



Finanziert von der
Europäischen Union
NextGenerationEU

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

BMWK-Verbundprojekt: progressivKI
Förderkennzeichen: 19A21006A
Projektlaufzeit: 01.04.2021 bis 30.09.2024

Schlussbericht

**Unterstützung der Entwicklung von effizienten
und sicheren Elektroniksystemen für zukünftige
KFZ-Anwendungen mit automatisierten
Fahrfunktionen mittels einer modular
strukturierten KI-Plattform**

**Teilvorhaben: Optimierung des KI- und
datengesteuerten Entwurfs sowie der
Verifikation**

Version: 0.03
Erstelldatum: 02.12.2024

Autoren: Dr. Michael Kühn, Markus Terres, Jan Krummenauer

Zuwendungsempfänger: Robert Bosch GmbH (Fkz: 19A21006A)

Ansprechpartner: Robert Bosch GmbH (Gesamtkoordinator)
Dr. Michael Kühn
31139 Hildesheim
michael.kuehn4@de.bosch.com

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19A21006A-R gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

© Copyright 2021-2024 by Robert Bosch GmbH, Infineon Technologies AG, Zuken GmbH, Microchip Technology Germany II GmbH & Co. KG, CELUS GmbH, Luminovo GmbH, HOOD GmbH, CLOUD & HEAT Technologies GmbH, DIQA Projektmanagement GmbH, EMC Test NRW GmbH electromagnetic compatibility, InnoZent OWL e.V., Fraunhofer-Institut für Angewandte Informationstechnik FIT, FZI Forschungszentrum Informatik, Technische Universität Dortmund, Helmut-Schmidt-Universität, Technische Universität Berlin FSP Technologien der Mikroperipherik, Hochschule Hamm-Lippstadt.

Inhalt

1 Zusammenfassung	5
2 Ziele	6
2.1 Problemstellung und allgemeine Ziele des Vorhabens	6
2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens	8
2.2.1 KI-gestützter Entwurfsprozess	8
2.2.2 Umsetzung des geplanten modular strukturierten KI-Konzeptes	10
2.2.3 Genutzte KI-Verfahren und Werkzeuge	11
2.2.4 Aufbau KI-Modulbaukasten	16
2.2.5 Entwurfsprozesse	17
2.2.5.1 Allgemeiner Entwurfsprozess	19
2.2.5.2 Funktionale Sicherheit	21
2.2.5.3 Kostenreduktion mittels virtueller Entwicklung	21
2.2.6 IP-Schutz und Interoperabilität	24
2.2.7 Darstellung der wesentlichen Projektinnovationen	26
2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	29
2.3.1 Der Stand von Wissenschaft und Technik	29
2.3.2 Bisherige Arbeiten des Antragstellers	44
2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten	45
3 Technische Ergebnisse	48
3.1 Arbeitspaket 1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform	49
3.1.1 Teilaufgabe 1.1: Funktionale Sicherheit + Entwurfsabläufe (Wertschöpfungsketten) + Schnittstellen	51
3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf	53
3.1.3 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen	54
3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung	59
3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen	61
3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung	63
3.2.3 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule	65
3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten	71

3.3.1	Teilaufgabe 3.2: Implementation Modul-Schnittstellen (Datenaustausch)	73
3.3.2	Teilaufgabe 3.3: Implementation spezifischer und vor-trainierter KI-Module für die Anwendungsebenen #1 und #2	80
3.4	Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik)	87
3.4.1	Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf	90
3.5	Arbeitspaket 5: Projektmanagement & Dissemination	96
3.5.1	Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board	98
3.5.2	Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale	99
4	Verwertung und voraussichtlicher Nutzen	99
6	Quellen	101

1 Zusammenfassung

Die wesentlichen Innovationen im Fahrzeug (~ 90%) beruhen auf Mikroelektronik, an deren Entwicklung und Produktion die gesamte Automobillieferkette beteiligt ist. Es ist daher unabdingbar, die sich ständig weiterentwickelnden neuen Möglichkeiten der Halbleiterindustrie und Elektronik möglichst schnell in die Entwicklung neuer Fahrzeuge einfließen zu lassen.

Dieses Vorhaben adressierte in dem BMWK-Förderaufruf „Künstliche Intelligenz als Schlüsseltechnologie für das Fahrzeug der Zukunft“ den Teilschwerpunkt (C) KI-Verfahren in der Fahrzeugentwicklung \Leftrightarrow KI-Methoden in der Simulation.

Um Entwurfsprozesse für zukünftige KFZ-Elektroniksysteme optimal zu unterstützen und zu automatisieren ist – aufgrund der deutlich zunehmenden Systemkomplexität auf dem Weg zum autonomen und möglicherweise elektrisch angetriebenen Fahrzeug – der Einsatz von KI-Modulen unbedingt erforderlich. Die dabei erforderlichen F+E-Schritte sind so umfangreich, dass sie zukünftig nur mit Hilfe einer KI-basierten Plattform in ausreichend kurzer Zeit und mit vertretbarem Kostenaufwand erfolgreich umgesetzt werden können.

Ziel des Projektes war es, durch den kooperativen Betrieb von KI-Systemen Elektroniksysteme (adressiert werden sollen alle in der SAE J3016 genannten Ebenen (no driving automation (level 0) to full driving automation (level 5)) schneller und zuverlässiger zu entwickeln, um somit für zukünftige Schlüsseltechnologien für die Automobilindustrie eine weltweit wirkende Innovations- und Technologieführerschaft der beteiligten Unternehmen zu erreichen. Typische elektronische Komponenten sind zum Beispiel: ABS oder ESP bzw. ACC. Weiterhin sollen hier genannt werden: Umfelderkennung durch kompakte Sensorik sowie die Sensordatenfusion und -interpretation in Echtzeit mittels leistungsfähiger Steuereinheiten und Multiprozessorsysteme. Zur Entwicklung sicherer und zuverlässiger elektronischer Komponenten und Systeme sind u. a. neue Entwurfs- und Validierungsmethoden auf KI-Basis notwendig.

Thematisch und organisatorisch wurden die F+E-Arbeiten der Projektpartner mittels der Anwendungsebenen #1: PCB-Entwurf/AVT und #2: IC-Entwurf/Sensorik (KI-Module) adressiert.

Durch Anordnung domänen- und applikationsspezifischer Schnittstellenmodule um einen leistungsfähigen KI-Kern wurde eine gute Portabilität und Übertragbarkeit der technischen Lösung auf die individuellen Entwurfsprozesse der beteiligten Industriepartner sichergestellt.

Durch die Einbindung von KI-Modulen in den Entwurfsprozess sollte die Systementwicklung durch KI-basiertes Feedback und Unterstützung des Entwicklers beschleunigt und gleichzeitig die funktionale Sicherheit des Entwurfes erhöht werden, um anschließend Entwurfsprozesse schrittweise weiter automatisieren zu können. Aufgrund der hohen Anforderungen an Innovationsgeschwindigkeit, Sicherheit und Effizienz besitzt dieser Ansatz insbesondere für elektronische KFZ-Anwendungen mit automatisierten Fahrfunktionen eine sehr hohe Relevanz.

Die an dem Vorhaben beteiligten Partner (1 Tier1; 2 Tier2; 1 EDA-Unternehmen; 8 KMU; 6 F+E Einrichtungen und 1 mittelständischer Cloud-Provider (GAIA-X Schnittstelle)) decken alle erforderlichen Komponenten der Wertschöpfungskette ab.

2 Ziele

2.1 Problemstellung und allgemeine Ziele des Vorhabens

90% aller Innovationen im Fahrzeug beruhen auf Mikroelektronik für die gesamte Automobillieferkette. Es ist daher unabdingbar, die sich ständig weiterentwickelnden neuen Möglichkeiten der Halbleiterindustrie und Elektronik möglichst schnell ins Fahrzeug einfließen zu lassen.

Um Entwurfsprozesse für zukünftige KFZ-Elektroniksysteme optimal zu unterstützen und zu automatisieren ist – aufgrund der deutlich zunehmenden Systemkomplexität auf dem Weg zum autonomen und möglicherweise elektrisch angetriebenen Fahrzeug – der Einsatz von KI-Modulen unbedingt erforderlich. Durch die KI-Nutzung können funktional sichere Elektroniksysteme schneller und zuverlässiger entwickelt werden. Typische elektronische Komponenten sind zum Beispiel: ABS oder ESP bzw. ACC. Weiterhin sollen hier genannt werden: Umfelderkennung durch kompakte Sensorik sowie die Sensordatenfusion und -interpretation in Echtzeit mittels leistungsfähiger Steuereinheiten und Multiprozessorsysteme.

Zur Entwicklung sicherer und zuverlässiger elektronischer Komponenten und Systeme sind u. a. neue Entwurfs- und Validierungsmethoden auf KI-Basis notwendig.

Durch die Einbindung von KI-Modulen in den Entwurfsprozess soll die Systementwicklung durch KI-basiertes Feedback und Unterstützung des Entwicklers beschleunigt und gleichzeitig die funktionale Sicherheit des Entwurfes erhöht werden, um anschließend Entwurfsprozesse schrittweise weiter automatisieren zu können. Aufgrund der hohen Anforderungen an Innovationsgeschwindigkeit, Sicherheit und Effizienz besitzt dieser Ansatz insbesondere für elektronische KFZ-Anwendungen mit automatisierten Fahrfunktionen eine sehr hohe Relevanz.

Um KMU den KI-Zugang zu ermöglichen (z.B. zur schnellen Anpassung ihrer Entwurfsprozesse auf sich plötzlich ändernde Requirements im Austausch gegen Daten zur Generierung von Informationen unter Wahrung des IP-Schutzes), wurde in diesem Vorhaben erstmalig ein 2-stufiger Ansatz zum IP-Schutz entwickelt. Dazu wurde eine für jede Domain allgemein zugängliche KI-basierte Wissensbasis (treffender: „Fähigkeiten-Basis“) aufgebaut und kontinuierlich weiterentwickelt. Mit dieser Wissensbasis kommuniziert in einer darunterliegenden Schicht eine unternehmensspezifische KI, die besonderes gegen nicht autorisierte Zugriffe geschützt wird. Damit kann die in progressivKI aufgebaute „Fähigkeiten-Basis“, die nach Projektabschluss kontinuierlich erweitert wird, im Hinblick auf die notwendige Wettbewerbssteigerung optimal genutzt werden.

Im Rahmen dieses Projektes wurden die System-Entwurfsebenen mittels der im Projekt geplanten KI-Anwendungsebenen |PCB-Entwurf| sowie |IC-Entwurf/Intelligente Sensorik| direkt durch die beteiligten Partner adressiert. Durch Anordnung domänen- und applikationsspezifischer Schnittstellenmodule um einen leistungsfähigen KI-Kern wurde eine gute Portabilität und Übertragbarkeit der technischen Lösung auf die individuellen Entwurfsprozesse der beteiligten Industriepartner sichergestellt. Zudem wurde erstmals eine Qualitätssicherung der Lernprozesse durch Metrisierung des Lernerfolges und einer darauf basierenden Algorithmenauswahl und Wahl des Anlernzustandes des Algorithmus ermöglicht. Die bereitgestellte Quantisierung von Lernerfolgen bietet das Alleinstellungsmerkmal einer Qualitätskontrolle für maschinelles Lernen.

Zur Bewältigung des Paradigmenwechsels in der Fahrzeugindustrie hin zu klimaneutralen, autonomen Mobilitätskonzepten steht die Automobilindustrie einschließlich aller an der Wert-schöpfung beteiligten Zulieferer unter einem enormen Innovations- und Effektivierungsdruck. Hier liegt es auf der Hand, die klassische Innovationsstärke der in hohem Maße von KMU bedienten Entwicklung neuer elektronischer Fahrzeugkomponenten durch den Einsatz von Verfahren der künstlichen Intelligenz zu stärken.

Dabei kann vorteilhaft genutzt werden, dass die Digitalisierung in der elektrotechnischen Industrie im Durchschnitt bereits weiter fortgeschritten ist als in vielen anderen industriellen Bereichen: Die Entwicklung neuer Komponenten erfolgt bereits heute in der Regel anhand von mehr oder weniger guten „Digital Twins“ der eigentlichen Komponenten, d.h., anhand von computergestützten Modellen. Anhand dieser Modelle entwickelte Produktionsschritte werden erst danach in die Realität umgesetzt. An dieser Stelle ist jedoch oft noch schwer formalisierbares Expertenwissen erforderlich, oder Entwürfe erweisen sich sogar in der Realität als untauglich.

Aufgrund dieses bereits hohen Digitalisierungsgrades eignet sich die Automobilzulieferindustrie in besonderem Maße als „Pilot“ für die umfängliche Transformation einer Wertschöpfungskette in die Phase der KI-gesteuerten Produktentwicklung. Über die Wertschöpfung in dieser Schlüsseltechnologie selbst hat progressivKI eine Best Practice definiert, wie systemrelevante Wertschöpfungsketten einem effizienteren KI-gesteuerten Entwurf zugeführt werden können.

Durch eine Cloud-Lösung wird eine Übertragbarkeit auf die Entwurfsprozesse industrieller Anwender garantiert, die nicht am Vorhaben beteiligt waren. Hierdurch wird im Zusammenhang mit entsprechenden Nutzungsmodellen, die insbesondere KMU einen Zugang zu KI-basierter Technologieentwicklung sicherstellen, eine zusätzliche Dimension einer erfolgreichen Vermarktung von progressivKI eröffnet. Die Kombination einer belastbaren und sicheren Cloud mit den Resultaten von progressivKI birgt auf lange Sicht das Potential, elektrotechnische Entwurfsprozesse mit verschwindenden Grenzkosten in kürzester Zeit auf neue, plötzlich auftretende Requirements umzustellen. Dies eröffnet nicht nur ein enormes Wertschöpfungspotential durch die Fähigkeit, die für eine klimaneutrale und sichere Mobilität erforderlichen Komponenten wirtschaftlich und unter Berücksichtigung weitreichender Kundenwünsche realisieren zu können, sondern definiert

eine technologische Basis zum Erreichen nationaler Klimaziele bei gleichzeitiger Stärkung der deutschen Wirtschaft. Dadurch, dass mit progressivKI intensive datenbasierte Dienstleistungen mit hohem Sicherheitsanspruch auf den Markt kommen, ist zu erwarten, dass auch der Ausbau der Serverinfrastruktur in Europa angekurbelt wird mit den entsprechenden positiven konjunkturellen Effekten.

2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens

2.2.1 KI-gestützter Entwurfsprozess

Die Digitalisierung ist in der elektrotechnischen Industrie im Durchschnitt bereits weiter fortgeschritten als in vielen anderen industriellen Bereichen. Dies wird an dem vergleichsweise hohen Virtualisierungsgrad deutlich: Die Entwicklung neuer Komponenten erfolgt bereits heute in der Regel anhand von mehr oder weniger guten „Digital Twins“ der eigentlichen Komponenten, d.h., anhand von computergestützten Modellen. Anhand dieser Modelle entwickelte Produktionsschritte werden erst danach in die Realität umgesetzt. An dieser Stelle ist jedoch oft noch schwer formalisierbares Expertenwissen erforderlich, oder Entwürfe erweisen sich sogar in der Realität als untauglich.

Genau an dieser Stelle setzt der KI-gestützte Entwurf an. Dazu werden die bereits teil-virtualisierten Prozesse in eine abstrakte Beschreibungssprache übertragen und so für eine Vielzahl von KI-Algorithmen analysier- und optimierbar. Im Projekt progressivKI soll anhand eines generalisierten KI-Entwurfsprozesses für komplexe Systeme untersucht werden, auf welche Weise es möglich ist, iterativ über die Ebene der einzelnen Subsysteme bis hinunter auf Komponentenebene eine Analyse der entsprechenden Funktionen und damit auch der funktionalen Sicherheit bereitstellen zu können. Hierbei zeigt sich eine hohe Komplexität, da die einzelnen Komponenten eines komplexen Systems aus Hardware, z.B. konfigurierbarer Hardware (FPGA) und Software bestehen können. Die KI-Module sollen all diese einzelnen Komponenten hinsichtlich ihrer funktionalen Sicherheit untersuchen und im Zusammenhang bewerten, ob durch bereits implementierte Maßnahmen eine hinreichende Sicherheit gewährleistet werden kann. Ein Einsatz dieser KI-Verfahren kann dazu beitragen, im Rahmen von Industrieanwendungen, im Bereich des autonomen Fahrens, etc. dafür zu sorgen, dass bessere Systeme in kürzerer Zeit entwickelt werden können, bei denen trotzdem eine hohe Sicherheit der Funktion gewährleistet ist.

Bekanntlich ist die Definition des Begriffes „künstliche Intelligenz“ schwierig – schon allein, da unklar ist, wie der zugrunde liegende Begriff „Intelligenz“ zu fassen ist und welche kognitiven Leistungen diesem zuzuordnen sind. In dieser Gesamtvorhabenbeschreibung soll der Begriff „künstliche Intelligenz“ daher nicht in seiner umgangssprachlichen Bedeutung als Oberbegriff für computerbasierte Methoden, die Aspekte der menschlichen Intelligenz, insbesondere dessen Lernvermögen aus Erfahrungen, auf unterschiedliche Arten nachbilden, verwendet werden, sondern lediglich zur Abgrenzung einer Forschungsdisziplin gegenüber anderen wissenschaftlichen Bereichen (siehe bitte die folgende Tabelle 1). Dies vermeidet die Diskussion, was „Intelligenz“ eigentlich ist, die sich zwangsläufig ergeben würde, wenn dem Begriff der "künstlichen Intelligenz" auch eine interpretierende Bedeutung gegeben werden würde. Die Interpretation des Begriffs „künstliche Intelligenz“ hat beispielsweise in

der Vergangenheit dazu geführt, dass die Definition von KI vom jeweils erzielten Fortschritt abhängig wurde, da allgemein die Neigung besteht, die bereits verstandenen („entzauberten“) Aspekte von Lernprozessen aus der Definition herauszunehmen. Genau dieses Phänomen ("AI effect") wird in dem bekannten Aphorismus "Artificial intelligence is whatever hasn't been done yet“ von Larry Tesler thematisiert.

Hierzu schreibt Pamela McCorduck: "Practical AI successes, computational programs that actually achieved intelligent behavior, were soon assimilated into whatever application domain they were found to be useful in, and became silent partners alongside other problem-solving approaches, which left AI researchers to deal only with the "failures", the tough nuts that couldn't yet be cracked.“ (McCorduck, Pamela (2004), Machines Who Think (2nd ed.), Natick, MA: A. K. Peters, Ltd., ISBN 1-56881-205-1, p. 423). Um andererseits modern Verfahren des selbstorganisierten Lernens, wie Reinforcement Learning, Transfer Learning oder die Behandlung von Situation mit unvollständiger Information (siehe unten), die im beantragten Projekt situationsabhängig entwickelt werden müssen, angrenzen zu können, wird dem Überbegriff KI der Begriff des „Selbstorganisierten Lernprozesses“ (SP) gegenübergestellt (siehe Tabelle 1). Die im Rahmen von SP bereitgestellten Algorithmen gehen über das Standardrepertoire von Verfahren des Machine Learnings (ML) und insbesondere dessen Teilgebietes Deep Learning (DL) hinaus, wobei sie auf diese Methoden zurückgreifen (siehe Tabelle 1).

Künstliche Intelligenz (KI/AI)	Wird als Bezeichnung der wissenschaftlichen Disziplin verwendet, die sich mit dem Studium von Agenten beschäftigt, die ihre Umgebung wahrnehmen, auf diese reagieren und Maßnahmen ergreifen, um die Wahrscheinlichkeit, ihre Ziele zu erreichen, zu maximieren (Poole, David; Mackworth, Alan; Goebel, Randy (1998). Computational Intelligence: A Logical Approach. New York: Oxford University Press. ISBN 978-0-19-510270-3).
Machine Learning (ML)	Bezeichnet die wissenschaftliche Disziplin, die sich mit Algorithmen befasst, die sich aufgrund von Erfahrungsdaten automatisch verbessern können (computerbasierte Generierung von Wissens Erfahrung). Als solche ist sie Teil der künstlichen Intelligenz.
Deep Learning (DL)	Bezeichnet eine Methode des Machine Learnings, bei der mehrschichtige künstliche neuronale Netze eingesetzt werden.
Selbstlernende Prozesse (SP)	Hierunter werden fortgeschrittenere Algorithmen zusammengefasst, die weitgehend auf neuronalen Netzen basieren, und diese in die Lage versetzen, kognitive Prozesse, die der Mensch beim Elektronik-Entwurf erbringt, maschinell abzubilden. Hierzu zählen das datenbasierte Aufbauen eines Modells der Realität zur Erfolgsbewertung (Reinforcement Learning), der Transfer erlernter Fähigkeiten in andere Domänen

	(Transfer Learning) und der Umgang mit unvollständiger Information („wahrnehmungsbasierte“ adhoc-Approximationen der Situation, vgl. [MORAVČÍK, Matej, et al. Deepstack: Expert-level artificial intelligence in heads-up no-limit poker. Science, 2017, 356. Jg., Nr. 6337, S. 508-513]).
--	--

Tabelle 1: Erläuterung Künstliche Intelligenz (KI/AI), Machine Learning (ML), Deep Learning (DL) sowie die in diesem Projekt vor allem eingesetzten fortgeschrittenen Methoden der künstlichen Intelligenz (SP).

2.2.2 Umsetzung des geplanten modular strukturierten KI-Konzeptes

Entsprechend den obigen Ausführungen wurden, basierend auf einem Modell für den verallgemeinerten Entwurfsprozess, in diesem Projekt Anforderungen an eine praxisrelevante KI-orientierte Anpassung von industriellen Entwurfs- und Analyseumgebungen für die Entwicklung von funktional sicheren elektronischen Systemen abgeleitet (Abbildung 20).

Mit Hilfe einer workflow-orientierten Integrationsumgebung wurden die abgeleiteten Anforderungen mit Partnern aus Industrie und Forschung abgeglichen und für die geplante modulare KI-Plattform aufbereitet. Dabei kam den Schnittstellen zwischen KI-Modulen und den einzelnen werkzeug-gestützten Entwurfsebenen eine erhebliche Bedeutung zu.

Nur dann können die bisher erarbeiteten und bereits etablierten Entwicklungs- und Analyseumgebungen und deren Vorteile effizient genutzt und weiterentwickelt werden.

Mittels progressivKI wurde eine modular strukturierte KI-Plattform erschaffen, die das gesamte vorhandene Open-Source Potential im Bereich der KI erschließt. Ausgeführt wird dies anhand der Schlüsseltechnologien physikalische Kopplungen und |System-/Schaltungsentwurf| in den Anwendungsbereichen Automotive/Medizinelektronik/-logistik und Industrieelektronik.

Im Bereich der KI-Systeme und Frameworks haben sich zahlreiche verschiedene Ansätze etabliert. Die meisten aktuellen Systeme setzen hierbei auf Deep Learning Methoden. Als bekanntestes Beispiel sei hier das Tool TensorFlow von Google erwähnt. Darüber hinaus existieren eine Vielzahl weiterer, klassischer Machine Learning Algorithmen, wie z.B. Support Vector Machines, Random Forrest, Markov Chains, etc. Die verfügbaren Tools konzentrieren sich hierbei auf das zur Verfügung stellen einzelner Algorithmen.

Das entwickelte KI-System soll an reale Anwendungsszenarien (Einführung von KI-Teilplattformen für die Bereiche: PCB-Entwurf - IC-Entwurf/Sensorik) angepasst und in diesen getestet und bewertet werden. Es muss darauf geachtet werden, dass im Zuge von evtl. F+E basierten Begleitprojekten durch entsprechende Modifikation des entwickelten KI-Systems zukünftig weitere Bereiche des KFZ-Systementwurfs (z.B. Bordnetze) adressiert werden können.

Hierzu existierten bereits erste Ansätze, die weiter ausgebaut wurden. So gab es z.B. im Rahmen des PCB/AVT-Entwurf erste Unternehmen, die mit Hilfe von KI-Ansätzen das PCB-Design beschleunigen [JITX].

Allerdings wird bei diesen Ansätzen in der Regel nur ein Aspekt des kompletten Systementwurfs-Prozesses verfolgt und abgebildet.

Im Prinzip liegt der KI-Prozess des Projektes in einer orthogonalen Ebene zum Herstellungsprozess der elektrischen Bauteile und wird nicht zwingend durch die verschiedenen Aspekte der Entwurfsprozesse beeinflusst. So können Algorithmen, die durch Daten oder auch Re-Inforcements von elektronischen Bauteilen bzw. Herstellungsprozessen für die Medizinelektronik trainiert wurden, durch ihre Modularität, zum Beispiel, auch auf Prozesse aus der Automobilbranche oder Elektrotechnik angewandt werden.

In allen Segmenten muss es möglich sein, Domänenwissen zu integrieren, um auf dieser Basis einen geordneten Prozess zu starten (ML, DL, SP) und schnell zu einer Problemdefinition und dann zu einer Lösung (einem Lösungsraum) zu gelangen. Andererseits muss das Ergebnis der Prozesse hinsichtlich der Qualität und Wirksamkeit als Lösung kontrolliert und eingeschätzt werden können.

Die Qualität muss also definiert und nachvollziehbar sein. Damit schafft man in einem Begriff eine qualitätskontrollierte modulare Plattform und schließlich eine qualitätskontrollierte modulare KI, deren Prozesse nachvollziehbar sind. Diese Eigenschaft stellt - vergleicht man KI-Ansätze – ein Alleinstellungsmerkmal der strukturierten KI-Plattform dar.

2.2.3 Genutzte KI-Verfahren und Werkzeuge

Um die geplante modulare KI-Plattform effizient entwickeln zu können, ist die Nutzung von Open-Source Produkten im Bereich des maschinellen Lernens der einzig gangbare Weg, um nicht den Anschluss an die weltweite wirtschaftliche Entwicklung zu verpassen. Die modulare, strukturierte KI-Plattform greift auf eine Reihe von Open Source-Tools zurück und vereinigt diese zu funktionierenden Workflows. Das bedeutet, dass dort, wo es notwendig ist – oder aus Gründen der Verwertung sinnvoll erscheint – auch generische Algorithmen entwickelt und zum Einsatz kommen. Dabei werden die OpenSource-Varianten als Basiswerkzeug eingesetzt und die generischen Algorithmen auf die Basis-Variante aufgesetzt. Dabei ist zu berücksichtigen, dass unterschiedliche Lizenzmodelle greifen können.

In Anbetracht des großen durch die weltweite wissenschaftliche Community bereitgestellten Methodenspektrums war es nicht sinnvoll, in progressivKI eine Parallelentwicklung von Algorithmen vorzusehen. Vielmehr wurde im Projekt mit der Wertschöpfung bei der Nutzung dieser Kompetenzen begonnen und im Bedarfsfall auch die Entwicklung/Anpassung von Algorithmen betrieben. Diesem Paradigma folgte progressivKI.

Die Vorgehensweise in progressivKI wurde durch die aktuelle Entwicklung im TensorFlow-Ökosystem unterstützt, da das Huskarl¹-Werkzeug als neues Werkzeug (Framework) einen neuen modularen Ansatz des Reinforcement erlaubt. Diesen Ansatz verfolgte progressivKI intrinsisch. Die unterschiedlichen Pfade durch die KI-System-Modullandschaft können

¹ Es handelt sich hierbei um ein Framework, das auf der Basis von Tensor-Flow ein Deep-Reinforcement-Learning unterstützt. Mittels Huskarl lassen sich schnelle Prototypen entwickeln.

iterativ gestaltet werden, so dass eine Optimierungsstrategie (stetige Verbesserung, Konvergenzverhalten) umgesetzt werden konnte.

Der progressivKI-Ansatz beschränkte sich zunächst auf eine Auswahl von Werkzeugen in drei Segmenten: Machine Learning (ML) => Deep Learning (DL) => Selbstlernender Prozess (SP) (vgl. Tabelle 1).

Das ML-Segment beinhaltet klassische Werkzeuge, wie die Support-Vector-Machines (SVM) oder Decision-Trees (DT). Fraunhofer-FIT stellt seine Zeta-Suite zur Verfügung, die eine einfach trainierbare Plattform darstellt, auf der Bildverarbeitungsmethoden durch IT-Laien innerhalb kürzester Zeit auf einem GUI mit der Maus generiert und zur Anwendung gebracht werden können.

Eine Übersicht zu den initial geplanten KI-Werkzeugen (OpenSource) als Grundlage für die Umsetzung der modular strukturierten KI-Plattform findet sich in nachfolgender Tabelle.

ML-Segment
<p>Zeta - Zeta ist eine von Fraunhofer FIT selbst entwickelte digitale Bildverarbeitungs-Suite in deren Entwicklung mehrere Personen-Jahre eingeflossen sind. Sie unterstützt zahlreiche Funktionen und Algorithmen zur Registrierung, Vorder-/Hintergrunderkennung, Segmentierung, Tracking, Klassifikation etc. Da ein Hauptteil der Problematik auf Bildverarbeitung (Leiterbahnen, Schematics) zurückzuführen sein wird, kann die Zeta Suite dort eine große Hilfe bieten.</p>
<p>Support Vector Machines - Support Vector Machines werden auf eine Menge von Trainingsdaten bezogen, deren Klassifizierung bekannt ist. Jeder Datenpunkt wird entsprechend durch einen Vektor im n-Dimensionalen Raum betrachtet. In diesen Raum wird eine Hyperebene gesetzt, die die jeweiligen Klassen der Datenpunkte mit maximalem Abstand trennt. Daten, deren räumlicher Abstand zur Trennebene gering ist, werden dabei mehr berücksichtigt als Datenpunkte, deren Abstand zur Trennebene groß ist.</p>
<p>Decision Trees - Decision Trees, oder auch Entscheidungsbäume sind geordnete, gerichtete Bäume, die der Erstellung und Darstellung von Entscheidungsregeln dienen. Besondere Bedeutung kommt Entscheidungsbäumen in Bereichen zu, in denen aus tacit knowledge/Erfahrungswissen formale Regeln abgeleitet werden können.</p> <p>Sie können entweder durch Experten manuell erstellt oder durch verschiedene Algorithmen des ML induziert werden. Dabei kann das tacit-Knowledge der Experten mit in den Induktionsprozess einfließen. Genau für diese Anwendung wurden die trainierbaren Prozesse erfunden. Ein Spezialfall der trainierbaren Prozesse ist das "supervised learning".</p>
<p>Random Forest - Ein Random Forrest besteht aus mehreren unkorrelierten Entscheidungsbäumen, die unter einer bestimmten Art der Randomisierung in einem Lernprozess induziert wurden. Eine Klassifikationsentscheidung wird durch einen einfachen Mehrheitsentscheid über alle Bäume getroffen.</p> <p>Vorteile:</p>

Evaluierung basiert auf mehreren Bäumen - ist also parallelisierbar.
Effizient für große Datenmengen.
Sehr schnelles Training möglich.
Zusammenhang zwischen Klassen/Entscheidungen kann unmittelbar hergestellt werden.

DL-Segment

Tensorflow - Entwickelt von Google bietet Tensorflow Schnittstellen zu allen populären Programmiersprachen. Am häufigsten verwendet wird es allerdings mit Python.

Tensorflow stellt eine Schnittstelle für Entwickler bereit, mit der effizient Architekturen neuronaler Netze erstellt und mit diesen experimentiert werden kann. Darüber hinaus können einfach Daten in Form von Graphen, Netzen, SQL-Tabellen und Bilder integriert bzw. importiert werden.

Torch - Ein großer Vorteil von Torch ist die Verwendung von dynamisch updatenden Graphen, deren Architektur während des Prozesses geändert werden kann. Dies birgt große Möglichkeiten für das Reinforcement Learning.

Keras - Keras ist die High-Level Umgebung zur effizienten Benutzung von Tensorflow. Die Erstellung und Importierung von Modellen und großen Datenmengen ist um vieles Einfacher als bei den Low-Level Frameworks. Dafür werden Einbußen in der Konfiguration hingenommen. Eine Kombination mit z.B. Tensorflow für diese Belange ist aber jederzeit möglich.

SP-Segment

Huskarl - Der ausgewiesene Fokus des auf TensorFlow basierenden Huskarl liegt auf dem Deep Reinforcement Learning. Neben der Basis von Tensorflow kann für schnelles Prototyping auch auf die High-Level API Keras zugegriffen werden. Zusätzlich sind integrierte Algorithmenbausteine wie Deep Q-Learning verfügbar.

<<https://www.heise.de/developer/meldung/Deep-Reinforcement-Learning-Huskarl-verspricht-schnelleres-Prototyping-4475103.html>>

Die dargestellten Werkzeuge (siehe Abbildung 17) sind so gewählt, dass einerseits Domänenwissen (siehe auch oben: tacit knowledge²) abgebildet werden kann und andererseits das Ergebnis des ML als Eingangsgröße für das nächste Segment dienen kann. Das bedeutet, man fängt mit der klassischen Feature Extraction an und kann diese – eventuell

² tacit knowledge ist nicht identisch mit dem Domänenwissen, wohl aber gehört es zu einer Domäne dazu. Es gibt unterschiedliche Definitionen - je nachdem, ob man es aus der Kognitionswissenschaft, der reinen Psychologie oder der KI-Community betrachtet.

nach Iteration – als Eingangsparameter für einen Deep-Learning-Prozess einsetzen. Denkbar ist auch, dass ein ML-Ansatz das Kundenproblem bereits löst. Dann endet die Problemlösung nach dem ML-Segment.

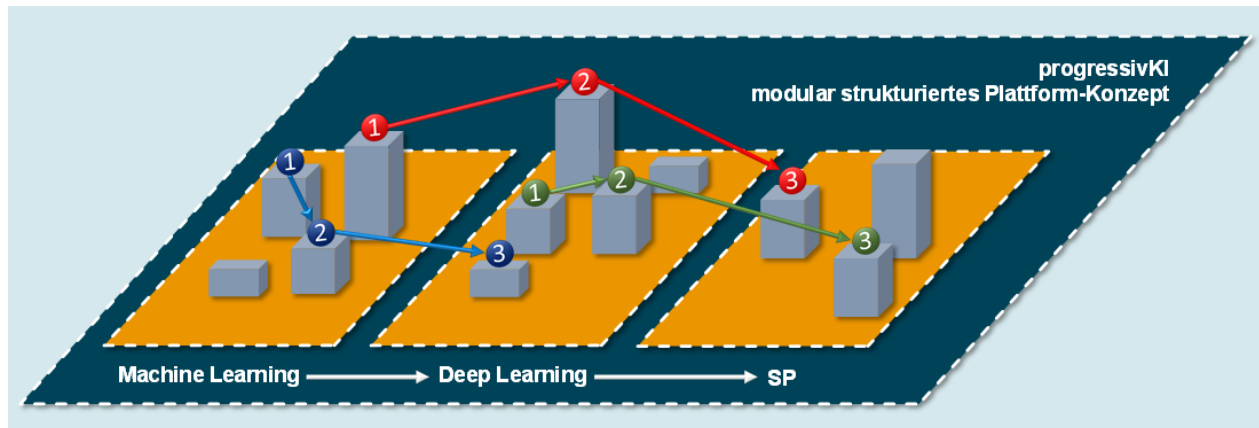


Abbildung 1: progressivKI modular, strukturierte KI-Plattform - Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP)

Vor allem der im Algorithmus von DeepStack (MORAVČÍK, Matej, et al. Deepstack: Expert-level artificial intelligence in heads-up no-limit poker. Science, 2017, 356. Jg., Nr. 6337, S. 508-513) verwendete Ansatz, kein Entscheidungsmodell des gesamten Vorganges (eines komplexen spieltheoretischen Systems im Falle von DeepStack, eines Entwurfsprozesses im EDA-Fall) durch Erfahrungen zu optimieren, was wegen der Komplexität der betrachteten Vorgänge immer einer fehleranfälligen Abstraktion bedarf, sondern stattdessen aufgrund des jeweiligen genau wahrgenommenen Zustandes und adhoc identifizierter Modelle des Gesamtvorganges Entscheidungen zu treffen, ist zielführend im Kontext des hierarchischen EDA-Entwurfsprozesses: Entscheidungen auf einer frühen Ebene des Entwurfs müssen erfolgen ohne vollständiges Wissen über die später realisierte Performance des Bauteils (z.B. dessen EMV-Eigenschaften). Dies trifft insbesondere auf die Entwurfstechniken der Anwendungsebenen #1 - #2 zu. Der Erfolg des in DeepStack umgesetzten Ansatzes zeigte sich darin, dass erstmals überhaupt ein Computerprogramm in der Lage war, mit menschlichen Gegnern (Profi-Pokerspieler) in komplexen Entscheidungssituationen (potentiell 10^{160} Entscheidungsmöglichkeiten) mit unvollständiger Information mitzuhalten, sondern diese sogar regelmäßig signifikant zu übertreffen.

Dies wird allgemein als ein Sprung in der KI-Forschung auf ein neues Niveau angesehen. Daher sollten Algorithmen, die diesen Ansatz umsetzen, auch im Rahmen der modularen Serviceplattform bereitgestellt werden.

Die Decision Trees können bei der Abbildung von Prozesswissen und bestehenden Design-Rules (vor allem wenn es um Entscheidungsvarianten geht) wertvolle Unterstützung leisten und helfen dabei, Strategie umzusetzen und zu verbessern.

Im Bereich des ML gibt es zwei Möglichkeiten die Algorithmen zu trainieren – supervised und unsupervised Learning:

Das supervised Learning wird auf der Basis einer Ground Truth durchgeführt. Wissen und vor allem tacit knowledge der Ingenieure wird so automatisch in die Algorithmenerstellung über supervised Learning, Trainingsalgorithmen und Feedback eingebettet. Das Ziel des supervised Learnings ist das Trainieren einer möglichst optimalen Approximationsfunktion, die die Beziehung zwischen Eingangs- und Ausgangsvariablen darstellt. Dabei können sowohl Problemstellungen aus den Bereichen der Klassifikation als auch der Regression dargestellt werden.

Unsupervised Learning wird ohne eingeflossenes Wissen trainiert. Da für die importierten Daten keine Ergebnisse aus dem tacit knowledge Vorliegen werden Algorithmen dieser Klasse vor allem für Problemstellungen aus dem Bereich des Clusterings oder der Dimensionsreduktion verwendet.

DL kann - muss nicht - der wichtige nächste Schritt auf dem Weg zu einem kontinuierlichen Selbstlernprozess sein. In der modularen KI-Plattform stellt das DL das nächste Segment nach dem ML dar und soll dabei helfen, komplexe Lösungsräume zu schaffen oder effizientere Lösungen zu realisieren.

Dabei werden die im ML-Segment erhaltenen Parameter und Features³ für den DeepLearning-Prozess nach Möglichkeit eingesetzt.

Da die ML-Trainingsansätze sehr große Datenmengen in hinreichender Qualität voraussetzen, stellte Reinforcement Learning einen wichtigen Aspekt der progressivKI KI-Plattform dar. Er sollte (neben anderem selbstorganisierten Lernprozessen) in der SP-Schicht der Plattform realisiert werden. Dabei sollten Strategien von den ML- und DL-Algorithmen ohne Vorgabe der Ergebnisse selbst erlernt werden. Ergebnisse werden nicht vorgegeben, sondern zu bestimmten Zeitpunkten Belohnungen/Bestrafungen in Bezug auf eine Nutzenfunktion erlangt. Wichtig hierfür ist ein geregeltes Qualitätsmanagement in Form von Qualitätsmatrizen, die für hintere Ebenen des Lösungsweges automatisiert werden können [PythonML].

