

Neuartiger hybrider Simulationsansatz für die Zustandsüberwachung elektronischer Systeme für Mobilitätsanwendungen

Mariam Elsothy^a, Maurice Paul Artelt^b, Johannes Jaeschke^a, Simon Kamm^b, Nasser Jazdi^b, Frederic Sehr^a, Martin Schneider-Ramelow^a, Michael Weyrich^b

^a Fraunhofer Institut für Zuverlässigkeit und Mikrointegration Berlin (IZM), Gustav-Meyer-Allee 25, 13355 Berlin

^b Universität Stuttgart. Institut für Automatisierungstechnik und Softwaresysteme (IAS), Pfaffenwaldring 47, 70550 Stuttgart

mariam.elsotohy@izm.fraunhofer.de, frederic.sehr@izm.fraunhofer.de, johannes.jaeschke@izm.fraunhofer.de, martin.schneider-ramelow@izm.fraunhofer.de, simon.kamm@ias.uni-stuttgart.de, maurice.artelt@ias.uni-stuttgart.de, nasser.jazdi@ias.uni-stuttgart.de, michael.weyrich@ias.uni-stuttgart.de

Kurzfassung

Das Kernziel des vorliegenden Beitrags ist die Entwicklung eines hybriden Ansatzes zur Selbstvalidierung von sicherheitskritischen Elektronikanwendungen. Auf Basis der realen, lokal verfügbaren Daten im Feld wird eine eindeutige Systemcharakterisierung durchgeführt. Hierdurch können sowohl kritische Systemzustände verhindert werden als auch Redundanzen und Überdimensionierung im System reduziert werden.

Keywords: Zustandsüberwachung, Zuverlässigkeitsabsicherung, Hybride Modellierung, Künstliche Intelligenz

1 Einleitung

Die Entwicklung von Selbstvalidierungsmethoden zur Gewährleistung der funktionalen Integrität komplexer elektronischer Systeme stellt eine interdisziplinäre Herausforderung dar. Bisherige Methoden wie der Einsatz von physikalischen Degradationsmodellen und datenbasierten Modellen werden typischerweise unabhängig voneinander genutzt, woraus Einschränkungen bei der Zustandsüberwachung resultieren. Physikalische Degradationsmodelle ermöglichen die Bewertung relevanter Fehlermechanismen in elektronischen Baugruppen unter Einwirkung einzelner Belastungsgrößen und erlauben somit die Fehlerprognose. Allerdings beschränkt sich diese Prognose auf ausgewählte Bauelemente und wird im Laufe der Nutzungsdauer aufgrund kombinierter Belastungen im Feld ungenauer [1]. Im Gegensatz dazu verwenden datenbasierte Künstliche Intelligenz (KI-)Modelle verfügbare und messbare Parameter der Baugruppen als Eingangsgrößen für Fehlerprognosen. Mit zunehmender Verfügbarkeit von Daten werden die Vorhersagen präziser. Dennoch sind beide Ansätze nur begrenzt geeignet, um die Lebensdauer des elektronischen Systems bei wechselnden Feldbelastungen vorherzusagen sowie Manipulationen zu erkennen [2].

Im Rahmen dieses Beitrags werden gezielt physikalische Degradationsmodelle (White-Box-Modelle) und datenbasierte KI-Modelle (Black-Box-Modelle) während der Nutzungsphase kombiniert und in einem hybriden Modell (Grey-Box-Modell) integriert, um die eindeutige Charakterisierung des Systems zu ermöglichen und die funktionale Integrität zu gewährleisten. Die hybride Modellierung zielt darauf ab, geeignete, eindeutige Signaturen der Baugruppen in einem System zu erstellen, die als digitale Zwil-

