Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:

Bundesministerium für Wirtschaft und Klimaschutz

aufgrund eines Beschlusses des Deutschen Bundestages

BMWK-Verbundprojekt: progressivKI

Förderkennzeichen: 19A21006C

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: Dateninfrastruktur für eine KI-Entwicklungsumgebung von ICs

Version: 1.0

Erstelldatum: 06.12.2024

Autoren: Volkan Esen (Infineon Technologies AG)
Manuela Neyer (Infineon Technologies AG)

Zuwendungsempfänger: Infineon Technologies AG (Fkz: 19A21006C)

Ansprechpartner:

Infineon Technologies AG
Manuela Neyer
85579 Neubiberg
manuela.neyer@infineon.com

Infineon Technologies AG
Volkan Esen
85579 Neubiberg
volkan.esen@infineon.com

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19A21006C 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

Bildverzeichnis **4**

Tabellenverzeichnis **4**

1 Zusammenfassung **5**

2 Ziele **6**

2.1 Problemstellung und allgemeine Ziele des Vorhabens **6**

2.2 Wissenschaftliche und/oder technische Ziele des Vorhabens **7**

2.2.1 KI-gestützter Entwurfsprozess 7

2.2.2 Umsetzung des geplanten modular strukturierten KI-Konzeptes 9

2.2.3 Genutzte KI-Verfahren und Werkzeuge 10

2.2.4 Aufbau KI-Modulbaukasten 15

2.2.5 Entwurfsprozesse 15

2.2.5.1 Allgemeiner Entwurfsprozess 17

2.2.5.2 Funktionale Sicherheit 18

2.2.5.3 Kostenreduktion mittels virtueller Entwicklung 19

2.2.6 IP-Schutz und Interoperabilität 21

2.2.7 Darstellung der wesentlichen Projektinnovationen 22

2.3 Ausgangssituation und Voraussetzungen, unter denen das Vorhaben durchgeführt wurde 24

2.3.1 Der Stand von Wissenschaft und Technik 24

2.3.2 Bisherige Arbeiten des Antragstellers 37

2.4 Abgrenzung und Zusammenarbeit mit anderen Projekten **38**

3 Technische Ergebnisse **41**

3.1 Arbeitspaket 1: edaKI-Anforderungen/Spezifikation modular strukturierte KI-Plattform 42

3.1.1 Teilaufgabe 1.1: Funktionale Sicherheit + Entwurfsabläufe (Wertschöpfungsketten) + Schnittstellen 43

3.1.2 Teilaufgabe 1.2: Spezifikation KI-gestützter Entwurf 46

3.2 Arbeitspaket 2: KI-Datenaufbereitung/-generierung **49**

3.2.1 Teilaufgabe 2.1: Definition und Planung von Schnittstellenmodellen 51

3.2.2 Teilaufgabe 2.2: Test-/Lerndatenerzeugung 54

3.3 Arbeitspaket 3: Verzahnte Entwicklung von Automobilkomponenten **56**

3.3.1 Teilaufgabe 3.1: Framework KI-Module für AW-Ebenen #2 + Optimierung KI-Module 57

3.4 Arbeitspaket 4: Erstellung Teilplattformen (#2: IC-Anwendung/Sensorik) **59**

3.4.1 Teilaufgabe 4.2: KI-Plattform Anwendungsebene #2 IC-Entwurf/Sensorik 62
3.5 Arbeitspaket 5: Projektmanagement & Dissemination 65
3.5.1 Teilbeitrag 5.1.3 Leitung Teilvorhaben 65
3.5.1.1 Geplanter Partnerbeitrag 65
3.5.1.2 Ergebnisse 65
4 Verwertung und voraussichtlicher Nutzen 66
5 Veröffentlichungen 68
6 Quellen 73

Bildverzeichnis

Abbildung 1: progressivKI modular, strukturierte KI-Plattform - Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP) 13
Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukasten..... 15
Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften 17
Abbildung 4: Verallgemeinerter Entwurfsprozess als Grundlage für die Analyse des Einsatzes von KI-Modulen im industriellen Umfeld 18
Abbildung 5: Entwurfsaspekte und -schritte auf HW- und SW-Ebene 19
Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation..... 20
Abbildung 7: Virtuelle Entwicklung: Einsatz von Simulationsverfahren und –prinzipien 20
Abbildung 8: progressivKI-Ansatz zur Sicherstellung eines umfassenden IP-Schutz und Herstellung der Interoperabilität (Beipiel Anwenderebene #2 PCB-Entwurf) 21
Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete 41
Abbildung 10: Konzept zur Datenmodellversionierung und der Verwaltung von Schnittstellen..... 55

Tabellenverzeichnis

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). ... 9
Tabelle 2: progressivKI-Innovationselemente gemäß Schumpeter-Definition* 23
Tabelle 3 - Klassifikation und typ. Beispielanwendungen 48
Tabelle 4 - Maßnahmen und Risiken..... 48

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 <=> 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 erfordert. 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: Umfelderfassung 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.

Dabei hat IFAG vor allem in der Anwendungsebene #2 (IC-Entwurf/ Sensorik) gearbeitet.

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: Umfelderfassung 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 Wertschöpfung 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 Huskarl[1]-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 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
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.
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 Datenpunktemit maximalem Abstand trennt. Daten, deren räumlicher Abstand zur Trennebene gering ist, werden dabei mehr berücksichtigt als Datenpunkte, deren Abstand zur Trennebene groß ist.
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 talcit knowledge/Erfahrungswissen formale Regeln abgeleitet werden können. 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".

[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.

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.

Vorteile:

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 knowledge[2]) abgebildet werden kann und anderseits 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 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.

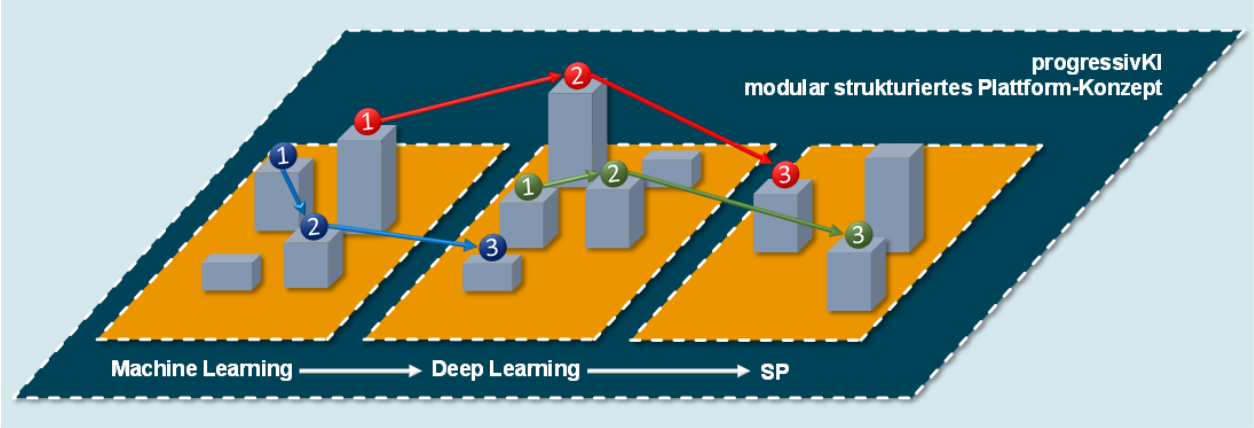

Abbildung 1: progressivKI modular, strukturierte KI-Plattform - Module aus den 3 Segmenten Machine Learning (ML) – Deep Learning (DL) – Selbstlernende Prozesse (SP)

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.