Da ein Großteil der im Projekt vorhandenen Daten aus prozessinternen Bildern, wie z.B. Schaltplänen oder Schematics besteht, spielt die Bildverarbeitung bei diesem Projekt eine sehr große Rolle. Besonders Convolutional Neural Networks (CNN) erweisen sich in dieser Problemstellung als hinreichend qualifiziert.

Im Zentrum der Entwicklung der modulare strukturierten KI-Plattform stand die Programmiersprache Python die für Datenauswertungen, Statistiken und KI-Algorithmen immense Vorteile bietet [TransLearn] und [PythonML].

- Python ist eine dynamische High-Level Programmiersprache, die schon knapp drei Jahrzehnte am Markt etabliert ist.
- Komplette Open Source

³ Der Begriff Parameter impliziert, dass es sich hierbei um Zahlen handelt. Das muss nicht notwendigerweise so sein. Die Begriffe Features und Parameter werden dennoch im Folgenden synonym verwendet

- Eine große Sammlung an built-in Bibliotheken die Funktionen für Maschinelles Lernen bereitstellen
- Einfach in andere Programmiersprachen wie C++, C, Java einzubetten.
- Objekt- und prozessorientierte Programmiersprache sorgt für sicheres Datenmanagement und schnelle Berechnung der Daten.

2.2.4 Aufbau KI-Modulbaukasten

Der geplanten modularen KI-Plattform zur Entwicklung von funktional sicheren Elektroniksystemen kam im Hinblick auf eine erfolgreiche KMU-bezogene Umsetzung von vorhandenen und geplanten Projektergebnissen eine besondere Bedeutung zu.

Die geplanten Konzepte sahen eine Teilung in einen Hersteller- und einen Anwenderbaukasten vor. Aus den Elementen des Herstellerbaukastens sollten geeignete KI-Module ausgewählt werden können. Diese Bauelemente stellen darüber hinaus die Module des Anwenderbaukastens dar. Durch Kombination der Module des Anwenderbaukastens kann dann die benötigte KI-Erweiterung von vorhandenen Entwurfsumgebungen realisiert werden (Abbildung 18).

Die bisherigen Überlegungen hatten ergeben, dass das geplante Baukastensystem mit Schnittstellen zu Modellen und Werkzeugen für den Entwurf, die Beschreibung, Realisierung und die jeweils anwender- und hersteller-spezifischen Elektroniksysteme hinterlegt werden muss. Darüber hinaus muss die Integration von AddOn-Werkzeugen möglich sein; falls diese wertschöpfungsketten-übergreifend für die Durchführung einer spezifischen Entwicklungsaufgabe notwendig sind. Mit Hilfe der KI-Module muss auch wertschöpfungsketten-übergreifend ein *netzbasierter* und *workflow-orientierte Ergebnistransfer* der in der Kette erarbeiteten Ergebnisse (Wissen, Methoden) realisiert werden.

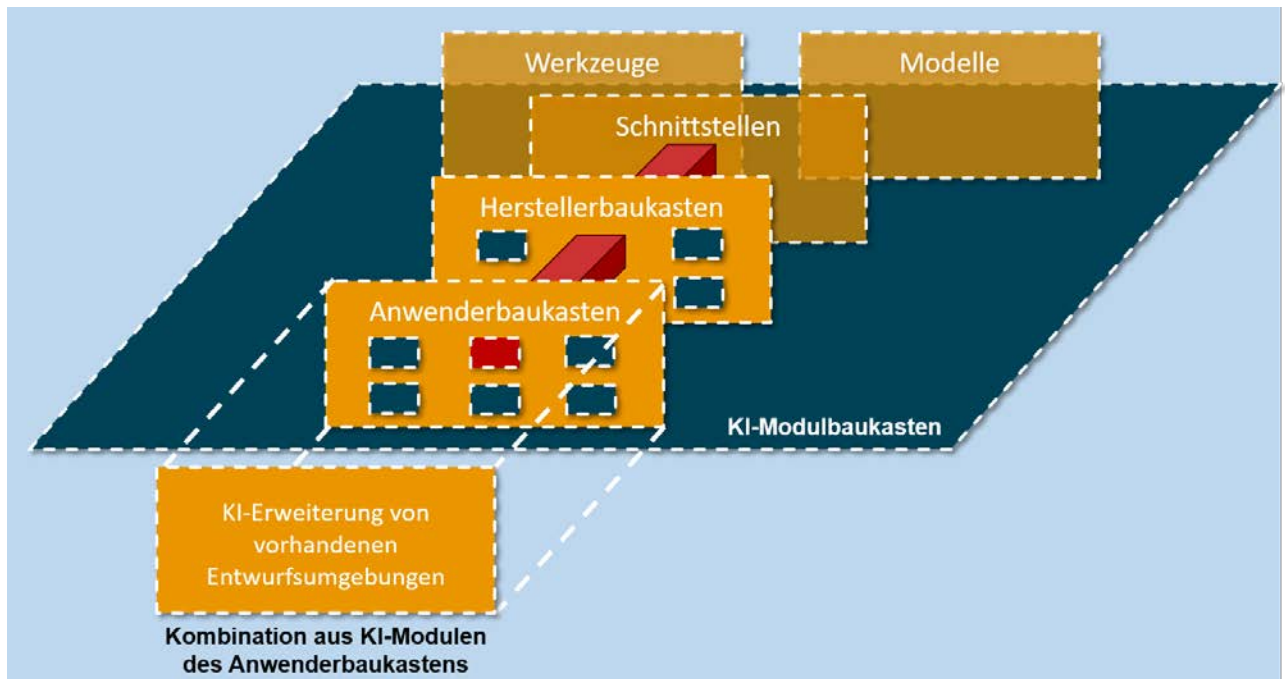


Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukastens

2.2.5 Entwurfsprozesse

Elektronische Systeme werden in immer stärkerem Maße durch hohe Komplexitäten und Anforderungen an die Systemsicherheit geprägt. Dazu kommt ein durch wirtschaftliche Zwänge motivierter Trend zur Integration von Komponenten und Subsystemen zu hochkompakten Systemen. Dieser Trend ist in allen Industriebereichen, wie z.B. Automobilindustrie, Medizintechnik, Automatisierungstechnik, Robotik, Logistik und Telekommunikation zu verzeichnen.

Die hohen Integrationsdichten führen dazu, dass auf System- und Komponentenebene erhebliche Anforderungen an die Entwicklung funktionssicherer Systeme gestellt werden. Diese Systeme dürfen z.B. durch interne und externe Wechselwirkungen in keinem Fall auf HW-Ebenen in ihrer Funktionssicherheit beeinflusst werden. Ähnliches gilt auch für die SW-Ebene. Daraus lässt sich ableiten, dass der Entwickler von elektronischen Systemen mit erheblichen Veränderungen bzgl. der Produktentwicklung konfrontiert wird. Diese betreffen, wie oben erwähnt, die Systemkomplexität, die Integrationsdichte auf allen Partitionierungsebenen und nicht zuletzt die unbedingt erforderliche Verkürzung von Entwicklungszyklen.

Da auf jeder Ebene die jeweiligen Entwicklungsentscheidungen, mit denen aus den anderen Ebenen in Einklang gebracht werden müssen, ist es zukünftig erforderlich die Eigenschaften eines spezifischen Entwurfs in seiner Gesamtheit zu betrachten.

Mit der Zielsetzung einer zufriedenstellenden Gesamtfunktion liefern z.B. eine messtechnische Validierung und ein abschließender Test sowie eine anschließende Dokumentation der Systemeigenschaften im Entwurfsprozess bereits eine erhebliche Datenmenge. Das darin steckende Entwurfswissen gilt es zukünftig mittels KI-Modulen, die

für jede Entwurfsebene eine andere Ausprägung haben müssen, effizient nutzbar zu machen. Dazu muss allerdings der systematische Entwurf des ganzheitlich betrachteten Systems auch unter dem Aspekt der funktionalen Sicherheit umgesetzt werden. Allerdings dürfen auch Faktoren wie Kosten und Marktanforderungen nicht vernachlässigt werden.

Weiterhin muss beachtet werden, dass für den Entwurf elektronischer Systeme neben den spezifizierten Haupteigenschaften auch die sogenannten Nebeneigenschaften (Abbildung 19) in den Entwurfsprozess vermehrt eingehen müssen. Diese sogenannten Nebeneigenschaften gewinnen immer mehr Einfluss auf die funktionale Sicherheit eines Systems und entwickeln sich vermehrt zum Kostentreiber.

Es bleibt festzuhalten, dass sich zukünftige elektronische Systeme noch mehr als bisher durch einen hohen Vernetzungsgrad auszeichnen. Durch mangelnde Funktionssicherheit verursachte Systemausfälle führen zu Ausfallzeiten (Verfügbarkeitskriterium) und damit zu Kosten, die die eigentlichen Investitionskosten der betroffenen Systeme um ein Vielfaches überschreiten können.

Der Entwurf elektronischer Systeme unter dem Aspekt der funktionalen Sicherheit gewinnt daher im Hinblick auf die Leistungsfähigkeit des Gesamtsystems sowie durch die erforderliche Verkürzung der Entwurfszyklen neben der Einhaltung von internationalen und nationalen Standards (Grenzwerten) zunehmend an Bedeutung. Viele industrielle Systemanbieter verfügen zwar über einen umfangreichen Pool an Erfahrungswissen (das innerhalb der Unternehmen in jahrelanger Arbeit erstellt und teilweise auch dokumentiert worden ist), allerdings müssen sich die Systementwickler häufig dieses umfangreiche Wissen selbst erarbeiten, da eine Hierarchie-übergreifende Zusammenfassung des Wissens aus zeitlichen Gründen häufig unterbleibt (diese Situation ist im KMU-Bereich sehr oft zu verzeichnen).

In diesem Zusammenhang zeigen neuere Entwicklungen auf, dass eine effiziente Wissenskonservierung und dessen Umsetzung für Nachfolgeprojekte durch den Einsatz von KI-gestützten Entwurfsumgebungssystemen erforderlich sind. Für diese Systeme muss von allen Entwurfsebenen aus ein möglichst einfacher Zugriff erfolgen können.

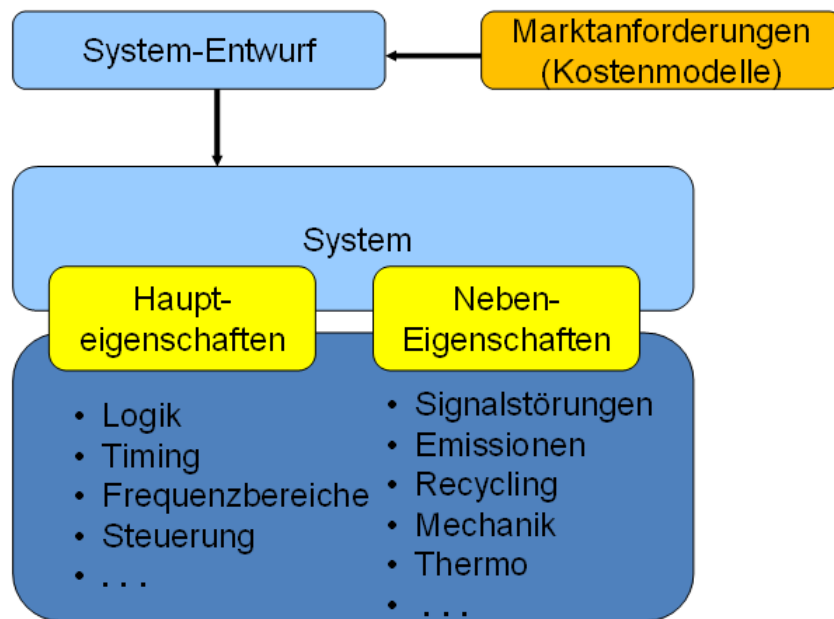


Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften

2.2.5.1 Allgemeiner Entwurfsprozess

Die Abbildung von industriellen Entwicklungsabläufen auf rechnergestützte Entwurfsumgebungen ist nur dann effizient möglich, wenn auf System-, Subsystem- und Komponentenebene ähnliche Arbeitsstrukturen sowie -abläufe definiert werden können. D.h. zu Beginn der Erstellung einer systemgerechten Entwurfs- und Simulationsumgebung muss eine Analyse der zu unterstützenden Entwicklungsabläufe erfolgen. Da in der Praxis an der Entwicklung eines Systems (auch im Falle der Variantenkonstruktion) unterschiedliche Gruppen beteiligt sind, kann die erforderliche Koordination nur auf der Basis einer Beschreibung der Entwicklungsabläufe durch einen einheitlichen Entwurfsprozess erfolgen.

Die Entwicklung von Systemen wird von übergreifenden Grundprinzipien geprägt. Verschiedene Entwurfsprozesse können daher allgemeingültigen Entwicklungsphasen zugeordnet werden. Durch die Partitionierung eines Systems in Subsysteme und Komponenten kann eine weitere Gliederung vorgenommen werden. Die Grundprinzipien einer systematischen Entwicklung von elektronischen Systemen werden üblicherweise durch sog. Prozessmodelle beschrieben.

Abbildung 20 zeigt ein weiterentwickeltes Prozessmodell für den Entwurf elektronischer Systeme. Die jeweiligen Phasen dienen der Strukturierung der zu beschreibenden Entwicklungsprozesse und müssen evtl. auch zeitlich überlappend abgearbeitet werden. Beginnend mit der |Anforderungsbeschreibung| werden die darauffolgenden Phasen bis zum |Test| auf der Systemebene durchlaufen. Die Definition der angedeuteten Systemhierarchie ergibt sich zwangsläufig aus der geforderten Funktionalität. Entsprechende Abläufe müssen deshalb auch für die Ebenen Subsysteme und Komponenten betrachtet werden. Es wird auch deutlich, dass eine Optimierung des Zielsystems auf den

unterschiedlichen Entwurfsebenen üblicherweise nach dem sog. JoJo-Prinzip erfolgt. Allerdings muss zusätzlich eine Optimierung der Subsysteme und Komponenten auf horizontalen Ebenen erfolgen. Bei allen Schritten zur Entwurfsoptimierung fallen erhebliche Datenmengen unterschiedlicher Natur an (z.B. Spezifikationsdokumente; Simulationsergebnisse; Messergebnisse; Berichte aus dem Feld; ...). Da die allermeisten Entwürfe in sog. Wertschöpfungsketten (z.B. Systemhaus - Tier1 - Tier2) erfolgen, wird deutlich, dass eine zukünftige KI-Unterstützung wertschöpfungsketten-übergreifend erfolgen muss.

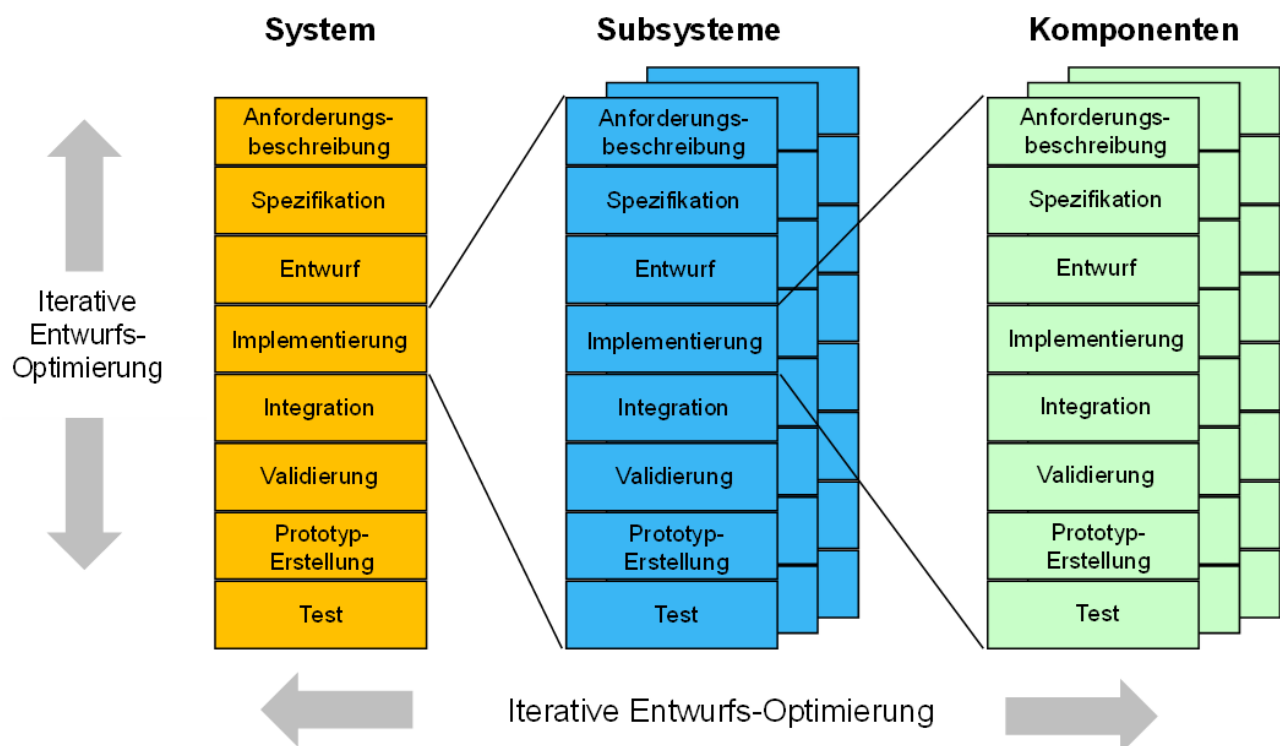


Abbildung 4: Verallgemeinerter Entwurfsprozess als Grundlage für die Analyse des Einsatzes von KI-Modulen im industriellen Umfeld

Der Übergang von der vorhergehenden zur nachfolgenden Entwicklungsphase erfolgt erst dann, wenn das jeweilige Ergebnis den Vorgaben genügt. Ist dies nicht der Fall, so sind jederzeit eine Rückkehr zu einer der vorangegangenen Entwicklungsphasen und ein erneuter Durchlauf mit veränderten Parametern möglich. Das zu entwickelnde System wird i.a. rekursiv in Subsysteme/Komponenten partitioniert.

Nach der Definition geeigneter Schnittstellen können die Subsysteme und Komponenten unabhängig voneinander entwickelt werden. Deren Entwurf lässt sich ebenfalls durch das Phasenmodell beschreiben. Dabei ist ein ständiger Informationsaustausch zwischen den beteiligten Entwicklergruppen (horizontaler Informationsfluss) notwendig, um so früh wie möglich eventuell auftretende Entwurfs- und Kompatibilitätsprobleme zwischen den

Subsystemen/Komponenten zu erkennen und geeignete Maßnahmen z.B. zu deren Lösung treffen zu können.

2.2.5.2 Funktionale Sicherheit

Funktionale Sicherheit bezeichnet den Teil der Sicherheit eines Systems, der von der korrekten Funktion der sicherheitsbezogenen Systeme und Subsysteme sowie Komponenten abhängt.

Mit der Komplexität elektronischer Systeme steigt auch die Vielfalt der Fehlermöglichkeiten. Entsprechend fordert die Normenreihe IEC 61508 (Funktionale Sicherheit) sicherheitsbezogener elektronischer Systeme die Anwendung diverser Methoden zur Vermeidung systematischer Fehler (das sind Fehler bei der Spezifikation, Implementierung etc. des Systems auftreten können) und zur sicheren Beherrschung von Ausfällen und Störungen (oft auch durch physikalische Kopplungen verursacht).

Die SIL-Klassifizierung (Safety Integrity Level) bezeichnet eine 4-stufige Skala (SIL1 = niedrig; SIL4 = hoch) für die erforderliche Risikoreduzierung (IEC 61508) im Systementwurf. Erreicht wird die erforderliche SIL-Klasse mittels anerkannter Methoden (Risikoanalyse) und durch die Summe verschiedener Maßnahmen, Methoden und Techniken.

2.2.5.3 Kostenreduktion mittels virtueller Entwicklung

Zur effizienten Integration von Komponenten und Modulen (Subsysteme) in elektronische Gesamtsysteme müssen unterschiedliche Aspekte (Entwurfsfragen; Technologie-Kenntnisse; Kostenfunktionen; physikalische Kopplungen;) in einem vollständigen hierarchisch gegliederten Entwurfsprozess einbezogen werden können. Weiterhin müssen die Faktoren Time2Market – RapidPrototyping – FirstTimeRight – DesignReUse (Variantenkonstruktion)/fertigungs-gerechter Entwurf und Testbarkeit in KI-gestützte Entwurfsprozesse einbezogen werden können. Den obigen Aussagen folgend, muss weiterhin beachtet werden, dass dem Prinzip der virtuellen Entwicklung entlang von anwender-spezifischen Wertschöpfungsketten in den nächsten Jahren eine erhebliche Bedeutung zukommen wird. Als Beispiel kann hier die virtuelle Entwicklung im Automobilbereich genannt werden (Abbildung 21).

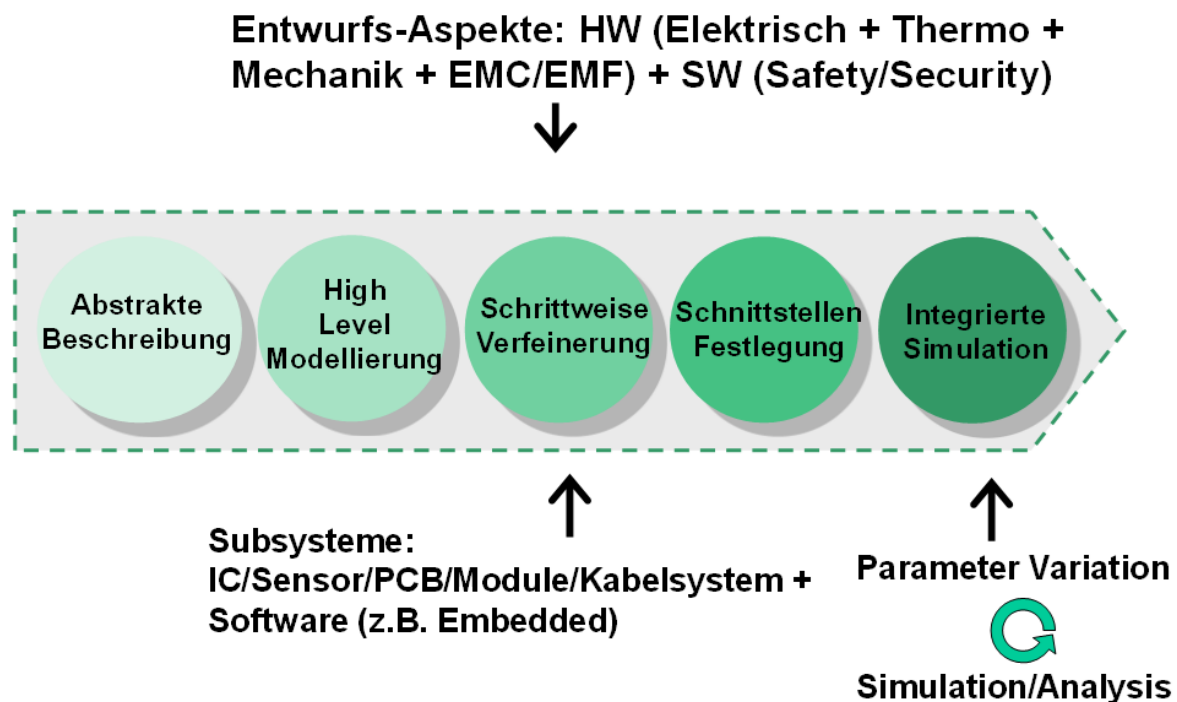


Abbildung 5: Entwurfsaspekte und -schritte auf HW- und SW-Ebene

Gezeigt wird die abstrakte Darstellung eines Entwurfsprozesses der mit einer abstrakten Beschreibung des zu entwickelnden Systems bzw. Subsystems (mögliche Subsysteme: IC/Sensor – PCB-Module + Software zur Systemsteuerung) beginnt. Die abstrakte Beschreibung basiert auf den vorgeschalteten Prozessebenen |*RequirementAnalyse*| und |*Spezifikation*| (siehe auch Abbildung 20). Es erfolgt ein Modellierungsschritt, der im Wesentlichen auf der Grundlage dieser Beschreibung beruht. Die so erstellten HighLevel-Modelle werden schrittweise verfeinert in dem aus Sicht der funktionalen Sicherheit die HW-Entwurfsaspekte |*physikalische Kopplungen*| sowie die SW- Entwurfsaspekte |*Safety/Security*| in die Modellierung einbezogen werden.

Einen Ansatz für die Einführung einer möglichen Modell-Hierarchie und die Modellierung von unterschiedlichen Effekten physikalischer Kopplungen im Hinblick auf die erforderliche Erweiterbarkeit (Granularität) der Modelle wird nachstehend angegeben.

Die Einführung der Modellierung technologie-unabhängiger und -technologie-abhängiger parasitärer physikalischer Effekte (z.B. SI/HF-Störungen und/oder EMI-Modulation) erlaubt eine systematische Analyse der Auswirkungen einzelner Störeffekte im Gesamtsystem (Ab- bzw. Zuschalten von Störeffekten ó abhängig von der Granularität der Modell-Hierarchie).

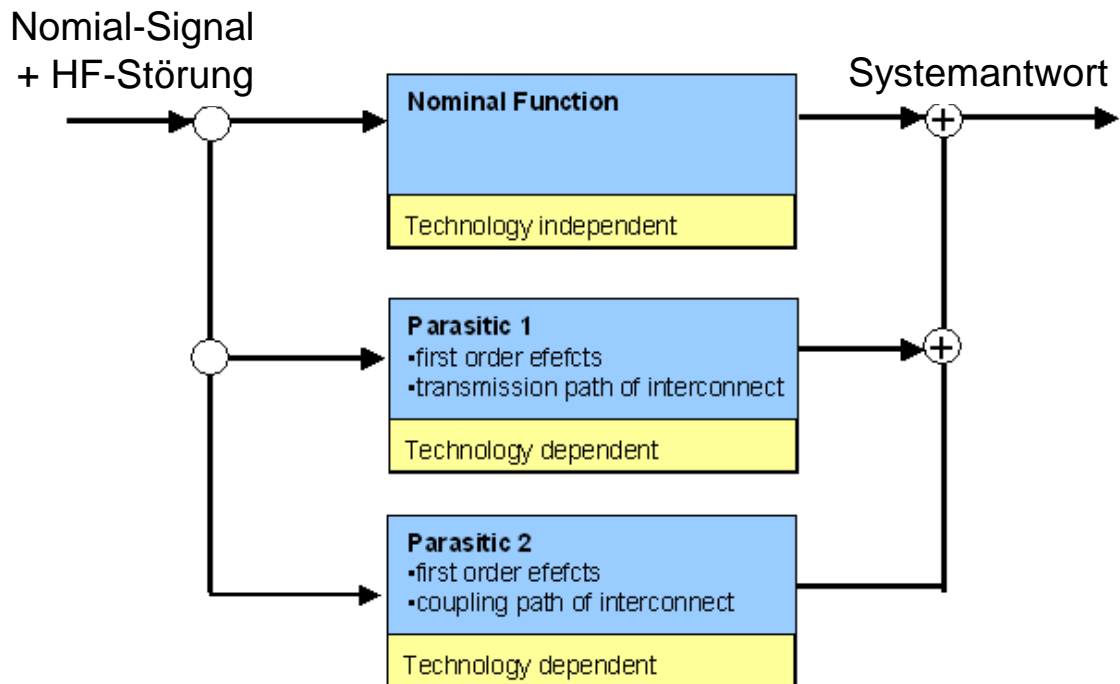


Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation

Nach Festlegung der Schnittstellen stehen Simulationsmodelle zur Verfügung mit denen eine virtuelle Analyse des Systemverhaltens mittels Parameter-Variation erfolgen kann.

Für die Anwendungsebene #1 (PCB-Entwurf) bedingt diese Art der Vorgehensweise zum Beispiel unmittelbar die Einführung eines geeigneten Fehlermodells (z.B. frequenz-/zeitabhängige Strom- und/oder Spannungsquellen) und einer Empfindlichkeitsmatrix für die elementaren Schaltungsblöcke eines Bauelementes und deren Integration auf PCB-Ebene (AVT). Auch die jeweilige Power-Ground-Verdrahtung (passives Netzwerk auf PCB-Ebene) muss in die Modellierung einbezogen werden.

Der gesamte Vorgang wurde zunächst auf die Ebenen 1 bis 3 und 6 des verallgemeinerten progressivKI Entwurfsprozess abgebildet (siehe auch Abbildung 10).

Cost Saving: Virtual Prototypes - Error Prevention



Time Saving: Concurrent Design – Reduced Number/Shorter Cycles

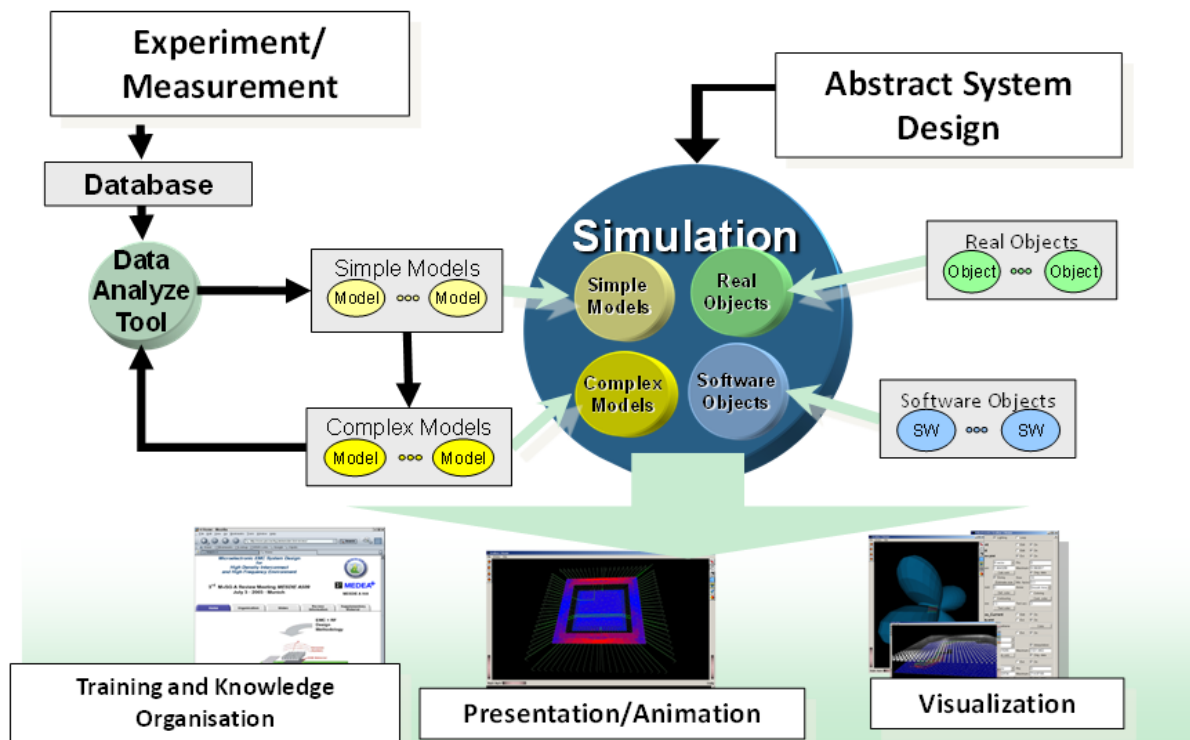


Abbildung 7: Virtuelle Entwicklung: Einsatz von Simulationsverfahren und -prinzipien

Diese Vorgehensweise zur virtuellen Entwicklung (Simulation und Analyse durch gezielte Parameter-Variation) muss als Bestandteil des in Abbildung 11 gezeigten progressiv KI-Interaktionsmodells verstanden werden. Dabei übernehmen die KI-Module die Teilaufgabe den jeweiligen Entwickler interaktiv hinsichtlich der in Abbildung 21 gezeigten Entwurfsschritte zu unterstützen. Besonders wichtig ist es zu beachten, dass diese HW-orientierte Vorgehensweise auch eine parallel durchgeführte SW-Entwicklung angewendet werden kann (die in diesem Vorhaben allerdings nicht adressiert wird).

Durch den frühen Einsatz von Simulationsverfahren und -prinzipien lassen sich die notwendigen Iterationsschritte in der Entwicklung deutlich reduzieren (Abbildung 23). Zukünftig ist besonders wichtig, dass hinsichtlich einer effizienten Entwurfsunterstützung die erforderlichen Konnektoren zu KI-Modulen bereitgestellt werden können.

2.2.6 IP-Schutz und Interoperabilität

Für KI-Anwendungen auf dem Entwurfssektor muss ausdrücklich das identifizierte Konfliktfeld zwischen Datenschutz und Interoperabilität auf eda-Werkzeugebene adressiert werden (Abbildung 24).

Viele Trainingsdaten basieren auf geschütztem und vertraulichem Kundenmaterial der Projektpartner und könnten als Trainingsdatensatz zu potentiellen Mitbewerbern gelangen.

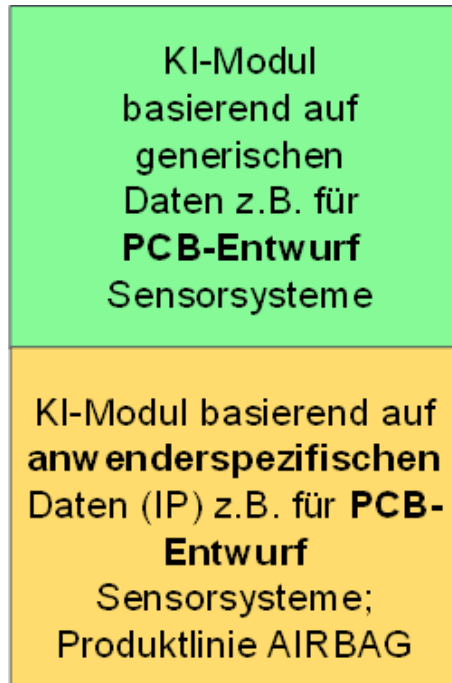


Abbildung 8: progressivKI-Ansatz zur Sicherstellung eines umfassenden IP-Schutz und Herstellung der Interoperabilität (Beispiel Anwenderebene #2 PCB-Entwurf)

Auch in anonymisierter und randomisierter Form existieren je nach Fall erhebliche rechtliche Unwägbarkeiten und Risiken. Um diesen Konflikt aufzulösen, und die Nutzung des vorhandenen Domänenwissens zu ermöglichen, sollten in progressivKI unterschiedliche Ansätze zum Schutz von IP und Unternehmenswissen verfolgt werden:

- ❑ Im ersten Schritt wurden lediglich Datenaustauschformate und Applikationsschnittstellen zwischen den Partnern geteilt. Dadurch kann eine generalisierte, vielseitige Plattform erstellt werden, ohne bereits IP-Konflikte lösen zu müssen.
- ❑ Alle zum Datenimport und zum Training der KI erforderlichen Werkzeuge wurden den Partnern zur Verfügung gestellt, so dass das Training von applikationsspezifischen KI-Modellen direkt beim progressivKI-Nutzer erfolgen konnte.
- ❑ Zwischen den Partnern können trainierte KI-Modelle ausgetauscht werden. In diesen ist das Domänenwissen lediglich in abstrahierter Form indirekt enthalten. Ein Rückschluss auf Nutzerdaten ist bei der angestrebten heterogenen Trainingsmenge nicht möglich.
- ❑ Durch progressivKI Forschungspartner wurden anhand von anonymisierten, nicht geschützten Daten vortrainierte KI-Modelle für einzelne Teilplattformen (z.B. Sensorentwurf) erstellt. Diese bieten ein generisches Modul, das durch Training beim

Kunden zu einem anwender- und anwendungsspezifischen Modul weitertrainiert werden kann.

2.2.7 Darstellung der wesentlichen Projektinnovationen

Die hier genannten progressivKI-Innovationselemente orientieren sich streng an der von Schumpeter entwickelten Definition*.

#	Vorwettbewerbliches Innovationselement	edaKI-Einsatzgebiet
IE.1	KI-Einsatz zur 20%igen Reduktion der zukünftig aufzuwendenden Ressourcen (Zeit, Personal, Kosten) für den Entwurf funktional-sicherer elektronischer KFZ-Systeme.	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.2	Entwicklung einer neuartigen, modular aufgebauten sowie flexibel einsetzbaren KI-Plattform zur direkten Abdeckung der System-Entwurfsebenen PCB-Entwurf und IC-Entwurf/Intelligente Sensorik .	Entwurfsprozess; Objekt 1 bis Objekt 8; siehe auch Abbildung 10.
IE.3	Entwicklung von sicheren, verschlüsselten und intelligenten Konnektoren zu den einzelnen (verteilten) Modulen und Subsystemen der modularen KI-Plattform.	IP-Schutz/Interoperabilität/KI-Interaktionsmodelle; siehe Abbildung 11; Abbildung 24.
IE.4	Portabilität und Übertragbarkeit der technischen Lösungen auf die individuellen Entwurfsprozesse durch Anordnung domänen- und applikationsspezifischer Konnektoren um einen leistungsfähigen KI-Kern.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.5	Erforschung neuartiger Konzepte für den kooperativen Betrieb von KI-Systemen in industriellen Entwurfsabläufen.	<ul style="list-style-type: none"> <input type="checkbox"/> Anwendungsebene #1: PCB-Entwurf; siehe Abbildung 11 + Abbildung 12. <input type="checkbox"/> Anwendungsebene #2: IC-Entwurf/Sensorik; siehe Abbildung 15. <input type="checkbox"/> Neuartige KI-basierte Unterstützung des Prinzips der Variantenkonstruktion.
IE.6	Innovations-Sprung und gesteigerte Wertschöpfung durch Einsatz und Adaption von OpenSource KI-Software. Vermeidung von zeitaufwendigen Parallelentwicklungen durch Nutzung des weltweit ausgereiften informationstheoretischen Knowhow mittels Open-Source KI-Software zur Entwicklung einer modular strukturierten KI-Plattform.	KI-Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP); siehe Abbildung 17.
IE.7	KI-Zugang für KMU; es wird eine für jede Domain allgemein zugängliche KI-basierte Fähigkeiten-Basis aufgebaut und kontinuierlich weiterentwickelt (2-stufiger Ansatz zum IP-Schutz). Diese kann für die zukünftig notwendige Wettbewerbssteigerung durch KMU optimal genutzt werden.	KI-Modulbaukasten; adaptierbar auf spezifische KMU-Randbedingungen (keine durchgängige Werkzeugkette; OpenSource Simulationswerkzeuge; Beauftragung an externe Dienstleister;...; siehe Abbildung 18.