linge bezeichnet werden. Dabei werden sowohl der Ausgangszustand der Baugruppen als auch die Auswirkungen der Feldbelastung auf die funktionale Integrität berücksichtigt [3]. Zur Erfassung lebensdauerabhängiger Signaturen und Zuverlässigkeitsindikatoren finden Multidomänenansätze Anwendung. Diese erfolgt durch die kontinuierliche Messung ausgewählter Systemparameter und die modellbasierte Einschätzung des Systemverhaltens, um eine solide Grundlage für die intelligente Zustandsbestimmung zu schaffen. Die Methode nutzt zur Demonstration eine Brückengleichrichterschaltung als relevante Beispielbaugruppe in der Mobilitätsanwendung. Hierbei werden sowohl thermo-mechanisch induzierte mechanische Spannungen aufgrund von globalen Temperaturwechselbelastungen als auch ein Anstieg der Sperrschichttemperatur des Halbleiters als Hauptbelastungsfaktoren betrachtet. Diese führen zu einer Degradation des Brückengleichrichter-Packages, insbesondere der Aufbau- und Verbindungstechnik. In diesem Zusammenhang wird das Verhalten der Sperrschichttemperatur bestimmt, indem die Schaltung einem Einsatzprofil unterzogen wird, das externe thermischen und elektrische Belastungen beinhaltet. Die Informationen des Einsatzprofils werden in das Multidomänenmodell eingespeist, um parametrische Studien durchführen zu können. Die generierten Daten werden anschließend zum Antrainieren des KI-Modells verwendet. Als KI-Modelle wurden sowohl der eXtreme Gradient Boosting (XGBoost)-Algorithmus als auch der Long short-term memory (LSTM)-Algorithmus in der Modellbildung realisiert und verglichen.

2 Zustandsüberwachungskonzept

Im Rahmen dieser Forschungsarbeit wurde ein Konzept zur Zustandsüberwachung und Selbstvalidierung elektronischer Schaltungen in der elektrischen und thermischen

Die vorgestellten Untersuchungen sind unter anderem im Rahmen des öffentlich geförderten Projektes SesiM entstanden und sind durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) gefördert (FKZ19|21018).

Domäne entwickelt. Das Konzept basiert auf einem strukturierten Ansatz, der zunächst die Identifizierung der funktionalen Struktur der Schaltung umfasst, gefolgt von der Entwicklung eines entsprechenden physikalischen Modells. Darauf aufbauend wird ein KI-Modell entwickelt und implementiert, das zur Zustandsüberwachung und Validierung verwendet wird. Jeder dieser Schritte wird im Folgenden ausführlich erläutert, um ein umfassendes Verständnis des vorgeschlagenen Konzepts zu vermitteln.

Die Simulation beschreibt die Auswirkungen von Veränderungen der Umgebungsbedingungen und konstanter Last auf den Brückengleichrichter. Die Modellimplementierung erfolgt mithilfe der objektorientierten Simulationsumgebung Simulink. Der erste Schritt bei der Zuverlässigkeitsbewertung ist die Belastungsanalyse des Brückengleichrichters (siehe Abbildung 1). Die Belastungen sind vom Einsatzprofil des elektronischen Bauteils abhängig und beeinflussen die Sperrschichttemperatur des Brückengleichrichters während eines vordefinierten Betriebsszenarios. Während der Simulation versorgt der Brückengleichrichter eine konstante elektrische Last, während die Betriebstemperatur über die Dauer des Benutzungsprofils variiert. Das Bauteil wird mit einem elektrischen Modell mit Verlustleistungsberechnung implementiert. Basierend auf den thermischen Eigenschaften des Gleichrichters werden die berechneten Gesamtverluste in ein thermisches Netzwerk

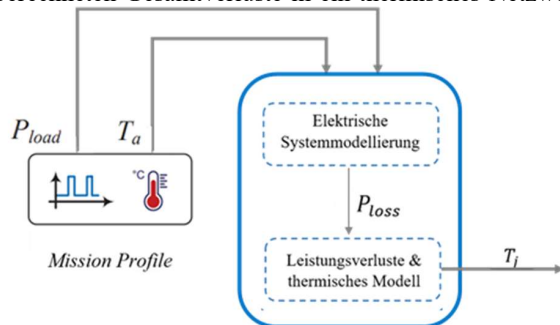


Abbildung 1 Workflow der Mission Profile-basierten Simulation der Sperrschichttemperatur des Gleichrichters

eingespeist. Anschließend wird das Sperrschichttemperaturprofil berechnet.