[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 Psychologe oder der KI-Community betrachtet.

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 Features[3] 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.
- Komplett Open Source
- Eine große Sammlung an built-in Bibliotheken die Funktionen für Maschinelles Lernen bereitstellen

[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

- 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 benötige 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.

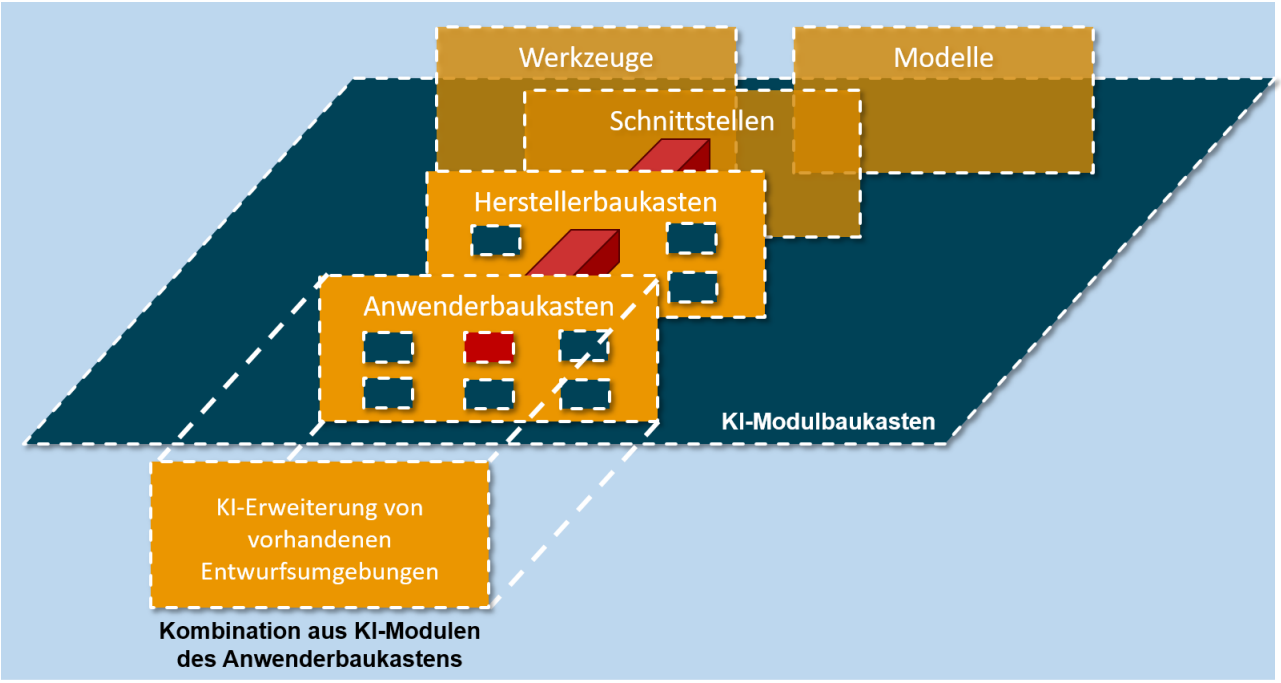

Abbildung 2: Prinzipieller Aufbau eines KI-Modulbaukasten

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 vernachlässig werden.

Weiterhin muss beachtet werden, dass für den Entwurf elektronischer Systeme neben den spezifizierten Haupteigenschaften auch die sogenannten Nebeneigenschaften (Abbildung 3) 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.

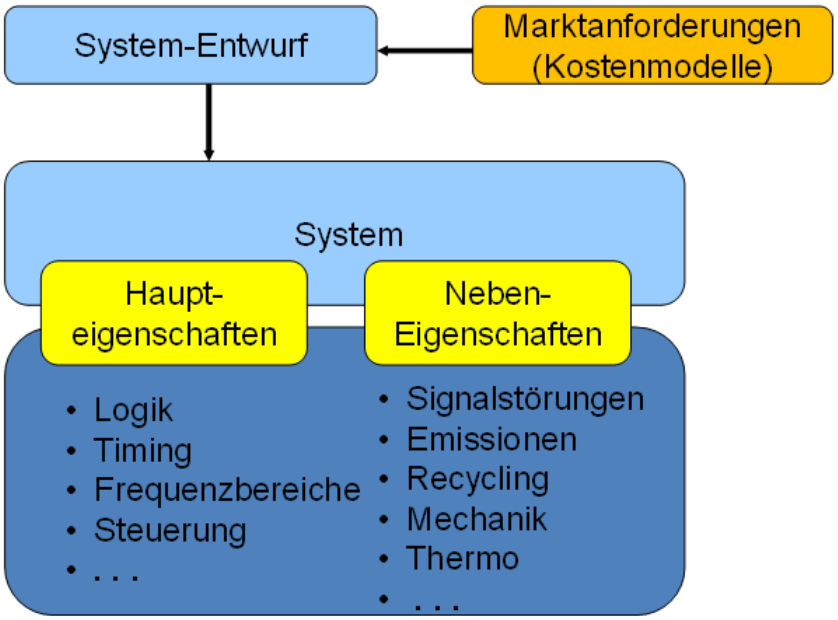

Abbildung 3: Gliederung eines mikroelektronischen Systems in Haupt- und Nebeneigenschaften

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 System-ebene 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.

