

Automatisierte Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen mithilfe von Ontologien und Graphen

S. Kamm, M. Sc.; Dr-Ing. **N. Jazdi**; Prof. Dr.-Ing. Dr. h.c. **M. Weyrich**,
Institut für Automatisierungstechnik und Softwaresysteme (IAS) der
Universität Stuttgart, Stuttgart;

Kurzfassung

Im Sinne der Qualitätssicherung sollen zukünftig produzierte Halbleiterbauelemente den steigenden Anforderungen an Zuverlässigkeit, Konnektivität und Automatisierung standhalten. Dazu ist ein Fehleranalyseprozess notwendig. Um die Effizienz zu steigern und die Fehleranfälligkeit zu reduzieren, soll der Fehleranalyseprozesses mit dazugehöriger Datenanalyse automatisiert werden. Dafür muss zunächst ein Konzept für die automatisierte Integration heterogener Daten aus unterschiedlichen Datenquellen auf Basis aktueller Daten Engineering Methoden entwickelt werden. Die Daten aus unterschiedlichen Quellen (z.B. Produktionsdaten, Datenblätter, Analyseverfahren) müssen eindeutig einem Bauelement zugeordnet werden können und neue Daten oder Analyseergebnisse diesem hinzugefügt werden können. In diesem Beitrag wird für die automatisierte Datenintegration des Fehleranalyseprozesses von Halbleiterbauelementen ein Konzept mithilfe von Ontologien und Graphen vorgestellt und dessen Mehrwerte anhand eines Anwendungsfalls mit einer prototypischen Umsetzung diskutiert. Dafür wird ein hybrider Ontologie-Ansatz genutzt, um die heterogenen Daten in einem Knowledge Graphen zu verknüpfen. Der vorgestellte Ansatz ermöglicht sowohl eine lokale als auch eine globale Datenanalyse. Dadurch können sowohl bisher entwickelte Datenanalyse-Ansätze genutzt werden, als auch neue Algorithmen aufgebaut werden.

1. Einleitung und Grundlagen

Halbleiterbauelemente sind wesentliche Komponenten für die Digitalisierung und Automatisierung von vielen Bereichen, wie z.B. der Produktion (Smart Manufacturing), dem Automobilbereich (Automatisierte und Autonome Fahrzeuge) oder der intelligenten Erzeugung und Nutzung von erneuerbaren Energien. Aufgrund steigender Anforderungen an die Funktionalität und der Bedeutung von Halbleiterbauelementen wird die Zuverlässigkeit dieser Komponenten immer bedeutender [1]. Es ist jedoch unmöglich, alle auftretenden Fehler vorzeitig zu entdecken. Es können Fehler während der Herstellung, der Bestückung oder der

Lebensdauer auftreten [2]. Um die Zuverlässigkeit von Halbleiterbauelementen zu erhöhen, ist die Analyse von defekten Elementen zur Bestimmung der Fehlerursache unabdingbar. Dazu muss zunächst ein Fehler erkannt werden, z.B. durch eine fehlerhafte Funktion einer Komponente. In der folgenden Fehlerdiagnose wird der auftretende Fehler klassifiziert, lokalisiert und charakterisiert [3]. Daraufhin kann die konkrete Fehlerursache bestimmt werden. Zusammengefasst wird im weiteren Verlauf von der Fehleranalyse gesprochen. Das gewonnene Wissen aus der Fehleranalyse kann in den Entwicklungsprozess fließen, um aufgetretene Fehler in Zukunft zu verhindern und damit die Zuverlässigkeit zukünftiger Komponenten zu erhöhen. Um den Fehler eindeutig bestimmen und lokalisieren zu können, wird eine Vielzahl an Methoden benötigt. Einige beispielhafte nicht-destruktive (zerstörungsfreie) und destruktive (zerstörende) Methoden sind in Tabelle 1 gelistet [2]:

Tabelle 1: Beispielhafte destruktive und nicht-destruktive Fehleranalysemethoden

Nicht-destruktive Methoden		Destruktive Methoden	
<i>Methodik</i>	<i>Anwendung</i>	<i>Methodik</i>	<i>Anwendung</i>
Mikroskopie	Externe und interne visuelle Inspektion	Entkapselung	Öffnen des Packages
Kurventracer	Identifikation der Breakdown-Spannung, Leakage	Chromatographie	Chemische Analyse
Time-Domain Reflektometrie	Elektrisches Reflektionsmuster	Sectioning	Querschnitt durch die Probe

Generell kann in nicht-destruktive und destruktive Techniken unterschieden werden. Die unterschiedlichen Techniken können unterschiedliche Bereiche der Fehleranalyse unterstützen. So können mithilfe eines Kurventracers offene Verbindungen, Kurzschlüsse oder eine Spannungsdegradation detektiert und bestimmt werden [2]. Mithilfe der Time-Domain Reflektometrie (TDR) können ebenfalls unterschiedliche elektrische Fehlermuster detektiert werden und der Fehler lokalisiert werden [4]. Mikroskopische Techniken wie z.B. die Scanning Acoustic Microscopy (SAM) können helfen, mechanische und thermomechanische Fehler zu detektieren und lokalisieren [5]. Mithilfe von destruktiven Techniken wird das Bauteil zerstört, und weitere Untersuchungen sind nur noch sehr beschränkt möglich. Diese Techniken können jedoch relevant sein für eine eindeutige Fehleranalyse. In Bild 1 ist ein vereinfachter Fehleranalyse Prozess dargestellt. Dabei werden in den unterschiedlichen Analyseschritten unterschiedliche Fehleranalysetechniken eingesetzt. Die gewonnenen Erkenntnisse aus der

Fehleranalyse fließen zum einen in den Entwicklungsprozess und zum anderen in die zukünftige Fehleranalyse mit ein.