2.1 Funktionale Struktur

Die Beispielbaugruppe verwendet einen Brückengleichrichter, der aus vier integrierten Dioden in einer Brückenschaltung in einem einzigen Dual-Flat-No-Leads (DFN)-Gehäuse besteht.

2.2 Elektrisches Systemmodell

Abbildung 3 stellt das Konzept der physikalischen Systemmodellierung dar. Vor der Durchführung der Multi-Domänen-Simulation wird zunächst der Brückengleichrichterschaltkreis elektrisch modelliert, und sein elektrisches Verhalten wird detailliert anhand der Spezifikationen im Datenblatt abgebildet. Die Leitungs- sowie Schaltverluste werden genutzt, um mithilfe einer 3D-Lookup-Tabelle die Energieverluste zu bestimmen. Diese Energie wird dann

als Leistungsimpuls in das thermische Netzwerk eingespeist. Der Vorwärtsstrom im Bauteil und die Sperrschichttemperatur werden daraufhin verwendet, um mithilfe einer 2D-Lookup-Tabelle den Durchlassspannungsabfall über der Diode zu bestimmen.

2.3 Thermisches Modell

Die Berechnung der Sperrschichttemperatur unter einer konstanten elektrischen Last erfolgt durch die Implementierung eines RC-Netzwerks. Dieses Netzwerk beschreibt den Wärmewiderstand zwischen dem Chip und dem Bauteilgehäuse sowie zwischen dem Bauteilgehäuse und der Umgebung, welche mittels transients thermischer Analyse experimentell ermittelt wurden.

2.4 Datengenerierung für die KI-Modellierung

Ein MATLAB-Skript wurde entwickelt und implementiert, um automatisierte Parameterstudien durchzuführen. Das Hauptziel des Skripts besteht darin, systematisch Variationen in den Inputdaten (Umgebungstemperatur und elektrische Last) des zugrunde liegenden Modells zu untersuchen und automatisch Daten zu generieren. Durch die präzise Steuerung dieser Parameter ermöglicht das Skript eine umfassende Abdeckung des Parameterraums, was zu einer breiten Palette von Trainingsdaten führt. Die gesammelten Daten werden im Anschluss in strukturierten Formaten automatisch gespeichert, um eine einfache Integration in den Modellierungsprozess zu ermöglichen.

2.5 Datenbasiertes KI-Modell

Die generierten Daten mit ihren systematischen Variationen in Umgebungstemperatur, elektrischer Last sowie Lastanforderungsprofil erzeugen einen Datensatz mit verschiedenen Temperaturkurven. Für das Training des datenbasierten KI-Modells ergibt sich ein Spannungsfeld bei der für das Training genutzten Anzahl an Temperaturkurven. Während bei physikalischen Modellen mittels Parameter in Gleichungen die Zusammenhänge direkt beschrieben werden können, lernen datengetriebene Modelle die Zusammenhänge aus den Trainingsdaten. Für die genutzten Trainingsdaten ist es damit entscheidend bei allen Variationen eine Auswahl an Temperaturkurven für das Training zu nutzen, die sowohl alle Variationen abbildet als auch ausreichend Temperaturkurven für die abschließenden Tests des Algorithmus zurückhält. In Abbildung 4 wird dieser Zusammenhang dargestellt. Die erzeugten Daten werden in einen Trainingsdatensatz (Trainingszeitreihen) und in einen Testdatensatz (Testzeitreihen) aufgeteilt. Mittels der Trainingszeitreihen wird das Modell trainiert, welches anschließend für die Vorhersage der Zeitreihen verwendet werden kann. Zum besseren Vergleich werden diese in einem Bild mit den ursprünglichen prognostizierten Temperaturen geplottet. Für den quantitativen Vergleich der Prognosegüte werden zusätzlich die Ergebnisse mittels Root Mean Square Error (RSME) verglichen.