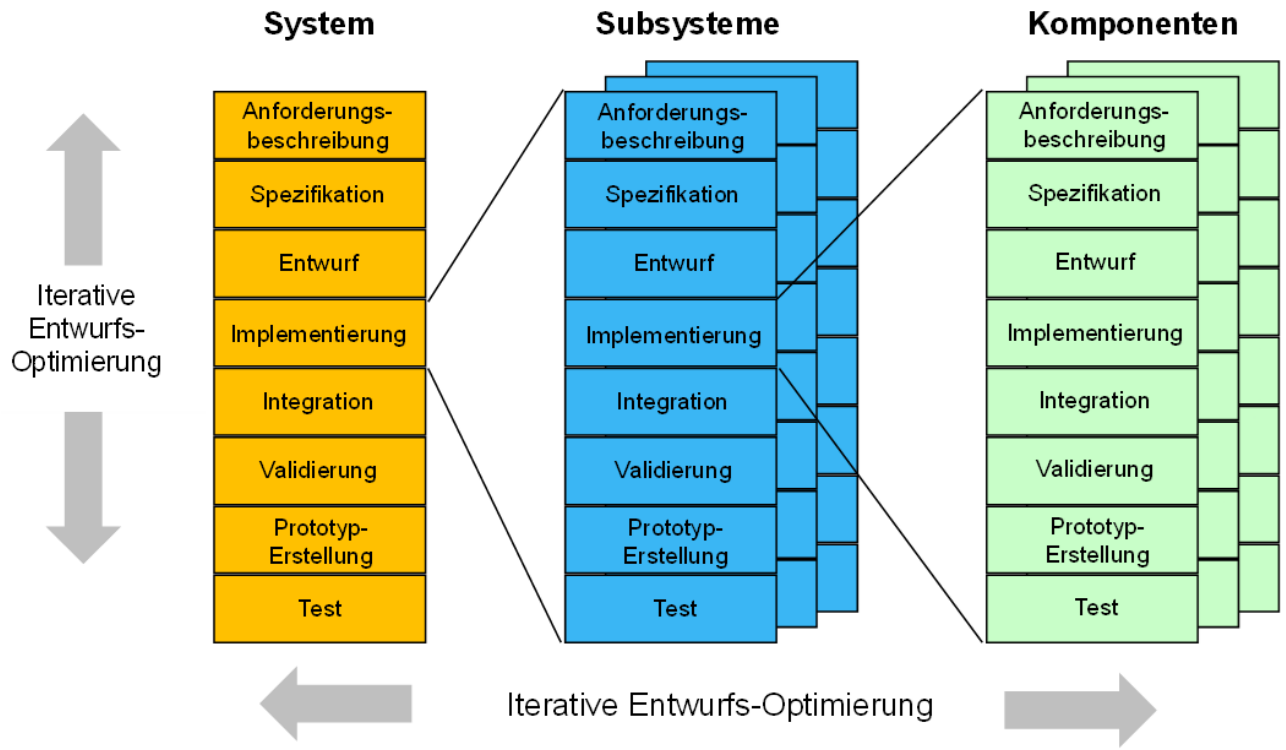

Abbildung 4: Verallgemeinerter Entwurfsprozess als Grundlage für die Analyse des Einsatzes von KI-Modulen im industriellen Umfeld

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).

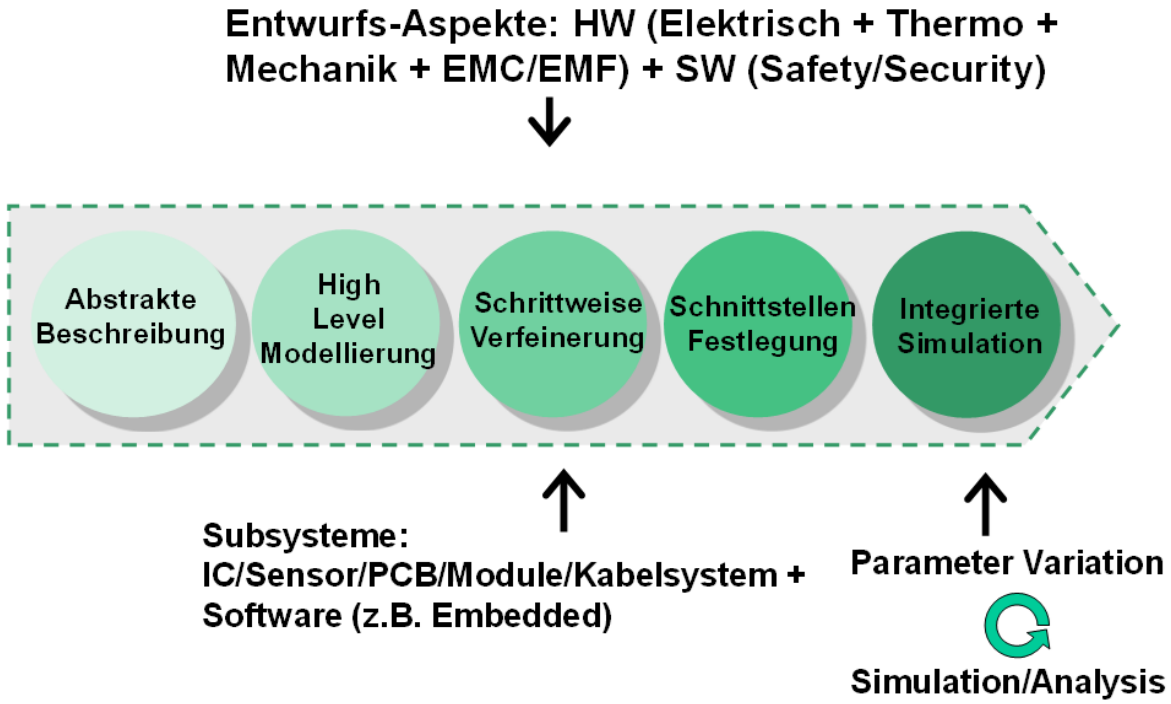

Abbildung 5: Entwurfsaspekte und -schritte auf HW- und SW-Ebene

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 |*RequirmentAnalyse*| 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-Demodulation) erlaubt eine systematische Analyse der Auswirkungen einzelner Störeffekte im Gesamtsystem (Ab- bzw. Zuschalten von Störeffekten ó abhängig von der Granularität der Modell-Hierarchie).

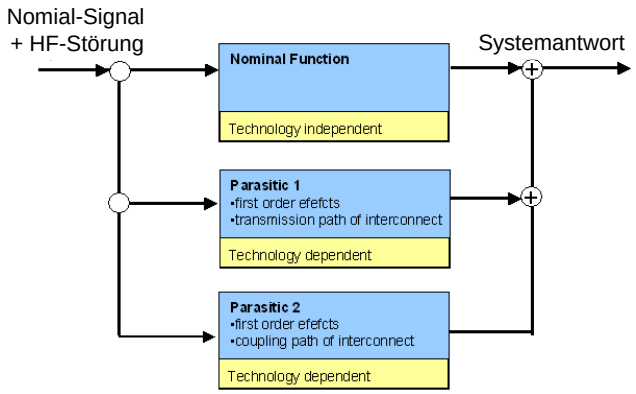

Abbildung 6: Ansatz zur Einführung von Modellhierarchien für eine Fehleranalyse durch Simulation

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).

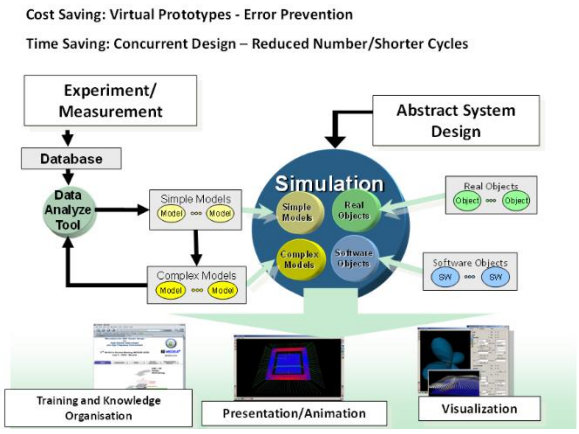

Abbildung 7: Virtuelle Entwicklung: Einsatz von Simulationsverfahren und –prinzipien

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 durchzuführte 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.

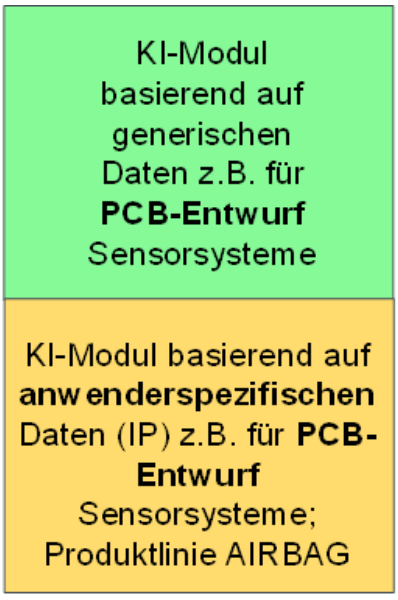

Abbildung 8: progressivKI-Ansatz zur Sicherstellung eines umfassenden IP-Schutz und Herstellung der Interoperabilität (Beipiel Anwenderebene #2 PCB-Entwurf)

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-Interaktions-modelle; 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.	❑ Anwendungsebene #1: PCB-Entwurf; siehe Abbildung 11 + Abbildung 12. ❑ Anwendungsebene #2: IC-Entwurf/Sensorik; siehe Abbildung 15. ❑ 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 waren[2].*

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. Erstmalig 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 Netzte 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 Rechenleitung 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 weitegehen 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 neuste 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 wird 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 weder, 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 Miloševic [Miloševic] 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) [Kavasidis], [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 Schlüsselelemente 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 Ressource Description Framework [RDF] ein Format für Graph-basierte Wissensmodelle standardisiert hat. Darauf bauen zahlreiche weitere Wissensrepräsentationsformte 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 Parameteraustausch 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.