Je nach Bauelement und Fehlerart sind nicht alle Schritte des Prozesses notwendig, um eine eindeutige Fehleranalyse zu ermöglichen. Dennoch zeigt Bild 1 die Komplexität des Prozesses, in welchem eine Vielfalt an Daten entsteht, die miteinander in Verbindung stehen (unterschiedlichste Messungen an eventuell unterschiedlichen Orten eines Bauteils). Auf Basis dieser Datenvielfalt soll die finale Fehlerursache bestimmt werden. Um diese Datenvielfalt effizient analysieren zu können, bedarf es jedoch einer möglichst einheitlichen und automatisierten Datenintegration, -haltung und -bereitstellung.

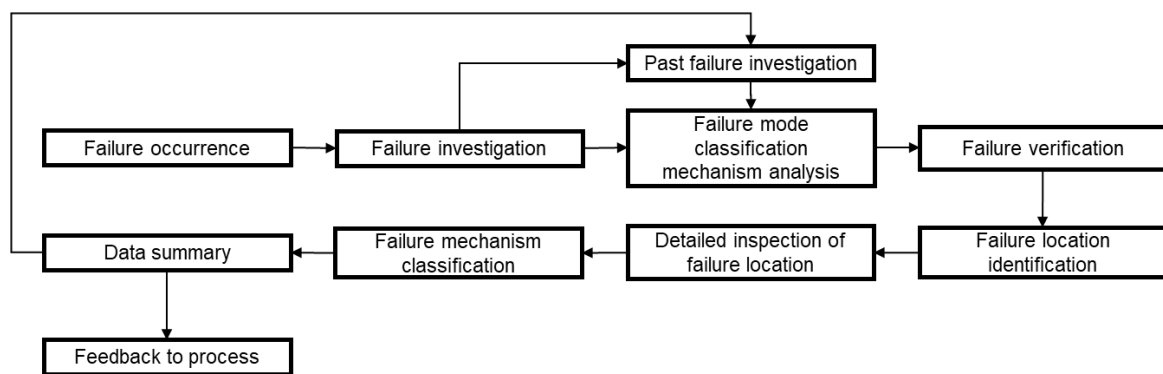


Bild 1: Beispielhafter Fehleranalyse Prozess in Anlehnung an [2]

Für die automatisierte Datenintegration und einheitliche formale und semantische Beschreibung der vorliegenden heterogenen Daten eignen sich Wissensbasen, da in diesen Wissensbasen die Daten und ihre Relationen formal und einheitlich beschrieben werden. In die Modellierung dieser Wissensbasen fließt vorhandenes Expertenwissen ein, was in der Fehleranalyse von Halbleiterbauelementen häufig über viele Jahre aufgebaut wurde. Eine weit verbreitete Realisierungsmöglichkeit für Wissensbasen sind Ontologien. Eine Ontologie wird als formale, explizite Spezifikation einer gemeinsamen Konzeptualisierung definiert, die sich durch eine hohe semantische Ausdruckskraft auszeichnet, die für eine erhöhte Komplexität erforderlich ist [6]. Ontologien können in sogenannte Lightweight Ontologien und Heavyweight Ontologien anhand ihrer Ausdruckskraft unterschieden werden. Lightweight Ontologien beinhalten Konzepte, Taxonomien, Beziehungen zwischen Konzepten und Eigenschaften die Konzepte beschreiben (z.B. ein UML Klassendiagramm). Heavyweight Ontologien fügen mathematische Axiome und Begrenzungen hinzu [7]. Ontologien versprechen dabei zwei Arten von Interoperabilität zu erreichen. Auf der einen Seite Interoperabilität zwischen mehreren Repräsentationen der Realität (z.B. unterschiedliche Datenmodelle), die sich in Computersystemen befinden. Auf der anderen Seite die Interoperabilität zwischen solchen Repräsentationen und der Realität [8]. Dadurch kann eine Ontologie die entstehende große

semantische Heterogenität auflösen und eine einheitliche formale und semantische Datenbeschreibung realisieren. Ein wissensbasiertes System erweitert eine solche Wissensbasis um eine sogenannte *Reasoning Engine*, welche Logik und Folgerungsmechanismen einbringt, um neues Wissen zu generieren (z.B. Empfehlung fehlender Relationen oder Detektion von falschen Relationen). Darüber hinaus erweitert der Knowledge Graph ein wissensbasiertes System um die Datenintegration. Mithilfe eines Knowledge Graphen können ebenfalls mehrere Wissensbasen (z.B. Ontologien) miteinander verknüpft und gegebenenfalls erweitert werden. In Bild 2 (links) ist eine schematische graphische Darstellung des Knowledge Graphen mit seinen Bestandteilen gegeben. Zusammenfassend erfasst und integriert ein Knowledge Graph Informationen in einer Ontologie und wendet einen Reasoner an, um neues Wissen abzuleiten [9]. Ein daraus resultierender Graph (z.B. Bild 2 (rechts)) kann in einer Graph-Datenbank abgelegt werden. Knowledge Graphen haben seit der Einführung von Google's Knowledge Graph in 2012 [10] viel Aufmerksamkeit gewonnen und werden als Herzstück der nächsten Generation von Enterprise Informationssystemen gesehen [11].