Für die datengetriebene Modellierung wurden zwei unterschiedliche Algorithmen ausgewählt und implementiert. Hierbei handelt es sich zum einen um XGBoost und zum

Die vorgestellten Untersuchungen sind unter anderem im Rahmen des öffentlich geförderten Projektes SesiM entstanden und sind durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) gefördert (FKZ19|21018).




Abbildung 3 Visualisierung des Modellierungsansatzes am Beispiel des Brückengleichrichters

anderen um ein LSTM- Netzwerk. Diese Modelle wurden aufgrund ihrer Stärken für den Vergleich gewählt [4]. Der XGBoost-Algorithmus ermöglicht es gute Resultate im Training des Algorithmus zu erzielen mit – für KI-Algorithmen – relativ wenigen Daten. Das LSTM-Netzwerk ermöglicht eine gute Abbildung der Zeitverläufe, benötigt jedoch mehr Daten. Die beiden Ansätze werden im Folgenden genauer beschrieben.

2.5.1 XGBoost -Algorithmus

Der Extreme Gradient Boost (XGBoost) Algorithmus wird in dieser Arbeit als Regressionsmodell eingesetzt. Er setzt sich aus Wahrscheinlichkeitsbäumen zusammen für die finale Vorhersage [5]. In dieser Arbeit wurde das Framework von Sklearn verwendet. Dieses Framework bietet eine geringe Einstiegshürde und ermöglicht damit einen schnellen Einstieg in die Implementierung. Jedoch wird aus diesem Grund ausschließlich auf dem Prozessor gerechnet. Dieser Algorithmus wurde mit zwei verschiedenen Ansätzen für die Datenaufteilung trainiert. Der erste Ansatz nutzt für das Training die erste Hälfte einer Zeitserie. Für den Test wurde anschließend die zweite Hälfte der Zeitserien verwendet. Der zweite Trainingsansatz nutzt die Verwendung von ausgewählten Zeitreihen der Datengenerierung. Diese zweite Auswahl stellte eine Gleichverteilung der Lastprofile, der Leistungsstufen und Umgebungstemperatur Profile sicher.

2.5.2 LSTM- Netzwerk

Für eine bessere Lernfähigkeit zeitlicher Zusammenhänge wurde zudem ein LSTM Netzwerk gewählt. Das Netzwerk wurde mittels dem Framework Tensorflow realisiert. Durch die bessere Abbildung der Zeitreihen wird ebenso eine bessere Abbildung der Zusammenhänge erwartet [6]. Der Eingang des Modells verarbeitet ein Tuple, bestehend aus der Sperrschichttemperatur T_j und der angelegten Leistung. Der Eingang wird anschließend mit einem 128 Neuronen LSTM verarbeitet. Die Klassifizierung erfolgt durch eine 8 Neuronen Dense Schicht, gefolgt von einer linearen Schicht, der Ausgangsschicht, mit einer Klasse.

3 Ergebnisse und Diskussion

Die Darstellung der Ergebnisse gliedert sich in die Darstellung der erzeugten Zeitreihen mittels der physikalischen Modelle sowie die Vorstellung der Ergebnisse der drei unterschiedlichen Ansätze der Machine-Learning Modelle. Unterschiedliche Implementierungsansätze wurden gewählt, die an dieser Stelle dargestellt werden. Darüber hinaus werden die daraus gezogenen Schlüsse in der Diskussion vorgestellt. Die Abbildungen 5-7 zeigen für einen einfacheren Vergleich alle dasselbe Variablen-tupel aus Laststufe, Temperaturset und Lastprofil.