Maschinenlernen 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, dass 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-Einsatzbereich (z.B. Bilderkennung) dezidiert zu unterstützen. Im Bereich KI-Technologien beschäftigen sich führende EDA-Unternehmen wie Cadence [KIcdn], Mentor [KIment] oder Synopsis [KIsyn] 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 Implementationen 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

03-IFAG

Unternehmensvorstellung

Infineon Technologies AG ist ein weltweit führender Anbieter von Halbleitern mit einem Umsatz von ca. 8 Mrd. EUR im Geschäftsjahr 2019. Mit weltweit 41.400 Mitarbeitern (Stand 30. September 2019) entwickelt, fertigt und vertreibt Infineon eine Vielzahl an Halbleiter und Systemlösungen. Diese verbinden die reale und die digitale Welt und ermöglichen intelligente Mobilität, effizientes Energiemanagement und sichere Erfassung und Übertragung von Daten. Das Produktangebot reicht von Standardkomponenten über kundenspezifische Lösungen für Bauteile und Systeme bis hin zu speziellen Komponenten für digitale, analoge sowie Mixed-Signal-Anwendungen. Der größte Bereich von Infineon, die Automotive Division (ATV), gestaltet die

Zukunft der Mobilität mit hochentwickelten Mikroelektronik-Lösungen, die saubere, sichere und smarte Autos ermöglichen. Sie unterstützt die zunehmende Elektrifizierung von bislang hydraulischen und elektromechanischen Systemen und entwickelt ständig innovative Konzepte in den Bereichen Fahrsicherheit, Komfort und Lichttechnik. Darüber hinaus unterstützen die ATV-Produkte und -Lösungen den Übergang zu Hybrid- und reinen Elektrofahrzeugen sowie zu einer stärkeren Automatisierung. Mit mehr als 40 Jahren Erfahrung bei Automotive-Halbleitern ist ATV weltweit führend in ihrem Bereich. Darüber hinaus ist das Unternehmen bei den Radarsensor-Chips für Fahrerassistenzsysteme die Nummer 1 und unterstützt auch diese Anwendung mit ihren hochskalierbaren AURIX™-Mikrocontrollern. Der Erfolg der Division basiert auf umfangreichen Systemkenntnissen kombiniert mit Leidenschaft für Innovation und Qualität.

Projektbezogene Kompetenzen und Schwerpunkte

Ein wesentlicher Faktor bei der Entwicklung erfolgreicher Produkte ist die Entwurfsumgebung von Infineon, die auf kommerziellen Werkzeugen aufbaut und die von Infineon Experten durch intern entwickelte Lösungen vervollständigt und für die eigenen Anforderungen optimiert wird. Bei Infineon arbeiten exzellente Experten mit Knowhow in den Bereichen Entwurfsprozesse, -methoden und –tools, die durch eine leistungsfähige IT unterstützt werden. In progressivKI wird Infineon auf der Ebene des IC-Entwurfs arbeiten und dabei insbesondere die Aspekte der systematischen Erfassung von Entwurfsdaten, der Klassifizierung von KI-Methoden und der Entwurfsmethodik unter Nutzung von KI erforschen. Die Ergebnisse sollen an einem Beispiel aus dem Bereich Sensorik demonstriert werden. Infineon verfügt über große Erfahrung in nationalen und europäischen Förderprojekten, die für EDA (Electronic Design and Automation) relevant sind.

Relevante Vorgängerprojekte

Mit Blick auf progressivKI können folgende Projekte genannt werden:

GENIAL!, „Gemeinsame ElektroNik Roadmap für Innovationen der AutomobiLen Wertschöpfungskette!“, BMBF, 1.10.2018 – 30.9.2023: Es werden Methoden und Werkzeuge erforscht und implementiert, mit denen auch langfristigere und deshalb unsicherere Anforderungen präziser in der Wertschöpfungskette berücksichtigt werden und bei der Konzeption und den ersten Designarbeiten für neue IC-Komponenten und deren späterer Einsatz in der Endanwendung simuliert und so wechselseitige Abhängigkeiten von IC-Komponente und Endprodukt in optimaler Weise berücksichtigt werden können.

Scale4Edge, „Entwicklungsplattform und Ökosystem für skalierbare Spezialprozessoren im Edge Computing“, BMBF, 1.5.2020 – 30.4.2023: IFAG erforscht basierend auf seiner In-House Generatorinfrastruktur Metagen Integrationslösungen für energieeffiziente sowie fein granular konfigurierbare sichere RISC-V-Subsysteme mit KI-Unterstützung und validiert Methoden und Tools des mit den Projektpartnern erforschten Ökosystems.

SAFE4I, „Sicherer, automatischer Software-Entwurf für Industrieanlagen“, BMBF, 1.10.2017 – 30.9.2021, IFAG erforscht einen semi-automatischen, modellbasierten Entwurfsprozess für die Entwicklung betriebssicherer Software von Industrie 4.0 Anwendungen“.

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 (BMWi - 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.

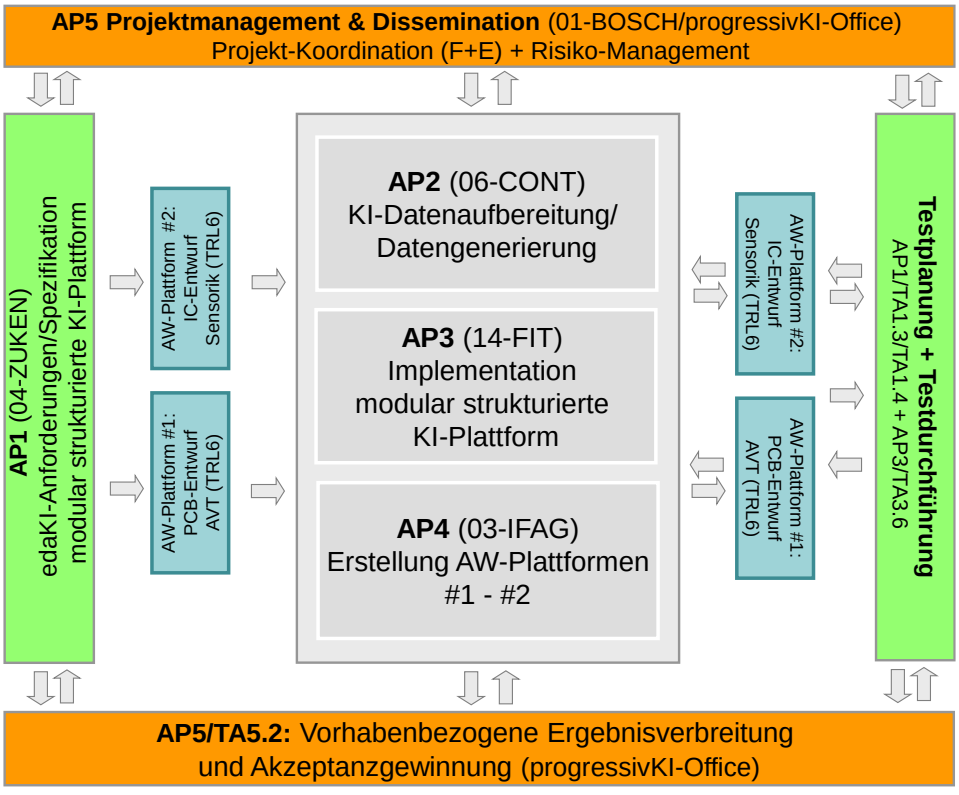

Abbildung 9: Abhängigkeiten und Interaktion der progressivKI-Arbeitspakete

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 #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 1.1.3: Anforderungsanalyse zur systematischen Erfassung von Entwicklungsdaten aus Entwurfsprozessen (03-IFAG)

