




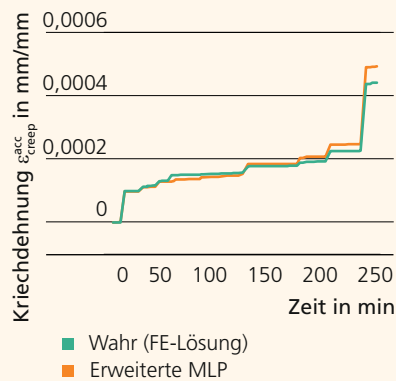
E-Bike für die Datenerfassung im Feld.

# KI-gestützte Prognostik und Zustandsmanagement für die Elektronik

M. Sc. Darshankumar Bhat, Dr. Stefan Münch, Dr. Mike Röllig



Beispielhafte Missionsprofil-daten vom E-Bike-Leistungsmodul.



Schädigungsvorhersage für das eBike-Leistungsmodul.

Insbesondere seit dem Aufkommen des Internet-of-Things (IoT) wächst der Bedarf an zuverlässiger, vertrauenswürdiger und intelligenter Elektronik. Eine kostengünstige und schnelle elektronische Systemüberwachung sowie eine schadensbasierte Wartungsplanung bietet das »Prognostics and Health Monitoring« (PHM). Bei dieser kontinuierlichen Zustandsüberwachung elektronischer Systeme entstehen jedoch große Datenmengen. Diese sollten idealerweise ausgewertet werden, ohne sie dauerhaft zu speichern. Eine Möglichkeit dafür bietet Maschinelles Lernen (ML), ein Teilbereich der Künstlichen Intelligenz (KI).

## Neuer Ansatz für die Echtzeit-Prognose

Die hier vorgeschlagene Methodik hat das Potenzial einer realisierbaren Lösung für die Online-Zustandsbewertung. Als Testobjekt wurde das Leistungsmodul, d. h. die Steuereinheit des eBike-Motors gewählt. Die verbleibende Lebensdauer wird hier direkt aus der thermischen Belastung während der Fahrt ermittelt (Graphik mitte). Für das Training der KI wurde ein großer Datensatz synthetischer Temperatur-Zeit-Profile generiert. Über eine Simulation mit der Finite-Elemente-Analyse (FEA) erfolgte die Auswertung der Schädigung von Lötverbindungen unter diesen Temperaturbelastungen und die Überführung in ein mehrlagiges Perzeptron-Modell (MLP). Temperaturmerkmale und entsprechende Kriechkremete (Schädigungen) bilden hierfür den Trainingsdatensatz. Die Genauigkeit des Modells wird durch »Transfer Learning« anhand der Daten aus Feldversuchen (Missionsprofil) verbessert. Die verbleibende Nutzungsdauer (RUL) dieser Leistungselektronikkomponente im Betrieb wird dann auf Grundlage der ermittelten Lebensdauer abgeschätzt.

Die wichtigsten Errungenschaften dieser Methode sind: (1) die Extraktion von Merkmalen aus Temperatur- und Zeitdaten, was den Aufwand für die Datenspeicherung reduziert, (2) das effiziente Training unter Verwendung synthetischer Daten und die einfache Erweiterung auf begrenzte Daten der realen Welt sowie (3) die sehr gute Vorhersagefähigkeit in Echtzeit.

Die Graphik unten zeigt die beeindruckend genaue Vorhersage der Kriechdehnung vom MLP im Vergleich mit den Daten aus der FEA. Anhand des Testdatensatzes wird ein durchschnittlicher Fehler von nur 6,7 % ermittelt.

An der Leistungselektronik des eBike-Motors wurde demonstriert, dass sich diese Methode in ein intelligentes PHM implementieren lässt. Sie bietet eine Echtzeit-Vorhersage der Restlebensdauer, die zur Gewährleistung der Zuverlässigkeit auch in anderen sicherheitskritischen Anwendungen, wie im Schienen- oder Automobilbereich, benötigt wird.



Diese Maßnahme wird mitfinanziert durch  
Stromerlöse auf der Grundlage des von dem  
Abgeordneten des Sächsischen Landtags  
beschlossenen Haushalts.