IE.8	Definition und Umsetzung eines reichhaltigen Anwenderökosystems mit komplexen Anforderungen, die in den entsprechenden Workstream des aktuellen GAIA-X Prozesses (GAIA-X Workstream 2 Technische Umsetzung) einfließen. Sicherstellung der Übertragbarkeit auf Entwurfsprozesse industrieller Anwender, die aktuell nicht am Vorhaben beteiligt sind, durch eine Cloud-Lösung (quasi als Goldstandard).	GAIA-X Ansatz für wertschöpfungsketten-übergreifende industrielle Entwicklungsabläufe; horizontaler + vertikaler Informationsfluss; siehe Abbildung 20.
------	---	---

#	Vorwettbewerbliches Innovationselement	edaKI-Einsatzgebiet
IE.9	KI-basierte Algorithmen zur Extraktion von Informationen aus Entwicklungsdaten von elektronischen Systemen.	PCB-Entwicklungsprozess; siehe z.B. Abbildung 9; Entwurfsebene Anforderungen/Spezifikation; Auswertung Datenblätter (Textverarbeitung).
IE.10	KI-Module zur Erzeugung von Anforderungsbeschreibungen bis zur Generierung von Fertigungsdaten im Wertschöpfungsprozess elektronischer Systeme	Entwurfsprozess; Objekt 1 ; Objekt 2 Entwurfsebene Anforderungen/Spezifikation; Auswertung Datenblätter (Textverarbeitung); siehe auch Abbildung 10: Typischer SchematicAufbau; siehe auch Abbildung 5:
IE.11	Entwicklung einer standardisierten Topologiebeschreibung, einer standardisierten Geometriebeschreibung und eines standardisiertes Datenbankformat für die Spezifikation elektronischer/elektrischer aktiver/passiver Bauelemente für den Entwurf elektronischer Systeme zur internen Darstellung für die geplanten KI-Plattformen.	ECU-Schaltbild (Quelle: ZUKEN); Typischer SchematicAufbau; siehe auch Abbildung 5. MOSTCheck AnwenderWorkflow (Quelle: 05-MCHP); siehe auch Abbildung 12.
IE.12	Entwicklung einer vollständigen Darstellung der Systemtopologie durch Netze; direkt in der von TensorFlow genutzten Repräsentation.	ECU-Schaltbild (Quelle: ZUKEN); Typischer SchematicAufbau; siehe auch Abbildung 5. MOSTCheck AnwenderWorkflow (Quelle: 05-MCHP); siehe auch Abbildung 12
IE.13	Alleinstellungsmerkmal durch Quantisierung von Lernerfolgen (Metrisierung) zur Qualitätskontrolle für maschinelles Lernen.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.
IE.14	Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.	Modular, strukturierte KI-Plattform/Training und Applikation; siehe auch Abbildung 16.

Tabelle 2: progressivKI-Innovationselemente gemäß Schumpeter-Definition*

*Zitat aus [E. Borbély; J. A. Schumpeter und die Innovationsforschung; MEB 2008 – 6th International Conference on Management, Enterprise and Benchmarking May 30 - 31, 2008 Budapest, Hungary]: Neue Verfahren zur Bewertung und Absicherung der Qualität von Trainings- und Lernprozessen für KI-Module.: *Schumpeter definiert die Innovation als die Umsetzung neuer Kombinationen in die Realität: |The doing of new things or the doing of things that are already done, in a new way|¹, wobei er immer an die erstmalige Durchführung einer Neuerung denkt. Innovationen sind also neue und*

andersartige Kombinationen der zur Verfügung stehenden [Dinge und Kräfte], wobei Produktion die übliche Kombination vorhandener Dinge und Kräfte ist – die einmal wahrscheinlich auch neuartig waren².

1: Schumpeter; 1947 - Freudenberger; Mensch; 1975; Seite 14 - 2: Schumpeter; 1980; Seite 132.

2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

2.3.1 Der Stand von Wissenschaft und Technik

Ökonomische Rahmenbedingungen des KI-Einsatzes

Systeme, die KI-Technologien enthalten, werden zur zuverlässigen Entscheidungsfindung in Industrieanwendungen eingesetzt. Maschinelle Lernalgorithmen, wie Deep Learning, garantieren zunehmend die Funktionalität sogenannter „intelligenter Anwendungen“. Laut Studien wird der Markt für künstliche Intelligenz bereits 2024 eine Marke von 71 Milliarden USD erreichen [AI Software]. Allerdings ist die Nutzung digitaler Technologien für KMU allgemein schwieriger als für größere Unternehmen [DiWiGe] trotz einer nachgewiesenen erheblichen „digitalen Dividende“ bei Investition in digitale Technologien [DiKMU].

Als besonderer Gunstfaktor ist zwar der bereits hohe Virtualisierungsgrad in elektrotechnischen Entwurfsprozessen zu nennen, ein wesentliches Hemmnis für weitere Effizienzsteigerungen durch Automatisierung der industriellen Entwicklungsprozesse, also eines an sich kreativen Vorganges, liegt jedoch darin begründet, dass die dazu erforderlichen KI-Algorithmen durch große Daten angelernt werden müssen, die in der Regel nur weltweit operierende Unternehmen (wie Google, Apple, Microsoft etc.) zusammenstellen können. Hinzu kommt, dass Firmendaten im Gegensatz zu persönlichen Konsumentendaten auch im Einzelnen als sehr wertvolles Gut angesehen werden, da mit ihnen das Knowhow eines Unternehmens verbunden ist. Das für eine vollständige Durchdringung der Automobil-Wertschöpfungskette mit KI erforderliche „Data-Sharing“ ist daher an zwei Bedingungen geknüpft:

1. Es muss für die beteiligten Unternehmen rentabel sein, ein Netzwerk zu bilden, um einen Teil der Wertschöpfungskette gemeinsam zu generieren (vgl. [DiWiGe])
2. Die bereitgestellte Lösung muss allen Nutzern Souveränität über die eigenen Daten und deren Sicherheit garantieren: Prozessinformationen bleiben Firmengeheimnis, auch wenn daraus abgeleitete Lernstrategien in einer Cloud geteilt werden, und nur die angelernten Algorithmen, die ihre Lerndaten nicht speichern, sondern nur den daraus abgeleiteten inneren Zustand, können von anderen erworben werden.

Dieses Konzept ist eines der Businessmodelle, die aus progressivKI hervorgehen wird und ist völlig neu. Erstmals wurde für die Entwurfsprozesse einer umfassenden Wertschöpfungskette eine komplette Umstellung auf KI ermöglicht, um perspektivisch mit Grenzkosten null in kürzester Zeit Entwicklungsprozesse auf geänderte Requirements einstellen zu können, was derzeit noch mit großem Zeit- und Kostenaufwand verbunden ist. Die aus progressivKI entstehenden Geschäftsmodelle decken aber nicht nur diesen Fall ab, sondern bieten auch risikoarme Konzepte mit bereits deutlicher Wertschöpfung ab (siehe hierzu die unten genannten Verwertungspläne).

Konzepte und Begriffe des Maschinellen Lernens

In progressivKI wurde künstliche Intelligenz (KI) zur Automatisierung intelligenten Verhaltens, namentlich der flexiblen, requirement-orientierten Entwicklung elektronischer Hardwarekomponenten für zukünftige Mobilitätskonzepte, eingesetzt. Der Begriff KI umfasst ein Universum unterschiedlicher Algorithmen (siehe z.B. [Ertel]), das angefangen mit lang bekannten, elementaren statistischen Algorithmen zur Klassifikation, Bestapproximation und Filterung über neuronale Netze unterschiedlicher Tiefe bis hin zu komplexen Lernstrategien wie „Reinforced Learning“ oder „Transfer Learning“ reicht. Die einfachste Form maschinellen Lernens erfolgt durch die Anpassung eines parametrischen Modells an einen großen Datensatz in der Hoffnung, dass die angepassten Parameter die Datenstruktur hinreichend wiedergeben. Die Betrachtung gewisser damals teilweise bereits bekannter mathematischer bzw. statistischer Verfahren unter dem Paradigma eines Lernprozesses begann Mitte des letzten Jahrhunderts (z.B. [Teich]).

F. Rosenblatt 1958 untersuchte einen bereits 1936 von R. Fisher [Fisher] vorgestellten Algorithmus zur Clusterung durch Hyperebenen unter diesem Aspekt. Bei dieser sogenannten Support-Vector Machine wird aufgrund der Daten eine Hyperebene bestimmt, die einen hochdimensionalen Raum in einen „guten“ und einen „schlechten“ Bereich zerlegt. In der Onlinephase, wenn die Maschine zur Entscheidung zwischen guten und schlechten Fällen herangezogen wird, nutzt sie genau die identifizierte Hyperebene zur Trennung von günstigen und ungünstigen Fällen. Die Support-Vector-Machine erhält in der Lernphase zu jedem Wert eine Beurteilung, ob dieser gut oder schlecht ist. Der zugrundeliegende Lernprozess wird „Supervised Learning“ genannt. Die ist jedoch in vielen Fällen nicht zweckmäßig, da teilweise nicht in jedem einzelnen Fall nachvollzogen werden kann, wie gut eine zu bewertende Instanz tatsächlich ist. Hier bietet das ebenfalls bereits in den 50er Jahren des letzten Jahrhunderts von M. Minsky vorgeschlagene sogenannte „Reinforcement Learning“ [SurTay] einen Vorteil: Nur wenn die erforderliche Information gegeben ist, muss dem lernenden Agenten ein positiver oder negativer Stimulus mitgeteilt werden. Dieser konstruiert sich aufgrund der unterschiedlich erhaltenen Stimuli mit verschiedenen mathematischen Approximationstechniken ein Bild der Umgebung und versucht, seine Ausgaben so anzupassen, dass er die aufgenommenen Stimuli maximiert, wobei sein Gedächtnis und auch die Qualität der Daten durch Gewichte modelliert werden können. Besonders reizvoll für dieses Projekt ist, dass im Kontext des Reinforcement Learnings das Transfer Learning implementiert werden kann, was es erlaubt, auch ohne Anlernen mit eigenen Daten einen für ein ähnliches Problem geschulten Agenten auf ein anderes Problem anzuwenden.

Auch (künstliche) neuronale Netze wurden bereits Mitte des 20. Jahrhunderts von M. Minsky vorgeschlagen [Minsky]. Neuronale Netze bestehen aus mehreren Schichten formaler Neuronen. Die einzelnen Neuronen verhalten sich in jedem Takt wie eine lineare Abbildung zwischen Eingangs- und Ausgangsports des Neurons. Entsprechend den paarweisen Korrelationen zwischen Eingangs- und Ausgangsports werden die Matrixeinträge in der Darstellung der linearen Abbildung im Sinne eines positiven Feedbacks modifiziert. Auf diese Weise passt sich das neuronale Netzwerk den Eingaben an und entwickelt eine ausgefeilte Filtercharakteristik, die die Lernantwort auf die erhaltenen Stimuli ist.

In den 70er Jahren wurden automatische Lernalgorithmen zunehmend zur Lösung technologischer Probleme eingesetzt. Die damals verfügbare Rechenleistung limitierte jedoch die Einsatzmöglichkeiten. Der Durchbruch dieser Algorithmen geschah mit der Digitalisierungswelle im Übergang vom 20. in das 21. Jahrhundert. Möglich wurde er, da einerseits nun ausreichend Rechenleistung verfügbar war und andererseits durch die leichte Erhebbarkeit und Transferierbarkeit großer Datenmengen verschiedene technologische Anwendungen und Geschäftsmodelle möglich wurden, die ausnutzen, dass diese Algorithmen relevante Informationen bis hin zur automatisierten Entscheidungsfindung aus diesen Daten ableiten können. Heutzutage stehen frei verfügbare Programmpakete mit ausgereiften Implementationen einer Vielzahl von Algorithmen zur Verfügung (siehe Abschnitt über freie Software unten). Eine Durchdringung im wirtschaftlich sinnvollen Rahmen ist jedoch bisher nur in weiten Teilen der IT-Industrie erfolgt, während in vielen technischen Bereichen der Transfer noch aussteht. Einige der typischen Hemmnisse wurden im vorhergehenden Abschnitt erläutert. Der Einsatz von KI zur Lösung elektrotechnischer Entwurfsprobleme entlang einer gesamten Wertschöpfungskette und die Ableitung von sinnvollen Geschäftsmodellen auf dieser Basis ist neu.

KI für Domänen-spezifische Anwendungsfälle

Computergesteuerte Systeme werden mittels KI-Algorithmen in die Lage versetzt, auf Grundlage gesammelter Daten, definierter Regeln und Wissensbasen zu lernen. Das erlernte Wissen kann in domänenspezifischen Anwendungsfällen genutzt werden, um zur Problembehandlung beizutragen. Die hohe Komplexität elektronischer Systeme und die Vielzahl von zu beachtenden externen und internen Effekten verhindern eine Validierung des entwickelten Systems durch umfassende formale Beschreibung des Systemverhaltens. Erforderlich ist eine Ebene aus Meta-Wissen, welches derzeit durch die jeweiligen Entwickler in den Entwurfs- und Validierungsprozess eingebracht wird.

Mittels Methoden der künstlichen Intelligenz können das Wissen und die Regeln beider Domänen vereint werden, und in Verbindung mit einer Erweiterung der Wissensbasis durch automatisierte Lernprozesse kann ein Konnektor beider Domänen repräsentiert werden. Im Zuge des Systementwurfs werden umfangreiche Datenmengen generiert. Darunter fallen Dokumentationen - manuell sowie automatisch generiert, Simulationsergebnisse, Baupläne, wie Schematics, und Messergebnisse. Mit einer Sammlung der ohnehin anfallenden Daten können neuronale Netze trainiert und auf unterschiedliche Problemstellungen adaptiert werden und somit neue Erkenntnisse in Bezug auf die Systementwicklung liefern. Die verwendeten neuronalen Netze werden in verschiedenen Modulen entwickelt, sodass auf jeder Systemebene (System / Subsystem / Komponente) aber auch übergreifend Informationen genutzt und verarbeitet werden können, um so in die Systementwicklung einzufließen. Wichtig ist zusätzlich auch die Interoperabilität der Systeme, da es unzählige Kombinationsmöglichkeiten der einzelnen Systeme und deren Subsysteme und Komponenten gibt. Zusätzlich können KI-Module auch wertschöpfungsketten- und branchenübergreifend erhobene Daten sammeln und verwerten. Dies, modular zusammengefasst auf einer Plattform, bildet einen echten Mehrwert für die Fertigungsindustrie jeglicher Branche.

KI-Frameworks

Die weltweit operierenden Protagonisten des Einsatzes von KI-Methoden wie Google, Apple, Microsoft etc., setzen für die Entwicklung der Technologie weitgehend auf eine gemischte Strategie: Einen Teil der Wertschöpfung, nämlich den mit der wissenschaftlichen Erforschung von Algorithmen und der Bereitstellung effizienter Tools verbundenen, lassen sie offen unter Partizipation beinahe aller Universitäten der Welt durchführen. So stellen sie sicher, dass sie nicht plötzlich durch eine Innovation, die ihnen nicht zugänglich ist, abgehängt werden, und gleichzeitig über die wissenschaftliche Entwickler-Community Zugriff auf die besten Köpfe jeder Generation haben. Erst daran schließt sich die Firmen-exklusive Wertschöpfung, in der angestrebt wird, durch besseren Zugriff auf mehr Daten, bessere Serverarchitekturen, bessere Anpassung der Algorithmen etc. die besseren Services anzubieten. Dieses Businessmodell, das in höchster Form von Kapitalanlegern goutiert wird, hat dazu geführt, dass weltweit ein freier Zugriff auf die neueste Generation von KI-Algorithmen besteht. Diese liegen in Form von standardisierten Bibliotheken für zahlreiche Programmiersprachen vor – im Rahmen von *progressivKI* sollte in erster Linie auf die in Entwicklerkreisen gerne verwendete und vollständige Python-Implementation zurückgegriffen werden. Über die standardisierten Bibliotheken hinaus besteht Zugriff auf die aktuellen Neuentwicklungen in der Community, die in der Regel über wissenschaftliche Publikationen kommuniziert werden. Dies war der Ausgangspunkt der Forschung für *progressivKI* sowie der Wertschöpfung bei Bereitstellung der modularen strukturierten KI-Plattform im EDA-Bereich.

Auf der Ebene des Deep Learnings stellt das Open-Source KI-Frameworks TensorFlow von Google derzeit den Goldstandard dar. Dieses freie Software-Paket wird zur Bereitstellung von KI-Funktionalität in zahlreichen kommerziellen Google Produkten, wie Spracherkennung, Gmail, Google Fotos und Google Suche verwendet. Über eine Graphen-basierte abstrakte Modellierung komplexer Problemstellungen ermöglicht TensorFlow eine Analyse durch mehrstufige neuronale Netze. Auf diese Weise können Klassifikationsschemata, eine Verständnis-basierte Auswertung von Wahrnehmungsdaten und komplexe Muster erlernt werden und verlässliche Prognosen über Prozesse erstellt werden. TensorFlow stellt komfortable Schnittstellen zu SQL-Datenbanken, unterschiedlichen Netz- und Graphen-basierten Datenformaten sowie Bildformaten zur Verfügung. Als Bibliothek steht es in zahlreichen Programmiersprachen zur Verfügung, soll aber in diesem Projekt hauptsächlich über seine Python-Anbindung genutzt werden. TensorFlow Bibliotheken unterstützen eine Vielzahl von High Performance Rechenplattformen mit CPU-, GPU- oder TPU-basierter Architektur (bei letzterem, den sogenannten Tensor Processing Units, handelt es sich um von Google entwickelte anwendungsspezifische Chips, die hardwareseitig neuronale Netze unterstützen).

In den letzten Jahren wurde in großem Umfang weitere freie KI-Software zur Verfügung gestellt, die Anbindungen an zahlreiche Datenbank- und andere Systeme umfasst, komfortable Frameworks bietet oder auf TensorFlow aufbauende komplexere KI-Algorithmen zur Verfügung stellt. Hier ist vor allem die in Python verfügbare Bibliothek Keras zu nennen, die eine einheitliche und leicht nutzbare Schnittstelle zu mehreren Deep Learning Backends, insbesondere zu TensorFlow bietet, und das Importieren bereits vorhandener

Modelle sowie großer Datenmengen vereinheitlicht und wesentlich vereinfacht. Dadurch ist es ohne Umwege möglich, wissenschaftlich belegte, vordefinierte und ggf. sogar vortrainierte neuronale Netze einzubinden und an die jeweiligen Anforderungen des Gesamtsystems anzupassen. Durch die zu Grunde liegende state-of-the-art API TensorFlow können die Modelle aber auch Low-Level adaptiert und manipuliert werden, um eine möglichst geringe Fehlerquote bei Klassifizierungen und Vorhersagen zu generieren [RamaSingh].

Neben modernen Verfahren wie Convolutional Neural Networks (CNNs, siehe unten) kommen ebenso klassische Verfahren des maschinellen Lernens zum Einsatz, wie z.B. Decision Trees und Kernel basierte Algorithmen (z.B. die bereits beschriebene Support-Vector-Machine). Als Framework in diesen Bereichen können beispielsweise Systeme wie Rapid Miner und Shogun genutzt werden. Da die Qualität der mittels maschineller Lernmethoden erstellten Modelle unter anderem von der Qualität aber auch Quantität der benutzten Trainingsdaten abhängt, ist es notwendig, ein entsprechendes Konzept zur Erstellung der Trainingsdaten zu implementieren.

Verwendung von Simulation

Obwohl EDA-Tools eine hohe Menge unterschiedlicher Datenobjekte während des Entwurfsprozesses generieren und zusätzliche proprietären Daten (insbesondere Entwurfs-Regeln / Anforderungen / Constraints) zum Anlernen von KI-Algorithmen zur Verfügung stehen könnten, soll im Rahmen des Projektes die verfügbare Zahl an hochwertigen Daten durch zusätzliche dezidierte Simulationen (SI/PI/EMC) erweitert werden. Somit kann ein kombinierter Ansatz aus Simulationsdaten und gemessenen Daten zum effizienten Anlernen der eingesetzten KI-Algorithmen verwendet werden. Als Instrumente der Simulation kommen je nach abzubildendem Anwendungsfall Netzwerk-Simulationstools, Field-Solver, multiphysikalisch gekoppelte Simulationstools (3D EM) und spezielle Simulationsverfahren für z.B. das Power-Ground-Verhalten zum Einsatz. Hierbei können mittels der Simulationstools, z.B. mit Hilfe eines Field-Solvers, in kurzer Zeit große Mengen unterschiedlicher zufällig generierter Schaltungsszenarien analysiert werden. Anschließend werden diese analysierten Szenarien hinsichtlich verschiedener Parameter (akzeptable EMV-Abstrahlung, zulässiger Cross-Talk zwischen Leitungen, etc.) bewertet.

Durch diesen simulationsbasierten Ansatz lässt sich sicherstellen, dass eine ausreichende Datenbasis generiert werden kann. Die Verfügbarkeit von qualitativ abgesicherten Simulationsergebnissen ist ein entscheidender Vorteil für das Anlernen von Algorithmen. Daher sollen alle Simulationskompetenzen gesammelt werden, um diese nutzbar zu machen. Auf der Grundlage der in diesem Projekt herzuleitenden Bewertungen für die Abdeckung des Konfigurationsraums durch verfügbare Daten ist es möglich, vorhandene Simulationskapazitäten optimal zu nutzen, um gute Daten zu erhalten.

Semantisches Interface

Wie bereits erörtert, wird ein entscheidender Punkt die Verfügbarkeit, Quantität und Qualität von Daten zum Anlernen des Systems sein. Um hier möglichst viele Daten von vielen Anwendern der Plattform zugänglich machen zu können, ist die Einführung einer

einheitlichen internen semantischen Beschreibungssprache vorteilhaft, einschließlich automatisierter Übersetzungsprozesse in diese Sprache. Dieses Modul soll optional zur Verfügung gestellt werden und sich durch autarkes Lernen ebenfalls kontinuierlich verbessern. Die Topologie einer elektronischen Schaltung kann bereits gut durch ein Netz wiedergegeben werden. Ferner steht mit VHDL eine umfangreiche Beschreibungssprache für elektrische Schaltkreise zur Verfügung, die genutzt werden kann. Ein analoges Konzept wurde in [Esteban] für chemische Produktionsanlagen realisiert.

KI-Module für EDA-Anwendungen

Im Rahmen der Electronic Design Automation (EDA) kann KI in vielerlei Hinsicht zur Lösung von Einzelproblemen eingesetzt werden: automatisiertes Einlesen von Systembeschreibungen verschiedener Art (bis hin zum Natural Language Processing), Suche von Komponenten mit einer geeigneten Charakteristik aus einer Datenbank, Assistenz beim Entwurf auf unterschiedlichen Ebenen und insbesondere zur Verifikation vorliegender Entwürfe. Für diese Einzelanwendungen wurden bereits in einigen Fällen spezielle KI-basierte Lösungen erprobt. Während jedoch KI-Anwendungen in den Bereichen Modellierung (Erstellung von „Digital Twins“) und insbesondere zur Verifizierung neuer Konzepte auf der Hand liegen, ist der kritische Schritt, der in progressivKI angestrebt wurde, die automatisierte Lösung von Design-Problemen, wie in [DACPan20] dargestellt wird. Hierin liegt ein entscheidender Schritt über bereits in der Erprobung befindliche Teilverfahren hinaus.

Da die Durchdringung mit und Entwicklung von Technologien der künstlichen Intelligenz (KI) zunimmt, zeichnet sich ab, dass die KI in ihren zahlreichen Erscheinungsformen (Deep-Learning / maschinelles Lernen usw.) zu tiefgreifenden Veränderungen auch in den Design-Bereichen führen werden, wo bisher manueller CAD gestützter Entwurf mit spezialisierter Automatisierung (wie im Bereich EDA mit Chip- und PCB-Design) vorherrschend war. Dies spiegelt sich auch in der Tatsache wider, dass die führende Fachmesse der EDA-Branche, die Design Automation Conference (DAC) seit 2019 einen speziellen Track zum Thema Machine Learning/AI [DAC_AI] vorsieht.

Anders als bei der automatischen Auswertung von Konsumentendaten ist jedoch zu beachten, dass industrielle KI-Anwendungen Spezialisierungen erfordern. Z.B. verlangt die Analyse sicherheitskritischer Anwendungen nach einer höheren Verlässlichkeit und Validierbar- bzw. Verifizierbarkeit. Weiterhin werden effiziente Methoden benötigt, um z.B. für mechatronische Systeme Entwurfsansätze umzusetzen, die mit KI-Unterstützung mechanische, elektrische und andere Komponenten zusammenführen können. Die Interoperabilität von Entwicklungswerkzeugen ist erforderlich, um für den Aufbau einer umfassenden KI-Lösung das Zusammenwirken von verschiedenen Systemen sicherstellen zu können. Zurzeit ist kein Framework verfügbar, das optimale Lösungen für alle KI-Anwendungsbereiche umfasst [Graeber].

Die steigende Entwurfskomplexität erfordert eine stärkere Zusammenarbeit auf allen Entwicklungsebenen. Durch den zunehmenden Einsatz von Machine- und Deep-Learning in komplexen Systemen, auch in Entwurfssystemen, werden mehr Mitarbeiter benötigt. Entwickler von Systemen bzw. Subsystemen und Komponenten benötigen Flexibilität bei der

Bereitstellung von Inferenzmodellen. Weiterhin müssen die Entwickler von Inferenzmodellen z.B. über das notwendige Fachwissen in den Bereichen Optimierung, Variantenkonstruktion und Wiederverwendung von Komponenten verfügen. Sie müssen auch in der Lage sein, die für die Entwicklung von Inferenzmodellen notwendigen Informationen zusammenzuführen. Es werden Werkzeuge benötigt, die die wachsende Menge an Trainingsdaten bewerten und verwalten können. Insbesondere dem Lifecycle-Management der Inferenzmodelle kommt in diesen Zusammenhang eine hohe Bedeutung zu [Graeber].

Der modulare Aufbau von progressivKI erlaubt es den Konsortialpartnern und späteren Kunden, auf Wunsch auch typische Teilaufgaben des Electronic Designs KI-basiert automatisiert durchzuführen, wie das Erkennen von Mustern auf Schematic-Layoutplänen für Systeme, Subsysteme und elektrischen Komponenten, die Datenerfassung aus Simulationen, Dokumentationen und Messungen oder der Parametrisierung von Modellen. Aktuelle Forschungsergebnisse zeigen, dass Problemstellungen dieser Art sehr gut durch Convolutional-Neural-Networks (CNN) wie AlexNet oder Inception V3 bewältigt werden können [Krizhevsky]. Mithilfe der CNNs können Muster sowie Teilnetze einer PCB-Verdrahtung detektiert und klassifiziert werden [Zhang][Qiao]. Durch weitere neuronale Netze, die mit Hilfe von Initialregeln und erhobenen Messungen und Simulationsergebnissen trainiert werden, können partielle Systemanalysen durchgeführt werden [LuSun]. Die Ergebnisse dienen zur Änderung der Systementwicklungspläne.

Da die modulare Nutzung von progressivKI einen wesentlichen Anteil an der Vermarktung der Plattform haben wird, soll im Folgenden der Stand der Technik der KI-Nutzung und die noch bestehenden Bedarfe in einzelnen Segmenten des Elektronik-Entwurfs detailliert diskutiert werden. Beispiele für KI-Anwendungen zu Lösung von Automatisierungsproblemen im Elektronikentwurf finden sich z.B. in [DeepPCB], [EffectivePCB], [TrainingModel],[GloBay].

Die große ökonomische Bedeutung der Verfügbarmachung all dieser Einzelkomponenten von progressivKI zeigt sich, u.a., daran, dass der Wertschöpfungsprozess bei der PCB-Produktion vor allem durch Prozessunterbrechungen und Schnittstellenprobleme eingeschränkt wird. Das Fehlen von zusammenhängenden Tools von einem Anbieter gepaart mit Kommunikationsproblemen und dem Austausch nicht standardisierter Informationen verhindern optimierte Arbeitsflüsse. Betroffen sind alle Arbeitsprozesse vom iterativen Anforderungsmanagement bis hin zur manuellen Angebotserstellung. Die Extraktion von Informationen aus Bauteil-Datenblättern erfolgt heutzutage größtenteils manuell. Wie Gespräche mit Industrieexperten ergeben haben, wird der Prozess der Informationsextraktion von Einzelteil-Lieferanten oftmals ins Ausland ausgelagert. Auch EMS-Firmen und Designer schauen manuell nach Informationen in den Datenblättern. Aus Gesprächen mit EMS-Firmen ist hervorgegangen, dass das Erstellen eines Angebots bis zu 40 Arbeitsstunden in Anspruch nehmen kann, was hauptsächlich an ineffizienten Informationsflüssen und iterativer Kommunikation mit Lieferanten liegt. Der hohe Zeitaufwand birgt das Risiko viel Zeit in Angebote zu stecken, die letztendlich nicht immer verkauft werden. Gleichzeitig entstehen für Designer häufig kostspielige Iterationen, die vermieden werden könnten, wenn sie frühzeitig an nötige Informationen zur Verfügbarkeit, Herstellbarkeit, Konformität usw. kommen würden.

Segment „KI zur Verifikation von Entwürfen“

Im Umfeld des physikalischen Designs und der Verifizierung wird ML auf IC-Ebene bereits hilfreich bei der Simulation von Teilstrukturen und zur Optimierung eingesetzt, ebenso im Bereich Halbleiterfertigung zur Lithografiesimulation und -korrektur. Durch maschinelles Lernen können somit Prozesse verkürzt bzw. die Komplexität der lösbaren Teilaufgaben deutlich erhöht werden.

Weiterhin bieten sich kombinatorische Probleme wie Platzierung und Routing/Verdrahtung auf IC- wie auch auf PCB-Ebene für den Einsatz von ML/AI Technologien an. Neben den etablierten EDA-Anbietern (s.o.) sind eine Vielzahl von Forschungseinrichtungen sowie auch Startups [DREAMplace] in diesem Kontext aktiv.

Segment „Interpretation Design-relevanter Informationsquellen“

Über Experteninterviews [Luminovo, 2020] wurde identifiziert, dass besonders das Lesen von Komponenten in Datenblättern und die Suche nach darin enthaltenen Informationen viel Zeit im elektrotechnischen Designprozess in Anspruch nimmt. Daher sollen mit diesem Vorhaben Wege gefunden werden, diese Datenblätter automatisiert mit einer KI auszulesen. Datenblätter beinhalten alle Informationen in Form von Texten, Tabellen und Zeichnungen, die zu verschiedenen Zeitpunkten bei der Elektronikfertigung für verschiedene Akteure relevant sind. Folgende Stakeholder extrahieren größtenteils manuell relevante Informationen aus den Datenblättern und würden von einer Prozessoptimierung profitieren:

1. Einzelteil-Lieferanten / Distributoren erhalten Datenblätter von Komponentenherstellern / Halbleiterunternehmen und extrahieren Bauteilspezifikationen (bsp.: Spannungskurven oder Temperaturkurven), um diese in ihre internen Informationssysteme einzupflegen.
2. EMS-Firmen extrahieren Informationen für die Verarbeitung und Zusammensetzung von Elektrokomponenten.
3. Designer / Elektroingenieur benötigen Datenblätter für das Entwerfen von Leiterplatten. Die Datenblätter zeigen z.B., ob die Komponenten den Ansprüchen an ein Elektroprodukt entsprechen.

Daher bot progressivKI u.a. Lösungsansätze für KI gestützte Informationsextraktion aus schematischen grafischen Darstellungen, Fließtexten und semi-strukturierten Tabellen von Datenblättern technischer Komponenten, damit diese den genannten Stakeholdern ohne zeitaufwändiges Suchen verfügbar gemacht werden können. Die Automatisierung dieses Arbeitsschrittes erlaubt alleine schon eine schnellere Markteinführung neuer Produkte für Firmen aus der gesamten Elektronikindustrie und wirkt gleichzeitig dem wachsenden Defizit an Fachkräften in der Branche entgegen. Im Jahr 2018 lag der Mangel an qualifizierten Mitarbeitern in der Elektronikindustrie in Deutschland bei rund 50.000 Stellen, was die Entwicklung der Industrie hemmt [Dierig, 2018]. Durch progressivKI sollen Firmen der Elektrobranche die Möglichkeit haben, in einem kürzeren Zeitraum mehr zu produzieren und ihre Innovationskraft zu verbessern, ohne an dem Mangel an Arbeitskräften zu leiden. Zusätzlich soll durch das System die internationale Wettbewerbsfähigkeit deutscher Unternehmen aus der Elektronikindustrie gefördert werden, da Ressourcen von repetitiven Arbeiten befreit werden und wertschöpfender eingesetzt werden können.

Die Herausforderung, automatisch strukturierte Informationen wie Tabellen oder Texte aus unstrukturierten und/oder halbstrukturierten maschinenlesbaren Dokumenten zu extrahieren, wird traditionell als Informations-Extraktion (IE) bezeichnet. Dieses Gebiet war in den letzten Jahren Gegenstand zahlreicher Forschungsarbeiten und Applikationen innovativer Methoden. Es beinhaltet die Verarbeitung von Texten in menschlicher Sprache mit Hilfe von Natural Language Processing (NLP). Überwachte oder halb überwachte Lernalgorithmen, die ein Verständnis des Dokumenten-Layouts mithilfe von geometrischen Merkmalen aufbauen, sind seit Jahrzehnten weit verbreitet. Wirklich präzise wurden diese Systeme jedoch erst in den letzten Jahren mit der Einführung von tiefen neuronalen Netzen (NN). So gibt es viele innovative Ansätze, die neben der Verwendung von neuronalen Netzen, Graph-Repräsentationen (Hartmann et al., 2018), [Coüasnon], oder auch Architekturen aus der klassischen Bildverarbeitung [Redmon] verwenden. In der Literatur existieren Lösungsansätze für die Tabellenerkennung mit Heuristiken [Jahan] unter Verwendung von Layouts [Dhiran], regulären Ausdrücken [Mandal], oder dem Nutzen von Tabellenzeilen [Gatos], [Gupta], [Liu], [Farrukh]. Eine großartige Übersicht wird in der Arbeit von Milošević [Milošević] gegeben. Des weiteren existieren Forschungsarbeiten, die versuchen, Tabellen in HTML [Tengli], [Chu], Freitext [NgLimKoo] oder wissenschaftlichen Artikeln [Clark] zu identifizieren. Viele Lösungsansätze stützen sich hierbei auf neue Methoden des maschinellen Lernens und verwenden beispielsweise Convolutional Neural Networks (CNNs) [Kavasisidis], [Silva], Fully Convolutional Networks (FCNs) [Schreiber], oder semantischen Region-based Convolutional Neural Networks (R-CNNs) [Gilani] unter Verwendung von euklidischen Abstands-Merkmalen. Insbesondere im Bereich der Named Entity Recognition (NER) hat es im letzten Jahrzehnt viele neue Lösungsansätze und technische Fortschritte gegeben [Dernoncourt], [Yadav], [Lample]. Bei der Entitäten-Extraktion werden in einem unstrukturiertem Text Schlüsselemente identifiziert sowie klassifiziert und vorab definierten Kategorien zugeordnet. Beginnend mit [Collobert] sind NER-Systeme mit neuronalen Netzen mit minimalem Feature Engineering populär geworden. Solche Modelle sind attraktiv, da Sie in der Regel weniger domänenspezifischen Ressourcen als Lexika oder Ontologien benötigen und somit Domänen unabhängiger sein können. Seither wurde eine Vielzahl weiterer Herangehensweisen und NER-Architekturen entwickelt, die oftmals auf von Recurrent Neural Networks (RNN) oder Transformer-Architekturen abstammen und auf die Schriftzeichen, Sub-Wörter oder Word-Embeddings zurückgreifen [Agerri], [Kuru], [Yadav]. [LiHanLi] geben in ihrer Arbeit eine umfassende Übersicht über die bestehenden Deep-Learning basierten NER-Techniken und verfügbaren NER-Datensätze und Industrieprojekte. Da die Fülle an angewandten Methoden jedoch jeweils auf verschiedenen Datensätzen angewendet wurde, lassen sich die Ergebnisse der Datenauswertung nur schwer auf die vorliegende Domäne der Elektronik übertragen. Die Datenblätter mit elektronischen Komponenten haben im Allgemeinen kein einheitliches Layout, und beinhalten neben dem Fließtext und den Tabellen auch technische Zeichnungen, Abbildungen und Spannungsdiagramme unterschiedlichster Formate.

Um alle relevanten Informationen aus einem semi-strukturierten Datenblatt zu extrahieren, muss das Zielsystem das Dokument somit in seiner Gesamtheit verstehen und differenziert methodisch bearbeiten. Somit ist neben der Kombination von führenden IE-Architekturen

auch ein qualitativ hochwertiger Datensatz notwendig, um einen möglichen Durchbruch bei der Automatisierung und Extraktionsleistung zu erreichen.

Der Konsortialpartner DIQA steuerte Methoden zu Wissensrepräsentation, Informationsextraktion, NLP und Machine Learning zu progressivKI bei. Als Input für diese Verfahren dienen natursprachliche Texte. Die Formalisierung von Wissen (aus Dokumenten oder Erfahrungswissen) bedeutet, dass es in ein formales, maschinenlesbares Format überführt wird. Aktuelle Forschungsbemühungen zur Wissensrepräsentation stammen z.B. aus dem Semantic Web-Umfeld, für das das W3C mit dem Resource Description Framework [RDF] ein Format für Graph-basierte Wissensmodelle standardisiert hat. Darauf bauen zahlreiche weitere Wissensrepräsentationsformate mit unterschiedlicher Ausdrucksfähigkeit auf [RDF11], [OWL2]. Für progressivKI war die Mächtigkeit des „Simple Knowledge Organization System“ [SKOS] geeignet, um Erfahrungswissen in Form von Taxonomien und Thesauren abzubilden. Es gibt einige SKOS-Editoren, die jedoch unterschiedliche Reifegrade haben, und nicht mit gängigen Dokumentenmanagementsystemen ausreichend tief kompatibel sind (z.B. Eurovoc, Taxonomymanager von Metavis, Poolparty von Semanticwebcompany). Zu Projektbeginn gab es keine Wissensmodelle, die den integrierten Entwurfsprozess von Elektroniksystemen für den KFZ-Bereich abbilden.

Methoden und Einsatzbereiche von Information Extraction sind sehr vielfältig (sh. [Sarawagi] für einen guten Überblick). Sie reichen von regelbasierten Systemen bis hin zu statistischen Machine Learning-Ansätzen. Seit einigen Jahren hat Deep Learning für das Verarbeiten von natürlicher Sprache zu erstaunlichen Erfolgen geführt. Hier ist insbesondere die Einführung von sog. Word-Embeddings, die Wörter oder Konzepte durch einen mathematischen Vektor hoher Dimensionalität repräsentieren [Mikolov], und die oft mittels Recurrent Neural Networks (RNNs [WIKImem]) gewonnen werden, zu nennen. Für die Umsetzung stehen einige Open Source Produkte zur Verfügung, wie bspw. Keras/TensorFlow, NLTK und Tesseract. Ihnen gemeinsam ist, dass es sich um Bibliotheken handelt, die implementiert und so in eine Anwendung integriert werden müssen, bevor die implementierten Algorithmen umfangreich trainiert bzw. konfiguriert werden können.

In progressivKI sollten Verfahren der eher symbolischen Wissensrepräsentation mittels diskreter Modelle mit den subsymbolischen Verfahren zur Ermittlung von Konzepten kombiniert werden. Hierzu kann die herausgehobene Situation des Projektes progressivKI als Kontext genutzt werden, da hier ausreichende Dokumentbestände für das Learning verfügbar sind und viele potenzielle Lernaufgaben sowohl von den expliziten Modellen als auch ihrer statistischen Vektorrepräsentation profitieren können.