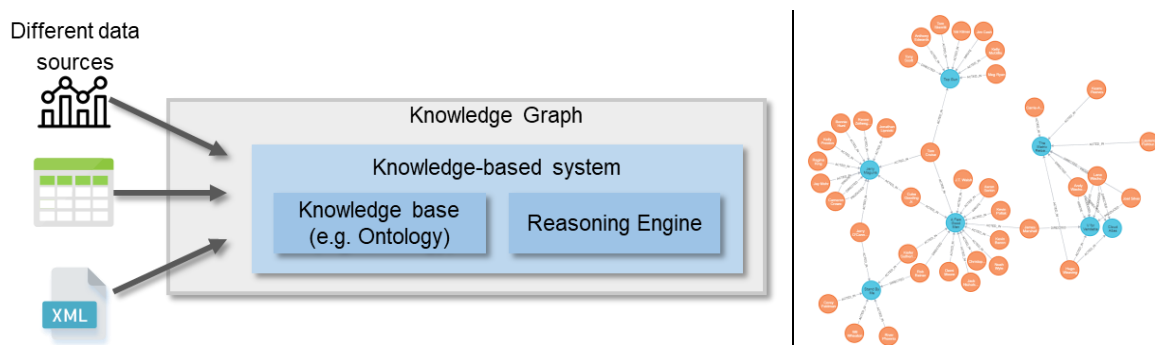


Bild 2: Schematische Darstellung eines Knowledge Graphen (links) und beispielhafter resultierender Graph (rechts)

In diesem Beitrag wird gezeigt, wie eine automatisierte Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen mithilfe von Ontologien und Graphen aufgebaut und realisiert werden kann. Dafür werden zunächst in Kapitel 2 die Herausforderungen der automatisierten Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen sowie bestehende Arbeiten in diesem Gebiet aufgezeigt. Daraufhin wird in Kapitel 3 das Konzept vorgestellt. In Kapitel 4 wird eine Realisierung und prototypische Umsetzung des vorgestellten Konzeptes gezeigt. Abschließend gibt Kapitel 5 eine Zusammenfassung des Beitrags und Ausblick auf zukünftige Arbeiten.

2. Herausforderungen und bestehende Arbeiten

Durch die große Datenvielfalt im Fehleranalyseprozess von Halbleiterbauelementen entstehen Herausforderungen für die Datenintegration, -haltung und -nutzung. Die Daten entstehen an unterschiedlichen Messgeräten von unterschiedlichen Herstellern, was in einer großen semantischen Heterogenität resultiert [7]. Um die Daten möglichst automatisiert zu integrieren, zu verarbeiten und damit für den Fehleranalyseprozess nutzbar zu machen, bedarf es einheitliche, formale und semantische Beschreibungen der Daten, um diese semantische Heterogenität zu lösen [12]. Mithilfe einer semantischen Beschreibung kann die Interoperabilität von Daten unterschiedlicher Systeme (z.B. unterschiedliche Cyber-Physischer Systeme – CPS) erreicht werden. Zudem stellt eine semantische Beschreibung eine notwendige Voraussetzung für das Nutzen der Potenziale dieser heterogenen Systeme dar [13]. Diese semantische Beschreibung ermöglicht unter anderem die einheitliche und maschinenlesbare Bereitstellung der Daten, um im weiteren Verlauf die Fehleranalyse zu vereinfachen bzw. zu automatisieren, z.B. mithilfe von Machine Learning Algorithmen [14]. Klassische relationale Datenbanken stoßen bei einer ansteigenden Datenheterogenität an ihre Grenzen und können die vorhandene Menge an komplexen Relationen oft nicht beherrschen [15]. Die genannten Herausforderungen können in drei Punkten zusammengefasst werden:

- Durch Vielzahl an Messgeräten entsteht eine große semantische Heterogenität [7]
- Zur Auflösung der großen semantischen Heterogenität wird eine einheitliche formale und semantische Datenbeschreibung benötigt [12]
- Die heterogenen Daten mit ihren formalen und semantischen Beschreibungen müssen gemanagt werden, wobei die vorhandene Datenvielfalt und die komplexen Relationen abgebildet werden [15]

Im betrachteten Szenario der Fehleranalyse werden Daten in unterschiedlichen Datenquellen generiert, die verknüpft werden müssen. Zudem sind darüber hinaus häufig weitere Daten, z.B. aus der Produktion (Technische Datenblätter) oder aus dem Lebenszyklus des Bauteils (Umgebungsbedingungen) vorhanden, welche für die Fehleranalyse relevant sein können. Mithilfe von Ontologie-basierten Daten Integration (OBDI) Ansätzen können Daten in eine definierte Ontologie integriert werden. Ontologie-basierte Daten Integration ist eine weit verbreitete Technik, um die zuvor genannten Herausforderungen zu lösen und besteht aus drei Komponenten [16, 17]:

- Die Datenquelle, welche die Daten erzeugt
- Eine Ontologie zur Repräsentation des vorhandenen Wissens in Form einer Wissensbasis
- Ein Mapping zwischen diesen beiden Komponenten

Ontologie-basierte Daten Integration-Ansätze können in drei verschiedene Arten unterteilt werden. Dem Single Ontologie Ansatz, dem Multiple Ontologie Ansatz und dem hybriden Ontologie Ansatz. Beim Single Ontologie Ansatz wird eine globale Ontologie als Referenz-Modell aufgesetzt, welche die gesamte Domäne beschreibt. Im Gegensatz dazu wird beim Multiple Ontologie Ansatz jede Datenquelle semantisch von einer eigenen lokalen Ontologie beschrieben und zwischen den unterschiedlichen Ontologien Austauschformate bestimmt. Der hybride Ontologie Ansatz kombiniert diese beiden, in dem er lokale Ontologie für die einzelnen Datenquellen nutzt und diese dann in eine übergeordnete Ontologie integriert [18].