Ziele

Das Trainieren von KI-Werkzeugen für den Entwurfsprozess erfordert eine balancierte Datenerfassung aus der Entwicklung. In einem ersten Schritt sollten die Anforderungen and die Datenerfassung definiert werden. Auf Basis der Anforderungsanalyse sollte die Architektur zur Erfassung der notwendigen Daten definiert werden.

Problemstellung

Insbesondere sollte im Projekt darauf geachtet werden, dass nicht nur die Endergebnisse von Entwicklungsschritten erfasst werden, sondern auch die Experimente die zwischenzeitlich gemacht wurden. Hierdurch wurde vermieden, dass trainierte KI-Algorithmen einseitig beeinflusst werden.

Lösungsweg und Ergebnisse

Infineon beschäftigte sich zunächst mit den Anforderungen an eine balancierte Datenerfassung. Die größten Herausforderungen, die durch die Architektur gelöst werden mussten, sind im Folgenden kurz dargestellt:

- Notwendigkeit einer übergreifenden Produktdaten-Struktur, um den Kontext der Entwicklungsdaten zu sichern:
  - Die Zuarbeiten zu einem Produkt erfolgen in der Regel aus unterschiedlichen unabhängig voneinander erzeugten Projektsetups. Um die Zugehörigkeit der entstehenden Daten zu einem definierten Produkt ableiten zu können, war es notwendig einen klar zuordenbaren Identifizierer zu definieren.
  - Unterschiedliche Projektsetups bedienen unterschiedliche Domänen und Bestandteile des Produkts, daher musste die Produktdaten-Struktur eine entsprechende maschinen-verarbeitbare Segmentierung aufweisen.
- Die Datensammlung darf den betrieblichen Entwicklungsablauf nicht stören:
  - Eine aktive durch den Nutzer angestoßene Sammlung der Daten wird in der Realität kaum Anwendung finden, da der Nutzer so häufig in seinem Entwicklungsfluss gestört werden würde, und damit selten das Erfassen anstoßen würde. Dies würde wiederum zu einem Ungleichgewicht in den erfassten Daten führen.
  - In wichtigen Teilbereichen sind die zu erfassenden Daten teilweise sehr groß oder müssen vor der Erfassung prozessiert werden, um die relevanten Metriken extrahieren zu können. Ein automatisierter Erfassungsprozess muss daher vermeiden, die Arbeit des Nutzers durch intensive Rechen und Datentransferprozesse zu verlangsamen.

- Für eine erfolgreiche Verwertung jeglicher Datenerfassung aus der Entwicklung war auch ein entsprechender Prozessvorschlag zu erarbeiten, der die Erfassung regelt:
    - Der Prozess darf weder zu strikt noch zu offen sein. Zu starke Strenge würde zu geringer Akzeptanz bzw. einer schlechten Umsetzbarkeit führen. Zu viele Freiheiten würden zu einer inkonsistenten Datenflut führen, die ihre Aussagefähigkeit verliert.
    - Ein Prozess muss auch die Wahrung regulatorischer Vorgaben sichern, wie z.B. Vertraulichkeiten, Export Kontrolle sowie die Privatsphäre.

Im weiteren Verlauf wurde eine initiale Gesamtarchitektur entworfen, die dann mit dem Fokus auf die Skalierbarkeit der Datenerfassung weiterentwickelt wurde.

- Übergreifende Produktdaten-Struktur:
    - Entwicklungsprojekte durchlaufen unterschiedliche Versionierungssysteme, welche in der Regel durch die jeweilige Entwicklungsdomäne bestimmt wird. Bei der Erfassung von Entwicklungsdaten ist daher auch die eindeutige Version der Quelldateien zu erfassen, auf Basis derer die Daten erhoben werden. Da die Erhebung in der Regel inhärent parallel abläuft, können so Konflikte vermieden werden.
    - Da es nicht möglich ist alle Datenarten, die zu erfassen sind, a priori festzulegen, muss die Produktdaten-Struktur zudem auch schnell erweiterbar sein und dabei bereits vorher erfasste Daten nach wie vor weiterführen.
- Datensammlung:
    - Bei einer Skalierung über mehrere Projekt-setups und Entwickler eines Produktes hinweg, wird eine automatisierte Erfassung der Daten zu einem hohen Datenaufkommen führen. Für eine Auswertung dieser Daten ist es unabdingbar auch einen Reifheitsgrad dieser Daten einzuführen, der beispielsweise anfängliche Experimente der Entwickler von Daten aus Regressionen unterscheidet.
    - Wenn KI-Lösungen auf Daten trainiert werden, die mit Hilfe der Datenkollektorschnittstellen erfasst werden, müssen diese Schnittstellen wiederverwendbar entwickelt werden, so dass die KI-Lösungen diese auch im Betrieb (z.B. Inferenz) nutzen können.
- Datenerfassung:
    - Der Prozess muss mehrere Rollen definieren, die die Verantwortlichkeiten zwischen Festlegung der zu erfassenden Daten, Datenerzeugung, Pflege der Dateninfrastruktur, Auswertung der Daten festlegen.
    - Ein Datenkatalog soll die Art der erfassten Daten dokumentieren, doppelte Erfassungen vermeiden und die Navigation für den Zugriff auf die Daten regeln.
    - Die erfassten Daten müssen den gleichen Zugriffsrechten unterliegen, die bei deren Erzeugung gelten, damit unerlaubter Zugriff vermieden werden kann.

Im Projektverlauf wurde die Skalierbarkeit um folgende Kategorien ergänzt:

- Skalierbarkeit in Richtung der Abarbeitung automatisierter Datenprozessierketten
  Vielmals können gesammelte Daten nicht direkt für analytische Zwecke genutzt werden und müssen Präprozessierschritte durchlaufen. Da Daten kontinuierlich entstehen ist daher auch die Möglichkeit automatisierte Prozessierschritte definieren zu können für einen skalierbaren Ablauf wichtig

- Skalierbarkeit in Richtung paralleler Datenverarbeitung
  Da gesammelte Daten aus unterschiedlichen Quellen entstehen und somit auch inhärent parallel entstehen, ist es wichtig das Auffangen und Prozessieren dieser Daten zu paralellisieren. Eine sequenzielle Abarbeitung würden sonst zu einer Flaschenhalsbildung führen.
- Skalierbarkeit in Richtung Vernetzung des Datensystems mit Analysesystemen
  Neben der inhaltlichen Struktur der Datensammel- und Zugriffsschnittstellen, ist es auch notwendig diese Schnittstellen, netzwerkfähig zu erstellen, um eine Modularisierbarkeit und Integrierbarkeit mit unterschiedlichen Systemen, wie zum Beispiel einer KI-Entwicklungsumgebung, zu ermöglichen.