Segment „Berücksichtigung der EMV im Entwurfsprozess“

Im Bereich der EMV-Abnahmemessungen wird derzeit keine KI zur Optimierung eingesetzt. Meist erfolgt eine Voroptimierung der Elektronik innerhalb des untersuchten Prüflings (Fahrzeugkomponenten EuB) vorab simulationsbasiert beim Kunden. Dies geschieht in einem frühen Stadium der Entwicklung – wie bereits erörtert - meist auf Basis von Simulationen. Hier gibt es für einige Anwendungen, wie z.B. Filteroptimierung, Ansätze, die Performance von Emissionsmessungen computergestützt zu optimieren [MueBel]. Die ersten Versionen der Hardware werden dann zum Teil noch beim Kunden vermessen. Langjährige Erfahrungen

aus dem Laborbetrieb zeigen aber, dass es immer wieder bei den Abnahmemessungen teilweise zu großen Abweichungen und Grenzwertüberschreitungen kommt. Da der Projektpartner EMC Test NRW GmbH als Prüflabor die Prüflinge immer als Black-Box betrachtet, wurden bei der Messung nur die äußeren Ports betrachtet. Eine Verknüpfung der Simulationen und der Vorabmessungen mit den Ergebnissen der Abnahmemessungen existierte nicht. Auch wird keine KI zur Optimierung eingesetzt. Rückschlüsse auf die Auswirkungen von Hardwareänderungen auf die Ergebnisse bei Komponentenmessungen könnten die Anzahl der Iterationsschleifen im Elektronikentwicklungsprozess im Bereich der EMV drastisch reduzieren.

Segment „Lieferkettenübergreifende Qualitätssicherung“

Die Verantwortung für das Erreichen eines funktional sicheren Systems betrifft nicht nur den Systementwickler bzw. Integrator, sondern die gesamte Lieferkette, wie Modul- und Komponentenlieferanten bis hin zu Bauteillieferanten und Technologieprovidern. Somit ist ein Austausch von Informationen über die gesamte Liefer- bzw. Wertschöpfungskette wünschenswert.

Zur Bewertung von Mikroelektronik-Technologien entlang der Wertschöpfungskette, d.h. vom Halbleiterhersteller bis hin zum OEM, wurde in [AlsAdHi] das Werkzeug Technology Black Box (TBB) vorgestellt, welches das kollaborative Entwickeln und Bewerten von Halbleitertechnologien ermöglicht. Hierzu bietet das Werkzeug den Abgleich von Anforderungen und Technologiebewertungen, wobei alle Akteure Modelle bereitstellen und nutzen können. Ein vergleichbares Werkzeug, Collaborative Technology Evaluation Framework (CTEF), wurde in [AhaNovVi] vorgestellt. Ziel war die Bewertung von Zuverlässigkeit und Energiebedarf, ohne den Austausch geistigen Eigentums (Intellectual Property). Hierzu wurde eine Austauschplattform geschaffen, bei welcher Akteure der Wertschöpfungskette Modelle zur Transformation von System- bzw. Technologieparameter anbieten konnten. Der Nutzer kann auf diese Modelle zugreifen, um eine System- bzw. Komponentenbewertung durchzuführen. Beiden Ansätzen gemein ist, dass sie vorrangig auf mathematischen Modellen sowie im begrenzten Umfang auf Simulationen aufbauen. Dennoch stellen sie eine gute Grundlage zur Adaption für den Austausch, bzw. die synergetische Nutzung von KI-Modellen dar. Fragestellungen wie die Handhabung der komplexeren Schnittstellen der Modelle müssen aber noch geklärt werden. Hier könnten Ansätze aus der kooperativen Nutzung von Simulationsmodellen als Vorlage dienen. Beispielsweise bietet das Functional Mock-up Interface (FMI) [FMI], eine standardisierte Schnittstelle zum Koppeln von Simulationsmodellen. In [Masudul] wird FMI zur Kopplung von RTL-Simulationen mit Software-Simulationen in MATLAB verwendet. Im Kontext von FMI wurden weitere Standards wie das System Structure and Parameterization (SSP) [SSP], um die Gesamtarchitektur der Co-Simulationen, sowie den benötigten Parameternaustausch zu spezifizieren. Des Weiteren ermöglicht das Distributed Co-Simulation Protocol (DCP) [DCP], den Austausch von Simulatoren über Kommunikationstechnologien zu koppeln. Wie bereits erwähnt, fokussieren sich die Standards auf die kooperative Nutzung von Simulationsmodellen, die grundlegenden Konzepte könnten aber auf die synergetische Nutzung von KI-Modellen übertragen werden.

Um den Anforderungen des IP-Schutz, der Komplexität von Systemen sowie dem Aspekt der unterschiedlichen Lieferanten gerecht zu werden, werden häufig Prädiktionsmodelle eingesetzt, welche von der eigentlichen Realisierung abstrahieren und nur die für den aktuellen Analysefall relevanten Aspekte versuchen zu bestimmen. Hierbei können die Modelle auf Erfahrungen mit verwandten Systemrealisierungen basieren, Experten- bzw. Domänenwissen oder aber auch Referenzmessungen. Ziel ist immer, den relevanten Aspekt des Systems mit Hilfe eines Modells abzubilden. Im Kontext von KI-basierten Methoden stellt die Gruppe des Imitation Learning (IL), was eine Untergruppe des Reinforcement Learning (RL) ist, interessante Konzepte zur Verfügung. Im Vergleich zu RL greift IL aber anstelle einer spezifizierten Kostenfunktion auf existierendes Expertenverhalten zurück. Im Falle von Behavioral Cloning erlernt das Modell das Expertenverhalten mittels des aktuellen Zustands sowie der ergriffenen Aktion [Pomerleau, BainSammut]. Das generelle Vorgehen bietet somit interessante Ansätze, um das Expertenwissen von Entwicklern bzw. das Verhalten von Systemen mittels Modellen nutzbar zu machen. Eine Weiterentwicklung stellt das Direct Policy Learning (DPL) dar, bei welchem anstelle auf existierendes Expertenwissen auf ein interaktives Referenzsystem zurückgegriffen wird, dies ist insbesondere bei der Nachbildung von Systemverhalten vielversprechend. Ein etwas abweichender Ansatz versucht anstelle des Verhaltens die Kostenfunktion zu schätzen. Beim Inverse Reinforcement Learning (IRL) wird die Reward-Funktion der Grundlage der Demonstrationen des Experten erlernt und dann die optimale Entscheidung mit Hilfe von RL zu finden. Den Ansätzen inhärent ist, dass sie neben dem aktuellen Zustand auch die ergriffene Aktion spezifiziert sein muss.

Der in [Torabi] vorgeschlagenen Ansatz versucht dieses Problem zu umgehen. Das Behavioral Cloning from Observation (BCO) strebt ein Lernen basierend auf Beobachtungen an, ohne die letztendlich getroffene Entscheidung mitberücksichtigen zu müssen, etwa, wenn diese nicht beobachtbar ist. Dies könnte ein vielversprechender Ansatz sein, wenn lediglich vergangene Ergebnisse eines Entwurfsprozesses aber nicht mehr die ergriffenen Aktionen (Entwurfsentscheidungen) vorliegen.

MetaModellierung

Obwohl sich unterschiedliche Lernprozesse im Detail sehr unterscheiden, z.B. hinsichtlich der Datenstruktur, anhand derer sie Probleme beschreiben (Netze bei TensorFlow, Vektoren oder Matrizen in anderen Fällen etc.), lassen sich Lernprozesse allgemein über Extremalprinzipien im Kontext Markovscher Entscheidungsprobleme mathematisch modellieren (z.B. [Csaba] oder [Ziebart]). Eine solche Beschreibung ermöglicht bei geeigneter Modellierung der zum Anlernen bereitstehenden Daten eine Beurteilung, wie gut der jeweilige Algorithmus geeignet ist, einen Lernerfolg zu erzielen und anschließend die richtigen Prognosen zu finden. Daher wird folgendermaßen vorgegangen:

- Auffinden einer geeigneten Metrik für die Bewertung der Qualität der Daten als Repräsentanten des Zustand- oder Designraumes.
- Modellierung des Ausgangszustand des jeweiligen Lernverfahrens.
- Analyse der Veränderung des Zustandes im mathematischen Modell aufgrund des Lernprozesses.

- Einordnen des Problems entsprechend des auftretenden dynamischen Verhaltens in eine Problemklasse.

Über die Entscheidung hinaus, welche Algorithmen für welche Probleme verwendet werden, kann auch ein Modell für die Qualität der Endzustände aus dem Laufzeitverhalten abgeleitet werden. Dies kann zur Kontrolle des Prozesses eingesetzt werden.

Neben der formalen Analyse sollen beide Fragen, Qualität des Endzustandes und Wahl geeigneter Algorithmen für ein gegebenes Problem, auch durch Verwendung einer übergeordneten „Meta-Maschine“, also eines regelnden maschinell lernenden Programms behandelt werden. Die Performance dieses Ansatzes wird mit dem formalen Ansatz verglichen. Durch die Analyse und Bewertung der Datenqualität entsteht die Möglichkeit, Kunden der modularen KI-Plattform Richtlinien zu geben, wie sie die Qualität der Datenerhebung verbessern können. Dieses Know-how wird auch Teil der avisierten Schulungsmaßnahmen für Wirtschaftsvertreter sein.

Die mathematische Analyse betrachtet eine große Familie von Algorithmen als Entität und beschreibt die Struktur dieses Objektes in Hinblick auf die Verwendbarkeit zur Lösung gewisser Probleme. Diesen Ansatz Mathematik zu betreiben, hat S. Smale als richtungsweisend für das 21. Jahrhundert identifiziert. Die mathematische Analyse sollte in diesem Projekt zur rigorosen Qualitätssicherung der in der Plattform implementierten Verfahren verwendet werden. Dabei spielen zusammenfassend die folgenden Punkte eine wichtige Rolle:

- Paradigma: „Mathematische Analyse von Gesamtheiten von Algorithmen“
- Definition von Metriken für Lernfortschritt
- Definition von Metriken für Datenqualität, operationelles Vorgehen zur Sicherung von Datenqualität
- Bewertung des Konfigurationsraums und dessen Ausschöpfung
- Validierung durch Simulation
- Die Bewertung des Lernerfolges durch künstliche Intelligenz kann genauer a posteriori erfolgen, wenn unterschiedliche Lernstrategien parallel verfolgt und verglichen werden.

Ein weiteres Problem, das mittels algorithmischer Steuerung der KI zu lösen sein wird, ist die Bewertung der Qualität der in einem Bereich anfallenden Daten in Hinblick auf den Lernfortschritt:

Im Bereich der Datenerfassung und Verwaltung sind im Zuge der vergangenen Jahre zwar einige neue Technologien entstanden, wie zum Beispiel sogenannte „Data Lake“ Systeme, die es ermöglichen, Daten aus unterschiedlichen Quellen miteinander in einen Kontext zu bringen, allerdings klären solche Systeme nicht, welche Daten sinnvoll für die Erfassung sind. Die besondere Herausforderung bei der Anwendung von KI in der effizienten Entwicklung von eingebetteten Systemen wird sein, zunächst die Art der Daten, die für eine KI-Anwendung relevant sind, zu identifizieren und dies auch dynamisch erweitern zu können. Insbesondere muss darauf geachtet werden, dass nicht allein die Daten, die zu einem erfolgreichen Schritt im Entwicklungsprozess geführt haben, gesammelt werden (wie es zum Beispiel mit der Versionierung der finalen Tool-Reports bei der Beendung eines

Entwicklungsschrittes gemacht wird), sondern auch die Daten der Zwischenschritte, die notwendig waren, zu dem Ergebnis zu kommen. Somit würde sichergestellt, dass eine zukünftige KI nicht auf vorgeprägten, sondern umfassenden Daten trainiert werden kann. Weiterhin, bedeutet dies auch, dass man klären muss, welche Strukturierung dieser Daten notwendig ist, um einen effizienten Zugriff auf diese Daten zu gewährleisten und, um sicherzustellen, dass diese Daten nicht auf konkrete Entwickler zurückführbar sind- um betriebliche Auflagen zu wahren.

Maschinelernen zur Reduktion von Modellfehlern

Die modulare Struktur von progressivKI war hervorragend geeignet, um Projektrisiken von vornherein abzufangen. Aus maschinellen Lernalgorithmen mit unterschiedlicher Komplexität (z.B. parametrische Verfahren niedriger Ordnung – mehrstufige neuronale Netze – Reinforcement Learning) wird je nach

- Lernerfahrung („State“) des jeweiligen Algorithmus,
- Klassifizierung der vorliegenden Problemstellung und
- Beurteilung der verfügbaren Daten zum Anlernen verwendet.

Als qualitätssichernde Maßnahme war im Rahmen dieses Projektes vorgesehen, den Lernerfolg des Algorithmus und die Qualität des Erlernten aus Beobachtungen während der Laufzeit abzuleiten. Diese transparente Objektivierung der Methode garantiert Wiederholbarkeit und Überprüfbarkeit der Resultate und war ein Alleinstellungsmerkmal dieses Projektes. Auch in diesem Fall sollte sowohl ein mathematisches Modell des automatischen Lernens eingesetzt werden (siehe unten) als auch optional ein maschineller Lernprozess auf der Metaebene.

Um darüber hinaus zu vermeiden, dass selbstlernende Verfahren – möglicherweise wegen des Fehlens ausreichend guter Daten – nicht konvergieren, sollten neben rein parametrischen Methoden auch gemischte Verfahren verwendet werden, bei denen, ausgehend von einem einfachen physikalisch motivierten Grundmodell, nicht ein selbstlernender Agent von Grund auf identifiziert wird, sondern nur der Modellierungsfehler verkleinert wird. Es können die gleichen Daten zur Identifikation des Modells und zum Anlernen des Maschinenagentens verwendet werden: Das einfach berechenbare Modell wird durch Daten in einer Offline-Phase identifiziert und gleichzeitig werden die Daten verwendet, um ein selbstlernendes System anzulernen, das Prognosen über den Fehler des Simulationsergebnis in Bezug auf Messdaten (oder anders gewonnenen genaue Referenzdaten) durchführt. In der Onlinephase werden dann das angelernte physikalische Modell und der angelernte Algorithmus gemeinsam verwendet. Dieses Verfahren hat den Vorteil, dass mangelnder Lernerfolg sehr unwahrscheinlich wird und das Lernen einer rigorosen mathematischen Analyse zugänglich ist. Dies ist insbesondere dann der Fall, wenn der Fehler so klein ist, dass er mit einem linearen Modell beschreibbar ist.

Insbesondere wenn das Modell bereits eine günstige Struktur aufweise, kann der Modellierungsfehler als so klein angenommen werden, dass ein lineares Modell für eine sehr genaue Modellfehleridentifikation vollständig ausreichend ist. Dieses Paradigma ist derzeit aktuell und viel diskutiert in der Computational Electromagnetics-Community (z.B. [Chinesta]). Eine solche Erweiterung von [modularKI] erhöht die Sicherheit der Plattform,

sinnvolle Ergebnisse zu liefern, die Möglichkeit, zusätzliche Sicherheit durch Crosschecks unterschiedliche Verfahren zu erhalten und mindert somit auch das Projektrisiko von progressivKI.

Beispiele sind Schaltkreismodelle, bei denen durch induktive und kapazitive Kopplung hervorgerufene feldgebundene EMV-Probleme durch zusätzliche Quellen modelliert werden, die durch Daten identifiziert werden bei gleichzeitigem Anlernen des fehlerschätzenden selbstlernenden Moduls. Die modulare KI-Plattform wird Schnittstellen zur Modellidentifikation bei gleichzeitigem Anlernen des Fehlerprognosemodells bieten. Als konkretes Beispiel für einen gemischten Ansatz sei ein Schaltungsentwurf (Topologie- und Geometrieentwurf) mittels eines Netzwerklösers (z.B. Spice), bei dem die feldgebundenen Kopplungen (z.B. Crosstalk und äußere Felder durch benachbarte Installationen) durch zusätzliche (durch Feldsimulation oder Experiment) zu identifizierenden Quellen und Senken identifiziert werden müssen. Hier könnten die zur Identifikation des Modells erforderlichen Daten sofort zum Anlernen eines Agenten verwendet werden, wodurch ein Schätzer für den Modellfehler angelernt würde.

Identifikation geeigneter Hardware

Nach dem im vorherigen Abschnitt allgemeine Konzepte, welche für die angestrebte Anwendungsdomäne interessant sein könnten, vorgestellt wurden, soll in diesem Abschnitt dedizierte Ansätze zur Einbeziehung von Hardwareeigenschaften zur Prädiktion des Softwareverhaltens vorgestellt werden. In [AbelRein] wird ein messbasierter Ansatz zur Modellierung des Cache-Ersetzungsverhaltens vorgestellt. Die Autoren beleuchten, an welchen Stellen der Einsatz von maschinellem Lernen die hohen Anforderungen an die Erstellung des Modells reduzieren können. Ein ähnlicher auf Messungen basierter Ansatz zur Prädiktion von Laufzeiteigenschaften ist in [CornVie] vorgestellt. Ähnlich zu [AbelRein] bieten sich KI-gestützte Modelle zur Reduktion der Komplexität sowie zur Steigerung der Adaptionsfähigkeit der Modelle an. Hier kann progressivKI mit der Generierung von Modellen basierend auf Experten- und Erfahrungswissen unterstützen und die rein messungsbasierten Ansätze erweitern. Der in [Graves] vorgestellte Ansatz ist rein KI-basiert. Mit Hilfe eines neuronalen Netzwerks, das externen Speicher lesen und schreiben kann (Differentiable Neural Computer, DNC), lernt das Modell mittels unterschiedlicher Referenz-Demonstrationen. Die Autoren demonstrieren den Ansatz am Beispiel von Graphen-basierten Experimenten, was vielversprechend für die Übertragung auf Basisblock-Abfolgen und somit die Laufzeitprädiktion von Software ist. Abschließend soll ein KI-basierter Ansatz, welcher die Laufzeitprädiktion mit Hilfe von Referenzmessungen auf unterschiedlichen Systemen angeht, vorgestellt werden. Hierbei wird ein Modell für den Wechsel von einer Hardware-Architektur auf eine Zweite trainiert. Mit Hilfe dieses Modells können Aussagen über die Zielplattform, bzw. das neue System, basierend auf Erfahrungen mit einem zweiten System getroffen werden. Viele der betrachteten Arbeiten bieten interessante Ansätze zum Entwurf von Prädiktionsmodellen im Kontext von progressivKI. Basierend auf den im Projekt identifizierten Datenquellen, bzw. deren Umfang, können unterschiedliche Ansätze adaptiert bzw. kombiniert werden. Eine vielversprechende Grundlage zur Erweiterung stellen die Arbeiten in [CornVie] dar.

Seit einigen Jahren findet weltweit intensive Forschung und Entwicklung beim KI-Einsatz für den Entwurf von Chips und Systemen statt, aber auch im Hinblick zur Entwicklung dezidierter Hardwaresysteme, um verschiedene KI-Einsatzbereiche (z.B. Bilderkennung) dezidiert zu unterstützen. Im Bereich KI-Technologien beschäftigen sich führende EDA-Unternehmen wie Cadence [Klcdn], Mentor [Klment] oder Synopsis [Klsyn] daher mit Fragestellungen wie der Entwicklung von Tools, mit denen Unternehmen KI-Beschleuniger (Hardwarelösungen) schneller entwickeln können, um auf diesen Systemen ihre maschinellen Lernalgorithmen zur Verbesserung der IC-Designtools einzusetzen und so Kunden die Möglichkeit zu geben, schneller bessere Ergebnisse erzielen zu können.

Der Bedarf an angepasster Hardware zeigt sich daran, dass KI-Methoden, die initial Implementierungen mathematischer Algorithmen sind, nach ihrer Erstellung in einem entsprechenden Werkzeug (z.B. MATLAB) und Übersetzung (z.B. über C-Code in entsprechenden Objektcode) bei Ausführung auf einem zufällig vorliegenden Prozessor oft nur zu Teilen optimal ausgeführt werden können, während andere Teile langsamer ausgeführt werden.

Neben Ansätzen, zur Vermeidung solcher Probleme für derartige Teilaufgaben leistungsfähige Grafikkarten CPUs (GPUs) einzusetzen, gibt es auch einen enormen Anstieg (und nachfolgende Investitionen der Venture-Community sowie großer Unternehmen) in die Entwicklung von AI/ML-Beschleunigern für IP und Silizium. KI-Plattformen und entsprechende ICs/SoCs, die für AI/ML-Anwendungen verwendet werden, benötigen große Parallelverarbeitungsberechnungseinheiten und zeichnen sich aber auch durch hohe Verlustleistung und komplexe Schaltungen aus.

2.3.2 Bisherige Arbeiten des Antragstellers

01-BOSCH

Unternehmensvorstellung

Die ehemalige Robert Bosch Car Multimedia GmbH wurde am 01.01.2022 in die Robert Bosch GmbH integriert und der Geschäftsbereich CM wurde in XC umbenannt. Der Unternehmenssitz befindet sich in Hildesheim, Deutschland. XC trägt mit intelligenten Lösungen dazu bei, die Integration von Entertainment, Navigation, Telematik und Fahrerassistenz im Fahrzeug flexibler und leistungsfähiger sowie möglichst komfortabel bedienbar zu gestalten. XC entwickelt Hard- und Software der Gegenwart und gestaltet die Zukunft der vernetzten Mobilität aktiv mit.

Das Portfolio umfasst weltweit einsetzbare, hochintegrierte Fahrerinformations- und Infotainment-Systeme sowie frei programmierbare Anzeigesysteme und Connectivity Control Units. Die Systemintegration von komplexen und vernetzten Multimedia-Systemen zeichnet XC dabei besonders aus.

Die Infotainment- und Displaylösungen von XC bringen das Smartphone-Nutzungserlebnis auch in das Auto und das Nutzfahrzeug. Damit macht Bosch die Fahrt nicht nur komfortabler und unterhaltsamer, sondern zusammen mit den Vernetzungslösungen auch sicherer und effizienter.

Mit Einführung des automatisierten Fahrens wird sich die Art, wie Fahrzeuge wahrgenommen und genutzt werden, grundlegend verändern. XC betreibt intensive Forschungen zu dem Thema, wie ein autonomes Fahrzeug der Zukunft neben Wohnung und Arbeit zum dritten Lebensbereich werden kann.

Bosch legt den Fokus dabei stets auf die Entwicklung innovativer Produkte und Systeme mit hohem Kundennutzen und exzellenter Qualität.

Projektbezogene Kompetenzen und Schwerpunkte

Aktuell wird im Entwicklungsprozess von Fahrzeugkomponenten kein KI-gestützter Entwurf genutzt. Hier wird häufig auf manuelle Techniken sowie semiautomatische Prozesse im Layout- bzw. Schaltplandesign zurückgegriffen. Auch die EMV wird manuell überprüft auf Basis von rudimentären und oft geometriebasierten Designregeln. Hierbei hat sich bereits häufig gezeigt, dass diese Analyse der EMV oft unzureichend ist und viele Probleme erst bei entsprechenden Messungen sichtbar werden. Daher muss das Ziel sein, dass durch KI der Entwurfsprozess verbessert und effizienter gestaltet wird. Durch den steigenden Anforderungsdruck und die Verkürzung von Entwicklungszeiten, wird eine detaillierte Bewertung vorliegender Layouts/Schematics immer herausfordernder.

Relevante Vorgängerprojekte

RobKom: Robert Bosch GmbH (Reutlingen), Optimierung der EMV von Inertialsensoren für den Einsatz in autonom fahrenden Fahrzeugen

Das wesentliche Projektziel des F+E Vorhabens RobKOM besteht darin, neuartige Konzepte für den kooperativen Betrieb von EMV-kritischen WBG-Halbleitern und Kommunikations- sowie Sensorsystemen für autonome Elektrofahrzeuge zu erforschen und deren Anwendbarkeit nachzuweisen. Bosch setzt sich im Projekt mit der Erforschung von Maßnahmen für den Entwurf von EMV-robusten Sensorsystemen für die Anwendung in autonomen Elektrofahrzeugen auseinander.

EM4EM: Robert Bosch GmbH (Reutlingen), Erforschung von Verfahren zur hierarchischen Modellierung für EMR-Simulation

Das Vorhaben EM4EM erforscht Verfahren zur Entwicklung neuartiger und zuverlässiger Elektrofahrzeuge mittels eines automobilindustrie-getriebenen EMZ-Gesamtsystemansatzes. Aspekte wie z.B. IC-/PCB-Entwurf, Material/Konstruktion, zeitliche Verläufe von Strömen/Spannungen, Netzarchitekturen und Leitungsführungen, Schirmkonzepte, effektive Filterung müssen im Verlauf der Systemintegration berücksichtigt werden. Bosch entwickelt im Projekt innovative Verfahren zur hierarchischen Modellierung für den EMR-Systementwurf.

2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten

KI-FLEX (BMBF, KI-Element:autonomes Fahren)

Rekonfigurierbare Hardwareplattform zur KI-basierten Sensordatenverarbeitung für das autonome Fahren

Anders als progressivKI war das Ziel von KI-FLEX, eine leistungsstarke Prozessorarchitektur zu erforschen, mit der die echtzeitnahe, KI-gestützte Auswertung heterogener Sensordaten effizient durchgeführt werden kann. D.h. die KI-Lösungen werden nicht für den Entwurf der Prozessorarchitektur genutzt, sondern KI-Anwendungen werden auf dem Prozessor ausgeführt.

<https://www.elektronikforschung.de/projekte/ki-flex>

KI-ASIC (BMBF, KI-Element:autonomes Fahren)

KI-Prozessorarchitekturen für Radarmodule im autonomen Fahrzeug

Auch KI-ASIC hatte nicht den KI-gestützten Entwurf zum Ziel, sondern die Erforschung einer neuartigen Prozessorarchitektur, sogenannten neuromorphen Prozessoren, die es erlauben, KI-Methoden speziell für Mustererkennung und -analyse beim autonomen Fahren einzusetzen.

<https://www.elektronikforschung.de/projekte/ki-asic>

KI-PREDICT (BMBF, Mikroelektronik für Industrie 4.0 (Elektronik I4.0))

Elektronik für verteilte Künstliche Intelligenz zur sensorbasierten Prozess- und Zustandskontrolle

Auch KI-Predict befasste sich nicht mit dem KI-gestützten Entwurf, sondern entwickelte sensorbasierte KI-Systeme, die zur Zustandsüberwachung von Produktionsanlagen eingesetzt werden sollen.

<https://www.elektronikforschung.de/projekte/ki-predict>

SiEvEI 4.0 (BMBF, Mikroelektronik für Industrie 4.0 (Elektronik I4.0))

Sichere und intelligente Elektroniksysteme für vertrauenswürdige Elektronikprodukte in Industrie 4.0

In SiEvEI 4.0 wurden innovative Sensorsysteme – sogenannte *Secure Smart Items* (SSI) – in einen elektrischen Schaltungsträger eingebettet, um den Zustand von Baugruppen im industriellen Umfeld zu überwachen und dadurch die Vertrauenswürdigkeit von Elektronikprodukten zu erhöhen. Dazu sollte eine KI entwickelt und in die SSI integriert werden, um verschiedene Umwelt- und Fertigungsdaten zu erfassen und zu analysieren.

<https://www.elektronikforschung.de/projekte/sievei-4.0>

KI-EDA (BMBF - Mikroelektronik für Industrie 4.0 (Elektronik I4.0))

Baukastensystem mit Künstlicher Intelligenz für das beschleunigte Entwickeln von Spezialchips für die Industrie 4.0

Im Vorhaben KI-EDA wurde der Einsatz von KI-Methoden für den Entwurf einer spezifischen IC-Gruppe (Encoder- und Sensorchips) untersucht. Es sollte ein dediziertes Baukastensystem zur KI-unterstützten Entwurfsautomatisierung für einzelne Schaltblöcke der Spezialchips konzipiert werden. Damit sollte die Anzahl von Entwurfsfehlern reduziert werden. Ziel des Projekts progressivKI ist die Entwicklung eines generalisierten KI-gestützten Entwurfsprozess für KFZ-Elektroniksysteme. Im Gegensatz zu KI-EDA wurde in progressivKI modular aufgebaute KI-Plattform entwickelt.

<https://www.elektronikforschung.de/projekte/ki-eda>

KI-Marktplatz (BMW i - KI-Innovationswettbewerb)

Ökosystem für Künstliche Intelligenz in der Produktentstehung

Im KI-Marktplatz entstand ein Innovationsökosystem rund um eine digitale Plattform, die KI-Experten, Lösungsanbieter und produzierende Unternehmen zusammenbringt. Diese digitale Plattform wird sukzessive um Funktionalitäten erweitert, mit denen eine gemeinsame Entwicklung von KI-Lösungen für die Produktentstehung sowie deren Bereitstellung ermöglicht wird.

<https://ki-marktplatz.com/>

KIPS (Technologieförderung Sachsen, KI-Plattform Sachsen)

KIPS ist eine Plattform basierend auf dem GAIA-X Ansatz, auf der individuelle KI-Anwendungen – z.B. für die Dokumentenverarbeitung – ausgewählt und genutzt werden können. Zusätzlich liefert die Plattform eine auf die eigenen Bedürfnisse anpassbare Cloudinfrastruktur bzw. energieeffiziente, skalierbare und sichere Rechenzentrumslösungen.

<https://siliconsaxony.lineupr.com/kips-auftaktveranstaltung>

3 Technische Ergebnisse

Die Laufzeit des Projektvorhabens betrug 3,5 Jahre. Sie teilte sich in 6 Phasen, die zum Teil parallel abgearbeitet wurden:

- Phase 1: Analyse KI-gestützte Entwicklungsumgebungen (Dauer 6 Monate)
- Phase 2: Definition von Anforderungen/KI-Demonstratoren/KI-Prototypen/UseCases (Dauer 9 Monate)
- Phase 3: Technische Realisierung I (Dauer 12 Monate)
- Phase 4: Integration der KI-Demonstratoren in industrielle Entwicklungsumgebungen und Erweiterung der Anforderungen (Dauer 9 Monate)
- Phase 5: Technische Realisierung II (Dauer 9 Monate)
- Phase 6: Integration + Beta-Test + Dokumentation (6 Monate).

Der Arbeitsplan (Abbildung 25) in progressivKI konzentrierte sich auf die folgenden Arbeitspakete:

- AP1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform;
- AP2: KI-Datenaufbereitung/Datengenerierung;
- AP3: Implementation modular strukturierte KI-Plattform;
- AP4: Erstellung Anwendungsebenen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik);
- AP5: Projektmanagement & Dissemination.

□

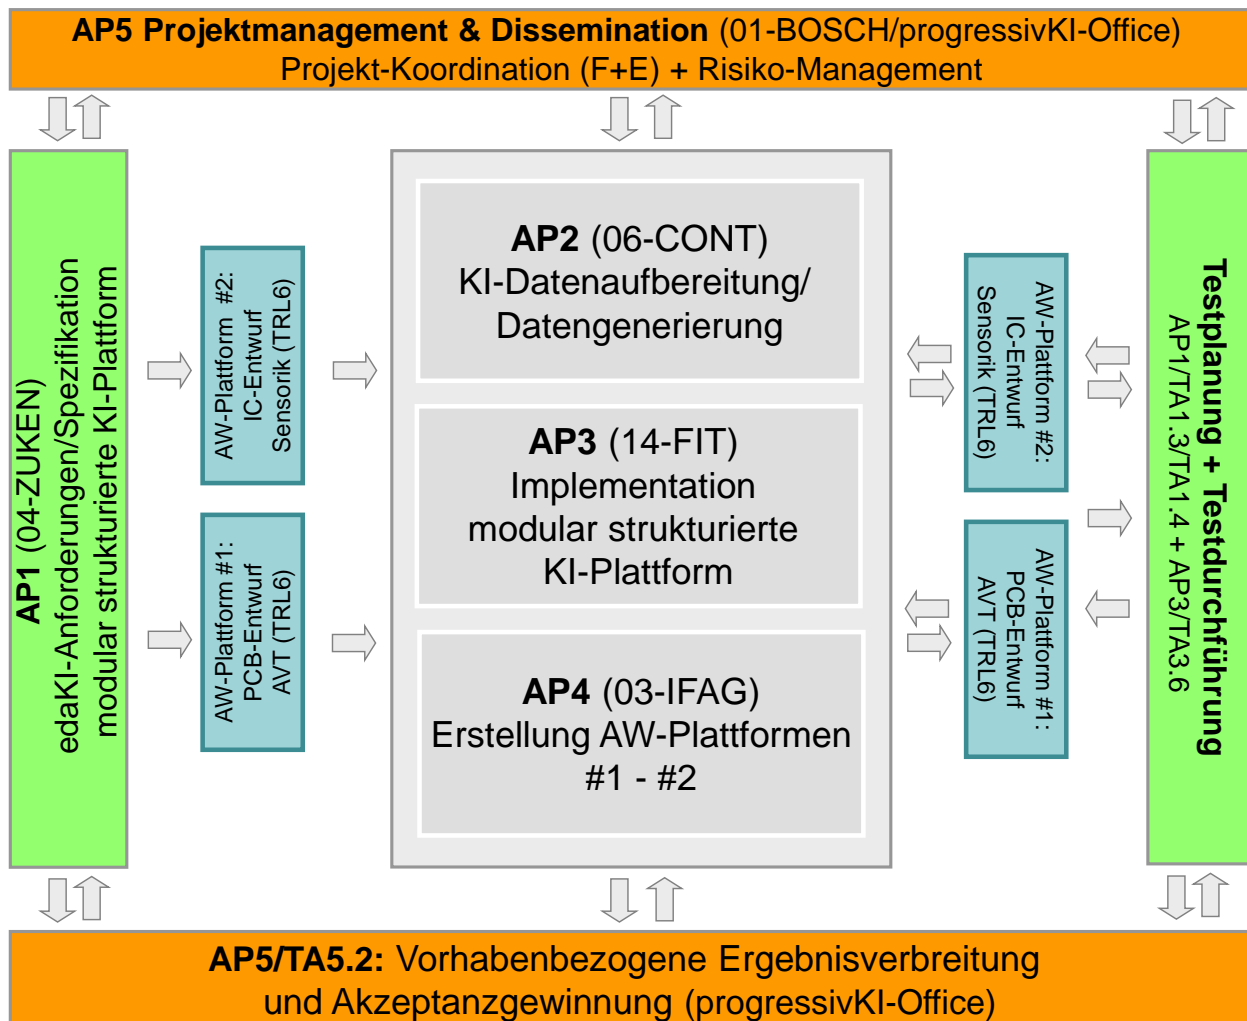


Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete

3.1 Arbeitspaket 1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform

Ausgangslage: Mit progressivKI wurde ein hochgradig modularer Ansatz verfolgt, der durch KI-basierte Automatisierung die Effektivierung der Entwurfsprozesse einer umfassenden Wertschöpfungskette unterstützt. Die große damit verbundene Wertschöpfung kann dank der modularen Struktur von Nutzern sowohl systemübergreifend umgesetzt werden als auch im Rahmen von spezifischen Einzelaufgaben entlang der betrachteten Wertschöpfungskette. Damit progressivKI die vorgesehene umfassende Anwendbarkeit und das entsprechende TRL erhält, war eine präzise Analyse des Systems der Requirements erforderlich, die entlang der betrachteten Wertschöpfungskette gelten, sowie eine transparente Darstellung aller verwendeten Formate und Schnittstellen. Diese wichtige Aufgabe wurde im AP1 geleistet zusammen mit der Definition der daraus abgeleiteten Anforderungen an progressivKI und die im Projekt zu bedienenden Formate, Protokolle und Schnittstellen. Derzeit sind gestützte

Entwurfsprozesse von (Teil-) elektronischen Systemen mit Constraints (wie z.B. Applikations- oder IC bzw. OEM-Hersteller-Vorgaben) in der Regel vom jeweiligen Entwickler durchgeführte manuelle Prozesse mit mehr oder weniger formalisiertem Entwurfsziel, zum Teil mit Analyseunterstützung durch EDA/CAD-Werkzeuge. Diese Prozesse sind zeitaufwendig und oft auch fehlerbehaftet. In diesem Arbeitspaket wurden die Spezifikationen für das Projekt im Hinblick auf Schnittstellen zwischen Entwurfsabläufen und den KI-Modulen erarbeitet. Weiterhin wurden Anforderungen an die Datensammlung sowie an die KI-Module definiert. Darüber hinaus musste analysiert werden, ob Synergien zwischen unterschiedlichen KI-Algorithmen nutzbar gemacht werden können.

Weiterhin wurden Methoden erforscht, um mithilfe von KI-Techniken Regeln algorithmisch aus verschiedenen Datenquellen zu erfassen bzw. abzuleiten und in entsprechende Design-Constraints (z.T. mangels vorliegender Standards in werkzeug-spezifischen Formaten) DesignConstraints zu überführen und soweit möglich, diese automatisiert in Entwurfsvorgaben bzw. -maßnahmen umzusetzen. Hierdurch war ein signifikantes Optimierungspotential im Entwurf elektronischer (Teil-) Systeme realisierbar.

Dieses Arbeitspaket definierte und lieferte:

- Voruntersuchungen zur Erstellung des KI-Konzeptes |KI-gestützter Systementwurf für den Bereich Elektronikentwicklung|.
- Definition der Ausprägungen für die Anwendungsebenen #1: PCB-Entwurf; #2: IC-Anwendung/Sensorik.
- Entwicklung von Vorlagen für eine prototypische Implementierung von KI-Modulen und die Analyse der Ergebnisse.
- Sichtung relevanter Fallbeispiele zu KMU-Entwicklungsprozessen.
- Erstellung eines Konzeptes für einen modularen Baukastens zur Entwicklung von anwendungsspezifischen Lösungen.
- Erstellung einer Spezifikationsmatrix zur Konzeptionierung von modularen KI-Plattformelementen.
- Gewährleistung eines optimalen Datenaustausches zwischen KI-Modulen und vorhandenen Entwurfsumgebungen.
- Anforderungen an Datenaustausch über Unternehmensgrenzen hinweg (IP-Schutz).
- Verfahren zur Sicherung von Erfahrungswissen generiert durch KI-Einsatz.
- Beschreibung und Bewertung von Markteffekten durch den KI-Einsatz auf KMU.
- Dokumentation der Ergebnisse zur Überführung in ein Lastenheft.
- Festlegung des funktionalen Rahmens des geplanten Chat-Bots. Der funktionale Rahmen könnte sich aus einer Integration von RASA NLU (Toolikt) und neuronalen Netzwerk (NN)-Methoden zusammensetzen. Der Umsetzung von Prinzipien der Entitäts-Extraktion, der Absichtserkennung und der Schlüsselwortzuordnung kommt dabei eine hohe Bedeutung zu. Zu klären ist, ob auch eine regelbasierte KI-Komponente in den funktionalen Rahmen integriert werden sollte.