Es gibt viele vorhandene Ansätze und Projekte, bei denen globale Ontologien für eine Domäne entwickelt wurden. Bekanntes Beispiel dafür ist z.B. die Semantic Sensor Network (SSN)-Ontologie aus einem Projekt des World Wide Web Konsortiums (W3C) [19]. Diese Ontologie soll Sensorik und deren Beobachtungen beschreiben. Weiter gibt es die Smart Appliances Reference (SAREF)-Ontologie [20], welche durch das ETSI (European Telecommunications Standards Institute) standardisiert wurde. Diese Ontologie soll Daten verknüpfen und Kommunikation über verschiedene Protokolle für IoT Geräte in smarten Anwendungen ermöglichen. Der Fokus lag dabei auf Gebäude Anwendungen. Um diese Ontologie auf weitere Bereiche anzuwenden, wurden Erweiterungen z.B. für die Industrie und Produktions Domäne mit SAREF4INMA, entwickelt [21].

Häufig wird der hybride Ontologie Ansatz genutzt, da eine globale Ontologie nicht alle spezifischen Bereiche der betrachteten Domäne abdecken kann [22]. In [23] wurde eine Ontologie für die Produktion von Halbleiterbauelementen entwickelt. Die entwickelte Semantik wurde mit geographischen Produktionsdaten angereichert und bietet die Möglichkeit, Rückschlüsse für die Produktion aus den semantisch beschriebenen Daten zu ziehen. Der Siemens Industrial Knowledge Graph [24] soll das Problem von isoliert und heterogen vorliegenden Produktionsdaten (Datensilos) lösen. Dafür soll der Knowledge Graph eine integrierte Sicht über diese verteilten Daten auf einer erhöhten Ebene liefern. In [25] prüfte Ford das Potenzial von föderierten, verteilten Ontologien, um damit Schlussfolgerungen in der Produktion zu unterstützen.

Insgesamt haben Ontologien mit Knowledge Graphen das Potenzial, die beschriebenen Herausforderungen zu lösen, die Daten automatisiert zu integrieren und in einer semantisch einheitlichen und formalen Beschreibung bereit zu stellen. Damit kann semantische Heterogenität aufgelöst werden, was eine eindeutige Bedeutung der Daten und damit maschinen-lesbarkeit für die weitere Verarbeitung sicherstellt.

3. Automatisierte Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen mithilfe von Ontologien und Graphen

Als Basis für eine intelligente Fehleranalyse von Halbleiterbauelementen ist eine automatisierte Datenintegration notwendig. Dabei soll vorhandenes Expertenwissen in der Modellierung genutzt werden und die Daten für die weitere Analyse vorbereitet und bereitgestellt werden. Wie im vorherigen Kapitel gezeigt, eignen sich Ontologien und Graphen zur Bewältigung der auftretenden Herausforderungen.

Eine globale einheitliche Beschreibung von allen Geräten ist nicht möglich, da die unterschiedlichen lokalen Messgeräte sehr heterogen sind. Eine grundlegende, übergeordnete Fehleranalyse-Struktur kann jedoch abgebildet werden. Aufgrund dessen wird ein hybrider Ontologie-Ansatz, wie in Bild 3 gezeigt, gewählt. Für jede auftretende Datenquelle (1...n) wird das Wissen eines Datenexperten (1...n) in Kombination mit dem Wissen eines Ontologieexperten genutzt, um eine lokale Lightweight-Ontologie dieser Datenquellen zu erzeugen. Durch diesen Schritt können die Daten dieser Datenquelle erfasst werden. Mithilfe der modellierten Lightweight-Ontologie werden die Daten vorbereitet und in die passende lokale Modellierung gebracht. Für eine übergeordnete Ontologie Fehleranalyse sollen möglichst einzelne Teile von bestehenden Ontologien (z.B. SAREF oder SSN), so genannte Ontologie Design Patterns (ODP), wiederverwendet werden [7]. Durch die Wiederverwendung können Entwicklungsaufwände reduziert. Zudem sind diese Ontologien bereits über einen langen Zeitraum entwickelt und eingesetzt worden und haben ihre Nutzbarkeit gezeigt. Zur Anpassung bzw. Erweiterung der wiederverwendeten Design Patterns ist Domänenwissen notwendig. Innerhalb der Ontologie Fehleranalyse werden schließlich die lokalen Lightweight-Ontologien automatisiert kombiniert und verknüpft, z.B. können über die einheitliche ID eines Bauelements Messungen aus unterschiedlichen Datenquellen einem gleichen Bauteil

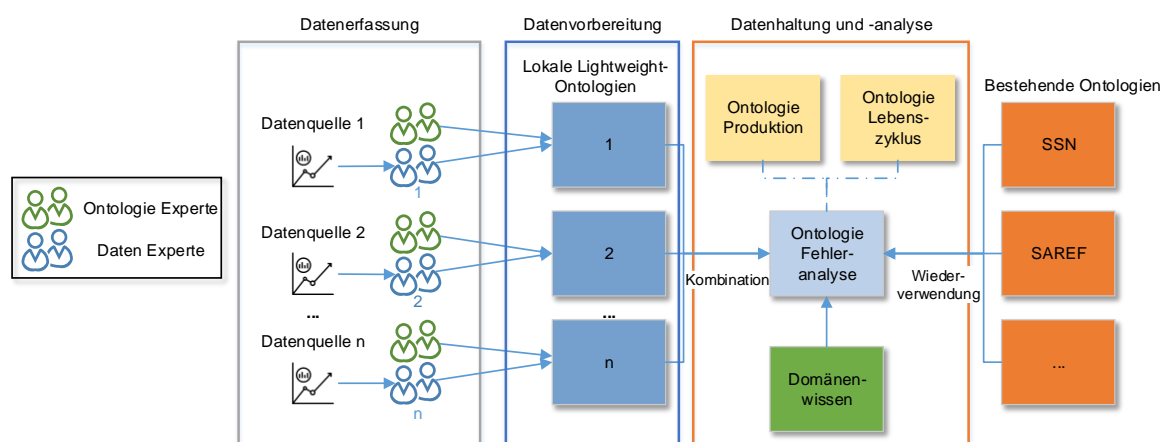


Bild 3: Konzeptioneller Ansatz für die automatisierte Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen

zugeordnet werden. Die Ontologie Fehleranalyse ermöglicht die einheitliche und zentrale Datenhaltung sowie die weitere Datenanalyse. Die Ontologie Fehleranalyse kann mit weiteren Ontologien (z.B. einer Ontologie Produktion oder Ontologie Lebenszyklus) verknüpft werden. Dadurch sollen Erkenntnisse aus der Fehleranalyse mit Informationen aus der Produktion oder dem Lebenszyklus verknüpft werden. Zukünftig sollen dadurch bisher unbekannte Verknüpfungen zwischen Produktionseinflüssen, Umgebungsbedingungen im Feld und einem aufgetretenen Fehler intelligent detektiert werden. Für eine Datenquelle (hier Time-Domain Reflektometrie) sieht der Daten- und Informationsfluss mit diesem Konzept wie in Bild 4 dargestellt aus.

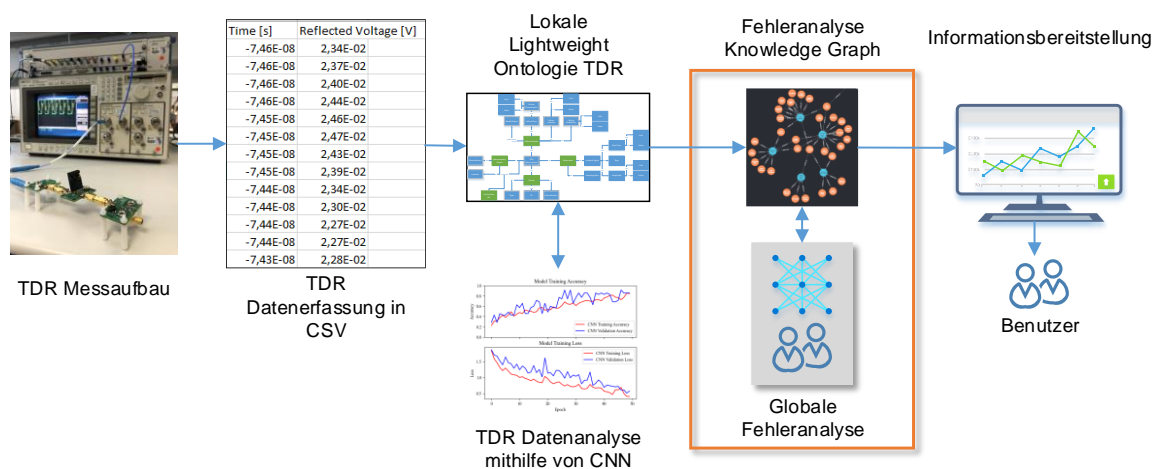


Bild 4: Daten- und Informationsfluss einer Datenquelle (hier Time-Domain Reflektometrie)

Zunächst werden die Daten einer Datenquelle erfasst und gegebenenfalls vor- oder aufbereitet vom Messgerät (z.B. in einer CSV-Datei). Die erfassten Daten und Datentypen variieren dabei stark von Gerät zu Gerät. Zusätzlich zu der Messung können auch beschreibende Daten der Messung (z.B. Parametereinstellungen) oder Umgebungsdaten (z.B. Temperatur) miterfasst werden. Die erfassten Daten fließen in die erstellte lokale Lightweight Ontologie ein, die für jede Datenquelle variieren kann und das Informationsmodell der Datenquelle darstellt. Auf dieser Stufe kann eine erste lokale Datenanalyse auf Basis der erfassten Daten durchgeführt werden. Bei der Fehleranalyse von Halbleiterbauelementen kann z.B. eine erste Schätzung des Fehlertyps oder -orts durchgeführt werden. Diese Analyse kann durch einen Experten oder automatisiert, z.B. durch ein Machine Learning Modell [26], durchgeführt werden. Die Ergebnisse der lokalen Datenanalyse werden an die lokale Ontologie zurück übermittelt und dort hinzugefügt. Diese lokale Ontologie wird in die Top-Level Ontologie integriert und mit weiteren vorhandenen Daten aus anderen lokalen Ontologien verbunden. Auf diesem Level kann eine „globale“ Datenanalyse auf Basis aller verfügbaren Daten durchgeführt werden. Diese Datenanalyse kann ebenfalls durch einen Experten oder ein Programm automatisiert

durchgeführt werden. Die Komponenten der Datenintegration, der Datenhaltung und der Datenanalyse auf diesem Level formen den Knowledge Graph. Der Knowledge Graph bietet die Möglichkeit, Analysen der vorhandenen Relationen durchzuführen (z.B. Detektion von fehlerhaften Daten oder Relationen, Prädiktion fehlender Relationen, etc.) oder mithilfe von Graph Neural Networks eine globale Fehleranalyse aus den vorhandenen Daten durchzuführen und damit neue, bisher unbekannte Zusammenhänge zu detektieren (z.B. Zusammenhänge zwischen Fehlern und Produktionsparametern bei der Kombination von Fehleranalyse- und Produktionsdaten). Der Knowledge Graph bietet weiter die Möglichkeit einer intuitiven Datenvisualisierung in Graph-Form sowie eines effizienten Datenzugriffs mithilfe von Graph Query Sprachen wie Cypher oder SPARQL.