Zusammen mit den Arbeiten aus den Beiträgen 2.1.3 und 2.2.3 wird dies in einen Unternehmenskontext gestellt.

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 1.2.3: Klassifikation von KI-Anwendungen im EDA-Bereich (03-IFAG)

Ziele

Im Projekt sollten KI-Anwendungen kategorisiert werden, um gemeinsame Validierungsanforderungen zu definieren. Auf Basis dieser Klassifikation sollte ein Leitfaden entwickelt werden, der Maßnahmen definiert, um die Qualität von KI-Anwendungen im EDA-Bereich abzusichern und sicherstellen, dass KI-Anwendungen im EDA-Bereich zuverlässig und effektiv eingesetzt werden können.

Problemstellung

KI-Anwendungen im EDA-Bereich können sehr vielseitig sein. Ausserdem bestehen wegen der probabilistischen Eigenschaften von KI besondere Anforderungen für die Validierung von KI-Algorithmen

Lösungsweg und Ergebnisse

Zunächst wurde mit der Erhebung von internen KI-Lösungsvorhaben im EDA-Bereich, sowie einer Stand-der-Technik Analyse begonnen um eine Kategorisierung der unterschiedlichen Lösungen

bezüglich Gemeinsamkeiten ihrer Wirkweisen auf den Entwicklungsprozess zu definieren. Für diese Erhebung wurde ein UseCase Definitionstemplate erstellt, welche neben Geschäftswert abfragenden Elementen auch Fragen zur Wirkweise und zur Abschätzung des Einflusses im Fehlerfall enthält. Im Groben lassen sich KI-Lösungen im EDA-Bereich in folgende Kategorien unterteilen:

- Zyklenreduzierer: Diese Kategorie umfasst KI-Lösungen, die das iterative Durchlaufen mehrerer Entwicklungsschritte mit EDA-Werkzeugen reduzieren in dem zu Beginn der Kette Vorhersagen zum wahrscheinlichen Ausgang getroffen werden können. Aufgrund dieser Vorhersagen können Anwender entscheiden, wann sie tatsächlich die Entwicklungskette anstoßen.
- Laufzeitoptimierer: Diese Kategorie umfasst KI-Lösungen, die durch Steuerung von Toolparametern in Summe die Laufzeiten eines Entwicklungsschrittes verkürzen.
- Assistenzgeber: Diese Kategorie umfasst KI-Lösungen, welche abzielen, manuelle durch den Menschen gemachte Schritte zu beschleunigen, indem sie auf Basis vorheriger Entwürfe oder Arbeiten anderer Ingenieure im gleichen Schritt, Vorschläge erzeugen oder auf Anomalien hinweisen. Diese Vorschläge/Hinweise müssen dann lediglich durch den Ingenieur geprüft werden.
- Entwurfsoptimierer: Diese Art von KI-Lösungen greift tatsächlich in den Entwurf selbst ein und erzeugt optimierte Entwurfsvorschläge.
- Abstrahierer: Diese Art von KI-Lösungen umfasst Ansätze, welche durch das Erlernen eines detaillierten Entwurfsbausteins ein schneller zu simulierendes Ersatzmodell erzeugen, um beispielsweise mehr Simulationen zu ermöglichen, um einen Entwicklungsschritt qualitativ zu verbessern.
- Entwurfsgenerierer: Dabei werden auch generative AI-Verfahren beleuchtet. Im Allgemeinen kann man Text/Sprache verarbeitende Technologien wie Large Language Models als Assistenzgeber betrachten, bspw. im Einsatz als Suchmachine zur Auffindung von Spezifikationsdaten. Durch die Fähigkeit dieser Technologien längere Textabschnitte zu generieren, ist allerdings denkbar, dass diese Technologien auch nutzbar sind für die Erstellung von Chip-Entwürfen auf Basis weniger, manueller Eingaben. Beispielsweise, für die Generierung eines digitalen Schaltungsblocks auf Basis von wenigen Eingangsparametern. Bei Lösungen in dieser Richtung wird also der Entwurf zumindest teilweise durch die Maschine automatisiert. In diesem Fall muss aus Qualitätssicherungsgründen sichergestellt werden, dass automatisch entworfene Blöcke technisch unabhängig von dieser Automatisierung verifiziert werden, um das Vier-Augen Prinzip zu wahren. Aus diesem Grund wurde der Entwurfsgenerierer als eigene Klassifikation aufgeführt.

Folgende Tabelle listet die Klassifikationstypen mit einem typischen Beispielanwendungen auf.

Klassifikation	Beispielanwendung
Zyklenreduzierer	KI-Prädiktion von Layoutanalysen
Laufzeitoptimierer	KI-Optimierte CAD-Werkzeugeinstellungen
Assistenzgeber	KI-Energiezonengruppierung von Transistoren
Entwurfsoptimierer	KI-Floorplanoptimierung
Abstrahierer	KI-Ersatzmodelle für Spice Schaltungen

Entwurfsgenerierer	Generierung von Chipkomponenten sowie Verifikationskomponenten durch generative KI-Verfahren.

Tabelle 3 - Klassifikation und typ. Beispielanwendungen

Danach wurden Maßnahmen und Risikobewertungen definiert, welche bei der Qualitätssicherung von Lösungen je Klassifikation berücksichtigt werden müssen. Die Risikoeinschätzung ist mit Hinblick auf die Gefahr einer fehlenden Akzeptanz aufgrund von Qualitätsproblemen zu sehen. Folgende Tabelle fasst die Maßnahmen und Risiken zusammen.

Klassifikation	Risikobewertung	Maßnahmen
Zyklenreduzierer	Hoch	Vertrauen in Vorhersagen erfordern Nachvollziehbarkeit der Ergebnisse ==> Einsicht von mehreren Domänenexperten in die Validierungsergebnisse Chiptechnologie-Abhängigkeit muss geprüft werden Überwachung der statistischen Eigenschaften der Eingaben während der Inferenzphase; Eine Verschiebung führt zur Verschlechterung der Prädiktionsergebnisse.
Laufzeitoptimierer	Gering	Erneutes Trainieren der KI-Lösungen bei Änderungen von Werkzeugversionen, deren Laufzeit optimiert werden muss Manuelle Bewertung der Optimierungsergebnisse durch den Nutzer
Assistenzgeber	Mittel	Periodisches Training der KI-Lösungen auf Basis von Feedback der Nutzer Nutzer muss in Kontrolle bleiben, kann Ergebnisse verändern
Entwurfsoptimierer	Hoch	Periodischer Vergleich gegenüber klassischen Optimierungsverfahren Ergebnisse müssen sinnvoll und nachvollziehbar sein Ergebnisse müssen durch Nutzer bewertet werden
Abstrahierer	Hoch	Einsatz nicht als Teil eines zu verifizierenden Objekts Erstellte abstrahierte Modelle müssen gegen die Originale getestet werden.
Entwurfsgenerierer	Mittel	Verifikation muss unabhängig von der Entwurfs-generierenden KI gestaltet werden

Tabelle 4 - Maßnahmen und Risiken

Danach wurden die Risikomanagement-Maßnahmen für die unterschiedlichen Klassifikationen verfeinert und in einen Qualitätsleitfaden überführt. Insbesondere lag der Fokus auf generativen KI-Lösungen, welche in die Klassifikation der Assistenzgeber einordnen lassen. In dieser Klasse bewegen sich Lösungen im Bereich von intelligenten Ratgebern zur Benutzung interner Automatisierungen oder zum Umgang und Programmierung von Bausteinen. Zumeist handelt es

sich um eine Art dedizierten Chatbot, welcher das firmeninterne Wissen effektiv den Entwicklungsingenieuren zugänglich macht.