Geplante Ergebnisse von AP1 waren:

- Im Rahmen dieses Arbeitspakets waren mehrere Schlüsselergebnisse vorgesehen. Zunächst erfolgte die Definition und Spezifikation der erforderlichen KI-Algorithmen, wobei der Schwerpunkt auf der funktionalen Sicherheit für die zu automatisierenden Entwurfsabläufe lag. Gleichzeitig wurden die Schnittstellen und Datenformate spezifiziert, um einen sicheren und effizienten Datenaustausch zu gewährleisten.
- Des Weiteren wurden KI-verwertbare Regelwerke erstellt, basierend auf Entwurfs- und Designregeln. Hierbei erfolgte die Spezifikation der Datenaufbereitung und die Festlegung von Anforderungen an die KI-Module aus der Perspektive der Entwurfsprobleme, die sich aus den Use Cases der beiden Anwendungsebenen ergaben.
- Eine umfassende Analyse verschiedener Open-Source KI-Frameworks wurde durchgeführt, wobei der Fokus auf den Eingangsdatenformaten lag. Dabei wurden Synergien zwischen den genutzten Frameworks herausgearbeitet, und die KI-Algorithmen wurden spezifiziert.
- Die Ergebnisse aus den Arbeitsschritten AT1.1 bis AT1.3 sowie AT 2.1 dienten als Grundlage für die Spezifikation der Anwendungsebenen und ihrer Strukturen. Zusätzlich wurden nutzbare Datenquellen der KI-Plattformen analysiert und klassifiziert, um eine umfassende Grundlage für die weiteren Entwicklungsphasen geschaffen zu haben.

3.1.1 Teilaufgabe 1.1: Funktionale Sicherheit + Entwurfsabläufe (Wertschöpfungsketten) + Schnittstellen

Im Rahmen dieser Teilaufgabe war es erforderlich, KI-Verfahren zu identifizieren, die es erlauben, die funktionale Sicherheit der Komponenten, für die im Vorhaben automatisierte Entwurfsabläufe adressiert werden, über geeignete Constraints zu gewährleisten sowie eine Spezifikation der Schnittstellen und Datenformate zum sicheren und effizienten Datenaustausch zu erstellen. Dabei ist eine ganzheitliche Betrachtung der Systemeigenschaften angezeigt, und die steigende Komplexität mikroelektronischer Systeme sowie die zunehmende Spezialisierung der Entwicklungsgruppen im Automotive-Bereich sind zu beachten. Hier sind insbesondere die Normenreihe IEC 61508 und die SIL-Klassifizierung einschlägig. Gegenwärtige Anforderungen an funktionale Sicherheit elektronischer Systeme werden durch die zunehmende Dichte elektronischer Systeme geprägt. Relevante Systembeispiele sind z.B. komplexe Infotainment-Systeme in Fahrzeugen (insbesondere im Zusammenhang mit Elektromobilität). Auch der Entwurf elektronischer Schaltungen (PCB + IC) und die erforderliche räumlich nahe Koexistenz von leistungselektronischen Systemen und datenverarbeitenden Komponenten stellen hohe Anforderungen an optimale Entwurfsprozesse.

Die folgenden Themen mussten im Detail bearbeitet werden:

- Analyse der Anforderungen an Verfahren zur wertschöpfungsketten-übergreifenden Behandlung des Themas Funktionale Sicherheit/Zuverlässigkeit (z.B. ASIL/SIL) in Entwurfsabläufen.
- KI-gestützte Methoden zur Sicherstellung der funktionalen Sicherheit von HW-Systemen
 - ⇒ Ermittlung der Anforderungen an funktionale Sicherheit und deren Abbildung auf die geplanten KI-Ansätze
 - ⇒ Hardware-Bewertungsmethoden mittels KI-Verfahren.
 - ⇒ Überprüfung der Funktionalität mit automatisierten Abläufen.
 - ⇒ Auswahl geeigneter KI-Algorithmen.

Teilbeitrag 1.1.1: Definition/Spezifikation von edaTool-Schnittstellen gemäß verallgemeinertem Entwurfsprozess (01-BOSCH)

Ziele

Definition und Spezifikation der edaTool-Schnittstellen zu den anderen Partnern. Es soll ein einheitliches Verständnis für die Schnittstellen zu edaTools sowie die Erfassung und Verarbeitung von Entwurfsdaten werden.

Lösungsweg und Ergebnisse

Bereits in der frühen Phase des Projekts konnte der wichtige Meilenstein edaTool-Schnittstellen erfolgreich umgesetzt werden. Diese Schnittstellendefinition umfasst die interne Verwendung von Layoutdaten und die weitere Verwendung in einem numerischen Feldsimulationsprogramm. Es können jetzt ohne etwaige Konvertierungen oder Anpassungen Layoutdaten direkt simuliert werden und so die EMV bewertet werden. Die nachfolgende Abbildung zeigt eine Übersicht der definierten edaTool-Schnittstellen.

- ▶ **Internal interface 1: Zuken Design Force / CST**
 - ▶ Use-Case: Full Layout incl. Stackup for field simulations (e.g. crosstalk)
 - ▶ SW: Zuken Design Force, CST
 - ▶ Im-/Export: .sdf/.sff files
- ▶ **Internal interface 2: Mech. Data / CST**
 - ▶ Use-Case: 3D shielding effectiveness simulation of mech. Design
 - ▶ SW: CST
 - ▶ Im-/Export: .stp file
- ▶ **External Interfaces: Zuken / Project Partner**
 - ▶ Use-Case: Deployment of layout data for training purposes
 - ▶ SW: Zuken Design Force
 - ▶ Im-/Export: .rif/.ctf Dateien

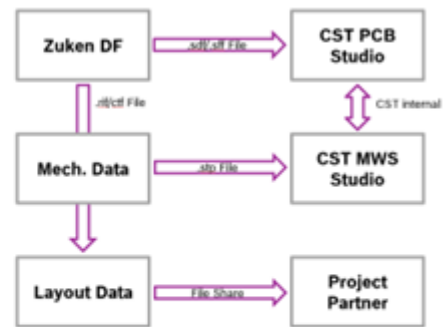


Abbildung 10: Übersicht definierte edaTool-Schnittstellen

Internal Interface 1 bezeichnet eine Schnittstelle zwischen dem Layoutprogramm Zuken Design Force und dem numerischen Feldsimulationsprogramm CST Studio Suite. Diese Schnittstelle dient für den Austausch von Layoutdaten und der Überführung in das Feldsimulationsprogramm, hierfür wurde das ASCII-basierte Dateiformat .sdf/.sff gewählt, welches alle relevanten Informationen enthält (Stack up, Netze, Materialien). Das zweite Internal Interface 2 definiert die Schnittstelle für den Austausch von mechanischen Daten und die Verwendung im numerischen Feldsimulationsprogramm für tieferegehende EMV-Untersuchungen. Die dritte Schnittstelle umfasst das External Interface, welches den Austausch von Layoutdaten mit den anderen Projektpartnern regelt. Hierfür werden aus dem Layoutprogramm die entsprechenden Daten im .rif/.ctf Format exportiert und dem Partner zur Verfügung gestellt. Dieser kann dann die Layoutdaten für etwaige Trainingszwecke oder weiteres nutzen.

3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf

Nur auf der Grundlage der bei den Partnern vorhandenen (in vielen Fällen bisher nicht kodifizierten) Vorkenntnisse über die adressierten Entwurfsprozesse konnte die Aufstellung eines Regelwerks basierend auf Entwurfsmaßnahmen erfolgen (Ermittlung und Dokumentation von relevanten Entwurfsregeln). Die Spezifikation der Datenaufbereitung sowie der Anforderungen an die KI-Module musste auf Basis der im Vorhaben vorhandenen praxisrelevanten UseCases der 2 Anwendungsebenen erfolgen. Da mögliche KI-Anwendungen im EDA-Bereich sehr vielseitig sein können, müssen mögliche KI-Anwendungen kategorisiert bzw. klassifiziert werden. Es wurde erwartet, dass Anwendungen einer Kategorie (siehe verallgemeinerter Entwurfsprozess) gemeinsame Anforderungen an die Validierung von KI-Modulen im Entwurfsprozess haben werden. Die Definition von Schnittstellen (siehe auch TA1.1), Abläufen und Algorithmen-Hierarchien musste partnerspezifisch erfolgen. Die Definition der Anforderungen an KI-Module kann nur einsatzspezifisch (KI-Einsatzszenarien) erfolgen. Zusätzlich war eine Anforderungsanalyse für Wissensmodelle und Dokumentenerschließung notwendig.

Teilbeitrag 1.2.1: Spezifikation der Anforderungen an KI-Module (#1 PCB) (01-BOSCH)

Ziele

Erstellung der Spezifikation für die Nutzung von KI-Plattformen basierend auf der Wertschöpfungskette. Hier sind die Spezifikationen für Schematic- und Layoutdaten im Vordergrund, damit auf geeignete und valide Daten zurückgegriffen werden kann.

Lösungsweg und Ergebnisse

Wie in TB1.1.1 beschrieben, wurden zuerst die Schnittstellen zwischen den edaTools definiert. Weiterhin wurde der Fokus im ersten Schritt auf Layoutdaten gelegt. Für den ersten Versuch wurde nur eine grobe Spezifikation entworfen, welche im Rahmen des UseCase #3 mit den Partnern FIT/HSHL abgestimmt wurde. Hierfür war es erforderlich, dass zu lösende Problem verständlich zu beschreiben und anschließend die notwendigen Daten zu definieren. Weitere Details werden in TB 1.4.1 beschrieben, wo der UseCase #3 vorgestellt wird.

3.1.3 Teilaufgabe 1.4: KI-Module für KI-Plattformen der Anwendungsebenen #1 - #2 + Struktur der KI-Plattformen

Anhand der Ergebnisse aus AT1.1 - AT1.3 sowie 2.1 wurden die Anwendungsebenen #1 - #2 sowie deren Strukturen spezifiziert. Darüber hinaus wurden für die Plattformen nutzbare Datenquellen analysiert und klassifiziert.

Von erheblicher Bedeutung war die Entwicklung von Klassifikationsschemata (Taxonomien) zur Schaffung von hierarchischen Untergliederungen für die Anwendungsszenarien aus AW #1 - #2. Auf dieser Basis wurde jeweils eine Ontologie als Netzwerk von Informationen mit logischen Relationen gebildet (Wissensrepräsentation für die zu erstellenden KI-Module).

Die folgenden Themen mussten im Detail bearbeitet werden:

- Anforderungen an den Austausch produktionsrelevanter Daten
- Analyse und Dokumentation ausgewählter industrieller Entwurfsabläufe insbesondere mit Blick auf funktional sichere Elektroniksysteme und deren KI-Bedarfe aus KMU-Sicht.-
- Klassifikation von Entwurfsproblemen, die bei der Entwicklung elektronischer Systeme auftreten können, und deren Überführung in geeignete Ontologien.
- Voraussetzungen für Entwicklung der geplanten KI-ModulPlattform als Basis für die Ausprägungen Anwendungsebene #1 - #2
- Anforderungen an die Integration von KI-Algorithmen sowie produktionspezifischer Daten in modulare KI-Plattformelemente.
- Funktionale und prozessbezogene Anforderungen im KMU-Entwurfsprozess
- Anforderungen an Modelle, Entwurfswerkzeuge und KI-WorkFlow
- Anforderungen an Datenaustausch über Unternehmensgrenzen hinweg (IP-Schutz).
- Erstellung einer Spezifikationsmatrix zur Konzeptionierung der modularen KI-Plattformelemente.

Teilbeitrag 1.4.1: Definition Datenumfang für #1 PCB (01-BOSCH)

Ziele

Beschreibung der zu liefernden Daten basierend auf den Anforderungen der Partner unter Berücksichtigung des Toolings. Auch die Auswahl von geeigneten Beispiel- und Trainingsdaten steht im Fokus dieses Beitrags.

Lösungsweg und Ergebnisse

Zunächst einmal wurde der UseCase #3 (PCB EMC-Entwurfsprozess) definiert. Dieser UseCase beschreibt ein konkretes EMV-Problem auf Layoutebene. Die Abbildung 11 zeigt zwei verschiedene Groundkonfigurationen im Steckerbereich.




Abbildung 11: PCB-Ausschnitt im Steckerbereich mit min/max. GND-Füllung

Einmal eine maximale Füllung (links) und eine minimale Füllung (rechts). Voruntersuchungen haben gezeigt, dass der GND-Ausschnitt einen signifikanten Einfluss auf das EMV-Verhalten (Abstrahlung) hat. Das in diesem Beispiel verwendete Modell ist ein Ausschnitt aus einem PCB und beinhaltet zwei Differential Pairs, welche über mehrere Lagen geroutet sind. Die Eingänge der beiden Signale sind an den Pins des Chips und die Ausgänge sind am Stecker bzw. den Pins des Steckers. In der nachfolgenden Abbildung ist der Ausschnitt des PCBs dargestellt sowie die Ports (rote Dreiecke) an den Ein- bzw. Ausgängen der Signalleitungen. Die blauen Elemente sind sogenannte Lumped Elements, welche hier einen Kondensator bzw. einen Filter im Signalpfad abbilden. Die beiden differenziellen Signalleitungen verlaufen größtenteils durch die Innenlage, daher zeigt die Abbildung 12 nur das Routing der Signalleitungen.




Abbildung 12: Routing der Signalleitungen mit Ein- und Ausgangsports (rote Dreiecke)

Die Impedanz der beiden Signalleitungen ist jeweils mit 100 Ohm bemessen und ergibt sich aus den geometrischen Parametern der Leitungskonfiguration. Der relevante Bereich für die Untersuchung befindet sich beim Stecker und konzentriert sich auf den Ausschnitt in der obersten Lage des PCB (gelbe Fläche). Dieser Ausschnitt hat, wie bereits Voruntersuchungen gezeigt haben, einen relevanten Einfluss auf die EMV und die Abstrahlcharakteristik der Signalleitungen. Daher wurden für die Bestimmung der elektromagnetischen Felder sogenannte Field Probes (Sonden) oberhalb sowie vor dem Stecker platziert. Das Modell wurde mit dem numerischen Feldsimulationsprogramm CST MWS erstellt und im Zeitbereich gerechnet. Das Eingangssignal für die beiden Signalleitungen war ein Standardpuls im Zeitbereich basierend auf einer Gauß-Normalverteilung. Der betrachtete Frequenzbereich war 0...6 GHz. Für den gewählten Ansatz soll von der Konfiguration mit maximaler Füllung eine Fläche mit automatisch erzeugter Geometrie subtrahiert werden. Zur Definition dieser Geometrie sollen Eckpunkte eines Vielecks miteinander verbunden werden. Diese Eckpunkte sind definiert durch Ihre Koordinaten. Die Verbindungsreihenfolge der Punkte wird vorgegeben durch den Index. Damit ergeben sich 3 Parameter (Position und Reihenfolge) zur Definition eines Eckpunktes eines beliebigen Vielecks (siehe Abbildung 13).




Abbildung 13: Beispiel für automatisch erzeugte Polygone mit 14 (links) und 30 (rechts) Datenpunkten

Dies ermöglicht die Erzeugung vielfältiger GND-Strukturen mit einer geringen Anzahl von Eingangsparametern. Der Wertebereich der verwendeten Koordinatenpunkte ist durch die Abmessungen des untersuchten Steckerbereichs beschränkt. Unter Verwendung dieses Ansatzes ergeben sich mehrere Möglichkeiten zur Parametererzeugung. Zum einen ist eine systematische Parametergenerierung denkbar, sodass die Eckpunkte durch einen festgelegten funktionalen Zusammenhang definiert werden. Dies hätte den Vorteil, dass auch KI-Methoden verfolgt werden können, die auf Basis bestimmter Outputs selbst systematisch Eingangsparameter variieren können, wie z.B. evolutionäre Algorithmen. Zum anderen kann eine zufallsbasierte Parametergenerierung verfolgt werden. So kann mit geringem Aufwand eine vielfältige Datenbasis geschaffen werden. Die resultierenden GND-Strukturen werden bezüglich Ihrer geometrischen Ausprägung zwischen den gezeigten Grenzfalldarstellungen in Bild 5 liegen. Für den ersten Schritt der Untersuchung wurde zur Einschränkung des Parameterraums nur die oberste GND-Lage berücksichtigt. Für weiterführende ist auch die Berücksichtigung weiterer Lagen der Leiterplatte denkbar. Zur Verdeutlichung des geometrischen Einflusses auf die Feldemissionen der gezeigten minimalen und maximalen Kupferfüllung der obersten GND-Lage ist in Abbildung 14 das elektrische Feld im Frequenzbereich für die beiden Groundkonfigurationen (siehe Bild 11) und die beiden Probe Positionen (top, front) dargestellt.

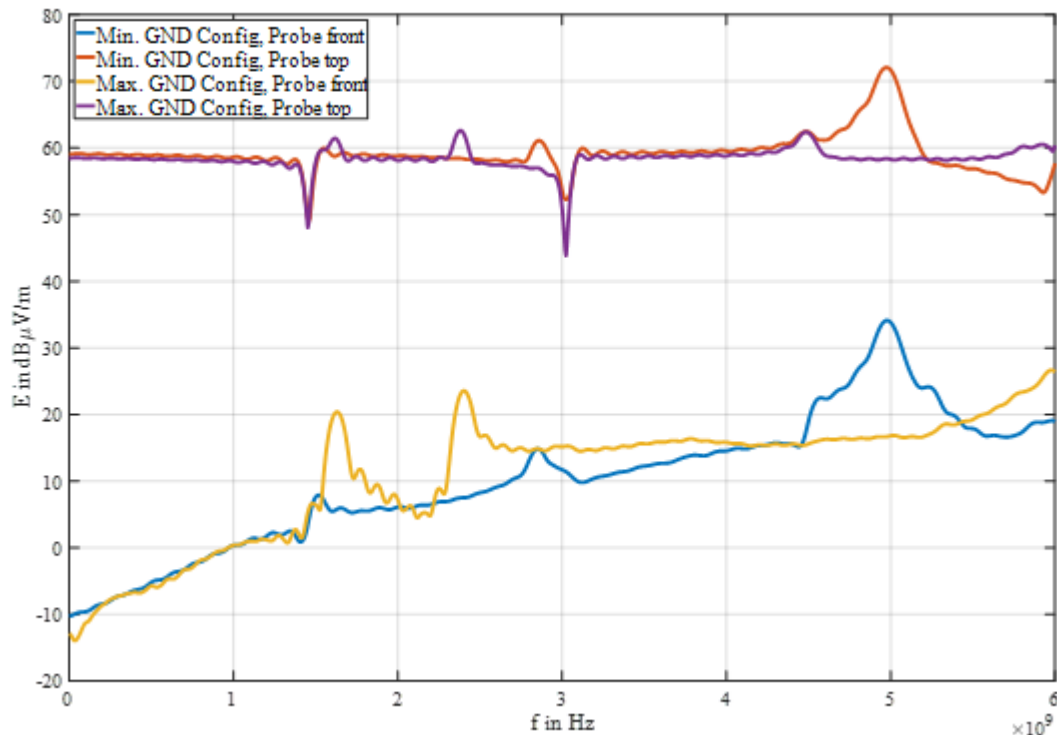


Abbildung 14: Abbildung 15: Beispiel für automatisch erzeugte Polygone mit 14 (links) und 30 (rechts) Datenpunkten

Hier lässt sich erstmal grundsätzlich feststellen, dass das elektrische Feld oberhalb (top) der Struktur höher ist, als vor (frontal) des PCB. Weiterhin lässt sich keine klare Tendenz ableiten, welches Design denn das bessere in Bezug auf die elektrische Feldemission ist. Es gibt aber leichtere Vorteile für die max. Groundkonfiguration. Hier muss angemerkt werden, dass sich der horizontale Steg im Steckerbereich (siehe Bild 5 links) nur einseitig an GND angeschlossen ist. Dieser kann also wunderbar als Antenne fungieren, was im obigen Ergebnisplot auch erkennbar ist (gelbe Kurve mit den Peaks bei 1.6GHz, 2.4GHz). Eine Anbindung des Stegs war aber durch die konsequente Anwendung der Constraints nicht möglich, daher können beide Konfigurationen erstmal keine optimale Lösung für die elektrische Feldemission sein. Dieses Beispiel ist daher perfekt für einen Optimierungsansatz, da die beste Lösung weder durch minimale, noch durch maximale Auslegung der GND Struktur erzielt werden kann. Ferner lässt sich dieses Beispiel ebenfalls perfekt nutzen für das Training eines KI-Moduls, wenn die elektrischen Feldverteilungen entsprechend bewertet werden. Beispielsweise wäre hier eine Metrik sinnvoll, welche eine Kombination aus der min. und max. Ergebniskurve und so einen Grenzwert für die Optimierung definiert.

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung

Der Erfolg einer KI-basierten Technologie hängt entscheidend von der Verfügbarkeit großer möglichst hochwertiger Datenmengen ab, mit denen die eingesetzten Algorithmen trainiert werden können. Daher wurden in progressivKI Methoden bereitgestellt und Verfahren definiert, die es erlauben, messtechnisch gewonnene Daten sowie Daten, die durch Prozesssimulation entstanden sind, zu diesem Zweck zu nutzen. Dies erfordert die Definition von Schnittstellen und Datenflüssen sowie die Entwicklung von Modellen und geeigneten Simulationsverfahren bzw. die Anpassung von Simulationssoftware. Besondere Bedeutung kommt übergreifenden Simulationen zu, die mehrere Schritte in der Wertschöpfungskette umfassen. Über die Projektphase hinaus ist die Fähigkeit, weiter zu lernen und sich auf ändernde Anforderungen und UseCases einzustellen, ein zentrales Merkmal von progressivKI. Daher wurden die entwickelten Verfahren des Datenmanagements einschließlich eines sicheren Rechtemanagements zur Garantie von Datensouveränität integraler Bestandteil der modularen KI-Plattform sein. Entsprechend dem Konzept der KI-Plattform, wurde auch das Datenmanagement in Form flexibler Module implementiert. Das in diesem Arbeitspaket zu etablierende Datenmanagement für das Training der Algorithmen wurde auch zu deren Verifikation eingesetzt.

Neben der Schaffung des erforderlichen Datenflusses bot progressivKI insbesondere auch das in der industriellen KI-Welt bisher nicht anzutreffende Feature einer fortlaufenden Analyse der Datenqualität in Hinblick auf angestrebte Lernziele. Diese Meta-Analytik wird in Verbindung mit Metriken zur Messung von Lernfortschritten einerseits und zur Beurteilung von Probleminstanzen hinsichtlich ihrer Lösbarkeit über KI-Algorithmen andererseits eingesetzt.

Dieser neue Zugang (hier MetaAlgorithmus genannt) ermöglicht eine automatisierte Steuerung des Einsatzes von KI-Algorithmen und wird so den vielfältigen KI-Aufgaben der modularen KI-Plattform gerecht.

Im Projekt konnte auf eine große Menge bestehender Test- und Entwurfsdaten aus unterschiedlichen Applikationen zurückgegriffen werden. Die Qualität der bisher gesichteten Daten ist dabei sehr heterogen und reicht von Schaltplänen in einfachen Grafikformaten (bmp, jpg) bis hin zu annotierten XML-Datenfiles inkl. korrespondierender DesignRules.

Daten und Domänenwissen sind der Schlüssel für eine funktionierende KI. In diesem Arbeitspaket wurden die Schnittstellen zu den applikationsspezifischen Datenquellen und Werkzeugen identifiziert und die Module zu deren Erschließung entwickelt und Trainingsdatenbanken für die spezifizierten UseCases aufgebaut. Wo erforderlich, wurden zusätzliche Daten durch Simulation generiert und, darauf aufbauend, werden Trainingsprozesse definiert, implementiert und anhand der gewonnenen Daten sowie zusätzlicher Regeln KI-Modelle erzeugt und in datenbasierte Trainings- und Lernmodule integriert.

Beim Datenimport mussten daher unterschiedliche Bedarfe und unterschiedliche Komplexitätsstufen der Probleme beim potenziellen Kunden zu berücksichtigen, um die Module zum Datenimport so zu gestalten, dass für den Kunden Lösungen mit einer großen

Hebelwirkung geschaffen und nutzbar gemacht werden können und das Domainwissen adäquat erschlossen werden kann. Hier kam der – ebenfalls KI-basierten - Bildverarbeitung auf unterschiedlichen Ebenen eine wichtige Rolle für die Qualitätskontrolle und als Wissensspeicher zu. Von großer Bedeutung war hier die Zeta-Suite.

Dieser erschlossene Wissensspeicher wurde weiterhin durch statistische und stochastische Ansätze, wie sie im Design of Experiment (DOE) und rational Design of Experiment (rDOE) angewandt werden, ergänzt. Bei allem theoretischem Verständnis für den Prozess und die einzelnen Schritte über die verschiedenen Segmente können so Varianten um stabile Lösungen herum geschaffen und die Wissens- und Lernmenge erweitert werden.

Ergänzt werden diese aus Wissensdatenbanken und Simulation erschlossenen Daten durch die Abbildung bestehender Design-Regeln in Form von Entscheidungsbäumen und als Qualitätsmaß zur Bewertung beim Reinforced Learning.

Aufgrund der möglicherweise besonderen Sensibilität der applikationsspezifischen Daten wurde ein besonderes Augenmerk auf die sichere und vertrauliche Verarbeitung der Daten gelegt. Dazu wurden geeignete Verschlüsselungsverfahren genutzt.

Die im Rahmen von AP2 bereitgestellten Module erlaubten es, den gesamten Lebenszyklus von Lerndaten zu strukturieren. Das Ziel war, die Beschaffenheit und nachhaltige Nutzung unter konsequenter Beachtung der Datensouveränität sämtlicher Daten zu definieren, und darüber hinaus einheitliche Formate und wenn möglich Standards zu definieren, so dass eine Interoperabilität so gut es möglich ist gegeben ist.

Die folgenden F+E Themen wurden in AP2 adressiert:

- Systematische Erforschung und Charakterisierung von Integrationsparametern für die unterschiedlichen Themengebiete anhand von Bestandsdaten, Simulationen, Messungen und Domänenwissen
- Techniken und Eingabedaten für einen fachspez. KI gestützten Chatbot (EMC-Chatbot im Rahmen der KNV)
- Prozessmodellierung und Bereitstellung von Simulationsverfahren zur Generierung simulationsbasierter Trainingsdaten
- Modellbildung und -training für unterschiedliche Wissensdomänen.
- Identifizierung und Klassifizierung der unterschiedlichen Arten von Daten (z.B. Datenblätter, Schaltpläne...)
- Definition von Einsatzzweck und Charakteristika der einzelnen Daten
- Ableitung von Schemata, Definitionen und Standards
- Definition von Qualitätskriterien der einzelnen Datenarten
- Erzeugung und Sammeln von Test-/Lerndaten
- Strukturierung und Aufbereitung der Daten
- Ermöglichen der Validierung und Testen der Ergebnisse und KI-Modelle
- Ermöglichen von Qualitätssicherung und Verifikation.

Geplante Ergebnisse von AP2 waren:

- Im Rahmen dieses Arbeitspakets standen mehrere zentrale Ergebnisse im Fokus. Zunächst erfolgte die Definition und Implementierung von Schnittstellenmodellen, die spezifisch auf die Entwurfs- und Simulationsumgebungen, Datenbanken sowie Dateiformate wie Bilder oder Textdokumente abzielten. Dabei wurde ein besonderes Augenmerk auf Verfahren zum Datenschutz gelegt. Die Schaffung einheitlicher Schnittstellen und Austausch-Dateiformate für sämtliche anfallende Daten sowie die Festlegung von Standards zur Beschaffenheit dieser Daten waren zentrale Aspekte.
- Das Arbeitspaket beinhaltete ebenfalls die Aufbereitung von Test- und Lerndaten aus bestehenden Datenbanken sowie durch Simulationen und Messungen an Demonstratoren. Modelle aus bereits vorhandenem Erfahrungswissen und Regelwerken wurden entwickelt, wobei die Annotation, Kontextualisierung und Klassifikation der Daten anhand von Metadaten, Messergebnissen und der Bewertung durch Entwicklerexperten im Fokus standen. Eine umfassende Evaluation und Bewertung der KI-Ausgaben war ebenfalls Teil der geplanten Ergebnisse.
- Ein wesentlicher Bestandteil bildete der Meta-Algorithmus, der Metriken zur Beschreibung von Problemschwierigkeiten und des Abstands von Problemen im Sinne eines Umlernprozesses sowie zur Bewertung von Lernprozessen und Datenqualität integrierte. Dieser Meta-Algorithmus beinhaltete auch Entscheidungsmethodiken zur Auswahl von Algorithmen, die bei der Vorgabe einer Problem Instanz zielführend eingesetzt werden konnten. Zusätzlich wurden Schnittstellen geschaffen, um den Meta-Algorithmus auf dem gesamten Spektrum der über die modularen KI-Plattform bereitgestellten KI-Verfahren operieren zu lassen.
- Ein weiterer Schwerpunkt lag auf applikationsspezifischen Trainings- und Lernmodulen, die auf den Use Cases für die Anwendungsebenen #1 bis #2 sowie den gewonnenen Daten und erstellten Modellen basierten.

3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen

Den Schnittstellen zwischen KI-Modulen und den einzelnen werkzeuggestützten Entwurfsebenen kommt eine erhebliche Bedeutung zu. Nur dann können die bisher erarbeiteten und bereits etablierten Entwicklungs- und Analyseumgebungen und deren Vorteile effizient genutzt und weiterentwickelt werden (siehe z.B. AW #1: Schnittstellen zur Anbindung von vorhandenen PCB-Daten + dazugehörige Berechnungswerkzeuge + Bauelement-Bibliotheken + Regeldepot + Simulationswerkzeuge an die geplanten KI-Module).

Der progressivKI-Ansatz musste vorsehen, dass alle KI-Module aus jedem Teilbereich miteinander kommunizieren und die verschiedenen physikalischen Eigenschaften eines elektronischen Systems zur Auffindung von optimalen Entwurfsentscheidungen miteinander verknüpft werden können (z.B. elektromagnetisches und thermisches Verhalten). Um die auftretenden unterschiedlichen Entwurfsprobleme bewältigen zu können, müssen alle vorhandenen Bibliotheken, Werkzeuge und Schnittstellen bereitgestellt werden können. Nur

dann kann das dazu hinterlegte Wissen auf das jeweilige Entwurfsproblem optimal angewendet werden.

Im Gegensatz zu bekannten Lösungen kann durch diesen Ansatz deutlich flexibler gearbeitet werden. Es können Daten verschiedenster Herkunft und Basis in den KI-Modulen kombiniert und ausgewertet werden, wodurch der Elektronik-Entwicklungsprozess auf allen Ebenen sicherer und effizienter gestaltet werden kann.

Zusätzlich wird durch die Möglichkeit, beim Endanwender verschiedenste Werkzeuge verwenden zu können, ein Investitionsschutz für Eigenentwicklungen sichergestellt und eine die Erweiterung von eigenen Modulen vereinfacht. Diese durch den progressivKI-Ansatz sichergestellte Interoperationalität unterscheidet sich deutlich von allen bekannten KI-gestützten Entwurfsprozessen.

Weiterhin ist es erforderlich, dem Nutzer die vielversprechendsten Ergebnisse und Bewertungen am Anfang des Entwicklungsprozesses angeben zu können. Eine Möglichkeit dazu bietet ein noch zu entwickelndes DecisionTree-Konzept, welches auf zahlreiche Schnittstellen zu allen relevanten Parametern und Dateiformaten des gesamten Wertschöpfungsprozesses zugreifen können muss. Dadurch sind auch KMU nicht gezwungen, kostspielige Werkzeuge für die Nutzung der KI-Module zu erwerben, und können ihre bereits etablierten Werkzeugketten weiter nutzen.

Eine weitere wichtige Randbedingung für den Einsatz von KI-gestützten Entwurfsverfahren stellt der IP-Schutz dar. Es muss möglich sein, dass die Unternehmen mit Grunddaten vortrainierte produktspezifische KI-Module (welche ohne Sicherheitsbedenken zugänglich sind) und zusätzlich weitere verschlüsselte unternehmens-spezifische KI-Module im eigenen Entwurfsprozess nutzen können.

Der individuelle IP-Pool der Industrie wird so geschützt, da nur die vortrainierten KI-Module mit den firmenspezifischen KI-Modulen kommunizieren können.

Unter anderem mussten die folgenden F+E Themen bearbeitet werden:

- Breite Berücksichtigung unterschiedlicher Arten/Typen von Daten (z.B. Schaltplan/Layout/Stückliste/Datenblatt-Parameter (min. - max. - typisch)). Es sind daher viele unterschiedliche (teils inkompatible) Datenformate (z.B. unterschiedliche EDA-Werkzeuge nutzen unterschiedliche Datenformate) einzubinden. Um Insellösungen zu vermeiden, müssen so gut es geht einheitliche Beschreibungen für Schnittstellen im Vorhaben definiert werden.
- Definition und Implementierung der Schnittstellenmodelle zu den applikations- und anwender-spezifischen Entwurfs- und Simulationsumgebungen, Datenbanken und Dateiformaten für Bilder oder Text sowie von Messsystemen, Datenschutz.
- Definierte Schnittstellen zwischen den unterschiedlichen Bereichen EMV, Layout, Schematic und Mechanik, die Möglichkeiten für eine Implementierung von KI sind evaluiert und geplant im beispielhaften Entwurfsprozess.
- IP-Schutz Anforderungen zum Datenaustausch über Unternehmensgrenzen hinweg.

- Ermittlung der Anforderungen und Definition von Schnittstellen um einen umfassenden Input für die geplanten KI-Module durch alle relevanten Parameter/Dateiformate des gesamten Wertschöpfungsprozess zu ermöglichen.
- Festlegung grundsätzlicher Anforderungen an die Schnittstellenbeschaffenheit zwischen den einzelnen KI-Modulen, sowie die notwendigen Beschreibungen der Ein- und Ausgangsschnittstellen des Gesamtsystems. Basierend auf den Anforderungen und Tests muss dann die bestmögliche Kombination gewählt werden.

Teilbeitrag 2.1.1: Ausarbeitung von Schnittstellen #1 PCB (01-BOSCH)

Ziele

Definition und Entwicklung von Schnittstellen zu den anderen Partnern. Diese Schnittstellen sind notwendig, damit ein effizienter und einfacher Transfer der Daten möglich ist. Denn nur mit einer sauberen Definition der Schnittstellen innerhalb des Verbundes können die weiteren Schritte erfolgen.

Lösungsweg und Ergebnisse

Die Schnittstellen wurden gemäß TB1.1.1 definiert und mit den Partnern abgestimmt. Die Zusammenarbeit konzentriert sich im UseCase #3 auf FIT/HSHL sowie ENAS und Zuken.

3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung

Daten und Domänenwissen sind der Schlüssel für einen funktionierenden edaKI-Ansatz. Es müssen die Schnittstellen zu den applikations-spezifischen Datenquellen und Werkzeugen identifiziert, die Module zu deren Erschließung entwickelt und Trainingsdatenbanken für die spezifizierten UseCases aufgebaut werden. Wo erforderlich, müssen zusätzliche Test- und Lerndaten durch Simulation generiert werden. Darauf aufbauend werden Trainingsprozesse definiert, implementiert und anhand der gewonnenen Daten sowie zusätzlicher Regeln werden KI-Modelle erzeugt und in datenbasierte Trainings- und Lernmodule integriert.

Zu Projektstart existierten nur wenige zugängliche Test-/Lerndatensätze für den Einsatz von KI in der Elektronikentwicklung, diese Daten müssen in großer Anzahl mit ausreichender Qualität erzeugt oder beschafft werden.

Darüber hinaus nimmt die Anzahl der generierten Datensätze für jeden Entwurf von elektronischen Schaltungen (bei KI-gerechter Aufbereitung) zu, so dass ein Training von KI-Modulen auf immer mehr und bessere Trainingsdaten zurückgreifen kann.

Folgende F+E Arbeiten zum komplexen Austausch von KI-Daten + KI-Datenaufbereitung/Datengenerierung mussten im Projektverlauf durchgeführt werden:

- Datenakquise und Trainingsdatenerzeugung für die AW #1 - #2

- Datenvorverarbeitung und Datentransformation zur Erzeugung des Ziel-Datensatzes für das Training von künstlichen Neuronalen Netzen auf Datenblättern + Deskriptive Datenanalyse auf Datenblättern
- Daten-Separierung bei der Erstellung der KI durch feste Regeln (durch z.B. feste DesignRules oder physikalischen Gesetze) und klassische Trainingsdaten
- Kombiniertes Ansatz aus Simulationsdaten und gemessenen Daten zur Erzeugung von hinreichend großen Datensätzen für ML
- Datenakquise durch Simulationen und realen Messdaten - Entwicklung von Konzepten zur Herstellung von EM- und thermischen Trainingsdaten für die KI-Module
- Batch-Simulation und -Parametervariationsmethodik zur externen automatischen Ansteuerung von Simulationswerkzeugen (HPC) + Definition von Metriken zur Bewertung von Simulationsdaten
- Einbindung von physikalischen Gesetzen und Design-Rules
- Verfahren zur Erstellung von Testdatensätzen zur Qualitätsbeurteilung KI-basierter Entwurfsentscheidungen/-vorschlägen
- Konzept zur Erstellung der Trainingsdaten, dass Qualität und Quantität der benutzten Trainingsdaten berücksichtigt
- Bewertungsverfahren für die zu erwartende wachsende Menge an Lern-(Trainings)-daten
- Werkzeuge zur Bewertung und Verwaltung (Lifecycle-Management) der wachsenden Menge an Trainingsdaten
- Management zur projektübergreifenden Bereitstellung von Lerndaten.

Teilbeitrag 2.2.1: Daten-Bereitstellung als Trainingsbasis (01-BOSCH)

Ziele

Bereitstellung von Layout- und Schematicdaten für Trainingszwecke sowie die Abstimmung mit den Projektpartnern. Nach Bereitstellung der Daten erfolgt eine Sichtung der Datenbasis und weitergehend eine Extraktion der relevanten Komponenten des PCBs. Aufgrund der hohen Komplexität der PCBs ist hier ein größerer Zeitaufwand eingeplant, damit auch eine solide Grundlage an Trainingsdaten den Partnern zur Verfügung gestellt werden kann.

Lösungsweg und Ergebnisse

Im Rahmen eines Workshops in UseCase #3 wurden mit den Partnern die benötigten Daten abgestimmt. Auf dem Whiteboard ist diese Übersicht entstanden (siehe Abbildung 16).