Der erste Ansatz ist in Abbildung 5 dargestellt und teilt den Datensatz in zwei unterschiedliche Abschnitte ein. Der hier dargestellte Abschnitt ist der Vorhersageabschnitt. Die

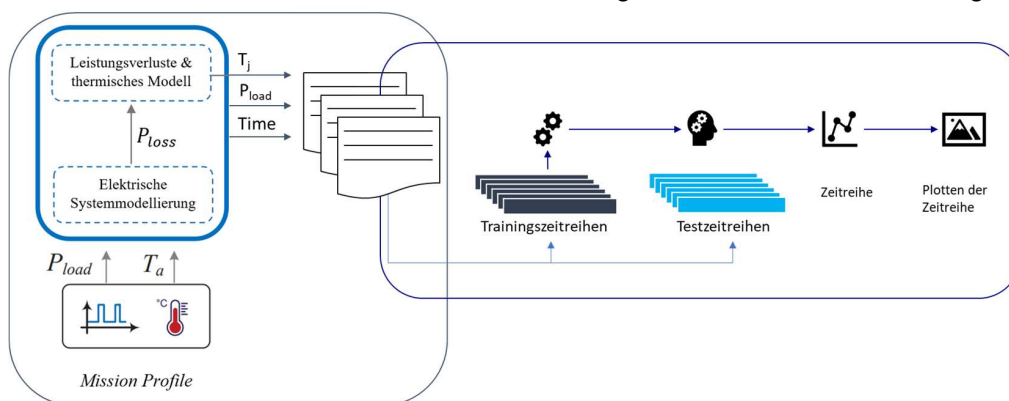


Abbildung 4 Visualisierung des Zusammenspiels des physikalischen Modells und dem Training des datengetriebenen Modells

Die vorgestellten Untersuchungen sind unter anderem im Rahmen des öffentlich geförderten Projektes SesiM entstanden und sind durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) gefördert (FKZ19|21018).

vorhergesagte Temperatur ist in blau dargestellt. Der Sollwert ist in Orange dargestellt. Deutlich sichtbar ist im ersten Drittel der abgebildeten Zeitreihe die noch gute Passform des Modells, welches jedoch ab dem zweiten Drittel stärker von der Ground-Truth abweicht, bis am Ende der Zeitreihe eine deutlichere Diskrepanz sichtbar wird. In Abbildung 6 wird der zweite Ansatz dargestellt. Zum einen wird die gesamte Kurve vorhergesagt, da das Modell separate komplette Zeitverläufe für das Training erhält. Zum anderen wird bei diesem Ansatz deutlich, dass der Algorithmus im zweiten Drittel Schwierigkeiten mit der Vorhersage der Temperatur hat. An einigen Stellen springt der vorhergesagte Temperaturwert. Dieser Ansatz gestaltete sich insbesondere mit der Adaptionsfähigkeit auf unterschiedliche Umgebungstemperaturen schwierig, dies lässt sich im Vergleich mit den anderen vorhergesagten Temperaturprofilen und Leistungsstufen feststellen. Die Ergebnisse des letzten Ansatzes (LSTM-Netzwerk) werden in Abbildung 7 dargestellt. Hier ist erkennbar, dass die Vorhersage dem Ground Truth sehr gut folgt. Die erzeugten Kurven zeigen deutlich die Form der Lastprofile. Es ist nur eine sehr geringe Abweichung festzustellen. Der Algorithmus ermöglicht die vollständige Vorhersage der Zeitreihe, als auch eine gute Passform.

4 Zusammenfassung und Ausblick

Zusammenfassend wurde in diesem Beitrag ein neuartiger Ansatz vorgestellt, wie physikalische und datengetriebene Modelle zu einem hybriden Systemmodell zusammengeführt werden können.

