



Elektrifizierung mit KI

Die Elektrifizierung der Antriebe bei Fahrzeugen schreitet unermüdlich voran. Damit einhergehend steigt auch die Anzahl der sich im Umlauf befindlichen Hochvolt-Batterien, die für die elektrischen Antriebe benötigt werden. Obwohl die Mindestanforderungen an die Lebensdauer dieser Batterien bei einer Laufleistung von 150.000 bis 200.000 Kilometern oder etwa 1.000 Vollzyklen liegen, sind Ausfälle von Batterien im Feld leider keine Ausnahme. Aufgrund der marktüblichen Herstellergarantien und der Klassifizierung von Batterien als Gefahrgut, was spezielle Prozesse im Transport und der Reparatur oder dem Recycling erforderlich macht, sind Ausfälle mit hohen Kosten für die OEMs verbunden. In diesem Insight Automotive wollen wir deshalb ein paar Ansätze aufzeigen, wie mit Hilfe von Künstlicher Intelligenz die Lebensdauer einer Batterie erweitert und das Ausfallrisiko reduziert beziehungsweise mögliche Ausfälle besser geplant und somit kostenoptimierter gehandhabt werden können.

Eine moderne Hochvolt-Batterie besteht aus einer Vielzahl von Bauteilen. Neben den eigentlichen Zellen und Modulen, welche den Strom speichern, benötigt eine Batterie unter anderem ein Batterie-Management-System (BMS) sowie Zellüberwachungseinheiten (CSE – Cell Supervision Electronics). Während bei Zellen die allmähliche Degradation (Verlust der Speicherkapazität über die zeitliche Nutzung) ein großes Thema ist, sind vor allem Fehler im Batterie-Management-System oder in den Zellüberwachungseinheiten häufige Ursachen für einen spontanen Ausfall von Batterien im Feld.

Aufgabenstellung

Hohe Kosten bei Batterieausfällen für OEMs

- Infrastruktur für Recycling noch im Aufbau
- Einstufung von Hochvolt-Batterien als Gefahrgut
- Transport von Hochvolt-Batterien ist eine Herausforderung für die Logistik
- Teure Entsorgung defekter Batterien
- Hohe Kosten für Reparatur oder Ersatz-Akkus

Auswirkungen von Batterieausfällen im Feld

Da die Automobilhersteller als Inverkehrbringer für die Entsorgung der Batterien verantwortlich sind und zudem eine Akkugarantie von 8 Jahren oder 160.000 Kilometern bei den meisten Fahrzeugen mittlerweile Standard ist, sind Batterieausfälle nicht nur für den Endkunden ärgerlich, sondern stellen auch für die OEMs ein großes Problem dar. Die Infrastruktur für das Recycling und die Reparatur von Hochvolt-Batterien befindet sich noch im Aufbau. Hochvolt-Batterien sind Gefahrgut und müssen auch als solches behandelt und transportiert werden, was für viele Hersteller vor allem in der Rückföhrlogistik eine Herausforderung darstellt. In Abhängigkeit des Batteriestatus müssen zudem Transporte in Spezialbehältern durchgeführt werden, welche für den jeweiligen Batterietyp zugelassen sein müssen.

Hinzu kommt, dass nicht-reparierbare Batterien als Abfall deklariert werden und teilweise nicht oder nur mit großem Aufwand und zeitlichem Verzug über Landesgrenzen verbracht werden können, um beispielsweise in einem anderen Land recycelt zu werden. Dazu kommen relativ hohe Kosten für eine Reparatur oder eine Ersatzbatterie und das Recycling der kaputten Batterie.

Allein aus diesen Gründen haben Hersteller ein großes Interesse, die Ausfälle von Batterien im Feld so gering wie möglich zu halten und die Planbarkeit bei unvermeidlichen Ausfällen zu erhöhen. Bei beiden Fällen kann der Einsatz von künstlicher Intelligenz einen wertvollen Beitrag leisten.