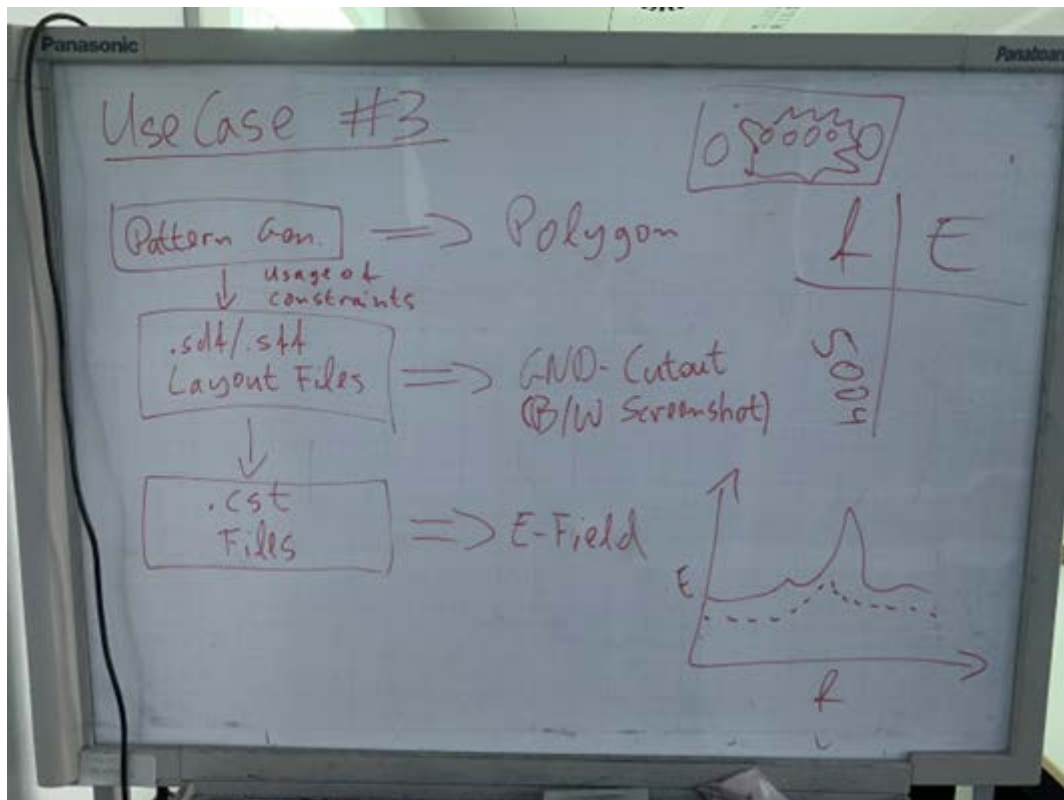


Abbildung 16: Foto vom Whiteboard aus UseCase #3 Workshop

Dort sind die benötigten Daten für das erste Training des KI-Moduls notiert. Für das erste Training wurde daher nur ein Bild des GND-Ausschnitts benötigt sowie das berechnete elektrische Feld für die jeweilige Konfiguration. Für den ersten Versuch wurden 400 verschiedene GND-Ausschnitte erstellt und entsprechend die Feldverteilungen berechnet. Mit diesem ersten Versuch sollte bestimmt werden, ob die gelieferten Daten überhaupt nutzbar für ein Training des KI-Moduls sind.

3.2.3 Teilaufgabe 2.5: Datenbasierte Trainings-/Lernmodule

Auf Basis der für die Anwenderszenarien #1 - #2 modellierten UseCases wurden mit den gewonnenen Daten und erstellten Modellen applikationsspezifisch vortrainierte bzw. angelegte Instanzen der verwendeten KI-Algorithmen erstellt. Die Organisation dieses Anlernprozesses wurde ebenfalls in automatisierter Form über Trainings- und Lernmodule bereitgestellt, die diese Aufgabe auch im zu entwickelnden Produkt, der modularen KI-Plattform, übernehmen. So wurde sichergestellt, dass progressivKI die für seine nachhaltige Funktionalität erforderliche Aufgabe einer permanent verbesserten automatischen Anpassung an sich ändernde Zielvorgaben und Randbedingungen effektiv erfüllen wird. Komplementiert wird die Fähigkeit zum Lernen aufgrund einer kontinuierlichen Datenauswertung durch bereitgestellte Algorithmen für Transfer-Learning, die über den Meta-Algorithmus gesteuert werden. Neben dem Training der Algorithmen übernehmen die Trainings- und Lernmodule auch Aufgaben bei der Verifikation angelegter Algorithmen.

Für die Realisierung der Lernmodule mussten zuvor in AP1 Aufgabenklassen im Entwurfsprozess definiert worden sein, die mit KI-Unterstützung erfüllt werden können - welche Aufgaben dies im Einzelnen konkret sind, musste von den entsprechenden KI-Modulen erkannt werden, und die Lernmodulen mussten automatisch entsprechend eingestellt werden; siehe Taxonomie und Ontologie).

Aufgrund der möglicherweise besonderen Sensibilität von applikationsspezifischen Daten wurde ein besonderes Augenmerk auf die sichere und vertrauliche Verarbeitung der Daten gelegt. Dazu wurden geeignete Verschlüsselungsverfahren genutzt.

Folgende Spezifikationen müssen für Schnittstellen und Teilplattformen, den Analyseverfahren zur Auswertung von vorgehenden Entwicklungen (Variantenkonstruktion), Verfahren zur Bereitstellung der Daten für Training und Test sowie für Testumgebungen für einzelne KI-Module zur Trainingsunterstützung vorliegen.

Um die Trainingsdaten für die KI erzeugen zu können, müssen die Konzepte zur Datenakquise aus TA2.2 genutzt werden. Wie bereits oben erläutert, muss zwischen Messdaten und mittels Simulation gewonnenen Trainingsdaten unterschieden werden. Messdaten können nur mit erheblichem Aufwand gewonnen werden. Deshalb ist es notwendig, mit Hilfe von DOE-Verfahren den Entwurfsraum vollständig abdecken zu können.

Die Messdaten können dann mit den Trainingsdaten aus Simulationen abgeglichen werden. Auf dieser Grundlage kann damit dann ein den Entwurfsraum abdeckender Trainingsatz erstellt werden.

Um genügend mittels Simulation gewonnene Trainingsdaten erzeugen zu können, müssen bei Verwendung von 3D-EM-Simulationswerkzeugen oft auch HPC-Umgebungen eingesetzt werden. Der Bedarf an Trainingsdaten wurde in TA2.2 festgelegt. Die notwendigen KI-Modelle wurden in TA2.3 erstellt.

Bearbeitung der folgenden TA2.5-Themen:

- Review der bisherigen Arbeiten an den Trainingsmodulen für AW #1 und #2.
- Auswertung des KI-Trainingsmoduls AW#1
- Erstellung, Verwaltung und Validierung von Trainings-Pipelines zur Verbesserung von bereits fertiggestellten KI-Modellen
- Aufteilung und Aufbereitung der Eingangs- und Ausgangsdaten der Datenblätter von elektronischen Komponenten in einen Trainings-, Validierungs-, und Testdatensatz
- Training für KI-Anwendung Kontext von Requirements-Engineering-Methoden
- Schnittstellenmodelle für Datenbasierte Training-/Lernmodule zur Unterstützung des Entwurfs von Komponenten der Industrieelektronik
- Analyse Open-Source Algorithmen für datenbasierte Training-/Lernmodule
- Anpassung von KI-Modulen und Generierung von Trainings- und Lerndaten
- Bereitstellung spezifischer Simulations- bzw. Berechnungsverfahren zur Generierung von Lerndaten (z. B. Daten für Power-Ground-Kopplungen)
- Anpassung von Entwurfsdaten sowie Vorverarbeitung zur Nutzung für CNN und Transfer-Learning.

Teilbeitrag 2.5.1: Review Eigenschaften Trainings-/Lernmodule AW #1 (01-BOSCH)

Ziele

Review der bisherigen Arbeiten sowie Überprüfung der Schnittstellen auf deren Tauglichkeit und Effizienz. Auch die Bewertung der Trainings- bzw. Lerndaten bezüglich Effektivität und praktischer Relevanz sollen überprüft werden.

Lösungsweg und Ergebnisse

Die erarbeiteten Schnittstellen sind ausreichend und funktionieren entsprechend gut. Aber im Rahmen des ersten Trainings zeigte sich, dass die GND-Ausschnitte zu ähnlich sind. Die nachfolgende Abbildung zeigt einen Teil der GND-Ausschnitte, welche für das erste Training verwendet worden sind.



Abbildung 17: Übersicht Trainingsdaten (GND-Ausschnitte)

Für jeden dieser GND-Ausschnitte existiert auch eine entsprechende berechnete Feldverteilung. Aber wie bereits erwähnt, hat sich gezeigt, dass die GND-Ausschnitte und die dazugehörigen Feldverteilungen zu ähnlich sind und daher keine Signifikanz aufweisen. Der

nächste Schritt ist daher die GND-Ausschnitte so zu verändern, dass eine entsprechende Signifikanz gegeben ist und das Training erfolgreich verlaufen wird.

Die unten beschriebene Pipeline wird dazu genutzt um Trainingsdaten für ein Machine Learning (ML) Modell zu generieren. Sie besteht aus den folgenden Software-Modulen:

- Polygon Generator
- Zuken Steuerung
- Windows Steuerung
- CST Projekt Generator
- CST Daten Postprocessing

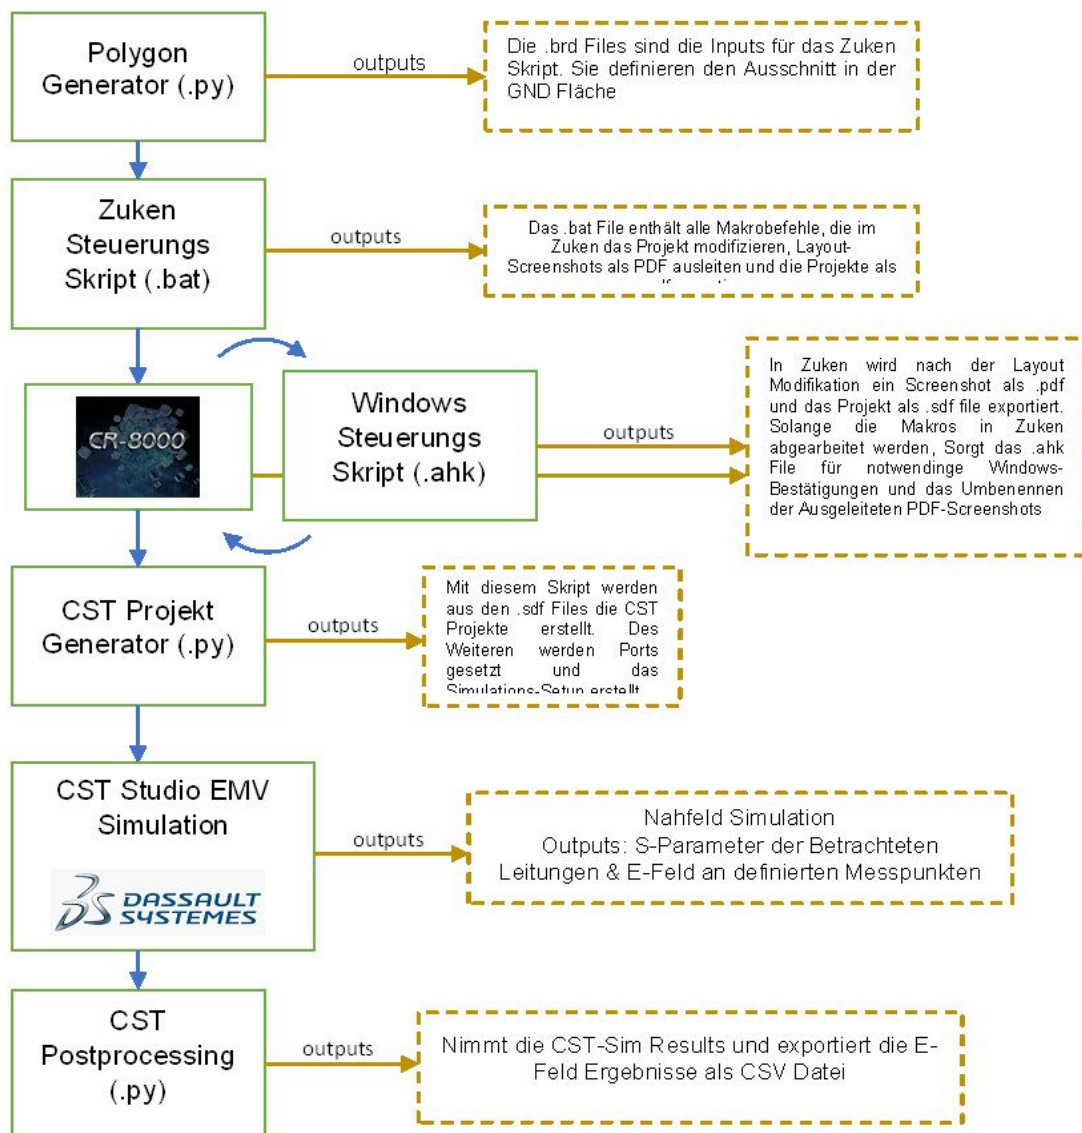


Abbildung 18: Datenerstellung für KI-Anwendungen auf PCB Ebene

Der Prozess beginnt mit einem „Polygon Generator“- Python File. Dort werden zufällige Polygone generiert und als „.brd“ File abgespeichert. Die Polygone dienen als Schablone für den GND-Layer Cutout, der im nächsten Schritt mittels Zuken ins Layout eingefügt wird. Dafür wurde ein „.bat“-Skript erstellt in dem die Zuken Makro-Befehle für die Steuerung des Vorgangs definiert werden. Die Befehle werden im nächsten Schritt dann in der Zuken Software abgearbeitet. Da während des Daten-exports manche Steuerungsbefehle nicht mittels internen Makros bedient werden können, musste ein weiteres „.ahk“-Skript erstellt werden. Mit dem ahk-Skript werden Windows-Bestätigungen bedient und die richtige Benennung der ausgeleiteten PDFs durchgeführt.

Nach der Layoutmodifikation mittels Zuken können die ausgeleiteten .sdf files in CST-Projekte importiert werden. Dieser Vorgang wird mit einem weiteren Python File durchgeführt. Weiterhin werden im gleichen Schritt einige CST-Konfigurationen für die Simulation vorgenommen.

Im letzten Schritt erfolgt die Simulation der generierten Layout-Samples und der Output der Simulation wird mittels eines weiteren Python Files in .csv Dateien abgelegt.

Anschliessend wurde die Pipeline auch wieder dazu genutzt, um weitere Trainingsdaten zu generieren. Auch wurden kleinere Anpassungen an den Skripten vorgenommen, um eine höhere Flexibilität bei der Erstellung von Trainingsdaten zu erzielen. Auch wurden diverse Anpassungen im EMV-Simulationsmodell durchgeführt, um mit den Simulationsergebnissen die Realität besser abbilden zu können.

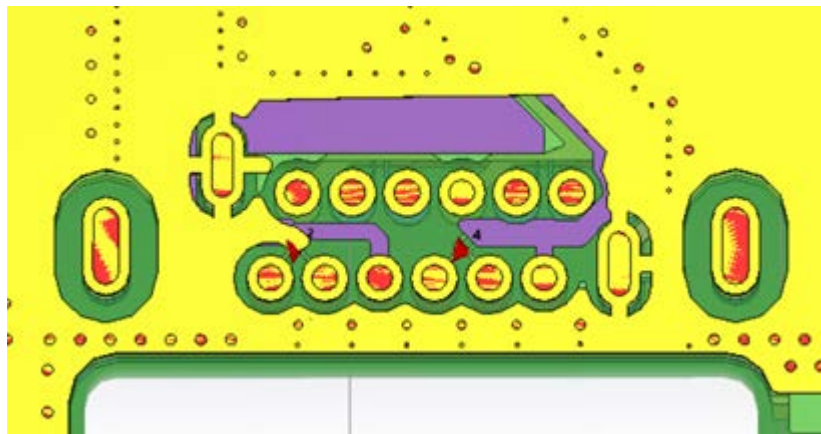


Abbildung 19: Draufsicht auf die Groundstruktur im Connectorbereich

Unter anderem wurde die Platzierung der Ports verbessert, was in der obigen Abbildung dargestellt ist. Auch wurde das Eingangssignal verändert und die komplette S-Parametermatrix (4 Ports) wurde berechnet. Das Eingangssignal für die beiden Differential Pairs ist in der nachfolgenden Abbildung im Zeitbereich dargestellt.




Abbildung 20: Eingangssignal im Zeitbereich

Hier noch die entsprechende Darstellung im Frequenzbereich, welche erkennen lässt, dass die Harmonischen bzw. Oberwellen auch im GHz-Bereich existent sind.




Abbildung 21: Eingangssignal im Frequenzbereich

Basierend auf diesem Eingangssignal wurden neue Trainingsdaten für die Konsortialpartner in UseCase #3 generiert, welche wiederum für ein weiteres Training des KI-Moduls genutzt werden.

Das im UseCase #3 entwickelte KI-Modul für die Optimierung von Groundstrukturen wurde bereits mehrfach durch die Konsortialpartner mit unterschiedlichen Trainingsdaten trainiert. Hierbei zeigte sich, dass die Prädiktion von bereits bekannten Daten sehr gut funktioniert. Lediglich bei unbekanntem Daten zeigt die Prädiktion noch Schwächen. Auch muss der Parameterraum noch erweitert werden, damit auch die S-Parameter sowie weitere relevante Parameter berücksichtigt werden können. Die Abbildung zeigt den Trainings- und Validierungsprozess mit den zur Verfügung gestellten Daten aus UseCase #3.




Abbildung 22: Training und Validierung des DNN

Hierfür werden auch weitere Trainingsdaten im UseCase #3 zur Verfügung gestellt. Nur so kann sichergestellt werden, dass das KI-Modul auch die notwendige Reife erzielt und brauchbare Ergebnisse erzielt.

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten

AP3 fasst alle Arbeiten zusammen, die zur Umsetzung der geplanten modularen KI-Plattformen erforderlich waren. Diese Arbeiten teilen sich auf in die Erstellung der Kern-Module (DNN-Framework), die Realisierung der Schnittstellen-Module zur Dateneingabe, die Ergebnisausgabe und die Anbindung der trainierten KI-Modelle. In enger Zusammenarbeit mit den in AP1 festgelegten UseCases und den Ergebnissen aus AP2 wurden die KI-Module für die modularen KI-Plattformen der in AP4 definierten Anwendungsebenen #1 - #2 vorbereitet.

Die folgenden F+E Themen wurden in AP3 adressiert:

- F&E DNN-Topologien und Entscheidungsstrategien für Fragestellungen aus dem Entwurf elektronischer Systeme
- Kalibrierung von Metriken zur Bewertung der Qualität eines KI-Algorithmus, zur Quantifizierung seines Vortrainingszustandes bezüglich einer Probleminstanz, zur Bewertung der Schwierigkeit einer gegebenen Probleminstanz sowie der Nähe zu anderen Probleminstanzen im Sinne eines Transfer-Learning-Prozesses
- Generische Algorithmen zur Lösung von Entwurfsaufgaben für verschiedene Anwendungsfälle (Anwendungsebenen #1 - #2).

Die folgende Liste fasst die Hauptziele dieses Arbeitspakets zusammen:

- Aufbereitung und Initialisierung der KI-Module auf der Grundlage gängiger KI-Frameworks sowie Installation auf den nötigen Rechnernetzen;

- Implementierung der in AP1 und AP2 erarbeiteten Schnittstellen zu den applikationsspezifischen Entwurfs- und Simulationsumgebungen, Datenbanken und Dateiformaten, wie Bildern oder Text sowie Messsystemen. Weiterhin werden auch die Schnittstellen zwischen den einzelnen Modulen implementiert, um das komplette System abzubilden;
- Auf der Grundlage der Spezifikationen aus AP1 werden die KI-Module maßgeschneidert an die produktspezifischen Instanzen der modularen KI-Plattformen angepasst und mit Hilfe der zu Grunde liegenden Daten auf die jeweilige Problemklasse vortrainiert;
- Implementierung, Verifikation und Validierung einer eindeutigen Beschreibungssprache für Domänenwissen; Implementierung von Schnittstellen zum Import von Tacit-Knowledge sowie Extraktion von Anwenderwissen und Regelsätzen;
- Implementierung der Meta-Algorithmen zur automatisierten Algorithmenwahl, der Lernfortschrittskontrolle und dem Reporting über Lernfortschritte auf unterschiedlichen Plattformen einschließlich der erforderlichen Zugriffsmethoden auf Datenflüsse und KI-Module;
- Nutzung mathematischer Metriken zur Bestimmung der Güte der Eingangs- und Ausgangsdaten, sowie der KI-Algorithmen.

Geplante Ergebnisse von AP3 waren:

- Im Zuge dieses Arbeitspakets wurden mehrere bedeutsame Ergebnisse angestrebt. Zunächst wurden Framework KI-Module für die Teilplattformen entwickelt und anschließend optimiert. Dies beinhaltete die Aufbereitung und Initialisierung der KI-Module, basierend auf etablierten Frameworks, sowie die Installation auf den erforderlichen Rechnernetzen.
- Es erfolgte die Implementierung von Modul-Schnittstellen für den Datenaustausch, einschließlich Schnittstellen zu den applikationsspezifischen Entwurfs- und Simulationsumgebungen, Datenbanken sowie Dateiformaten für Bilder und Text. Zusätzlich wurden Schnittstellen für Messsysteme und zwischen den einzelnen KI-Modulen implementiert.
- Eine weitere Zielsetzung war die Implementierung von anwendungsspezifischen vortrainierten KI-Modulen. Dies umfasste auch die Umsetzung von Domänenwissen, einschließlich geistigem Eigentum (IP), einer klaren Beschreibungssprache für das Domänenwissen sowie Schnittstellen für den Import von TacitKnowledge, die Extraktion von Anwenderwissen und Regelsätzen.
- Die Implementierung von Meta-Algorithmen, einschließlich eines Moduls zur effektiven Planung des Lernfortschrittes, gehörte ebenfalls zu den geplanten Ergebnissen dieses Arbeitspakets.
- Schließlich wurden die validierten KI-Module und KI-Frameworks als Abschluss dieses Arbeitspakets hervorgebracht, um sicherzustellen, dass die entwickelten Komponenten den definierten Anforderungen entsprachen und ihre Leistungsfähigkeit nachgewiesen war.

3.3.1 Teilaufgabe 3.2: Implementation Modul-Schnittstellen (Datenaustausch)

Die Implementierung von Schnittstellen zu den applikationsspezifischen Entwurfs- und Simulationsumgebungen, zu Datenbanken und Implementation von Datenformaten für Bilder oder Text sowie Messkurven ist erforderlich um die geplanten KI-Module für die Anwendungsebenen #1 - #2 erstellen zu können. Weiterhin ist es notwendig, auch die Schnittstellen zwischen den einzelnen KI-Modulen zu implementieren, um das komplette prototypische System auf TRL 6 erstellen zu können.

Zusätzlich sind auch weitere Schnittstellen zwischen den Nutzern und den jeweiligen KI-Modulen außer dem Datenaustausch notwendig. So soll der Nutzer, wenn er sich bei seinen Anweisungen sicher ist, das jeweils aktive KI-Modul während des Entwicklungsprozesses lenken und trainieren; Wobei vorzugsweise der Nutzer zum Zwecke des Trainings und der Steuerung des individuellen Entwurfsablaufs nicht aktiv an diesem Lernprozess der aktiven KI-Module beteiligt werden soll. Damit wird eine indirekte Beeinflussung der Lernprozesse vermindert. Dabei werden die Schritte des Entwicklers protokolliert (Datenschutz-Richtlinien beachten!).

Die Arbeiten zu dieser Teilaufgabe wurden wie folgt zusammengefasst:

- Implementierung der in AP1 und AP2 erarbeiteten Schnittstellen für die applikationsspezifischen Entwurfs- und Simulationsumgebungen (Datenaustausch)
- Implementierung der Schnittstellen zu Entwurfs-Datenbanken
- Implementierung von Dateiformaten für Bilder/Texte/Schaltpläne/Datenbücher sowie Messsystemen.
- Implementation von Schnittstellen zwischen den einzelnen KI-Modulen um das komplette System einer KI-Plattform für die Anwendungsebenen #1 - #2 realisieren zu können.
- Optimierung der Teilalgorithmen für deren Einsatz in den geplanten KI-Plattformen
- Implementierung Meta-Algorithmen
- Implementierung von Pre/Post-Processing Algorithmen zur Datenanpassung
- Entwicklung von Test- und Validierungsprozeduren für Modul-Schnittstellen
- Entwicklung von User-Interfaces zur Verwaltung von KI-relevanten Datensätzen
- Implementation von Schnittstellen und Komponenten für Cloud-Lösungen zum Austausch von KI-Daten in hier adressierten Wertschöpfungsketten.
- Ermittlung von weiteren Schnittstellen:
 - ⇒ Rechte zum Intervenieren des Nutzers in der KI-Struktur anhand dessen Erfahrung
 - ⇒ Speicherung von Nutzereingriffen zur Analyse für zukünftige Abläufe/Regeln.
 - ⇒ Protokollierung der Eingriffe von erfahrenden Nutzern zur Sicherung des Knowhows im Unternehmen (spezielle KMU-Anforderungen).

Teilbeitrag 3.2.1: Test und Validierung Modul-Schnittstellen Anwendungsebene #1 PCB-Entwurf (01-BOSCH)

Ziele

Entwicklung von Test- und Validierungsprozeduren; Abstimmung mit den Konsortialpartnern. Grundsätzliche Fragestellung, welche hier behandelt werden soll, ist die Entwicklung von Test- und Validierungsprozeduren der relevanten Schnittstellen zu den Partnern.

Lösungsweg und Ergebnisse

In der Toolchain geht es darum, eine Softwareschnittstelle zwischen dem ECAD Programm Zuken und dem Simulationsprogramm CST zu erstellen. Anschließend soll diese Schnittstelle immer weiter optimiert und auch für weitere Anwendungen erweitert werden.

Dabei wird die Ground (GND) Fläche um einen Highspeed-Connector in zufällig erstellten Polygonen ausgeschnitten. Die dabei entstandenen, unterschiedlichen Layouts werden simuliert und die Ergebnisse verglichen. Das Platinenlayout mit der geringsten elektromagnetischen Abstrahlung wird übernommen.

Die oben beschriebene Toolchain wurde verändert, erweitert und damit weiter optimiert. Folgende große Änderungen wurden implementiert:

- Das Batch-Skript wurde durch ein Python-Skript ersetzt. Die objektorientierte Programmiersprache eignet sich besser für unsere moderne Anwendung
- Anstelle von Auto-Hot-Key überwacht die robotergesteuerte Prozessautomatisierungssoftware PowerAutomate den Prozess
- Die Toolchain wurde um die Funktion „Optimierung von Vias“ erweitert

Der Prozess lässt sich in sechs einfache Schritte einteilen:

- Input
- Zuken Steuerungsskript
- Robotergesteuerte Prozessautomatisierung (RPA)
- Automatic CST-file generator
- CST Studio EMV Simulation
- CST postprocessing



Abbildung 23: Blockdiagramm zur Toolchain

Die Optimierung der Vias ist ein gutes Beispiel, warum es möglich sein sollte, EMV-Maßnahmen in der Zukunft automatisiert entwickeln zu können.

Vias sind Durchkontaktierungen von elektrischen Leitungen auf einer Platine zwischen verschiedenen Lagen des PCB. Damit haben sie unabhängig eine Kapazität und eine Induktivität, damit auch eine eigene Impedanz. Wenn hochfrequente Signale über diese Leitung fließen, kann es sein, dass durch Reflexion und Brechung der Signale die Signalqualität leidet. Das kann zu Fehlfunktionen auf der gesamten Platine führen.

Bei der Optimierung von Vias werden daher die verschiedenen Durchmesser des Vias variiert, um die Impedanz zu beeinflussen. Im nachfolgenden Bild sind diese Durchmesser $d-1$ und $d-2$ in ein beispielhaftes Via eingezeichnet.




Abbildung 24: Traces mit Via

d_1 ist der Durchmesser des Kupferpads, d_2 beschreibt den Durchmesser des Cutouts um das Via. d ist der Durchmesser des Vias selbst, allerdings ist dieser durch Layoutvorgaben festgelegt und kann daher nicht verändert werden.

Für das Steuerungsskript im zweiten Schritt wurden als Erstes Makros in Zuken selbst erstellt. Makros sind zusammengefasste Anweisungen, die mithilfe von Befehlszeilen wieder aufgerufen werden können. Dafür werden die Befehle in einem speziellen Makro-Tool aufgenommen und als Code gespeichert. Wenn das Macro wieder abgespielt wird, werden genau die gleichen Befehle wiederholt.




Abbildung 25: Macroskript für Veränderung des Viapads

In dem Beispielbild wird als erstes der DRC (Online Design Rule Check) ausgeschaltet und als zweites der Durchmesser des Viapads auf 0,8mm festgelegt.

Mit diesem Verfahren werden die Befehle, die für die Veränderung des Vias benötigt werden, gesammelt und gespeichert.

Python ist eine höhere, objektorientierte Programmiersprache, die darauf ausgelegt ist, Code möglichst einfach und übersichtlich darzustellen. Die für uns zwei wichtigsten Eigenschaften von Python sind die Möglichkeiten in Dateien zu schreiben und die Verwendung von Schleifen und Bedingungen.

Um am Ende die Befehle in Zuken ausführen zu können, muss die zu verändernde Datei mit einer Makrodatei zusammen geöffnet werden. Diese Makrodatei wird auch in Python erstellt. Die vorher gesammelten Befehle werden Zeile für Zeile in eine .log-Datei geschrieben. Im Beispiel oben wird der Durchmesser des Viapads verändert. Da das immer wieder passieren soll, nur mit anderen Durchmessern, kann eine Schleife die Befehle zusammenfassen und damit den Code vereinfachen.

Die Veränderung der Via-Eigenschaften läuft ab wie folgt:

Um das Cutout um das Via verändern zu können müssen die sogenannten Design Rules verändert werden. Dort wird zum Beispiel festgelegt, welche Grenzwerte bei Kupfer- und Isolierabständen und Leiterbahndicken eingehalten werden müssen. In diesen „DesignRules“ wird auch der Abstand zwischen der GND-Kupferfläche und Vias festgelegt. So kann einfach eine neue Designregel für den Bereich des Vias erstellt und dann immer wieder verändert werden. Wenn die Anpassungen am Via durchgeführt wurden, werden die neuen .dsgn Dateien in einem eigenen Ordner abgespeichert. Außerdem wird das Platinenlayout, in für CST zu verarbeitende Dateiformate (.sdf, .sff, .tech), exportiert.

Wenn alle Dateien für CST erstellt worden sind, werden in Schritt fünf die verschiedenen Layouts simuliert. Die Simulation ist in unterschiedlichen Projekten mit unterschiedlichen Leiterplatten sehr individuell. Beispielsweise müssen Ports anders platziert werden, oder es muss das PCB für bessere Simulationsergebnisse zurechtgeschnitten werden.

Deswegen wird das erste unveränderte Layout in CST importiert und von dort weiter in Microwave Studio (MWS) exportiert. Die Platine wird dann einmal manuell simuliert.

Dafür werden als erstes alle Einstellungen nach und nach festgelegt. Zuerst die Randbedingungen, wie die Einheiten, Materialeigenschaften und der Frequenzbereich. Danach die Einstellungen für den Solver und das Netz.




Abbildung 26: Anpassung einer Platine zur Simulation in MWS

In der Abbildung 26 ist zu sehen, dass im Anschluss an der Platine noch individuelle Anpassungen gemacht werden müssen. Einmal wurde die Leitung, die zum Via hinführt, gekürzt, damit das Ende nicht mehr über den Rand der GND-Fläche hinausragt. Das könnte die Simulationsergebnisse verfälschen. Außerdem wurden an den Enden der Leitungen Ports angelegt, als Ein- und Ausgänge der simulierten elektrischen Signale.

Bei der Simulation wird das Modell der Platine in Hexaeder eingeteilt. Mithilfe der Finite-Integral-Methode (FIT) wird das PCB simuliert. Die FIT ist ein numerisches Simulationsverfahren, bei dem die Integrale der Maxwell-Gleichungen angewendet werden

Für diesen Anwendungsfall werden als Auswertung die Streuparameter (S-Parameter) verwendet. S-Parameter geben das Verhältnis der Antworten auf die Anfangsstimulation an. Beispielsweise gibt S11 an, welcher Anteil von den aus Port 1 gesendeten Signal bei Port 1 wieder ankommt, wie viel also reflektiert wurde. S21 hingegen verdeutlicht, wie viel von dem Signal, das von Port 1 gesendet wird, auch bei Port 2 ankommt.

Diese Informationen sind bei der Via-Optimierung besonders wichtig, denn die Ausgangsfrage war, wie Vias verändert werden müssen, um eine optimale Signalübertragung zu gewährleisten.

Wenn die Auswertung für das erste Layout vorliegt, müssen die anderen verschiedenen Layouts simuliert werden. Dafür kann auf die „History List“ zugegriffen werden. Dort werden alle Schritte, die in MWS durchgeführt werden, dokumentiert.

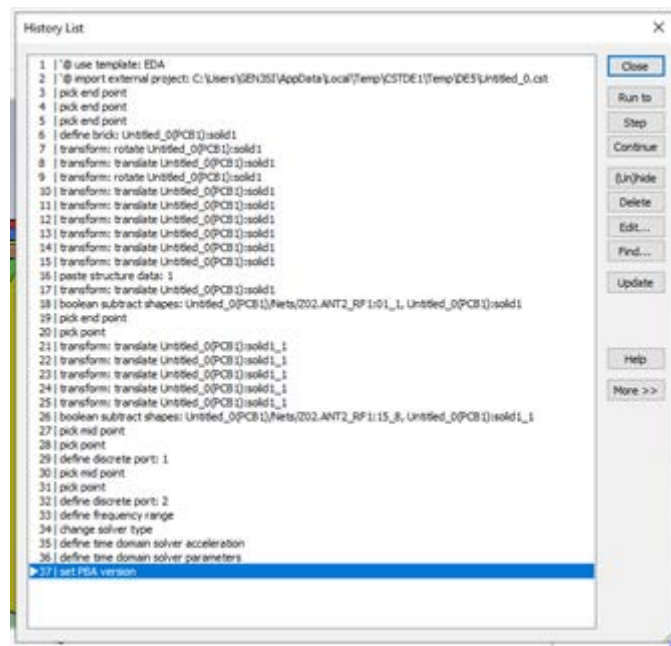


Abbildung 27: History List einer Simulation



Abbildung 28: VBA-Code für Schritt "@use template: EDA"

Hinter den einzelnen Überschriften aus Abbildung 27 verbirgt sich VBA-Code. In dem wird detailliert dargestellt, was für Einstellungen und Veränderungen im Hintergrund vorgenommen worden sind. Die Automatisierung der restlichen Dateien erfolgt über eine

CST-Python-Schnittstelle auch in Python. In der Folgenden Abbildung ist der Python-Code zu sehen, in dem Dateien aufgerufen, verändert und anschließend simuliert und wieder geschlossen werden.

```
32
33 for x in range(len(filelist)):
34     number = x - 1
35     name = "mws_file{}.ldb"
36
37     import_projekt = VBA.import_project.format(filelist[number],name.format(number))
38
39     try:
40
41         project = cst.interface.DesignEnvironment()
42         project.set_quiet_mode(False)
43         mws = cst.interface.DesignEnvironment.new_mws(project)
44         mws.modeler.add_to_history("template", VBA.template)
45         mws.modeler.add_to_history("import project", import_projekt)
46         mws.modeler.add_to_history("complete History List", VBA.history_list)
47         mws.save(save_path + "\\\" + name.format(number))
48
49     #mws.close()
50     #project.close()
51
52
```

Abbildung 1: Python-Skript zur Simulation von Platinen

Abbildung 29: Python-Skript zur Simulation von Platinen

Ganz am Ende lassen sich die S-Parameter vergleichen und das Via mit der besten Signalübertragungsqualität kann übernommen werden.

3.3.2 Teilaufgabe 3.3: Implementation spezifischer und vor-trainierter KI-Module für die Anwendungsebenen #1 und #2

Auf der Grundlage der Spezifikationen aus AP1 und den Ergebnissen aus AP2 wurden die KI-Module maßgeschneidert an die produktspezifischen Instanzen der modularen KI-Plattformen für die Anwendungsebenen #1 - #2 angepasst und mit Hilfe der zu Grunde liegenden Daten auf die jeweilige Problemklasse vortrainiert.

Anhand von anonymisierten, nicht geschützten Daten können vortrainierte KI-Modelle für einzelne Teilplattformen (z.B. Entwurf von passiven und aktiven elektronischen Systemen) erstellt werden. Diese bieten ein generisches Modul, das durch Training beim Kunden zu einem anwender- und anwendungsspezifischen Modul weitertrainiert werden kann. Die produkt-spezifisch vortrainierten KI-Module und das erforderliche Domänenwissen können unter zusätzlicher Garantie des notwendigen IP-Schutzes und der erforderlichen Interoperabilität von KI-Modulen bereitgestellt werden. Durch die Einführung dieser von Firmendaten abstrahierten KI-Layer wird der individuelle IP-Pool der Anwender geschützt, da nur bei der Kommunikation der vortrainierten firmenübergreifenden KI-Module mit den anwender-spezifischen KI-Modulen firmenspezifisches Wissen nicht den Zugriffsbereich der

anwender-spezifischen Module verlässt. Auf diese Weise können insbesondere KMU von „BigData“ profitieren, ohne dass sie oder andere ihre Datensouveränität aufgeben müssen.

Alle zum Datenimport und zum Training der KI erforderlichen Werkzeuge mussten in dieser Teilaufgabe erarbeitet und den anderen TA in AP3 bzw. AP4 Verfügung gestellt werden. Ein erweitertes Training von applikationsspezifischen KI-Modellen kann dann direkt durch Nutzer der jeweiligen KI-Plattformen erfolgen.

Es war zu klären, welche Open-Source-Algorithmen für die geplanten KI-Module optimal adaptiert werden können. Zum Beispiel ermöglichen die Framework-Kombination TensorFlow und Keras sowohl einen schnellen Einstieg durch die High-Level-API Keras, bei der es ohne Umwege möglich ist, wissenschaftlich belegte, vordefinierte und ggf. sogar vortrainierte neuronale Netze einzubinden und an die jeweiligen Anforderungen des Gesamtsystems anzupassen. Durch die zu Grunde liegende State-of-the-Art API TensorFlow können die Modelle allerdings auch Low-Level adaptiert und manipuliert werden, um eine möglichst geringe Fehlerquote bei Klassifizierungen und Vorhersagen zu generieren.

Die nachfolgenden F+E Komplexe mussten in dieser Teilaufgabe bearbeitet werden:

- Implementation einer KI-gestützten Entwurfsmethodik + Vortrainierte KI-Module für die Anwendungsebenen #1 - #2
- Abbildung von Reinforcement-Learning Methoden in KI-gesteuerte Entwurfsabläufe
- Vortrainierte KI-Module mittels Transfer-Learning für partner-spezifische Entwurfsabläufe
- Bereitstellung von annotierten und klassifizierten Trainingsdaten für die Implementierung vortrainierter KI-Module
- Cloud-Plattform für die Implementation der benötigten KI-Module
- ML-Architektur für Transfer Learning (TL)
- Training einer produkt-spezifischen KI für Automotive-Elektronik-Anwendungen
- Vortrainierte KI-Module auf der Basis von Entwurfs-Details
- Vorhersage und Extraktion von Entwurfs-Details aus Datensätzen für elektronische Systeme
- Umsetzung von KI-Anwendungsfällen und Optimierungsszenarien für funktionale Sicherheit
- Umsetzung Modulschnittstellen zur Nutzung von KI-Ergebnissen als Eingabe für weitere Module
- Automatische Konzeptextraktion aus natürlich-sprachlichen Texten
- Automatische Metadatengenerierung aus Dokumenten
- Vorverarbeitungsalgorithmen zur Anpassung von Datensätzen an KI-Module.