4. Realisierung und Prototypische Umsetzung

Für die Realisierung wurden Daten des Time-Domain Reflektometrie Verfahrens genutzt. Dieses Verfahren bietet die Möglichkeit, einen Fehler in einem Bauelement mithilfe eines elektrischen Signals zu detektieren. Dabei wird ein elektrisches Signal inziert und das reflektierte Signal gemessen. Anhand des Reflektionssignal kann der Zustand des Bauelements detektiert werden. Eine beispielhafte Messung für einen SiC Transistor SCT2160KE der Firma Rohm ist in Bild 5 zu sehen.

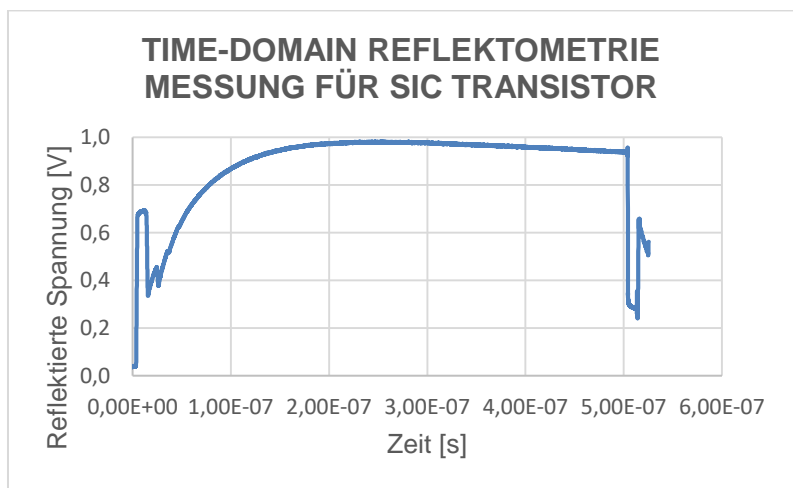


Bild 5: Beispielhafte Time-Domain Reflektometrie Messung (links) für SiC Transistor SCT2160KE der Firma Rohm (rechts)

Für diese Datenquelle wurde ein Informationsmodell, die lokale Lightweight-Ontologie aufgebaut. Diese ist in Bild 6 dargestellt. Diese und auch weitere lokale Ontologien können zukünftig iterativ erweitert werden.

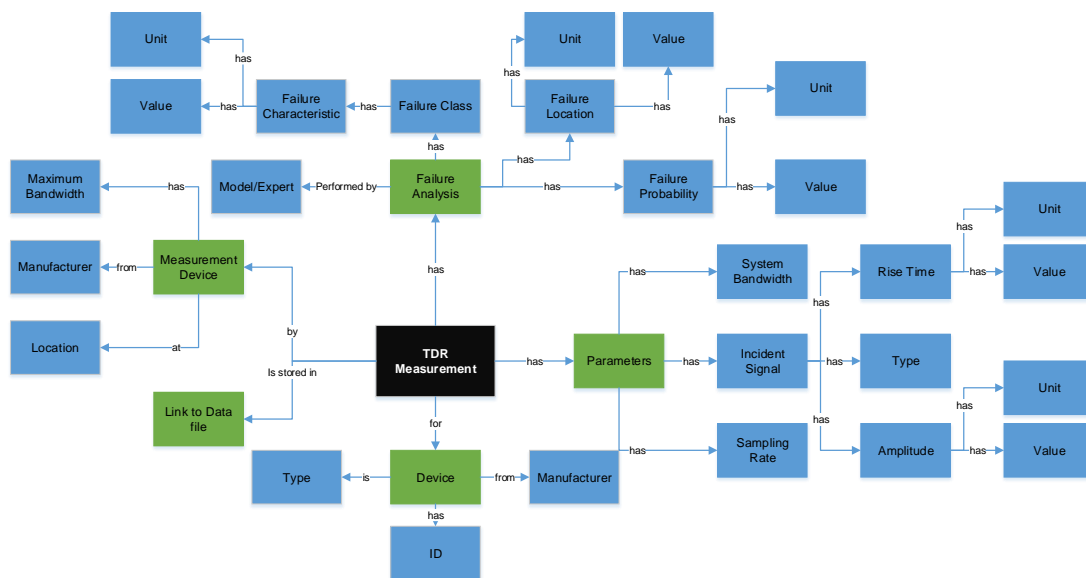


Bild 6: Lokale Lightweight-Ontologie für das Time Domain Reflektometrie-Verfahren

Der Ausgangspunkt der lokalen Ontologie bildet die *Time-Domain Reflektometrie (TDR) Measurement* (schwarz). Die grün dargestellten Sub-Klassen *Measurement Device*, *Link to Data File*, *Device*, *Parameters* und *Failure Analysis* sind für jede Datenquelle zu erwarten und werden von der Ontologie Fehleranalyse wiederverwendet. Die darunter aufgeführten Attribute variieren von Datenquelle zu Datenquelle. Die Eigenschaften von *Measurement Device*, *Link to Data File*, *Device*, *Parameters* werden direkt bei der Datenerfassung befüllt. Die Informationen für die Sub-Klasse *Failure Analysis* werden von der lokalen Datenanalyse geliefert. Im hier gezeigten Beispiel wurde eine hybride Modellierungsmethodik eingesetzt. Dabei wurde ein Convolutional Neural Network in Kombination mit physikalischen Modellen genutzt, um die Attribute der Fehleranalyse (Fehlerklasse, Fehlerort, Fehlerwahrscheinlichkeit und Fehlercharakteristik) automatisiert zu bestimmen und zu befüllen. In Bild 7 wird die befüllte lokale Ontologie für eine beispielhafte offene Verbindung gezeigt. Diese Instanz der lokalen Ontologie wurde in Neo4j realisiert. Die Daten für die lokale Ontologie werden in einer JSON-Datei bereitgestellt.