Use Case 1: KI zur Prognose von Batterieausfällen

Ausfälle von Batterien im Feld können verschiedene Ursachen haben. Neben technischen Ursachen wie der Defekt einer Zelle oder eines Steuergerätes können auch Kräfteinwirkungen von außen im Rahmen eines Unfalles oder aufgrund missbräuchlicher Verwendung zu Schäden an Batterien führen, die die Weiterverwendung im jeweiligen Zustand rein technisch bedingt oder aus Sicherheitsgründen verhindern.

Während Prognosen von Ausfällen aufgrund von externen Einwirkungen eine hinreichend große Stichprobe und Anzahl von Fahrzeugen im Feld voraussetzen, sollten technisch bedingte Störungen bereits nach wenigen Fällen systematisch analysiert und bewertet werden. Ein modernes Auto erzeugt täglich bis zu 600 Gigabyte an Daten, wovon im Schnitt nur circa 50 MB pro Monat wirklich von den OEMs verwendet werden. Diese umfassen neben Fehlercodes einzelner Steuergeräte auch Parameter des Nutzerverhaltens wie zum Beispiel die typische Lade- und Entladeleistung oder die maximale Beanspruchung. Auch externe Faktoren wie die Temperatur oder batterie-spezifische Informationen wie die maximale Kapazität werden in unterschiedlichen Intervallen erfasst.

Die Herausforderung bei der Vorhersage von Batterieausfällen besteht darin, aus der Vielzahl der verfügbaren Daten die relevanten Parameter zu identifizieren und diejenigen Muster zu erkennen, welche mit einer bestimmten Wahrscheinlichkeit in einem definierten Zeitraum zu einem Ausfall führen. Hierbei können auch nicht batterie-spezifische Informationen eine Rolle spielen. Beispielsweise können – obwohl die Temperatur einer Batterie aktiv geregelt wird – die Umgebungstemperatur oder die lokalen klimatischen Verhältnisse einen Einfluss auf die durchschnittliche Batterietemperatur während des Ladevorganges haben, was wiederum die Zellchemie beeinflussen kann. Oder minimale Stromschwankungen während des Ladevorganges können die empfindliche Elektronik im Batterie-Management-System beeinflussen.

Vor allem bei Nutzfahrzeugen hat das Konzept von Ausfallsprognosen aufgrund von Fahrzeugdaten als „Predictive Maintenance“ schon länger Einzug bei den OEMs gehalten. Während bei konventionellen Fahrzeugen jedoch das relevante Entwicklungs-Know-how meist vollständig beim OEM liegt und daher technische Interpretationen und Bewertungen hausintern durchgeführt werden können, muss dies bei Elektrofahrzeugen nicht zwingend der Fall sein. Hier kann zumindest das technische Fachwissen über die Batterien bei einem externen Hersteller liegen. In Kombination mit der Infrastruktur des Fahrzeuges ergeben sich also auch organisatorische Herausforderungen bei der Interpretation von Fehlermustern.

Ein weiterer Gegensatz zur Predictive Maintenance besteht darin, dass die Prognosen über Batterieausfälle nicht nur auf fahrzeuginternen Daten basieren, sondern auch externe Einflüsse wie Unfälle und Missbrauch inkludieren sollen, welche ebenfalls eine Reparatur oder einen Tausch der Batterie notwendig machen können. Hierzu ist die Betrachtung von makroskopischen Daten wie die Anzahl der Fahrzeuge im Feld, das Unfallrisiko etc. in die Prognose mit einzubeziehen.

