen zu den in Abbildung 12 a) aufgezeigten Ergebnissen in der kPCA und der in b) mittels Confusion Matrix aufgetragenen Modellvorhersagen der OC-SVM. Die Ergebnisse zeigen, dass trotz des Verzichts auf zusätzliche Sensortechnik eine sehr gute Vorhersagegenauigkeit sowie eine geringe False-Positive Rate erzielt werden konnte, die das Vertrauen in den KI-Algorithmus stärken, da ein geringer Pseudoanomalieanteil vorliegt.



a)



b)

Abbildung 12: Ergebnisse der trainierten Machine Learning Modelle basierend auf ausgelesenen Umrichterströme: Abhängigkeiten zwischen den ersten drei Hauptkomponenten der kPCA a), Confusion Matrix der OC-SVM Vorhersagen b).

Ad 2: Die Algorithmen zur Anomaliedetektion der Temperatursensoren zur korrekten zeitlichen und datensparsamen Ausführung auf dem Edge-Device wurden erfolgreich validiert. Hierfür wurden mehrere Docker Images (Module im Azure Kontext) durch das Fraunhofer IISB entwickelt, welche über die auf dem Edge-Device installierte Azure Edge Runtime ausgeführt und überwacht werden. Die Softwarearchitektur mit den Docker Images als Microservices sind schematisch in Abbildung 13 dargestellt.

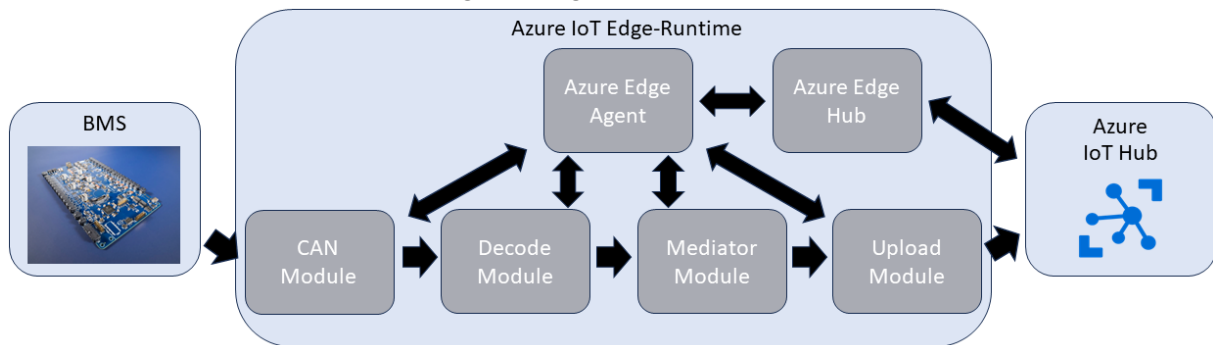


Abbildung 13: Softwarearchitektur des Edge-Devices

Das „CAN Module“ liest die CAN Nachrichten mit den Batteriedaten in einer hexadezimalen Darstellung vom angeschlossenen foxBMS, wobei diese durch das „Decode Module“ in Echtzeit aufbereitet werden. Das „Mediator Module“ nimmt die aufbereiteten Batteriedaten und speichert diese in einem Ringpuffer zwischen. Der integrierte intelligente Algorithmus, welcher im „Mediator Module“ hinterlegt ist, fordert dann die benötigten Daten in dem Moment an, in welchem der Algorithmus durch ein vordefiniertes Ereignis ausgelöst wird. Dieser Vorgang wird für die gesamte Laufzeit des Edge-Devices wiederholt und etwaige Ausgaben des Algorithmus werden über das „Upload Module“ in Cloud (Azure) hochgeladen. Für die Validierung wurde der entwickelte Algorithmus auf dem Edge-Device mit Live-Daten aus dem Fraunhofer IISB Testfahrzeug gefüttert. Da sich zum Zeitpunkt der Validierung keine Temperatursensoranomalien in dem Fraunhofer Testfahrzeug befanden, wurde in der Ausgabe des entwickelten Algorithmus kein Warnhinweis auf eine Temperatursensoranomalie erwartet. Zusätzlich wurde die Robustheit der entwickelten Datenvorverarbeitung und des Ringpuffers durch hinzufügen von künstlichen Übertragungsfehlern getestet. Da kein Warnsignal vom entwickelten Algorithmus ausgegeben wurde, noch ein Programmabbruch durch die künstlichen Übertragungsfehler stattfand, wird die Validierung der Implementierung des Algorithmus als erfolgreich angesehen.

2. Wichtigste Positionen des zahlenmäßigen Nachweises

Der zahlenmäßige Verwendungsnachweis wurde vorgelegt. Es gab keinen nennenswerten Abweichungen von der Planung.

3. Nutzen und Verwertbarkeit der Ergebnisse

Die im Projekt erzielten Ergebnisse im Kontext der sensorarmen Zustandsüberwachung elektrischer Antriebe und der Anomalieerkennung in Batteriesystemen werden unmittelbar im Forschungsgebiet *Cognitive Power Electronics* (CPE) des Fraunhofer IISB genutzt und verwertet:

Mit *Cognitive Power Electronics* verbindet das Fraunhofer IISB seine Kernkompetenz im Bereich der leistungselektronischen Systeme mit Data Analytics und künstlicher Intelligenz. Durch diese Integration werden innovative Einsatzmöglichkeiten für intelligente Leistungselektronik ermöglicht: von der Datenaufnahme und -analyse im Wandler bis zur vorausschauenden Wartung im Zusammenspiel mit der Cloud.