Teilbeitrag 3.3.1: Datenbereitstellung für die Implementation von vortrainierten KI-Modulen (01-BOSCH)

Ziele

Bereitstellung von Trainingsdaten für die Implementierung der vortrainierten KI-Module. Diese Trainingsdaten umfassen beispielsweise Schematic- und Layoutdaten aus unserer Datenbank. Die Extraktion der Daten erfordert einen hohen Aufwand, da diese manuell gesichtet und ebenfalls manuell gelabelt werden müssen.

Lösungsweg und Ergebnisse

Es wurde gemeinsam mit 12-DIQA ein neuer UseCase definiert, der unter der Nummer 6a gelistet ist. Der UseCase behandelt das Thema Datasheet Analyse und soll dem Entwickler aus einem großen PDF mit mehreren hundert Seiten ein kurzes sowie übersichtliches Factsheet generieren. Dieses Factsheet soll beispielsweise dem EMV-Entwicklungsingenieur kurz und knapp die relevanten Informationen darstellen. Dies sind beispielsweise Datenraten, Informationen zu den Pixel-Clock-Frequenzen oder aber auch relevante Schematic- bzw. Layoutmaßnahmen für eine störungsfreie Implementierung des Chips.



DS90UH983-Q1
DS90UH983-Q1
06/2009A - JUNE 2021 - REVISED SEPTEMBER 2022

DS90UH983-Q1 4K DisplayPort/eDP to FPD-Link IV Bridge Serializer With HDCP

1 Features

- DisplayPort receiver
 - DP/eDP v1.4 compatible
 - Supports data lane swap and polarity inversion
 - HBR3/HBR2/HBR/RBR link bit rates
 - Main link: 1, 2, or 4 lanes
 - Each lane up to 8.1 Gbps
 - AUX CH 1 Mbps
 - Hot plug detect (HPD)
 - Multi-display (MST) and SST support
 - Supports Symmetric and Asymmetric MST
 - Daisy chaining and spitting
 - SuperFrame unpacking capability
 - Suitable for 4K at 60 Hz video resolution
- FPD-Link IV interface
 - Supports 13.5/12.528/10.8/6.75/3.375 Gbps per channel. Up to 27 Gbps over dual channels
 - Coax/STP interconnect support
 - Port spitting to enable Y-cable interfaces
 - MST and SuperFrame based data spitting to different FPD channels
- Ultra-low latency control channel
 - Three fast-mode plus I²C up to 1 MHz (up to 3.4 MHz for local bus access)
 - High speed GPIOs
- Backwards compatibility
 - IVI 94x and 92x product families
- Security and diagnostics
 - Integrated HDCP v1.4 with on-chip keys for FPD-Link III
 - Link diagnostics
 - Voltage and temperature monitoring
 - Line fault detection
 - BIST and pattern generation
 - CRC and error diagnostics
 - ECC error correction for control bits
 - Replica mode for redundancy
- Advanced link robustness and EMC control
 - Spread spectrum clocking (SSC) input support
 - Spread spectrum clocking generation (SSCG)
 - Data scrambling
- Low power operation
 - 1.8V and 1.15V dual power supply
- AEC-Q100 qualified for automotive applications
 - AEC-Q grade-level 2, -40°C to 105°C
 - 64-pin QFN wettable flanks 9 mm x 9 mm
 - ISO 10605 and IEC 61000-4-2 ESD compliant

2 Applications

- Automotive displays:
 - Central Information Displays (CID)
 - Rear Seat Entertainment (RSE)
 - Digital instrument clusters
 - Head units and HMI modules
 - Head Up Display (HUD)
 - Rear view and side mirror displays

3 Description

The DS90UH983-Q1 is a DisplayPort/eDP to FPD-Link III/IV bridge device. In conjunction with an FPD-Link IV deserializer, the chipset provides a high-speed serialized interface over low-cost 50Ω coax or STP cables. The DS90UH983-Q1 is a VESA DP Standard v1.4 compatible device that supports advanced features such as MST, HBR3, and SuperFrame formats. The device is capable of supporting video resolution up to 4K resolutions with 30-bit color. 8b10b encoded DP data is serialized onto an FPD-Link IV interface output. The FPD-Link IV interface supports video and audio data transmission and full duplex control, including I²C, and GPIO data over a single channel or dual channels. Consolidation of video data and control over FPD-Link IV lanes reduces the interconnect size and weight and simplifies system design. EMI is minimized by the use of low voltage differential signaling, data scrambling, SSCG, and randomization. In backward compatible mode, the device supports up to 720p and 1080p resolutions with 24-bit color depth over a single/dual link as well as HDCP v1.4 support when paired with an HDCP-capable deserializer.

Device Information

PART NUMBER	PACKAGE	BODY SIZE (NOM)
DS90UH983-Q1	QFN (64)	9.0 mm × 9.0 mm

(1) For all available packages, see the orderable addendum at the end of the datasheet.



Simplified Application Diagram

An IMPORTANT NOTICE at the end of this data sheet addresses availability, warranty, changes, use in safety-critical applications, intellectual property matters and other important disclaimers. PRODUCTION DATA.

Abbildung 30: Beispiel PDF für Datasheet Analyse

Hierfür wurden im ersten Schritt mehrere Datasheets ausgewählt, welche in unserem Entwicklungsprozess eine besondere Relevanz haben werden. Anschliessend wurden die relevanten Begrifflichkeiten markiert und unserem Partner 12-DIQA erklärt. Da häufig unterschiedliche Bezeichnungen für die gleiche Sache verwendet werden, wurden entsprechend Datenblätter von unterschiedlichen Herstellern benutzt. Nachfolgend in Abbildung 31 befindet sich ein Beispiel aus einem der ausgewählten Datasheets mit der Markierung der relevanten Begriffe. In diesem Fall geht es um die Signalcharakteristik des Clock Signals und relevant für die EMV sind neben der Grundfrequenz auch die Steig- und Fallzeiten des Signals sowie der Jitter.

Electrical Characteristics (continued)

(V_{DD18} = 1.7V to 1.9V, V_{DD} = 0.95V to 1.05V or 1.14V to 1.26V, V_{DDIO} = 1.7V to 3.6V, T_A = -40°C to +105°C, EP connected to PCB ground, typical values are at V_{DD18} = V_{DDIO} = 1.8V, V_{DD} = 1.0V, T_A = 25°C, unless otherwise noted.) (Note 1)

PARAMETER	SYMBOL	CONDITIONS	MIN	TYP	MAX	UNITS
Input Duty Cycle	t _{DUTY}		40		60	%
Input Fall Time	t _F	80% to 20%			4	ns
AC ELECTRICAL CHARACTERISTICS / REFERENCE CLOCK OUTPUT (RCLKOUT)						
Frequency	f _{REFOUT}	Crystal or reference clock input	f _{REF} / 1	25		MHz
			f _{REF} / 2	12.5		
			f _{REF} / 4	6.25		
Rise Time	t _R	20% to 80%, C _L = 10pF, 25MHz divided by 1, 2, or 4 (Note 2, Note 9)			4	ns
Fall Time	t _F	80% to 20%, C _L = 10pF, 25MHz divided by 1, 2, or 4 (Note 2, Note 9)			4	ns
Jitter	t _J	C _L = 10pF, rising or falling edge, f _{REFOUT} = 12.5MHz		260		ps(p-p)

Abbildung 31: Relevante Begriffe aus einem Datasheet

Mehrere solch markierter Datasheets wurden an 12-DIQA übergeben und befinden sich dort im Analyseprozess.

Ein weiteres Thema, welches im Rahmen dieses Teilbeitrags bearbeitet wurde, ist die Analyse von Gehäuseresonanzen. Je nach Konstellation der mechanischen sowie elektrischen Parameter eines Steuergeräts können sich zwischen PCB und Gehäuse entsprechende Hohlraumresonanzen ausbilden, welche sich wiederum als EMV-Störung darstellen. Dies kann verhindert werden, in dem zusätzliche Massepunkte zwischen PCB und Gehäuse platziert werden.





Abbildung 32: Analyse von Gehäuseresonanzen

Dabei stellt sich aber die Frage, wie viele dieser Massepunkte benötigt werden und wo diese idealerweise platziert werden müssen. Hierzu wurden entsprechende Voruntersuchungen durchgeführt, um den Parameterraum zu bestimmen.



Spring Configuration	1. Resonance		2. Resonance	
	f_Shift (MHz)	attenuation (dB)	f_Shift (MHz)	attenuation (dB)
1 Spring(#2)	124.7	11.4	91.8	2.62
2 Springs(#2)	182.5	14.4	130.0	3.32
3 Springs	197.5	17.2	228.6	10.98

Abbildung 33: Analyse von Gehäuseresonanzen und Bestimmung des Parameterraums

In Abbildung 33 ist zu erkennen, dass durch Verschiebung oder zusätzliche Massepunkte, die störende Resonanzstelle entsprechend verschoben werden kann. Beispielsweise kann so ein unkritischer Frequenzbereich gewählt werden. Mittels der Voruntersuchung war nun der Parameterraum bekannt und es wurde ein simplifiziertes Simulationsmodell in CST aufgebaut.




Abbildung 34: Simulationsmodell in CST für die Analyse der Gehäuseresonanzen

Das Simulationsmodell besteht aus einem Gehäuse mit Boden- und Deckelteil sowie einem PCB. Auf dem PCB befinden sich $m \cdot n$ Ports, welche das PCB mit dem Gehäuse verbinden. Durch Anregung der Ports kann nun für jede Konstellation das Impedanzspektrum bestimmt werden. Mit Hilfe dieser Daten kann im nächsten Schritt ein KI-Modul trainiert werden und so die optimale Positionierung der Massepunkte bestimmt werden.

3.4 Arbeitspaket 4: Erstellung Teilplattformen (#1: PCB-Entwurf; #2: IC-Anwendung/Sensorik)

Anhand von zwei zu gestaltenden Ausprägungen der modularen KI-Plattform sollte der bisherige Entwicklungsprozess angewendet werden und so dessen Impact nachgewiesen werden. Diese zwei Plattformausprägungen (Instanzen) decken Schlüsselpositionen der Automobil-Zulieferindustrie ab. Die jeweils geschaffenen Instanzen von progressivKI decken vollständig einen Bereich der jeweiligen Wertschöpfungskette ab und können von Nutzern sowohl für die KI-basierte Automatisierung wertschöpfungsketten-übergreifender Entwurfsprozesse als auch für die Automatisierung einzelner im Entwurfsprozess kritischer Schritte eingesetzt werden.

Aufbauend auf den bereits bestehenden und neu erstellten KI-Anforderungen und Spezifikationen für modular strukturierte KI-Plattformen (AP1) und den konzipierten und bereitgestellten KI-Modulen (AP2 - AP3), sollten die jeweiligen Gültigkeitsbereiche der Plattformausprägungen für die Anwendungsbereiche #1 - #2 nachgewiesen werden.

Die Struktur der zwei Arbeitsthemen in AP4 ist ähnlich aufgebaut. Zunächst wurden - in enger Abhängigkeit von den Arbeiten und den Ergebnissen aus AP3 |Implementation modular strukturierte KI-Plattform(en)| - die Plattformausprägungen #1 - #2 auf die jeweiligen Wertschöpfungsteilketten (elektronische Referenzsysteme (HW)) angepasst und die anhand der in AP2 aus den Daten abgeleiteten Informationen und erzeugten KI-Modelle eingebunden.

Die erstellten Teilplattformen wurden dann als Proof-of-Concept zunächst mit generischen, und dann mit realen Fragestellungen aus dem Feld (z.B. Planung eines PCB-/Kabelanschlusses oder Schaltungsentwurf für eine Anwendung MicroContoller/integrierter Sensor) evaluiert. Das daraus gewonnene Feedback wurde genutzt, um eine weitere Iteration der Plattformausprägungen #1 - #2 vorzunehmen; gegebenenfalls auch um weitere UseCase spezifische Trainingsdaten zu akquirieren und die KI-Modelle nachzutrainieren. An diesen Schritt können sich nach Bedarf weitere Evaluationen und Iterationen von KI-Werkzeugen und KI-Modellen anschließen.

Da die implementierten KI-Module auch auf der Grundlage von festen Regeln arbeiten sollten, war zu überprüfen, inwieweit z.B. das Einhalten von gesetzlichen Richtlinien durch die implementierten KI-Module zu Entwurfskonflikten führt. Dabei musste je nach Themenbereich und Notwendigkeit unterschieden werden (UseCases/Referenzsysteme (HW)). Diese Richtlinien können gesetzliche Vorgaben oder Erfahrungswerte sein.

Die damit zusammenhängenden Arbeiten sind an der Normenreihe IEC 61508 (Funktionale Sicherheit) der SIL-Klassifizierung (Safety Integrity Level) orientiert (4-stufige Skala für die erforderliche Risikoreduzierung: SIL1 = niedrig; SIL4 = hoch) zu orientieren.

Auch ist es notwendig zu überprüfen, ob die Analyse von Entwurfsentscheidungen hinsichtlich physikalischer Kopplungen durch die jeweiligen KI-Module (z.B: EMC/SI/Thermische Kopplungen) im Zusammenhang mit dem Entwurf eines vollständigen elektronischen Systems (Use-Cases/Referenzsysteme (HW): Leiterplatte für Infotainment-Komponente oder PCB/Kabel mit an-geschlossenen Steuergeräten bzw. Microcontroller-Applikation) zu in der Praxis brauchbaren Ergebnissen führt.

Hinsichtlich der Minimierung von Projektrisiken musste überprüft werden, ob maschinelle Lernalgorithmen mit unterschiedlicher Komplexität (z.B. parametrische Verfahren niedriger Ordnung – mehrstufige neuronale Netze – Reinforcement Learning) je nach

- Lernerfahrung (State) des jeweiligen Algorithmus;
- Klassifizierung der vorliegenden Problemstellung und
- Beurteilung der verfügbaren Daten zum Anlernen

ein |maßgeschneiderter| Algorithmus ausgewählt wurde bzw. ausgewählt werden kann.

Das im Rahmen dieses Projektes implementierte Transfer Learning sollte es ermöglichen, einmal angelernte Algorithmen direkt auf andere Problemklassen übertragen zu können, und dort durch weiteres Lernen langfristig weitere Verbesserungen zu erzielen. Dieser Ansatz war ebenfalls mittels der in AP4 geplanten Arbeiten zu überprüfen.

Desweiteren musste geprüft werden, ob die richtigen mathematisch fundierten Strategien zur Approximation der zustands-, problem- und datenabhängig richtigen Lernstrategien identifiziert wurden und auch wirksam eingesetzt werden können.

Die Anforderungen von KMU und Großunternehmen an die Integration von modularen KI-Plattformen können sich unterscheiden. Während große Unternehmen durchaus in der Lage sind, KI-Applikationen an die eigenen Prozesse anzupassen bzw. diese Prozesse zu verändern, fehlen KMUs hier in der Regel die nötigen Ressourcen, um diese Anpassungen selber vorzunehmen.

Es ist deshalb auch zu validieren, ob die erstellen KI-Module und die darauf basierenden KI-Modul Plattformen von Nutzern aus kleinen und mittleren Unternehmen zur Lösung ihrer Entwurfsaufgaben verwendet werden können.

Für diese Nutzer war im Vorhaben progressivKI vorgesehen:

- einen |Werkzeugkasten| angelernter Algorithmen zu validieren bzw. durch weiteres Lernen zusätzliche Anforderungen zu spezifizieren;
- eine Metanalyse mit der Fragestellung |welche Kombination von Algorithmen und Daten führt zum besten Erfolg| vorzunehmen;
- eine rigorose Bewertung vorhandener Daten sowie Anleitungen zur Generierung geeigneter Daten vorzunehmen;
- rigorose Bewertung des Lernfortschrittes und der Verlässlichkeit von Entwurfsvorschlägen durchzuführen;

- die implementierten User-Interfaces auf ein kontextabhängiges Arbeiten zu überprüfen.

Die oben genannten Features sollten auch automatisiert (vgl. Meta-Modul) bereitgestellt werden.

Da jedoch das Meta-Modul aufgrund des umfassenden Forschungsbedarfs während der Projektlaufzeit nicht das TRL der übrigen Plattformmodule erreichen wurde (TRL 5 statt 6), sollte es vorerst nur als Option bereitgestellt werden und seine Funktionalität im Rahmen der Verwertung zunächst auch als Beratungsservice angeboten werden. Den finalen Schritt in diesem AP stellte die Dokumentation der gefundenen Entwurfsentscheidungen hinsichtlich der für die UseCases erzielten Ergebnisse (z.B. Bauelementauswahl oder Layoutvorschläge; ...) dar. Die Erstellung dieser Dokumente erfolgte parallel zum Test der Plattformausrüstungen #1 - #2. Diese Dokumentation enthält auch alle Angaben zu den Entwurfs-Entscheidungen, die durch die verwendeten KI-Module getroffen wurden. Darüber hinaus stellt diese Dokumentation für das sogenannte Nach-Training der KI-Module eine wesentliche Rolle dar. So lassen sich die Entwurfsentscheidungen der erfahrenen Entwickler mit den Entwurfsvorschlägen der KI-Module vergleichen und als weitere Trainingsdaten verwenden.

Es müssen alle von den KI-Modulen gelieferten Entwurfsvorschläge, von der Entwicklungsanfrage bis hin zur Abschlussdokumentation, dokumentiert werden. Nur dann ist sichergestellt, dass ein eventuelles Nach-Training sinnvoll eingeleitet werden kann.

Das Arbeitspaket AP4 orientierte sich an den in AP 1 – AP 3 adressierten UseCases und wurde in die Arbeitsthemen AT 1 - 3, in diesem Fall in die Anwendungsebenen #1 - #2 gegliedert. Die UseCases werden innerhalb der Anwendungsebenen #1 - #2 agil ergänzt und angepasst.

In AP4/AT 1 - 2 wurden die folgenden Themen bearbeitet:

- Erstellung von Test- und anwendungsbezogenen UseCases/Referenzsystemen (HW) zur Überprüfung der erreichbaren Entwurfsqualität.
- Die Spezifikation und der Entwurf der geplanten UseCases/Referenzsystemen (HW) erfolgt in Verbindung mit AP 1 - 3. Um die Effektivität der neuen KI-orientierten Entwurfsmethoden, der KI-Modelle nachzuweisen, sind mittels der UseCases/Referenzsysteme (HW) Simulations- und Messergebnisse (Ergebnisse aus AP 2 und AP 3) zu vergleichen (Gültigkeitsbereiche der Plattformausrüstungen für die Anwendungsbereiche #1 - #2).
- Nachweis des vorgegeben Systemverhaltens anhand der ausgewählten Referenzsysteme (HW).
- Validierung/-verifikation der KI-Modelle (Festlegung der Testkonfiguration entsprechend Do-E-Prinzipien und Testdurchführung);
- Proof-of-Concept zunächst mit generischen und dann mit realen Fragestellungen
- Evaluationen und Iterationen von KI-Werkzeugen und KI-Modellen
- Einhalten von gesetzlichen Richtlinien durch die implementierten KI-Module bei Entwurfskonflikten
- Ergebnisüberprüfung hinsichtlich der mittels KI-Modulen gelieferten Analyse von Entwurfsentscheidungen

- Maschinelle Lernalgorithmen mit unterschiedlicher Komplexität auf Brauchbarkeit
- überprüfen (|maßgeschneiderte| Algorithmen)
- Überprüfung der direkten Übertragbarkeit angelernter Algorithmen auf andere Problemklassen
- Proof-of-Concept und prototypische Realisierung eines fachspez. Chatbots zur Unterstützung des PCB-Entwurfs (AW#1) im Rahmen der KNV
- Überprüfung, ob die erstellten KI-Module und deren Plattformausrprägungen insbesondere auch von Nutzern kleiner und mittlerer Unternehmen zur Lösung ihrer Entwurfsprobleme verwendet werden können. Gleichzeitig muss geprüft werden, ob die gewählten KI-Ansätze ausreichend modular sind, um sich auch an die Prozesse von Großkunden anpassen zu lassen.
- Umfassende Dokumentation der gefundenen Entwurfsentscheidungen hinsichtlich der für die UseCases erzielten Ergebnisse.

Geplante Ergebnisse von AP4 waren:

- In diesem Arbeitspaket sollte die Entwicklung einer KI-Teilplattform (Technologiereifegrad TRL6) für die Anwendungsebene #1 vorgenommen werden. Dabei wurden anwendungsbezogene Use Cases und Referenzsysteme im Hardwarebereich genutzt, um die erreichbare Entwurfsqualität zu überprüfen. Ein wesentlicher Bestandteil dieses Prozesses war die umfassende Dokumentation der gefundenen Entwurfsentscheidungen, insbesondere in Bezug auf die für die Anwendungsebene #1 relevanten Use Cases.
- Parallel dazu wurde eine KI-Teilplattform (Technologiereifegrad TRL6) für die Anwendungsebene #2 entwickelt. Auch hier dienten anwendungsbezogene Use Cases und Referenzsysteme im Hardwarebereich zur Überprüfung der erreichbaren Entwurfsqualität. Die erzielten Ergebnisse in Bezug auf die Use Cases der Anwendungsebene #2 wurden ausführlich dokumentiert, um die Entscheidungsfindung im Entwurfsprozess transparent zu machen und nachvollziehbar zu gestalten.

3.4.1 Teilaufgabe 4.1: KI-Plattform Anwendungsebene #1 PCB-Entwurf

Dieses Teilarbeitspaket (TA) hatte die Entwicklung von der KI-Plattform Anwendungsebene #1 PCB-Entwurf zum Ziel. Der Einsatz von KI-Methoden zur Beschleunigung des PCB-Entwurfs in der Elektronik ist für die künftige Entwicklung von funktional-sicheren komplexen elektronischen Systemen (Stichwort Systemintegration Automotive bzw. Industrieelektronik u.a.) von entscheidender Bedeutung. Bedingt durch die zu beherrschende hohe Entwurfskomplexität wurde hier ebenfalls eine deutliche Wirkung des KI-Einsatzes hinsichtlich der Entwicklungsziele |First Time Right| und |Time2Market| sowie |Sicherstellung der gewünschten Systemfunktion (funktionale Sicherheit)| erwartet.

Als Schaltungsträger für funktional sichere elektronische Systeme werden hier alle heute gängigen PCB-Ausprägungen betrachtet (Material: FR4/PTFE/Polyamid/...; Ausführung: Flex-

oder Starrflex-PCBs; Metallkern; HF; Hoch-TG; Dickkupfer; hochlagige Multilayer; Feinstleiterstrukturen).

Die Arbeiten zur KI-Plattform Anwendungsebene #1 PCB-Entwurf (wie die der anderen KI-Plattformen der Anwendungsebene #2 auch) beruhen auf dem für progressivKI zugrunde gelegten verallgemeinerten Entwurfsprozess.

Aus den zwei notwendigen Teil-Ansätzen, einem Entwurfs- und einem Analysesystem wurde dann ein kombiniertes System von KI-Modulen abgeleitet werden (progressiv KI-Interaktionsmodell).

Die zu erstellende modulare KI-Plattform Anwendungsebene #1 PCB-Entwurf sollte die Entwicklung von PCB als Schaltungsträger für funktional sichere elektronische Systeme im Entwurfsprozess unterstützen. Dazu wurden bereits in der Entwurfsphase KI-basiert Vorschläge für zum Beispiel die Platzierung und Verdrahtung der Bauelemente, die Leitungsführung auf dem PCB oder die Entkopplung der aktiven Bauelemente dem Entwickler zur Verfügung gestellt.

Das Analysesystem wurde eingesetzt, um Entwurfsprobleme, die auf |physikalische Kopplungen (SI/PWG/EMI/Thermal/...)| zurückzuführen sind, bei einem bereits bestehenden Entwurf (auch die Behandlung von Teilentwürfen muss möglich sein) zu behandeln (Variantenkonstruktion). Die Rechtfertigung für dieses Vorgehen wurde aus der Tatsache abgeleitet, dass erfahrungsgemäß noch erhebliche Reserven für lokale Änderungen in einem Entwurfsansatz vorhanden sind. Die Änderungen können sowohl layout- als auch schaltungsspezifisch sein.

Die Behandlung von physikalischen Kopplungen (SI/PWG/EMI/Thermo/...) auf Schaltungsträgern (PCB) stellt ein Problem hoher Komplexität dar. Um für den Problembereich |physikalische Kopplungen (SI/PWG/EMI/Thermal/...)| KI-basierte und effektive Lösungsmethoden entwickeln zu können, war es notwendig, eine vollständige Strukturierung des Problemfeldes der physikalischen Kopplungen (SI/PWG/EMI/Thermal/...) mittels eines Taxonomieansatzes vorzunehmen und in die KI-Module aus AP3 zu integrieren.

Auf der Basis des Taxonomieansatzes wird dann jeweils eine Ontologie als Netzwerk von Informationen mit logischen Relationen gebildet (Wissensrepräsentation für die zu erstellenden KI-Module).

Der Hauptteil der Arbeiten beschäftigte sich deshalb mit der Integration der jeweiligen Teil-Wissensbasen und der Integration von Simulationswerkzeugen in die modulare KI-Plattform (flexible Abbildung von Entwurfsabläufen). Dazu sollte insbesondere auch eine Parametrisierungs- sowie eine Messtechnik-Wissensbasis integriert werden.

Damit sollte die Möglichkeit geschaffen werden, Parameterberechnungen, die zur Entscheidungsfindung notwendig sind, durch externe Analyse-Werkzeuge ausführen zu lassen und die Ergebnisse an das KI-System zu übergeben. Darüber hinaus musste die Integration von Knowledge-Engineering-Modulen (z.B. Regeln + Deep-Learning) für den Bereich der physikalischen Kopplungen durchgeführt werden.


Teilbeitrag 4.1.1: Test und Validierung von KI-Ausprägungen der Anwendungsebene #1 (01-BOSCH)


Ziele

Test und Validierung der Anwendungsebene sowie Einordnung und Bewertung der Ergebnisse. Unterstützung der Partner beim Thema PCB-Entwurf aus der Perspektive des Tier-1.

Lösungsweg und Ergebnisse

Im neu gegründeten UseCase 6a, welcher bereits in TBB 3.3.1 vorgestellt wurde, lagen nun erste Ergebnisse vor, welche umgehend getestet wurden. Hierfür wurden mehrere hundert Datasheets durch den EMC Factsheet Generator von dem Partner 12-DIQA analysiert und das Ergebnis bewertet sowie an den Partner zurückgemeldet. In diesem Bericht wird das Vorgehen exemplarisch an einem Datasheet gezeigt. Im Testdatensatz waren Datasheets von unterschiedlichsten Bauteilen vorhanden (Prozessoren, Videochips, Speicher, MOSFETs, passiven Bauelementen usw.) Im exemplarischen Beispiel wird das Vorgehen an einem MOSFET mit der Bezeichnung DMP3098L-7 gezeigt, siehe Abbildung 35.





DMP3098L

P-CHANNEL ENHANCEMENT MODE MOSFET

Product Summary

V _{GS}	R _{DS(on)} max	I _D T _A = +25°C
-30V	70mΩ @ V _{GS} = -10V	-3.8A
	120mΩ @ V _{GS} = -4.5V	-3.0A

Features and Benefits

- Low On-Resistance
- Low Gate Threshold Voltage
- Low Input Capacitance
- Fast Switching Speed
- Low Input/Output Leakage
- Totally Lead-Free & Fully RoHS Compliant (Notes 1 & 2)
- Halogen and Antimony Free, "Green" Device (Note 3)
- Qualified to AEC-Q101 Standards for High Reliability


Description and Applications

This new generation MOSFET has been designed to minimize the on-state resistance (R_{DS(on)}) and yet maintain superior switching performance, making it ideal for high efficiency power management applications.

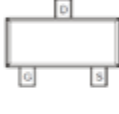
- Power management functions
- Analog Switch
- Load Switch
- Boost Switch

Mechanical Data

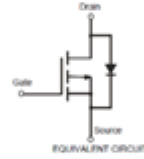
- Case: SOT23
- Case Material: Molded Plastic, "Green" Molding Compound, UL Flammability Classification Rating 94V-0
- Moisture Sensitivity: Level 1 per J-STD-020
- Terminals: Finish — Matte Tin annealed over Copper leadframe. Solderable per MIL-STD-202, Method 208
- Terminal Connections: See Diagram
- Weight: 0.008 grams (approximate)



SOT-23
Top View



Pin Configuration



EQUIVALENT CIRCUIT

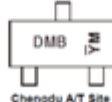
Ordering information (Note 4)

Part Number	Case	Packaging
DMP3098L-7	SOT23	3000/Tape & Reel


Notes:

1. No purposely added lead. Fully EU Directive 2002/95/EC (RoHS) & 2011/65/EU (RoHS 2) compliant.
2. See http://www.diodes.com/quality/lead_free.html for more information about Diodes Incorporated's definitions of Halogen- and Antimony free, "Green" and Lead free.
3. Halogen- and Antimony free "Green" products are defined as those which contain <900ppm bromine, <900ppm chlorine (>1500ppm total Br + Cl) and <1000ppm antimony compounds.
4. For packaging details, go to our website at <http://www.diodes.com/products/packages.html>

Marking information



Chengdu A/T Site



Shanghai A/T Site

DMB = Product Type Marking Code
 YM = Date Code Marking for SAT (Shanghai Assembly) Test site
 YM = Date Code Marking for CAT (Chengdu Assembly) Test site
 Y or Y = Year (ex: A = 2013)
 M = Month (ex: 9 = September)

Date Code Key

Year	2008	2009	2010	2011	2012	2013	2014	2015				
Code	V	W	X	Y	Z	A	B	C				
Month	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
Code	1	2	3	4	5	6	7	8	9	O	N	D

DMP3098L
Document number: DS31447 Rev. 8-2

1 of 5
www.diodes.com

October 2013
© Diodes Incorporated

Abbildung 35: Exemplarisches Datasheet für die Validierung des EMC Factsheet Generators

Zunächst einmal wird das Datasheet im PDF-Format in das Analysetool von 12-DIQA geladen. Dort gibt es dann im oberen Bereich den Menüpunkt *Generate EMC Report* (siehe Abbildung 36).

Chip
Name: DMPL3098L
Labels: n/a

All reports
Generate EMC report

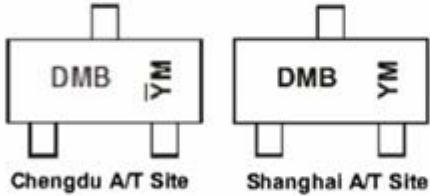
Contents [hide]
1 Ordering information
2 Errata
3 Notes
3.1 Threshold voltage

Ordering information [edit]

Mechanical data

Case: SOT23 Case Material: Molded Plastic, "Green" Molding Compound. UL Flammability Classification Rating 94V-0 Moisture Sensitivity: Level 1 per J-STD-020 Terminals: Finish Matte Tin annealed over Copper leadframe. Solderable per MIL-STD-202, Method 208 Terminal Connections: See Diagram Weight: 0.008 grams (approximate) (from 63ed7e3b1baeffab7278f50472161759e4c2db18f25bdf321e1ea2b05c51b215/Paragraph_11)

Image: caption thumbnap



DMB = Product Type Marking Code
YM = Date Code Marking for SAT (Shanghai)
Y or Y̅ = Date Code Marking for CAT (Chengdu)
Y or Y̅ = Year (ex: A = 2013)
M = Month (ex: 9 = September)

Errata [edit]

- The maximum drain-source voltage of the DMPL3098L P-Channel Enhancement Mode MOSFET is -30 volts. (from DH) ref. able Maximum Ratings for the DMPL3098L P-Channel Enhancement Mode MOSFET.

Notes [edit]

Threshold voltage [edit]

The threshold voltage is the gate voltage at which the mosfet just begins to conduct. It varies from part to part. In the case of your two mosfets, it can range from a minimum of 2V to a maximum of 4V. You have to apply gate voltage well above the threshold to turn the mosfet fully on. Generally, when you are switching mosfets with 3.3V signals, you would use a "logic level" mosfet, which would have a typical threshold voltage of about 1V.

Category: Chip

Abbildung 36: Geladenes PDF im Analysetool von 12-DIQA

Nach Klick auf den Menüpunkt *Generate EMC Report* wird ein neuer Bericht erzeugt, welcher nur die EMV-relevanten Informationen des Datenblatts enthält. Im Beispieldatenblatt des oben gezeigten MOSFETs ist für den EMV-Entwickler lediglich die Tabelle auf Seite 2 relevant, welche ausschließlich im neu generierten Report enthalten ist. Die weiteren Tabellen und Grafiken im Datasheet haben zwar auch ihre Daseinsberechtigung, sind aber für den EMV-Entwickler irrelevant. In Abbildung 37 ist ein Auszug aus dem EMC Factsheet zu sehen. Im oberen Bereich sind noch die Metainformationen enthalten, welche gegenwärtig bei der Validierung und Fehlersuche helfen und in der finalen Version nicht mehr enthalten sein werden.

Table Electrical Characteristics of the P-Channel Enhancement Mode MOSFET.

Table
 Label Table Electrical Characteristics of the P-Channel Enhancement Mode MOSFET.
 Document 63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215
 Page 63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215/page_1
 Parent element 63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215/Heading_25
 Prev element
 Next element 63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215/image_27
 Page number 1 (open page)
 Page image File:63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215-page 1.png
 Bounding box 51,313,531,331
 Electronic Components Chip DMPL3098L
 Keywords
 63ed7e3b1baeffab7278f50472161759e4c2db18Q25bd9321e1ea2b05c51b215-Table_26.png

Characteristic	Symbol	Min	Typ	Max	Unit	Test Condition
OFF CHARACTERISTICS (Note 7)						
Drain-Source Breakdown Voltage	BV_{DSS}	-30	—	—	V	$V_{GS} = 0V, I_D = -250\mu A$
Zero Gate Voltage Drain Current	I_{DSS}	—	—	-800	nA	$V_{DS} = -30V, V_{GS} = 0V$
Gate-Source Leakage	I_{GSS}	—	—	± 100	nA	$V_{GS} = \pm 20V, V_{DS} = 0V$
ON CHARACTERISTICS (Note 7)						
Gate Threshold Voltage	$V_{GS(th)}$	-1.0	-1.8	-2.1	V	$V_{DS} = V_{GS}, I_D = -250\mu A$
Static Drain-Source On-Resistance	$R_{DS(on)}$	—	56 98	70 120	m Ω	$V_{GS} = -10V, I_D = -3.8A$ $V_{GS} = -4.5V, I_D = -3.0A$
Forward Transfer Admittance	$ Y_{fs} $	—	3.6	—	S	$V_{DS} = -5V, I_D = -2.7A$
Diode Forward Voltage (Note 6)	V_{SD}	—	—	-1.26	V	$V_{GS} = 0V, I_S = -2.7A$
DYNAMIC CHARACTERISTICS (Note 8)						
Input Capacitance	C_{iss}	—	336	1008	pF	$V_{DS} = -25V, V_{GS} = 0V, f = 1.0MHz$
Output Capacitance	C_{oss}	—	70	210	pF	
Reverse Transfer Capacitance	C_{rss}	—	49	147	pF	
Gate Resistance	R_G	—	4.6	—	Ω	$V_{GS} = 0V, V_{DS} = 0V, f = 1MHz$
SWITCHING CHARACTERISTICS (Note 8)						
Total Gate Charge	Q_g	—	4.0	8.0	nC	$V_{DS} = -15V, V_{GS} = -4.5V,$ $I_D = -3.8A$
Gate-Source Charge	Q_{gs}	—	1.0	—		$V_{DS} = -15V, V_{GS} = -10V,$ $I_D = -3.8A$
Gate-Drain Charge	Q_{gd}	—	2.5	—		
Turn-On Delay Time	t_{son}	—	6.0	12.0		

Abbildung 37: Auszug aus dem EMC Factsheet

Auch ist das Programm in der Lage, dass aus der oben gezeigten Tabelle auch automatisch ein Fließtext generiert werden kann (siehe Abbildung 38).

Fulltext

OFF CHARACTERISTICS: The drain-source breakdown voltage of the DMPL3098L is $\approx 30V$, with a zero gate voltage drain current of up to $-800nA$ when the drain-source voltage is $0V$ and the gate-source voltage is $-30V$. The gate-source leakage current is up to $100nA$ when the drain-source voltage is $20V$ and the gate-source voltage is $0V$.

ON CHARACTERISTICS: The gate threshold voltage of the DMPL3098L is between $-1.0V$ and $-2.1V$ when the drain-source voltage is equal to the gate-source voltage and the drain current is $0A$. The static drain-source on-resistance is $50m\Omega$, $98m\Omega$, or $120m\Omega$ when the gate-source voltage is $-10V$ and the drain current is $-3.8A$, or when the gate-source voltage is $-4.5V$ and the drain current is $-3.8A$. The forward transfer admittance is 3.6 when the drain-source voltage is $-5V$ and the drain current is $-2.7A$. The diode forward voltage is $71.26V$ when the drain-source voltage is $0V$ and the drain current is $-2.7A$.

DYNAMIC CHARACTERISTICS: The input capacitance of the DMPL3098L is $336pF$ to $1008pF$ when the drain-source voltage is $-25V$, the gate-source voltage is $0V$, and the frequency is $1.0MHz$. The output capacitance is $70pF$ to $210pF$ under the same conditions. The reverse transfer capacitance is $49pF$ to $147pF$ under the same conditions. The gate resistance is 46 when the drain-source voltage is $0V$, the gate-source voltage is $0V$, and the frequency is $1MHz$.

SWITCHING CHARACTERISTICS: The total gate charge of the DMPL3098L is $40nC$ to $8.0nC$ when the drain-source voltage is $-15V$, the gate-source voltage is $-4.5V$, and the drain current is $-3.8A$. The gate-source charge is $1.0nC$ when the drain-source voltage is $-15V$, the gate-source voltage is $-10V$, and the drain current is $-3.8A$. The gate-drain charge is $2.5nC$ under the same conditions. The turn-on delay time is $6.0ns$ to $12.0ns$ when the drain-source voltage is $-15V$, the gate-source voltage is $-10V$, the drain current is $-1A$, and the gate resistance is 6.00 . The rise time is $2ns$ to $10.0ns$ under the same conditions. The turn-off delay time is $17.6ns$ to $35.2ns$ under the same conditions. The fall time is $9.5ns$ to $19.0ns$ under the same conditions.

0,1,2,3,4,5,6

Characteristic, Symbol, Min, Typ, Max, Unit, Test Condition

OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7), OFF CHARACTERISTICS (Note 7)

Abbildung 38: Konvertierter Fließtext aus Tabelle gemäß Abbildung 37

Hier wird die Einstellung des Ausgabeformats (Tabelle oder Fließtext) dem Entwickler und seiner persönlichen Präferenz überlassen. Natürlich ist diese Lösung skalierbar, so dass auch andere Reports erzeugt werden können. Beispielsweise für die mechanischen oder thermischen Eigenschaften des Bauteils. Durch die umfangreichen Tests konnte der ein oder andere Fehler identifiziert werden und an den Partner 12-DIQA gemeldet werden.

3.5 Arbeitspaket 5: Projektmanagement & Dissemination

Um den zentralen Ansatz der Entwicklung einer modular strukturierten KI-Plattform optimal bearbeiten zu können, war es notwendig, ein möglichst breit aufgestelltes Projektteam in die geplanten F+E-Arbeiten einzubinden. Aufgrund der sich daraus ergebenden Heterogenität des Projektkonsortiums stellte dieses AP ein Schlüsselement für den Erfolg des Vorhabens progressivKI dar.