In diesem Rahmen wurde identifiziert, dass beim Einsatz sichergestellt werden muss, dass die Informationen im Chatbotsystem ihre Vertraulichkeitseinschätzung bewahren müssen, sowie auch die an das System erfolgenden Anfragen. Des Weiteren ist für die Umsetzung einer derartigen Lösung wichtig ein Qualitätsmaß bzw. eine Qualitätsbeschreibung vorab zu definieren, was die Güte der Antworten eines solchen Systems umschreibt. Dies bedeutet zum Beispiel für ein Assistenzsystem zum Umgang mit internen Entwurfsautomatisierungsumgebungen, zu definieren, ob es ausreichend ist, dass das System Antworten mit Verweisen auf Dokumentationen im Intranet generiert – also ähnlich wie das Prinzip „Suchmaschine“— oder ob das System in der Lage sein muss, die Anfrage mit einer konkreten Lösung zu beantworten. Die Klärung dieser Fragen sind entscheidend, bei der Auswahl der zu verwendenden Technologien, aber auch bei der Einschätzung des notwendigen Aufwands ein solches System zu entwickeln, bzw. dessen Erfolgsaussichten einschätzen zu können sowohl für Entwicklung als auch für die Akzeptanz.

Die erarbeiteten Klassifikationen werden im Verwertungszeitraum in die Infineon Entwicklungsprozess-schritte eingearbeitet. Anhand dieser Klassifikationen werden zukünftige KI Anwendungsprojekte mit Hinblick auf ihre technischen Risiken überprüft werden.

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 Rechtemanagement 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 Probleminstanz 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 Anwendungsebene #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.

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 2.1.3: Konzept zur Umsetzung einer modularen Schnittstelle zur Erfassung von Design-Prozessdaten #2 IC/Sensor (03-IFAG)

Ziele

Der Teilbeitrag verfolgte folgende Ziele:

- Entwicklung eines einheitlichen Konzepts für die Definition und Steuerung von Datenkollektoren für den Chip-Entwurfsprozess
- Entwicklung eines Konzepts zur Strukturierung und Standardisierung von Daten für den Chip-Entwurf
- Entwicklung eines Konzepts zur systematisierten Zugriffssteuerung auf die erfassten Daten des Entwurfs für effizientes KI-Training

Problemstellung

Dabei sollten folgende Problemstellungen adressiert werden:

- Verbesserung der Effizienz und Konsistenz der Datenkollektion und -strukturierung im Chip-Entwurfsprozess durch die Einführung eines einheitlichen Konzepts
- Erhöhung der Vergleichbarkeit und Standardisierung von Daten für den Chip-Entwurf durch die Entwicklung eines geeigneten Konzepts
- Optimierung des Zugriffs auf die erfassten Daten des Entwurfs für ein effizientes KI-Training durch die Einführung einer systematisierten Zugriffssteuerung

Lösungsweg und Ergebnisse

Infineon entwickelte ein Konzept für eine modular erweiterbare Datenerfassungsschnittstelle. Ein Datenverwaltungsmodell wurde konzipiert, das auf dem JSON-Format basiert. Das Schema definiert die Attribute innerhalb eines Datenpunkts und ermöglicht die automatisierte Erzeugung von Schreib- und Leseverfahren. Danach wurde das Konzept zur Steuerung großer Datenmengen weiterentwickelt. JSON-Dateien werden im Parquet-Spaltenspeicher-Dateiformat abgelegt, um den Speicherbedarf zu minimieren. Ein Katalogisierungsblock verwaltet die Transaktionen zur Speicherung von Daten.

Fortgeführt wurden die Entwicklungsarbeiten mit der Konzipierung des Zugriffs auf die Daten. Ein Kommandozeilen-gestützter Zugriff (CLI) wurde entwickelt, der alle verfügbaren Daten auf Basis des Produktidentifikators laden und eine Suchfunktion anbieten kann.

Nachfolgend wurde das bestehende Konzept erweitert, um die Skalierbarkeit in Richtung automatisierter Datenprozessierketten, paralleler Datenverarbeitung und Vernetzung des

Datensystems mit Analysesystemen zu ermöglichen. Eine Ebene für die Datenprozessierung und -Aufbereitung wurde definiert, um die Anforderungen zu erfüllen.

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 #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
- Kombinierter 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 2.2.3: Erweiterung der modularen Schnittstelle zur Erfassung von Design-Prozessdaten (03-IFAG)

Ziele

Ziel war die Erweiterbarkeit der Datenkollektions-Schnittstelle sicherzustellen.

Problemstellung

Die Problemstellung besteht darin, dass die Datenkollektions-Schnittstelle erweiterbar sein muss, ohne dass bereits erfasste Daten verloren gehen. Dazu muss eine Versionierung des Datenmodells und der darauf aufbauenden Schnittstellen eingeführt werden. Dies soll sicherstellen, dass Datenpunkte mit unterschiedlichen Schemaversionen gesammelt werden können, ohne dass alle Datenpunkte auf die neueste Version aktualisiert werden müssen. Stattdessen soll eine kompatible Version der Zugriffsschnittstelle für jede Schemaänderung bereitgestellt werden, um die Datenpunkte auszuwerten.

Lösungsweg und Ergebnisse

Für die Erweiterbarkeit der Datenkollektions-Schnittstelle muss sichergestellt werden, dass Erweiterungen bereits erfasste Daten nicht verwerfen. Hierfür muss eine Versionierung des zugrunde liegenden Datenmodells eingeführt werden, sowie der darauf aufbauenden Schnittstellen. In untenstehender Abbildung ist die Architektur der Verwaltung unterschiedlicher Schema- bzw Datenmodellversionen skizziert. Wenn ein Datenpunkt über die Datenkollektoren angelegt wird, wird gemäß dem Schema auch die aktuell geltende Schemaversion gespeichert. Somit ist davon auszugehen, dass über längere Zeiten, Datenpunkte gesammelt werden, welche sich in ihrer Schemaversion unterscheiden. Da die Menge an Datenpunkten stetig wächst ist es keine Alternative, alle bereits existierenden Datenpunkte immer auf die neueste Version des Schemas zu aktualisieren. In dem Fall würden die Prozessierzeiten ebenfalls stetig wachsen, so dass das System nicht mehr handhabbar werden würde. Aus diesem Grund sieht die gewählte Architektur vor, dass es zu jeder Schemaänderung auch eine entsprechende kompatible Version der Zugriffsschnittstelle (API) geben muss. Somit ist es möglich das bei jedem Zugriff auf einen Datenpunkt automatisch ermittelt werden kann, welche API zu nutzen ist, um diese Informationen auszuwerten.