Mithilfe eines physikalischen Modells wurden Datensätze zum Training eines KI-Modells generiert. Darunter zählen neben der simulierten Sperrschichttemperatur die von außen messbaren Umweltparametern wie Leistung und Umgebungstemperatur. Anschließend wurden die unterschiedlichen Evaluationsstufen der Modellbildung visualisiert. Hier zeigte sich der grundlegende Wirkzusammenhang bei allen erstellten Modellen. Es konnten mit den drei verschiedenen Ansätzen unterschiedliche Problemstellungen bei der Auswahl der Trainingsdaten sowie gewählten Trainingsmethoden gezeigt werden. Wenn diese nicht mit Trainingsdaten aller Zeitabschnitte eines Leistungsprofils, Leistungsstufe und Temperaturbands trainiert wurden, zeigten sich Defizite in der Vorhersagegenauigkeit der Modelle. In weiteren Versuchen sollen diese Abweichungen weiter reduziert werden, insbesondere für eine bessere

Vorhersage von Leistungsstufen, die zwischen den trainierten Leistungsstufen liegen. In zukünftigen Untersuchungen ist es von entscheidender Bedeutung, die Degradation der Aufbau- und Verbindungstechnik in ein umfassendes Modell zu integrieren. Dieses Modell wird auf Finite-Elemente-Methode (FEM) Simulationen sowie auf Ergebnissen beschleunigter Alterungstests basieren. Durch die Einbindung dieser Erkenntnisse kann ein physikalisches Modell entwickelt werden, das die fortschreitende Degradation und die Auswirkungen auf die Lebensdauer präzise abbildet. Ein bedeutender Schritt besteht des Weiteren darin, dieses physikalische Degradationsmodell mit einem datengetriebenen Ansatz zu verbinden. Hierbei werden die gesammelten Daten über die tatsächliche Lebensdauer und Degradation der Bauteile genutzt, um das Modell zu kalibrieren und zu validieren. Durch diese Verbindung ist eine präzise Vorhersage der Restlebensdauer möglich. Zur Vereinfachung der Datengenerierung bzw. -übergabe wurde in weiteren Untersuchungen ein Modell entwickelt, das die standardisierte Schnittstelle FMI nutzt. Ähnlich einer Blackbox berechnet dieses Modell auf Basis der Eingangsdaten das entsprechende Ergebnis, in dem Fall die Sperrschichttemperatur. Die Datenerzeugung für das Training des KI-Modells erfolgte mithilfe einer zeiteffizienten Schleife zur automatischen Berechnung des Modells sowie Speicherung der Daten, die in der Open Source Umgebung Python implementiert wurde.

5 Literatur

- [1] Daigle, M.J. and Goebel, K., Model-based prognostics with concurrent damage progression processes, IEEE Trans. Syst., Man, Cybern.: Syst. 43 (3) (2013),535–546.
- [2] Tsui, K.L. et al., Prognostics and health management: a review on data driven approaches, Math. Problems Eng. 2015, (2015) 1–17
- [3] Liao, L. and Kottig, F., Review of Hybrid Prognostics Approaches for Remaining Useful Life Prediction of Engineered Systems, and an Application to Battery Life Prediction, IEEE Trans. on Reliability, vol. 63, issue 1, 191 – 207.
- [4] Feng N. et al., A Novel LSTM-XGBoost Model Optimized by SSA for Predicting Short-Term Photovoltaic Power, 2023 3rd International Conference on Energy, Power and Electrical Engineering (EPEE), Wuhan, China, 2023, pp. 128-133
- [5] Wang, Y. et al, Short-term load forecasting of industrial customers based on SVM and XGBoost, International Journal of Electrical Power & Energy Systems, vol. 129, (2021) 106830
- [6] Eskandari H. et al, Convolutional and recurrent neural network-based model for short-term load forecasting, Electric Power Systems Research, vol. 195, (2021) 106830
- [7] Elsothy et al, Mission profile-based digital twin framework using functional mock-up interfaces for assessing system's degradation behavior. Proceedings of Microelectronics Reliability (2023)




Abbildung 5: Darstellung der Ergebnisse nach dem ersten Ansatz (Regression)




Abbildung 6: Darstellung der Ergebnisse nach dem zweiten Ansatz (XGBoost)




Abbildung 7: Darstellung der Ergebnisse nach dem dritten Ansatz (LSTM)

Die vorgestellten Untersuchungen sind unter anderem im Rahmen des öffentlich geförderten Projektes SesiM entstanden und sind durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) gefördert (FKZ19|21018).