Dieses Arbeitspaket diente der fachlichen und administrativen Steuerung des Projektes mit seinen Organen ProjektOffice und progressivKI Advisory Board, einschließlich der Berichterstattung nach außen und nach innen, dem Erstellen eines Projekthandbuchs (PHB) und einer kontinuierlichen Risikobewertung zur Steuerung des Projektes. Die Verfolgung der Meilenstein-Abarbeitung sowie der Ausarbeitung und Durchführung von Steuerungsmaßnahmen bei Zeitverzug, Budget- oder technologischen Problemen wurde ebenfalls in AP5 wahrgenommen.

Hauptziel war der Nachweis, dass mithilfe der im Projekt erarbeiteten KI-Implementationen die geplanten Anwendungs-Plattformen #1 - #2 aufgebaut werden konnten und somit die im Projekt gemeinsam entwickelten automatisiertem Entwurfsverfahren geeignet sind, nach Projektende effiziente und sichere Elektroniksystemen für zukünftige KFZ-Anwendungen und vergleichbare Industrieprodukte zu entwickeln und zu fertigen. Die geplante edaKI-RoadMap sollte die im Projekt gewonnenen Erkenntnisse und Methoden in geeigneter Form den Projektpartnern zur Verfügung stellen und dafür sorgen, dass dem Thema edaKI (Positionspapier edaKI; Analyse OpenSource KI/AI-Werkezeugen hinsichtlich eda-Eignung; Beteiligte an der Wertschöpfungskette KI-für-EDA zusammenbringen;) auch über die Projektlaufzeit hinaus die erforderliche Beachtung geschenkt wird.

Zur Sicherstellung des Erreichens der Projektziele wurde eine mit allen Partnern abgestimmte Projektorganisation eingeführt. Die Projektkoordination übernahm 01-BOSCH. Es wurden interne und externe Koordinationsaufgaben durch die Projektleitung wahrgenommen.

Bedingt durch die neuen Herausforderungen hinsichtlich KI-gestützter Entwicklung auf dem KFZ-Sektor war eine Vielzahl von technisch/wissenschaftlichen Fragestellungen zu bearbeiten; der Austausch von Projektergebnissen auf nationaler oder internationaler Ebene musste daher unbedingt sichergestellt werden. Insbesondere musste auch der Austausch zwischen Forschung und Anwendung im Vorhaben sichergestellt werden. Es musste daher ein entsprechender Ergebnistransfer organisiert werden – die jeweiligen IP-Interessen der Projektpartner mussten dabei berücksichtigt werden.

Alle progressivKI-Partner beteiligten sich aktiv am Projektmanagement und übernahmen entsprechende organisatorische Aufgaben. Alle algorithmischen Entwicklungen und Implementationen sowie die zugrundeliegenden mathematischen Analysen und Simulationen + Messungen wurden gegenüber den Partnern dokumentiert.

Ferner leisteten die Partner gemeinsam mit dem ProjektOffice Zuarbeit für die Ergebnisverbreitung und Akzeptanzgewinnung, die durch andere Teilprojekte federführend geleistet wurde (z.B. durch Bereitstellung von Anschauungsmaterial zur Funktionsweise der bereitgestellten KI-Algorithmen). Einen großen Anteil wurden die Forschungspartner zur Dokumentation der Projektergebnisse gegenüber der KI- und MikroelektronikCommunity durch Publikationen beigesteuert.

Der Koordinator + ProjektOffice berichteten an den nationalen Projektträger TÜV und nahmen die folgenden Hauptaufgaben war:

- Einrichtung einer Projektorganisation (Projektbüro)
- Aufbereitung strategischer edaKI-Themen (Beitrag zur edaKI-RoadMap)
- Organisation von Treffen mit dem Projektteam
- Organisation von Review-Treffen
- Herstellung relevanter Kontakte mit anderen edaKI-Forschungsaktivitäten auf europäischer und nationaler Ebene
- Überwachung des technischen/wissenschaftlichen progressivKI-Managements und Behandlung rechtlicher progressivKI-Themen, die Behandlung von IP-Angelegenheiten und laufenden Konsortiumsabsprachen

- Überwachung des technischen Projekt-Fortschritts, der Einhaltung von Meilensteinen und Darstellung der Projektergebnisse
- Erstellung eines halb-jährlichen Fortschrittberichts zum Projekt
- Einrichtung und Durchführung eines Qualitäts- und Risikomanagements; dazu werden spezifische progressiv-Projekt Stakeholder von jedem Industriepartner vorgeschlagen
- Abstimmung der Kostenaufstellung(en) mit dem jeweils aktuellen Fortschrittsbericht.

Geplante Ergebnisse von AP5 waren:

- Im Rahmen des Arbeitspakets 5 waren mehrere Schlüsselergebnisse geplant, um eine effiziente und strukturierte Projektabwicklung zu gewährleisten. Zunächst wurde ein Projekthandbuch (PHB) erstellt, das als umfassende Richtlinie und Informationsquelle für alle Beteiligten diente.
- Des Weiteren wurde das progressivKI-ProjektOffice in einen arbeitsfähigen Zustand versetzt, um die reibungslose Koordination und Verwaltung sämtlicher Projektaktivitäten sicherzustellen.
- Ein dreistufiger Ansatz zur Umsetzung der progressivKI F+E-Ergebnisverbreitung und Nutzungsplanung wurde installiert, um sicherzustellen, dass die erzielten Forschungs- und Entwicklungsergebnisse effektiv und zielgerichtet verbreitet und genutzt werden konnten.
- Ein internes und externes Workshopkonzept wurde implementiert, um den Austausch von Ideen, Erfahrungen und Erkenntnissen zwischen den Teammitgliedern sowie externen Stakeholdern zu fördern.
- Zusätzlich wurde ein Verfahren zur umfassenden Projektdokumentation etabliert, um sämtliche Entwicklungen, Entscheidungen und Erkenntnisse während des Projektverlaufs transparent festzuhalten und somit eine umfassende Grundlage für die zukünftige Weiterentwicklung zu schaffen.

3.5.1 Teilaufgabe 5.1: Projektleitung/ProjektOffice + progressivKI Advisory Board

Die Aufgaben in Teilaufgabe 5.1 war jeweils die interne Leitung des Teilvorhabens eines Partners. Aufgrund dieser rein administrativen Aufgabe wird in diesem Kapitel auf eine Ergebnisvorstellung verzichtet.

Alle Projektpartner verfügten über ausreichend Erfahrung zur Steuerung und fachlichen Bearbeitung ihrer jeweiligen Teilaufgaben.

Die Forschungspartner müssen in enger Zusammenarbeit mit den Industriepartnern an der Erstellung der benötigten KI-Module und den jeweiligen Ausprägungen der geplanten modularen KI-Plattform zusammenarbeiten. Ebenfalls benötigt werden die langjährigen Erfahrungen der Forschungspartner auf dem Gebiet EDA-Werkzeuge/Schnittstellen und der Verwendung von OpenSource KI-Algorithmen und Frameworks.

Im progressivKI-Konsortium wurde festgelegt, dass die Koordination der Projektarbeit und die Steuerung der wichtigen Aufgaben Innen- und Außenkommunikation, Datenfluss und

Informationsmanagement, IT-Ressourcenplanung, Verwertung etc. nur mit Hilfe eines ProjektOffice in der erforderlichen Qualität geleistet werden kann und dass für den Betrieb des progressivKI-Office umfangreiche Erfahrungen auf dem Gebiet der Steuerung und FE-Betreuung von öffentlich geförderten Projekten verfügen müssen.

3.5.2 Teilaufgabe 5.2: F+E-Ergebnisverbreitung + F+E-Nutzungspotentiale

Projektziel war die Entwicklung von KI-Modulen (modulare KI-Plattform) für den Aufbau von KI-Plattformen für 2 unterschiedliche Anwendungsebenen und die zugehörige nachhaltige Ergebnisverbreitung. progressivKI sollte zur Projektlaufzeit zunächst einen KI-Modulbaukasten zur Unterstützung der schnellen und effizienten Entwicklung von anwenderspezifischen Elektronikmodulen für eine effiziente Systemintegration erforschen und testen. Darüber hinaus erfolgte die Bereitstellung neuartiger Konzepte für den kooperativen Betrieb von KI-Systemen in industriellen Entwurfs- und Entwicklungsabläufen.

Mit dem hier vorgestellten Ansatz verfügte das gesamte progressivKI Konsortium (Partner/UA/assoziierte Partner) über ein Alleinstellungsmerkmal auf den Gebieten Simulationseinsatz/edaKI/OpenSource KI-Algorithmen.

Um optimale Lösungen für alle Komponenten des Gesamtsystems erarbeiten zu können, war die gemeinsame Nutzung und Weitergabe von Ergebnissen zu den Themen: Modulare KI-Plattform/System-Anforderungen/Entwurfs-/Entwicklungs-regeln/Modelle und Simulationsverfahren im Vorhaben vorgesehen.

Teilbeitrag 5.2.1: Ergebnisverbreitung/Patentrechte (OpenSource) (01-BOSCH)

Ziele

Ergebnisverbreitung Patentrecherche OpenSource Nutzungspotentiale: Diskussion mit potentiellen Anwendern. Ergebnisbericht.

Lösungsweg und Ergebnisse

Die Ergebnisverbreitung wird im Erfolgskontrollbericht beschrieben werden und es wurden keine Patente angemeldet.

4 Verwertung und voraussichtlicher Nutzen

01-BOSCH

Ausgangslage

01-Bosch hat gemäß des Zuwendungsbescheids die nachfolgend aufgelisteten Punkte für den Verwertungsplan vorgegeben bekommen:

- Die erzielten Projektergebnisse zur KI-basierten Optimierung von Entwicklungsabläufen in Review-Prozessen sind in weitere Entwicklungsarbeiten einfließen zu lassen
- Zusätzlich sind die Erkenntnisse zu KI-gestützten Methoden in die interne Wissensbasis zu EMV-Designregeln zu integrieren
- Des Weiteren sind die Ergebnisse des Projekts in die eigene Produktentwicklung zu überführen

Ergebnisse in progressivKI

Nachfolgend werden die wesentlichen und wichtigsten Ergebnisse von 01-Bosch in progressivKI aufgelistet:

- Anwendungsfälle für KI im Entwicklungsprozess evaluiert
- Toolchain für die flexible Generierung von KI-Trainings- und Simulationsdaten
- Datasheet Analyse für die Extraktion relevanter Daten (EMV) aus Datenblättern

Nutzen und Verwertbarkeit

Ein wesentliches Ergebnis für 01-Bosch im Projekt progressivKI ist die Toolchain, welche in den Arbeiten in UseCase #3 entwickelt wurde. Diese Toolchain wird nach Ende des Projekts ein fester Bestandteil in Reviewprozessen sein. Dafür wird beispielsweise ein Datensatz von einem PCB erstellt, welches dann in unterschiedlichsten Parameterkonstellationen betrachtet werden kann und so die beste Lösung für das vorliegende EMV-Problem gefunden werden kann. Ferner wird die Toolchain auch dazu benutzt werden, dass neue Designregeln erstellt und bestehende Designregeln auf Tauglichkeit überprüft werden können. Hier liegt der große Vorteil in der Flexibilität der in progressivKI entwickelten Toolchain. Ein weiteres gutes Ergebnis aus progressivKI für 01-Bosch konnte im UseCase #6a in Kooperation mit DIQA erzielt werden: Datasheet Analysis. Die Datasheet Analysis ermöglicht, dass aus Datenblättern für Chips (Video, USB, Ethernet usw.) die EMV-relevanten Daten extrahiert werden können und dem Entwickler in einem kurzen übersichtlichen Factsheet präsentiert werden. Dies spart Zeit im Entwicklungsprozess, da hier die mühsame und manuelle Suche nach EMV-relevanten Daten sowie Parametern entfällt. Alles in allem konnte durch das Projekt progressivKI ein Mehrwert für die internen Entwicklungsprozesse generiert werden. Dies wird sich in Zukunft durch die Steigerung der Effizienz sowie durch die Reduktion von Designschleifen bemerkbar machen.

6 Quellen

- [AbelRein] A. Abel and J. Reineke, "Measurement-based modeling of the cache replacement policy," 2013 IEEE 19th Real-Time and Embedded Technology and Applications Symposium (RTAS), Philadelphia, PA, 2013, pp. 65-74, doi: 10.1109/RTAS.2013.6531080.
- [Agerri] Agerri R. und German Rigau (2016) Robust multilingual named entity recognition with shallow semisupervised features. *Artificial Intelligence*, 238:63–82.
- [AhaNovVi] A. Ahari, J. Novacek, A. Viehl, O. Bringmann and W. Rosenstiel, "CTEF: Collaborative Technology Evaluation Framework," 2018 IEEE International Systems Engineering Symposium (ISSE), Rome, 2018
- [AI Software] The Best 7 Free and Open-Source Artificial Intelligence Software; <https://www.goodfirms.co/blog/best-free-open-source-Artificial-Intelligence-software>
- [AlsAdHi] Alsioufy, Adnan; Hirler, Alexander; Lehndorff, Thomas; Sulima, Torsten; Lochner, Helmut; Simon, Stefan; Siddabathula, Mahesh; Wiatr, Maciej; Hansch, Walter, *Technology Black Box : A Pioneering Tool for Semiconductor Technology Development in the Automotive Industry*, 2020
- [AMELI] BMBF-Förderprojekt „Mikro-elektromechanisches Elektroniksystem zur Zustandsüberwachung in der Industrie 4.0“, <https://www.elektronikforschung.de/projekte/ameli-4.0>
- [Andecy] d'Andecy, V. P., Hartmann, E., & Rusinol, M. (2018, April). Field extraction by hybrid incremental and a-priori structural templates. In 2018 13th IAPR International Workshop on Document Analysis Systems (DAS) (pp. 251-256). IEEE.
- [BainSammut] Michael Bain and Claude Sammut. 1999. A Framework for Behavioural Cloning. In *Machine Intelligence 15, Intelligent Agents* [St. Catherine's College, Oxford, July 1995]. Oxford University, GBR, 103–129.
- [Chinesta] Francisco Chinesta, *From Data-based engineered models to Model-based engineered data*, Compumag, Paris, 2019
- [Chu] Chu, X., He, Y., Chakrabarti, K., & Ganjam, K. (2015, May). Tegra: Table extraction by global record alignment. In *Proceedings of the 2015 ACM SIGMOD international conference on management of data* (pp. 1713-1728).
- [Clark] Clark, C. A., & Divvala, S. (2015, April). Looking beyond text: Extracting figures, tables and captions from computer science papers. In *Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence*.

- [Collobert] Collobert R. und Weston J. (2008) A unified architecture for natural language processing: Deep neural networks with multitask learning. In Proceedings of the 25th international conference on Machine learning, pp. 160–167.
- [CornVie] Alessandro Cornaglia, Alexander Viehl, Oliver Bringmann, and Wolfgang Rosenstiel. 2019. SIMULTime: Context-sensitive timing simulation on intermediate code representation for rapid platform explorations. In Proceedings of the 24th Asia and South Pacific Design Automation Conference (ASPDAC '19).
- [Coüason] Coüason, B., & Lemaitre, A. (2014). Handbook of Document Image Processing and Recognition, chapter Recognition of Tables and Forms.
- [Csaba] Csaba Szepesvári, Algorithms for Reinforced Learning, Morgan & Claypool, 2010
- [Csurka] Domain Adaptation for Visual Applications: A Comprehensive Survey, Csurka, 2007, arXiv:1702.05374
- [DAC_AI] Machine Learning/AI, DAC 2019; <https://www.dac.com/content/machine-learningai>
- [DACPan20] DAC Panel – Artificial Intelligence Comes to CAD: Where’s the Data? by Tom Simon on 07-30-2020 at 10:00 am, Categories: AI, EDA, Events, Synopsys <https://semiwiki.com/eda/288904-dac-panel-ai-artificial-intelligence-comes-to-cad-wheres-the-data/>
- [DCP] <https://dcp-standard.org/>
- [DeepPCB] Chip Placement with Deep Reinforcement Learning (<https://arxiv.org/pdf/2004.10746.pdf>), A Deep Reinforcement Learning Approach for Global Routing (<https://arxiv.org/abs/1906.08809>), DeepPCB™: Pure AI-powered, cloud-native PCB routing (<https://deeppcb.ai/>), Demystifying Machine Learning for Signal and Power Integrity Problems in Packaging (<https://ieeexplore.ieee.org/document/9149655>)
- [Dernoncourt] Dernoncourt F., Young Lee J. und Szolovits P. (2017) Neuroner: an easy-to-use program for named-entity recognition based on neural networks. arXiv preprint arXiv:1705.05487
- [Dhiran] Dhiran, T., & Sharma, R. (2013). Table detection and extraction from image document. International Journal of Computer & Organization Trends, 3(7), 275-278.
- [Dierig] Dierig, C. (2018, April 22). Fachkräftemangel kostet Deutschland 30 Milliarden Euro. WELT. Retrieved from: <https://www.welt.de/wirtschaft/article175699077/Fachkraeftemangel-kostet-Deutschland-30-Milliarden.html>

- [DiKMU] Karl Lichtblau, Thomas Schleiermacher, Henry Goecke, Peter Schützdeller: Digitalisierung der KMU in Deutschland – Konzeption und empirische Befunde, iwconsult, Köln, 2018
- [DiWiGe] Karl Lichtblau, Manuel Fritsch, Agnes Millack: Digitalisierung von Wirtschaft und Gesellschaft in Deutschland – ein Überblick, iwconsult, Köln, 2018
- [DREAMplace] DREAMPlace: Deep Learning Toolkit-Enabled GPU Acceleration for Modern VLSI Placement (<https://www.cerc.utexas.edu/utda/publications/C252.pdf>)
- [EffectivePCB] Effective PCB Decoupling Optimization by Combining an Iterative Genetic Algorithm and Machine Learning (<https://www.mdpi.com/2079-9292/9/8/1243>)
- [Ertel] Wolfgang Ertel: Grundkurs Künstliche Intelligenz - Eine praxisorientierte Einführung, 4., überarbeitete Auflage, Springer Vieweg, 2016
- [Esteban] Arroyo Esquivel Esteban, Capturing and Exploiting Plant Topology and Process Information as a Basis to Support Engineering and Operational Activities in Process Plants, Dissertation, HSU / UNiBw H 2017
- [Eurostat] Eurostat. (November 20, 2018). Number of enterprises in the manufacture of electronic components industry in Germany from 2008 to 2016 [Graph]. In Statista. Retrieved May 07, 2020, from <https://www.statista.com/login.bibproxy.whu.edu/statistics/383830/enterprises-manufacturing-electronic-components-germany/>
- [Evertiq] Evertiq (2018, Januar 08). Top 25 der EMS-Dienstleister in Europa. Retrieved from: <https://evertiq.de/news/21703>
- [Farrukh] Farrukh, W., Foncubierta-Rodriguez, A., Ciubotaru, A. N., Jaume, G., Bejas, C., Goksel, O., & Gabrani, M. (2017, November). Interpreting data from scanned tables. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 2, pp. 5-6). IEEE.
- [Fisher] Fisher, R. A.: The Use of Multiple Measurements in Taxonomic Problems. Annals of Eugenics. 7 (2), Seiten 179–188, 1936
- [FMI] <https://fmi-standard.org>
- [Gatos] Gatos, B., Danatsas, D., Pratikakis, I., & Perantonis, S. J. (2005, August). Automatic table detection in document images. In International Conference on Pattern Recognition and Image Analysis (pp. 609-618). Springer, Berlin, Heidelberg.
- [Gilani] Gilani, A., Qasim, S. R., Malik, I., & Shafait, F. (2017, November). Table detection using deep learning. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 771-776). IEEE.
- [GloBay] A Global Bayesian Optimization Algorithm and Its Application to Integrated System Design (<https://ieeexplore.ieee.org/abstract/document/8253829>)

- [Graeber] F. Graeber; Sechs KI-Trends in 2019; Elektronik 04-2019 (GMM); Seiten 25 – 26
- [Graves] Graves, Alex & Wayne, Greg & Reynolds, Malcolm & Harley, Tim & Danihelka, Ivo & Grabska-Barwińska, Agnieszka & Gómez, Sergio & Grefenstette, Edward & Ramalho, Tiago & Agapiou, John & Badia, Adrià & Hermann, Karl & Zwols, Yori & Ostrovski, Georg & Cain, Adam & King, Helen & Summerfield, Christopher & Blunsom, Phil & Kavukcuoglu, Koray & Hassabis, Demis. (2016). Hybrid computing using a neural network with dynamic external memory. Nature. 538. 10.1038/nature20101.
- [Gupta] Gupta, A., Tiwari, D., Khurana, T., & Das, S. (2019). Table detection and metadata extraction in document images. In Smart Innovations in Communication and Computational Sciences (pp. 361-372). Springer, Singapore.
- [ISO26262] ISO 26262: „Road vehicles – functional safety“, 2018-12
- [ITAS] BMBF-Förderprojekt „Integrationstechnologien für autonome Sensorsysteme“, <https://www.binder-elektronik.de/referenzen#itas-integrationstechnologien-fuer-autonome-sensorsysteme>
- [Jahan] Jahan Mac A. und Ragel R. G. (2014) Locating Tables in Scanned Documents for Reconstructing and Republishing (ICIAfS14).
- [JITX] Startup JITX Uses AI to Automate Complex Circuit Board Design, <https://spectrum.ieee.org/tech-talk/computing/hardware/startup-jitx-uses-ai-to-automate-complex-circuit-board-design> (Artikel vom 31.07.18)
- [KabYed] M. R. Kabir, B. B. Yedla Ravi, and S. Ray, “A virtual prototyping platform for exploration of vehicular electronics,” IEEE Internet of Things Journal, vol. 10, no. 18, pp. 16 144–16 155, 2023.
- [Kavasidis] Kavasidis, I., Pino, C., Palazzo, S., Rundo, F., Giordano, D., Messina, P., & Spampinato, C. (2019, September). A saliency-based convolutional neural network for table and chart detection in digitized documents. In International Conference on Image Analysis and Processing (pp. 292-302). Springer, Cham.
- [Klcdn] AI / Machine Learning Solutions;
https://www.cadence.com/ko_KR/home/solutions/machine-learning.html
- [Klment] Deliver “smarter” faster: Mentor introduces new AI/ML toolkit, adds AI/ML power to Calibre tools to speed smarter IC innovation;
<https://www.mentor.com/company/news/siemens-mentor-introduces-new-ai-ml-toolkit-adds-ai-ml-power-to-calibre-tools-to-speed-smarter-ic-innovation>
- [Klsyn] Artificial Intelligence Solutions, Unlock the Transformative Power of AI;
<https://www.synopsys.com/ai.html>

- [KI-MUSIK40] BMBF-Förderprojekt „Mikroelektronik-basierte universelle Sensor-Schnittstelle mit Künstlicher Intelligenz für Industrie 4.0“, <https://www.elektronikforschung.de/projekte/ki-musik4.0>
- [Krizhevsky] Krizhevsky, Sutskever, Hinton; ImageNet Classification with Deep Convolutional Neural Networks; 2012; Advances in Neural Information Processing Systems 25
- [Kuru] Kuru O., Can O. A., und Yuret D. (2016) Charner: Character-level named entity recognition. In Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers, pp. 911–921.
- [Lample] Lample G. , Ballesteros M., Subramanian S., Kawakami K. und Dyer C. (2016) Neural architectures for named entity recognition. arXiv preprint arXiv:1603.01360.
- [LiHanLi] Li J.,Sun A., Han J. und Li C. (2020) A Survey on Deep Learning for Named Entity Recognition. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167-172.
- [Liu] Liu, Y. (2009). Tableseer: automatic table extraction, search, and understanding.
- [LuSun] T. Lu, J. Sun, K. Wu and Z. Yang; High-Speed Channel Modeling With Machine Learning Methods for Signal Integrity Analysis; IEEE Transactions on Electromagnetic Compatibility, vol. 60, no. 6, pp. 1957 - 1964, Dec. 2018.
- [Mandal] Mandal, S., Chowdhury, S. P., Das, A. K., & Chanda, B. (2004). A Very Efficient Table Detection System from Document Images. In ICVGIP (pp. 411-416).
- [Masudul] Masudul H. Quraishi, Hessam S. Sarjoughian, and Soroosh Gholami. 2018. Co-simulation of hardware RTL and software system using FMI. In Proceedings of the 2018 Winter Simulation Conference (WSC '18). IEEE Press, 572–583.
- [Mikolov] Tomas Mikolov, Kai Chen, Greg Corrado, Jeffrey Dean: Efficient Estimation of Word Representations in Vector Space. <https://arxiv.org/abs/1301.3781>
- [Milošević] Milošević, N. (2018). A multi-layered approach to information extraction from tables in biomedical documents.
- [Minsky] M. Minsky, Neural Nets and the Brain Model Problem, Ph.D. dissertation in Mathematics, Princeton, 1954; siehe auch: M. Minsky, Seymour Papert: Perceptrons. An Introduction to Computational Geometry. MIT Press, Cambridge MA u. a. 1969
- [MueBel] D.Mueller, M.Beltle, S.Tenbohlen: Automated Filter Optimization for High-Voltage Cable Harness Based on Circuit Simulations for Conducted Emissions Prediction, EMC Europe 2018, Amsterdam 2018

- [NgLimKoo] Ng, H. T., Lim, C. Y., & Koo, J. L. T. (1999, June). Learning to recognize tables in free text. In Proceedings of the 37th annual meeting of the Association for Computational Linguistics on Computational Linguistics (pp. 443-450). Association for Computational Linguistics.
- [OWL2] <https://www.w3.org/TR/owl2-overview/>
- [Pomerleau] Dean A. Pomerleau. 1988. ALVINN: an autonomous land vehicle in a neural network. In Proceedings of the 1st International Conference on Neural Information Processing Systems (NIPS'88). MIT Press, Cambridge
- [PythonML] Pros and Cons of Python in Machine Learning, <https://www.zarantech.com/blog/pros-and-cons-of-python-in-machine-learning/>
- [Qiao] Qiao, Kai; Zeng, Lei; Chen, Jian; Hai, Jinjin; Yan, Bin; Wire segmentation for printed circuit board using deep convolutional neural network and graph cut model; IET Image Processing, 2018, 12, (5), p. 793 – 800
- [RamaSingh] Ramasubramanian K., Singh A.; Deep Learning Using Keras and TensorFlow; Machine Learning Using R. Apress, Berkeley, CA, 2019
- [RDF] <https://www.w3.org/TR/rdf-schema/>
- [RDF11] <https://www.w3.org/TR/rdf11-concepts/>
- [Redmon] Redmon, J., & Farhadi, A. (2018). Yolov3: An incremental improvement. arXiv preprint arXiv:1804.02767
- [Sarawagi] Sunita Sarawagi: Information Extraction. In: Foundations and Trends in Databases. Volume1, Issue 3, 2008 <https://doi.org/10.1561/1900000003>
- [Schreiber] Schreiber, S., Agne, S., Wolf, I., Dengel, A., & Ahmed, S. (2017, November). Deepdesrt: Deep learning for detection and structure recognition of tables in document images. In 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR) (Vol. 1, pp. 1162-1167). IEEE.
- [SciKit] scikit-learn, Machine Learning in Python; <https://scikit-learn.org/stable/>
- [Silva] e Silva, A. C., Jorge, A., & Torgo, L. (2003, December). Automatic selection of table areas in documents for information extraction. In Portuguese Conference on Artificial Intelligence (pp. 460-465). Springer, Berlin, Heidelberg.
- [SKOS] <https://www.w3.org/TR/skos-primer/>
- [SSP] <https://ssp-standard.org/>
- [Statista] Statistisches Bundesamt. (May 28, 2019). Industry revenue of “manufacture of electronic components and boards“ in Germany from 2011 to 2023 (in billion U.S. Dollars) [Graph]. In Statista. Retrieved May 07, 2020, from

<https://www.statista.com/login.bibproxy.whu.edu/forecasts/883959/manufacture-of-electronic-components-and-boards-revenue-in-germany>

- [SurTay] Transfer Learning for Reinforcement Learning Domains: A Survey, Tayler et al., 2009, Journal of Machine Learning Research 10 1633-1685
- [Teich] Irene Teich: Meilensteine der Entwicklung künstlicher Intelligenz. Informatik Spektrum 43, Seiten 276-284, 2020
- [Tengli] Tengli, A., Yang, Y., & Ma, N. L. (2004, August). Learning table extraction from examples. In Proceedings of the 20th international conference on Computational Linguistics (p. 987). Association for Computational Linguistics.
- [Torabi] Faraz Torabi and Garrett Warnell and Peter Stone, Behavioral Cloning from Observation, 2018
- [TrainingModel] A Data-Efficient Training Model for Signal Integrity Analysis based on Transfer Learning (<https://ieeexplore.ieee.org/document/8953103>)
- [TransLearn] Journal of Machine Learning Research 10 (2009) 1633-1685 Submitted 6/08; Revised 5/09; Published 7/09, Transfer Learning for Reinforcement Learning Domains: A Survey;
- [TUDO1] Marian Patrik Felder, Michael Kiffmeier, Jürgen Götze, Stephan Frei, Daniel Renner, Fusion of measurements by existing nodes in an on-board power supply system for condition monitoring with focus on the battery, In Beiträge der 8. GMM-Fachtagung, VDE VERLAG GMBH, vol. 8, pp. 75-80, 2017.
- [TUDO2] P. Jansen, T. Gebel, D. Renner, D. Vergossen, W. John, J. Götze, An approach to determine the state of charge of a lithium iron phosphate cell using classification methods based on frequency domain data, In 8th IET International Conference on Power Electronics, Machines and Drives (PEMD 2016), Glasgow, 2016.
- [TUDO3] M. P. Felder, J. Götze, State of Charge-Klassifizierung für Lithium-Ionen-Batterien anhand von impedanzbasierten Merkmalen, In Advances in Radio Science, Copernicus Publications, vol. 14, Miltenberg, Germany, pp. 1-5, 2016.
- [TUDO4] Jansen, M. Vollnhals, D. Renner, D. Vergossen, W. John, J. Götze, Advanced binary search pattern for impedance spectra classification for determining the state of charge of a lithium iron phosphate cell using a support vector machine, In Advances in Radio Science, vol. VI, no. 14, pp. 55-62, 2016.
- [TUDO5] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Impedance spectra classification for determining the state of charge on a lithium iron phosphate cell using a support vector machine, In Advances in Radio

- Science, Copernicus Publications, vol. 13, Miltenberg, Deutschland, pp. 127-132, 2015.
- [TUDO6] P. Jansen, D. Vergossen, D. Renner, W. John, J. Götze, Bestimmung des Ladezustands von Batterien mittels zustandsraumbasierter Verfahren mit online-Parameterschätzung, In Elektrik/Elektronik in Hybrid- und Elektrofahrzeugen und elektrisches Energiemanagement, expertverlag, vol. VI, no. 138, Bad Boll, Deutschland, pp. 361-376, 2015.
- [TUDO7] T. Nick, Signalverarbeitungsmethoden zur Lokalisierung passiver UHF RFID Label in der Logistikbranche, In 6. Dresdner RFID-Symposium, Dresden, Germany, 2012.
- [TUDO8] T. Nick, J. Götze, Multi-Hypothesis Kalman Filter for RFID-Based Localization and Tracking, In URSI Kleinheubacher Tagung 2012, Miltenberg, Germany, 2012.
- [TUDO9] M. Lechtenberg, J. Götze, K. Görner, C. Rehtanz, Parameter Estimation under Non-Stationary Circumstances using extended Signal Model, In Kleinheubacher Tagung (KH 2013)/Advances in Radio Science 2014, Miltenberg, Germany, 2013.
- [UNECE10] Regelung Nr. 10 der Wirtschaftskommission der Vereinten Nationen für Europa (UN/ECE) — Einheitliche Bedingungen für die Genehmigung der Fahrzeuge hinsichtlich der elektromagnetischen Verträglichkeit, Rev. 6, Europäische Union, 20.12.2018
- [VRue] Von Rueden, Laura, et. al., „Informed Pre-Training on Prior Knowledge“, arXiv preprint arXiv:2205.11433, 2022
- [Weiss] Weiss, D. (2019, Dezember). Die Europäische EMS Industrie, eine detaillierte Analyse. Weiss Engineering. Retrieved from: <https://www.in4ma.de>
- [WIKImem] https://de.wikipedia.org/wiki/Long_short-term_memory
- [Yadav] Yadav V., Sharp R., und Bethard S. (2018) Deep affix features improve neural named entity recognizers. In Proceedings of the Seventh Joint Conference on Lexical and Computational Semantics, pp. 167–172.
- [Zhang] L. Zhang et al.; Convolutional neural network-based multi-label classification of PCB defects; The Journal of Engineering, vol. 2018, no. 16, pp. 1612 - 1616, 11 2018.
- [Zhu] Semi-Supervised Learning Literature Survey, Zhu, 2005, Technical Reports Archive for the Department of Computer Science at the University of Wisconsin-Madison; The Simple and Efficient Semi-Supervised Learning Method for Deep Neural Networks, Lee, 2013

- [Ziebart] Brian D. Ziebart, Andrew Maas, J. Andrew Bagnell, Anind K, Dey, Maximum Entropy Inverse Reinforced Learning, Proc. 23th AAAI Conf. On Artificial Intelligence, 2008
- [ZVEI2019] ZVEI, (2019, Juli 11). Die globale Elektroindustrie – Daten, Zahlen und Fakten. Retrieved from: <https://www.zvei.org/presse-medien/publikationen/die-globale-elektroindustrie-daten-zahlen-und-fakten/>
- [ZVEI2020] ZVEI, (2020, April 21). The German Electric Industry – Facts & Figures. Retrieved from: <https://www.zvei.org/en/press-media/publications/the-german-electric-industry-facts-figures/>

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel Schlussbericht zum Förderprojekt „progressivKI - Unterstützung der Entwicklung von effizienten und sicheren Elektroniksystemen für zukünftige KFZ-Anwendungen mit automatisierten Fahrfunktionen mittels einer modular strukturierten KI-Plattform“ Teilvorhaben: Optimierung des KI- und datengesteuerten Entwurfs sowie der Verifikation	
4. Autor(en) [Name(n), Vorname(n)] Kühn, Michael Terres, Markus Krummenauer, Jan	5. Abschlussdatum des Vorhabens 30.09.2024
	6. Veröffentlichungsdatum
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) Robert Bosch GmbH - 31139 Hildesheim	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A21006A
	11. Seitenzahl 109
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 67
	14. Tabellen -
	15. Abbildungen 38
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung Die wesentlichen Innovationen im Fahrzeug (~ 90%) beruhen auf Mikroelektronik, an deren Entwicklung und Produktion die gesamte Automobillieferkette beteiligt ist. Es ist daher unabdingbar, die sich ständig weiterentwickelnden neuen Möglichkeiten der Halbleiterindustrie und Elektronik möglichst schnell in die Entwicklung neuer Fahrzeuge einfließen zu lassen. Dieses Vorhaben adressierte in dem BMWK-Förderaufruf „Künstliche Intelligenz als Schlüsseltechnologie für das Fahrzeug der Zukunft“ den Teilschwerpunkt (C) KI-Verfahren in der Fahrzeugentwicklung => KI-Methoden in der Simulation. Um Entwurfsprozesse für zukünftige KFZ-Elektroniksysteme optimal zu unterstützen und zu automatisieren ist – aufgrund der deutlich zunehmenden Systemkomplexität auf dem Weg zum autonomen und möglicherweise elektrisch angetriebenen Fahrzeug – der Einsatz von KI-Modulen unbedingt erforderlich. Die dabei erforderlichen F+E-Schritte sind so umfangreich, dass sie zukünftig nur mit Hilfe einer KI-basierten Plattform in ausreichend kurzer Zeit und mit vertretbarem Kostenaufwand erfolgreich umgesetzt werden können. Ziel des Projektes war es, durch den kooperativen Betrieb von KI-Systemen Elektroniksysteme schneller und zuverlässiger zu entwickeln, um somit für zukünftige Schlüsseltechnologien für die Automobilindustrie eine weltweit wirkende Innovations- und Technologieführerschaft der beteiligten Unternehmen zu erreichen. Typische elektronische Komponenten sind zum Beispiel: ABS oder ESP bzw. ACC. Weiterhin sollen hier genannt werden: Umfelderkennung durch kompakte Sensorik sowie die Sensordatenfusion und -interpretation in Echtzeit mittels leistungsfähiger Steuereinheiten und Multiprozessorsysteme. Zur Entwicklung sicherer und zuverlässiger elektronischer Komponenten und Systeme sind u. a. neue Entwurfs- und Validierungsmethoden auf KI-Basis notwendig.	
19. Schlagwörter EDA, Mikroelektronik, Halbleiterindustrie, Fahrzeugentwicklung, Künstliche Intelligenz (KI), Systemkomplexität, Autonomes Fahren, Elektroniksysteme, Sensordatenfusion, Validierungsmethoden, Innovationsführerschaft	
20. Verlag	21. Preis

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Final Report
3. title Final Report on the Funding Project "progressivAI - Supporting the Development of Efficient and Safe Electronic Systems for Future Automotive Applications with Automated Driving Functions Using a Modular AI Platform" Sub-projects: Optimization of AI and data-driven design and verification	
4. author(s) (family name, first name(s)) Kühn, Michael Terres, Markus Krummenauer, Jan	5. end of project 30.09.2024
	6. publication date
	7. form of publication Final Report
8. performing organization(s) (name, address) Robert Bosch GmbH - 31139 Hildesheim	9. originator's report no.
	10. reference no. 19A21006A
	11. no. of pages 109
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 67
	14. no. of tables -
	15. no. of figures 38
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract The essential innovations in vehicles (~90%) are based on microelectronics, in the development and production of which the entire automotive supply chain is involved. It is therefore essential to incorporate the constantly evolving new possibilities of the semiconductor industry and electronics into the development of new vehicles as quickly as possible. This initiative addressed the sub-focus (C) "AI Methods in Vehicle Development <=> AI Methods in Simulation" in the BMWK funding call "Artificial Intelligence as a Key Technology for the Vehicle of the Future". To optimally support and automate design processes for future automotive electronic systems, the use of AI modules is indispensable, due to the significantly increasing system complexity on the path to autonomous and possibly electrically powered vehicles. The necessary R&D steps are so extensive that they can only be successfully implemented in the future with the help of an AI-based platform, in a sufficiently short time and at a reasonable cost. The goal of the project was to develop electronic systems faster and more reliably through the cooperative operation of AI systems, thus enabling the participating companies to achieve worldwide innovation and technology leadership for future key technologies in the automotive industry. Typical electronic components include, for example, ABS or ESP and ACC. Further examples include environmental sensing using compact sensors as well as sensor data fusion and interpretation in real time via powerful control units and multiprocessor systems. To develop safe and reliable electronic components and systems, new AI-based design and validation methods are necessary.	
19. keywords EDA (Electronic Design Automation), Microelectronics, Semiconductor Industry, Vehicle Development, Artificial Intelligence (AI), System Complexity, Autonomous Driving, Electronic Systems, Sensor Data Fusion, Validation Methods, Innovation Leadership	
20. publisher	21. price