Die Vorteile der verwendeten Modellierung mithilfe der separaten lokalen Ontologien sind die **Erweiterbarkeit**, **Änderbarkeit** und die **partielle Wiederverwendbarkeit**. Es können neue Datenquellen (z.B. ein neues Messgerät) hinzugefügt werden, bestehende Modelle können angepasst werden und vorhandene Teil-Modellierungen (z.B. für die Sub-Klasse *Device*) können für neue Datenquellen wiederverwendet werden. Diese befüllte lokale Ontologie wird an die globale Ontologie weitergeleitet, in der diese Daten mit bestehenden Daten verknüpft werden. Auf diesem Level können weitere Datenanalysen durchgeführt werden. Dadurch kann eine globale Fehleranalyse auf Basis aller verfügbaren und verknüpften Daten durchgeführt

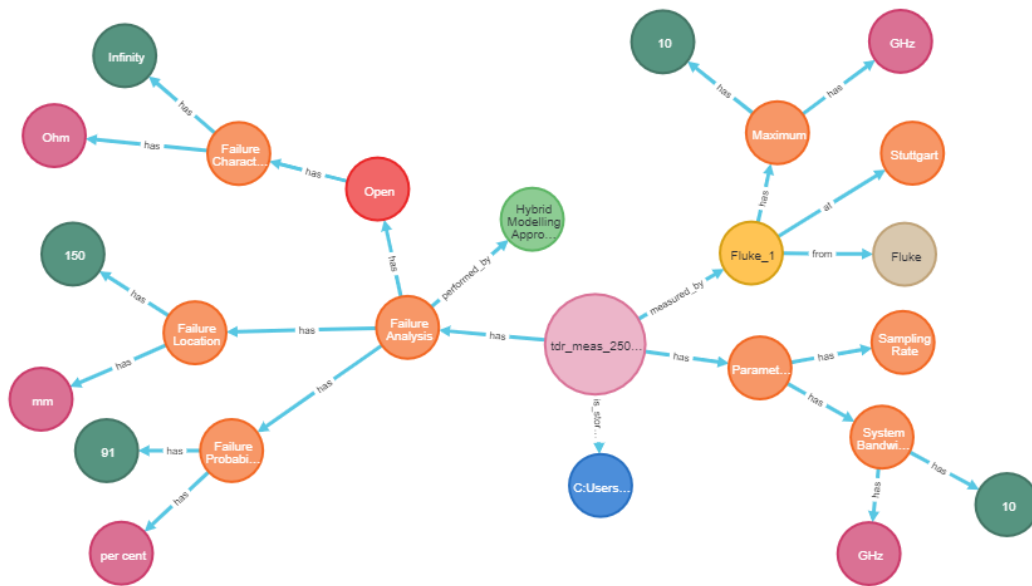


Bild 7: Befüllung der lokalen Lightweight-Ontologie auf Basis einer beispielhaften Time Domain Reflektometrie-Messung

werden. Die Daten sind für den Benutzer in der Fehleranalyse an einer zentralen Stelle verfügbar, wodurch die Fehleranalyse automatisiert und optimiert werden kann. Die Daten der einzelnen Datenquellen werden dabei automatisiert von der lokalen Datenerfassung mithilfe eines Mappings in den Knowledge Graphen integriert.

5. Zusammenfassung und Ausblick

In diesem Beitrag wurde ein Konzept für die automatisierte Datenintegration für den Fehleranalyseprozess von Halbleiterbauelementen mithilfe von Ontologien und Graphen vorgestellt. Das Konzept basiert auf einem hybriden Ontologie-Modellierungsansatz.

- Der Ansatz ermöglicht eine einfache Erweiterbarkeit, Änderbarkeit und partielle Wiederverwendbarkeit, um neue Datenquelle hinzufügen zu können.
- Einzelne lokale Datenquellen können mit weiteren Datenquellen einfach verbunden werden
- Der Ansatz ermöglicht sowohl eine lokale als auch eine globale Datenanalyse, in dem mehrere Datenquellen kombiniert für die Analyse genutzt werden können
- Es können über einen zentralen Zugriff alle verknüpften Daten abgefragt werden
- Weitere externe Datenquellen (z.B. Datenblätter aus dem Internet oder verfügbare Produktionsdaten) können mit dem aufgebauten Knowledge Graphen verknüpft werden, um weitere Informationen einzubinden.

Zukünftig wird weiter die automatisierte Ontologierstellung und Wiederverwendung mithilfe von Ontology Design Pattern und Methoden wie Ontology Matching oder Ontology Alignment

untersucht. Dadurch soll der Aufwand für die Entwicklung der Ontologien reduziert werden. Die globale Datenanalyse auf Basis des Knowledge Graph ist ebenfalls Teil zukünftiger Arbeit. Dafür werden aktuelle Ansätze wie Knowledge Graph Embeddings und Graph Neural Networks untersucht, mit deren Hilfe Daten aus unterschiedlichsten Datenquellen gemeinsam für die Fehleranalyse genutzt werden sollen, um das Ergebnis zu verbessern.