Ermöglicht wird *Cognitive Power Electronics* durch die Verknüpfung des Datenwissens mit dem Systemwissen innerhalb des Fraunhofer IISB: Die Expertise im Bereich Leistungselektronik bezüglich der Umwandlung, Versorgung und Speicherung von elektrischer Energie fließt in die intelligenten Funktionalitäten ein. Beispiele für aktuelle Entwicklungen sind umrichterbasierte Health-Monitoring-Funktionen für elektrische Antriebe ohne zusätzliche Sensoren, Wandler-basierte Impedanzspektroskopie und Stabilitätsoptimierung in Gleichstromnetzen.

Entsprechend werden insbesondere die folgenden Ergebnisse nach Projektende verwertet:

KI-Pipeline zur sensorarmen Zustandsüberwachung:

- In Zusammenarbeit mit Forschungspartnern und Kunden ist die Integration der entwickelten Algorithmen als Echtzeit-Überwachung in verschiedenen Anwendungen der intelligenten Leistungselektronik geplant, zunächst mit Schwerpunkt in der Antriebstechnik.
- Im Kontext der Antriebstechnik ist einer Erweiterung bzw. Skalierung auf andere Motorleistungsklassen und/oder Branchen (z.B. Luftfahrt) geplant. Der nächste Schritt in der Weiterentwicklung der KI-Modelle ist das Trainieren der Modelle mit zusätzlichen Daten aus dem Feld in Kooperation mit Forschungspartnern.
- Mit Entwicklungsarbeiten zur IoT-Integration der Motoren und Edge-Systeme für eine umfassende Datenerfassung und -analyse vor Ort wurde begonnen.

DMD-basierte Anomalierkennung:

- Das Verfahren zur Anomalieerkennung basierend auf DMD ist ein sehr recheneffizientes Verfahren, das schnell trainiert und auf Edge-Devices eingesetzt werden kann. Die Erkennung beruht auf der Auswertung eines Ensembles von Sensoren bzw. einer Gruppe von Daten, wobei das Modell direkt aus dem Zeitverlauf der Sensordaten erstellt werden kann.
- Das Verfahren stellt somit einen effizienten Ansatz zur Überwachung der Temperatursensoren in Batteriesystemen dar. Darüber hinaus ist es als generischer Ansatz der Anomaliedetektion in weitere Anwendungen der intelligenten Leistungselektronik übertragbar.

IoT-Integration:

- Für die Integration der entwickelten intelligenten Algorithmen wurden mehrere Docker Images (Module im Azure-Kontext) entwickelt, um die Batteriedaten aus foxBMS aufzubereiten. Diese Docker Images können, wie in einer Microservice Architektur üblich, als ein Bestandteil eines Softwarebaukastens für unterschiedliche Use-Cases wiederverwendet werden.

- Zusätzlich können die Azure-Edge-Runtime, sowie die entwickelten Docker-Images auf mehreren unterschiedlichen Hardwareplattformen betrieben werden. Dies ermöglicht den Einsatz der Software in weiteren Edge-Device als Erweiterung anderer Hardwarekomponenten als dem BMS.

Die Ergebnisse wurden bereits in Fachartikeln und einem Konferenzbeitrag präsentiert und mit der Fachwelt diskutiert (siehe Abschnitt 5).

4. Während der Laufzeit bekannt gewordene, relevante Ergebnisse Dritter

Das regelmäßige Überprüfen einschlägiger Journale und der Besuch geeigneter Konferenzen erbrachten keine Erkenntnisse, die zu einer Änderung des Arbeitsplans geführt hätten.

5. Erfolgte und geplante Veröffentlichungen

Fachartikel

Lfd. Nr.	Autoren	Titel	Journal, Volume, Issue, Page	DOI	Datum
1	Walch, D.; Blechinger, C.; Schellenberger, M.; Hofmann, M.; Eckardt, B.; Lorentz, V.R.H	Detection of Demagnetization Faults in Electric Motors by Analyzing Inverter Based Current Data Using Machine Learning Techniques	MDPI, machines 2024, Vol. 12, 468	https://doi.org/10.3390/machines12070468	11.07.2024
2	Schellenberger, M.; Lorentz, V.; Eckardt, B.	Cognitive Power Electronics - An Enabler for Smart Systems	Tagungsband: PCIM Europe 2022, VDE-Verlag GmbH, Berlin.	10.30420/565822006	10.-12.05.2022

Konferenzbeitrag

Lfd. Nr.	Autoren	Titel	Typ (Poster, Präsentation)	Konferenz/Tagung	Datum
1	Blechinger, C.; Walch, D.; Schellenberger, M.; Hofmann, M.; Steinmetz, H	Cognitive Power Electronics for Detection of Demagnetization in Electric Drives	Präsentation	2023 13th International Electric Drives Production Conference (EDPC)	29.-30.11.2023