Die Anwendungsfälle für die Prognose von Ausfällen im Feld sind vielschichtig. Die erwartete Menge an ausgefallenen Batterien sowie deren Ausfallursache ist zuallererst ein wichtiger Einflussfaktor für die Entscheidung, wie mit kaputten Batterien umgegangen werden soll. Die Investitionen in die Infrastruktur zur Reparatur von Batterien lohnen sich erst ab einer bestimmten Menge an Batterien, die auch aus technischer Sicht reparierbar sind. In Abhängigkeit der prognostizierten Mengen an reparierbaren Batterien sowie der notwendigen Investitionen und variablen Kosten für Reparatur, Ersatzteile und Logistik kann zwischen zentralen (ein zentrales Reparaturwerk für alle Länder), regionalen (mehrere Reparaturwerke in unterschiedlichen Ländern) und lokalen (Reparatur beim Händler) Reparaturkonzepten unterschieden werden. Diese Betrachtung muss je Batterietyp erfolgen, da unterschiedliche technische Anforderungen auch eine unterschiedliche Infrastruktur und damit unterschiedliche Investitionen erforderlich machen.

Selbst wenn Batterien aufgrund ihrer Bauart nicht repariert werden können, hilft eine hohe Prognosegenauigkeit bei der Planung der notwendigen Kapazitäten für Tauschbatterien sowie den Transport und das Recycling der Alt-Batterien. Letzten Endes erhöht dies auch die Prognosegenauigkeit für die Garantiekosten.

Problemlösung Use Case 1

Mit Hilfe von KI technische Ausfallprognosen erstellen.

- Moderne Autos sammeln bis zu 600 GB an Daten pro Tag
- Aus den Datensätzen Muster erkennen
- Lösungsansatz „Predictive Maintenance“
- Herausforderung: Interpretation von Fehlermustern
- KI kann Prognoseungenauigkeiten verringern bzw. vermeiden

Use Case 2: KI zur Optimierung der Lebensdauer / Reduktion von Batterie-Degradation

Neben der Vermeidung oder der Erhöhung der Prognosegenauigkeit von Ausfällen stellt KI auch ein unverzichtbares Hilfsmittel bei der pro-aktiven Optimierung der Lebensdauern von Batterien im Feld bereit. Der Haupteffekt, welcher die Lebensdauer langfristig beeinflusst und in unterschiedlichen Formen bei allen Batterien auftritt, ist die Degradation. Unter Batterie-Degradation versteht man die langsame Änderung des Zustands der Batterie, bei der die maximale Speicherkapazität sinkt. Das passiert zum einen über die Zeit und zum anderen über die Anzahl der Ladezyklen.

Die Degradation ist ein unerwünschter Prozess, der durch diverse Maßnahmen von Hersteller und Fahrer reduziert werden kann. Dazu zählen zum Beispiel die Akku-Chemie, die Festlegung der Akku-Reserve, die maximale Geschwindigkeit beim Schnellladen, die Temperaturfenster bei der Be- und Entladung, der übliche Ladezustandsbereich bei der täglichen Nutzung und vieles mehr.

Umfassende Erkenntnisse über die Einflussfaktoren der Batterie-Degradation sind heute für alle Batteriehersteller sowie OEMs von zentraler Bedeutung. Eine (zu) konservative Auslegung der Batterie schützt zwar vor starker Degradation, aber die Wettbewerbsfähigkeit der Produkte leidet darunter, da beispielsweise die Batteriekapazität nur begrenzt ausgenutzt wird oder die Ladevorgänge länger dauern als technisch notwendig. Andererseits kann eine (zu) progressive Auslegung der Batterie zu einer erhöhten Degradation und damit zu einer erhöhten Anzahl von Garantiefällen und letzten Endes auch wieder zur Unzufriedenheit von Kunden führen.

Die optimale Bewirtschaftung einer Batterie ist ein komplexes Unterfangen, weswegen bereits während der Entwicklung ausführliche Tests zur Auslegung und Optimierung der Systeme durchgeführt werden. Aufgrund der größeren Stichprobe und der längeren Beobachtungsdauer bietet jedoch die Auswertung von Fahrzeugdaten im Feld ein ungleich größeres Optimierungspotential.