Acknowledgement

Diese Arbeit wurde vom deutschen Bundesministerium für Bildung und Forschung (BMBF) im Projekt FA4.0 gefördert. Dieses Projekt ist eine gemeinsame Initiative mit tschechischen, französischen und schwedischen Konsortien in den europäischen EUREKA-Clustern EURIPIDES2 und PENTA.

6. Literaturverzeichnis

- [1] J. Falck *et al.*, "Reliability of power electronic systems: An industry perspective," *IEEE Industrial Electronics Magazine*, vol. 12, no. 2, pp. 24–35, 2018.
- [2] Toshiba Electronic Devices & Storage Corporation, "Reliability Handbook," Toshiba, 2018. Accessed: Apr. 20 2021. [Online]. Available: <https://toshiba.semicon-storage.com/content/dam/toshiba-ss/shared/docs/design-support/reliability/reliability-handbook-tdsc-en.pdf>
- [3] R. Isermann, *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*: Springer Science & Business Media, 2005.
- [4] C. M. Furse *et al.*, "Fault diagnosis for electrical systems and power networks: A review," *IEEE Sensors Journal*, vol. 21, no. 2, pp. 888–906, 2020.
- [5] F. Altmann *et al.*, "Failure analysis techniques for 3d packages," in *2018 IEEE International Symposium on the Physical and Failure Analysis of Integrated Circuits (IPFA)*, 2018, pp. 1–8.
- [6] C. Feilmayr and W. Wöß, "An analysis of ontologies and their success factors for application to business," *Data & Knowledge Engineering*, vol. 101, pp. 1–23, 2016.
- [7] C. Hildebrandt *et al.*, "Ontology Building for Cyber-Physical Systems: Application in the Manufacturing Domain," *IEEE Transactions on Automation Science and Engineering*, vol. 17, no. 3, pp. 1266–1282, 2020.
- [8] M. Hepp, "Ontologies: State of the art, business potential, and grand challenges," *Ontology Management*, pp. 3–22, 2008.
- [9] L. Ehrlinger and W. Wöß, "Towards a Definition of Knowledge Graphs," *SEMANTiCS (Posters, Demos, SuCCESS)*, vol. 48, pp. 1–4, 2016.
- [10] A. Singhal, *Introducing the Knowledge Graph: things, not strings*. [Online]. Available: <https://blog.google/products/search/introducing-knowledge-graph-things-not/> (accessed: Apr. 20 2021).

- [11] M. Galkin *et al.*, "Enterprise Knowledge Graphs: A Semantic Approach for Knowledge Management in the Next Generation of Enterprise Information Systems," in *ICEIS (2)*, 2017, pp. 88–98.
- [12] V. Jirkovsky and M. Obitko, "Semantic Heterogeneity Reduction for Big Data in Industrial Automation," *ITAT*, 2014.
- [13] T. Mueller *et al.*, "Cyber-Physical Production Systems: enhancement with a self-organized reconfiguration management," *Procedia CIRP*, 2020.
- [14] L. Wang, "Heterogeneous data and big data analytics," *Automatic Control and Information Sciences*, vol. 3, no. 1, pp. 8–15, 2017.
- [15] B.-H. Yoon *et al.*, "Use of graph database for the integration of heterogeneous biological data," *Genomics & informatics*, vol. 15, no. 1, p. 19, 2017.
- [16] G. de Giacomo *et al.*, "Using ontologies for semantic data integration," in *A Comprehensive Guide Through the Italian Database Research Over the Last 25 Years*: Springer, 2018, pp. 187–202.
- [17] M. Cheatham and C. Pesquita, "Semantic data integration," in *Handbook of big data technologies*: Springer, 2017, pp. 263–305.
- [18] M. Sabou *et al.*, "Semantic web technologies for data integration in multi-disciplinary engineering," in *Multi-disciplinary engineering for cyber-physical production systems*: Springer, 2017, pp. 301–329.
- [19] M. Compton *et al.*, "The SSN ontology of the W3C semantic sensor network incubator group," *Journal of Web Semantics*, vol. 17, pp. 25–32, 2012.
- [20] L. Daniele *et al.*, "Created in close interaction with the industry: the smart appliances reference (SAREF) ontology," in *International Workshop Formal Ontologies Meet Industries*, 2015, pp. 100–112.
- [21] M. de Roode *et al.*, "SAREF4INMA: a SAREF extension for the industry and manufacturing domain," *Semantic Web*, Preprint, pp. 1–16, 2020.
- [22] N. Sahlab *et al.*, "Dynamic Context Modeling for Cyber-Physical Systems Applied to a Pill Dispenser," in *2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*, 2020, pp. 1435–1438.
- [23] S. Schabus and J. Scholz, "Semantically Annotated Manufacturing Data to support Decision Making in Industry 4.0: A Use-Case Driven Approach," in *Data Science-Analytics and Applications*: Springer, 2017, pp. 97–102.
- [24] A. Fishkin, "Industrial knowledge graph at siemens," in 2017.
- [25] D. Ostrowski *et al.*, "Integration of big data using semantic web technologies," in *2016 IEEE Tenth International Conference on Semantic Computing (ICSC)*, 2016, pp. 382–385.
- [26] B. Maschler *et al.*, "Deep industrial transfer learning at runtime for image recognition," *at-Automatisierungstechnik*, vol. 69, no. 3, pp. 211–220, 2021.