Mit Hilfe von künstlicher Intelligenz kann im ersten Schritt aus der Vielzahl von vorliegenden Daten ermittelt werden, welche Parameter einen Einfluss auf die Lebensdauer bzw. Ausfallswahrscheinlichkeit einer Batterie haben. Im nächsten Schritt wird anhand von künstlicher Intelligenz analysiert, wie diese Parameter gestaltet sein müssen, um eine möglichst lange Lebensdauer der Batterie zu erhalten. Sofern möglich, können diese Erkenntnisse direkt auch für Fahrzeuge im Feld umgesetzt werden, indem mittels Over-the-air-updates die Batterie-Management-Systeme mit den optimierten Parametern versorgt werden.

Hierbei muss erwähnt werden, dass aufgrund der physikalischen Gegebenheiten immer ein Trade-off zwischen Leistung bzw. Ladeschnelligkeit und Lebensdauer gefunden werden muss. Dieser Umstand kann jedoch auch aktiv gegenüber dem Kunden vermarktet werden. Denkbar wäre zum Beispiel, dass der Kunde über sein Navigationssystem Hinweise zur schonenden Nutzung oder Ladung der Batterie eingeblendet bekommt. Ab einer bestimmten Anzahl von umgesetzten Hinweisen kann ein Kunde Rabatt bei einer Garantieverlängerung erhalten.

Problemlösungen Use Case 2

Optimierung der Lebensdauer einer Batterie mit Hilfe von KI

- KI kann die Lebensdauer von Hochvolt-Batterien verlängern
- KI kann die Batterie-Degradation senken
- Optimale Bewirtschaftung einer Batterie ist komplex
- Mit Hilfe von KI können diejenigen Parameter identifiziert werden, die für eine lange Lebensdauer einer Batterie entscheidend sind

**KI kann helfen eine möglichst lange Lebensdauer
der Batterie zu erhalten.**



Fazit

Die genaue Betrachtung und Analyse der Betriebsdaten der Fahrzeugflotte im Feld ermöglicht Erkenntnisse über den Umgang mit dem Fahrzeug und der Batterie, sowie das Verhalten der Batterie (Degradation und Ausfälle) als Reaktion darauf, die vorher nicht bekannt sind. Die Zusammenhänge müssen aus den gesammelten Daten extrahiert und die Kompetenz und das Wissen muss in Form von Software und wiederholbaren Analysen strukturiert festgehalten werden. Dadurch können immer wieder neue Daten und zum Beispiel neue Fahrzeug-Modelle entsprechend berücksichtigt werden.

Die Umsetzung der oben genannten Use Cases bedingt unter anderem die Analyse von teilweise unstrukturierten Betriebsdaten auf Fahrzeug-Ebene. Für die wertstiftende Auswertung dieser riesigen Datenmenge sind moderne, skalierbare und automatisierbare Methoden unerlässlich. Künstliche Intelligenz umfasst diesen Funktionsumfang und hilft uns, konkrete Schlussfolgerungen aus den Daten zu ziehen.



Über BDS – Business Development & Services

BDS – Business Development & Services unterstützt aus den Büros in Graz und Stuttgart Unternehmen bei allen Fragen rund um das Thema Geschäftsentwicklung. Zu den Kunden gehören sowohl namhafte Automobilhersteller als auch Zulieferunternehmen. Die Berater von BDS vereinen tiefgehende Branchen-Expertise mit exzellentem Methoden-Know-how, um die besten Ergebnisse für ihre Kunden zu erzielen.

Autoren:

Christian Moritsch

christian.moritsch@bds-germany.com

Dr. Jan Fränkle

jan.fraenkle@itm-p.com

Über ITM

ITM bietet über seine Standorte Karlsruhe und Pfäffikon SZ Implementierung und Beratung im Bereich Machine Learning seit 2013 an. Die Data Scientists von ITM haben jahrelange Erfahrung in der Entwicklung von Machine-Learning-Algorithmen und der Umsetzung von komplexen Projekten.



reThink Business