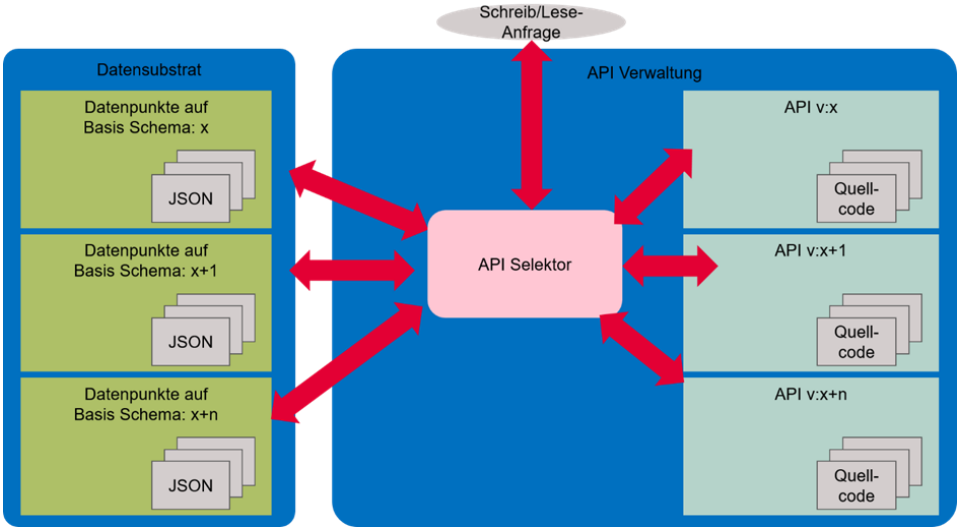

Abbildung 10: Konzept zur Datenmodellversionierung und der Verwaltung von Schnittstellen

Mit der Umsetzung des Prototyps aus in Teilbeitrag 4.2.3, hat sich die gewählte Architektur mit Hinblick auf ihre Erweiterbarkeit als funktionsfähig erwiesen, bereits in der Domäne des „Physical Design“.

Das verwendete Datenmodell-Schema entspricht – im Rahmen des Prototyps -- aktuell der Version 200. Dies geschah in Folge von iterativen Erweiterungen und dem damit einhergehenden Anreichern der Datenpunkte um weitere „nützliche“ Informationen.

In Summe konnten im Rahmen eines Probebetriebs circa 4 Terrabyte an Rohdaten erhoben werden, welche über das Schema und der dazugehörigen API verwaltet werden können.

Das Einfügen weiterer Domänen des IC-Entwurfsprozess erfordert lediglich neben der Entwicklung der domänenspezifischen Extraktoren, das weitere Hinzufügen von Attributen in das Datenmodell und das Erstellen einer erweiterten Version der Zugriffsschnittstelle.

Auf eine Erweiterung der Datenerfassung um eine weitere Domäne des Chipentwurfs, wie ursprünglich in diesem Projekt geplant, wurde verzichtet, da sie mit Hinblick auf die Projektziele keine neuen technologischen Erkenntnisse mit sich bringen würde. Daher wurde die weitere Vertiefung der Prototyp-Entwicklung vorgezogen, um den Skalierungsanforderungen gerecht zu werden, welche sich im Laufe des Projekts schärfer darstellten als ursprünglich angenommen.

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 #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 #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 Rechennetzen;
- 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 Platt-formen 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 Rechennetzen.
- 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 3.1: Framework KI-Module für AW-Ebenen #2 + Optimierung KI-Module

In dieser Teilaufgabe sollten KI-gestützte Entwurfsmethoden unter Berücksichtigung der Ergebnisse aus AP 1 und 2 für die AW #2 erstellt werden. Die entwickelten KI-gestützte Entwurfsmethoden müssen den Qualitätsmerkmalen für den Werkzeugeinsatz im EDA-Bereich entsprechen. Dazu müssen die Aufbereitung und Initialisierung der KI-Module auf der Grundlage gängiger KI-Frameworks sowie die Installation auf geeigneten Rechnernetzen erfolgen.

Es musste sichergestellt werden, dass durch das Training der betreffenden KI-Module anhand von aggregierten Wissensbassen nicht nur die gegenwärtigen Entwicklerfähigkeiten und die Eigenschaften der vorhandenen Werkzeug-Fähigkeiten im Entwurfsprozess abgebildet werden, sondern auch das Wissen aus vergangenen Entwürfen eingebunden, und dieses für zukünftige Anwendungen dauerhaft zur Verfügung steht.

Erst dann kann der angestrebte Paradigmenwechsel im Systementwurf eingeläutet werden und dem Begriff Variantenkonstruktion eine neue (KI-) Komponenten hinzugefügt werden.

Herkömmliche Entwurfsabläufe wurden bisher linear innerhalb enger Systemgrenzen optimiert. Es musste sichergestellt werden, dass durch den KI-Einsatz diese serielle Arbeitsweise überwunden werden kann. Damit musste dann eine vollständige Entwurfs-Aufgabenstellung holistisch von der Lastenhefterstellung bis zum Systemtest KI-gestützt abgebildet werden können.

Durch Anordnung domänen- und applikationsspezifischer Schnittstellenmodule um einen leistungsfähigen KI-Kern musste außerdem eine gute Portabilität und Übertragbarkeit der technischen Lösung auf andere Entwurfsprozesse inner- und außerhalb der Elektronik sichergestellt werden.

Das hier zu verfolgende Vorgehen zur Auswahl eines geeigneten Konzeptes für die Realisierung eines Frameworks für KI-Module und dessen Abbildung auf die Anwendungsebenen #2 (AP4) muss von allen Unternehmen, bei denen Entwurf elektronischer Systeme ein wichtiges Glied der Wertschöpfungskette ist, eingesetzt werden können.

Die Arbeiten zu dieser Teilaufgabe werden wie folgt zusammengefasst:

- Festlegung Framework KI-Module für Anwendungsebenen #2 + Optimierung KI-Module
- Aufbereitung und Initialisierung der KI-Module auf der Grundlage gängiger KI-Frameworks sowie Installation auf den nötigen Rechennetzen.
- Erstellung einer Entwurfsmethodik für PCB-/Kabelanschluss auf der Grundlage von Handbüchern und sonstiger Entwicklungsvorgaben (z.B. OEM-Input) unter Einbeziehung geeigneter KI-Frameworks (z.B. Keras)
- Vorbereitung der Integration von KI-Modulen in bestehende Entwicklungsprozesse
- Vorbereitung von KI-Modulen für die Detektion von Entwurfsdaten und -fehlern aus Schaltplänen, PCB-Layouts und Datenblättern
- Implementierung und Initialisierung einer geeigneten Modellarchitektur für die KI-basierte Erkennung und Extraktion von entwurfs-relevanten Informationen aus strukturell unterschiedlichen Datenblättern für elektronische Komponenten
- KI-bedingte Anpassung von Fertigungsprozessen
- Vorbereitung und Initialisierung von KI-Modulen für den Einsatz auf unterschiedlichen Rechnernetzen/-architekturen
- Realisierung der geplanten KI-Plattformen für AW #2 (Implementierung von KI-Modulen)

Teilbeitrag 3.1.3: Entwurfsmethodik für KI gestützte Lösungen im EDA-Bereich für den Chip-Entwurf (03-IFAG)

Ziele

In diesem Beitrag sollte eine Entwurfsmethodik unter Rücksichtnahme der Erkenntnisse der vorhergegangenen Arbeitspakete erstellt werden.

Problemstellung

Die Entwurfsmethodik soll den besonderen Qualitätsmerkmalen von Lösungen im EDA-Bereich nachkommen

Lösungsweg und Ergebnisse

Es wurden wesentliche Fortschritte bei der Standardisierung der Entwurfsmethodik für allgemeine KI-Lösungen im Bereich des Elektronik-Design-Automation (EDA) gemacht. Dabei wurden erste Ergebnisse aus verschiedenen Beiträgen sowie aus der Zusammenarbeit in den Projekt-UseCases integriert. Die Methodik zielte darauf ab, einen konsistenten und effizienten Ablauf zur Entwicklung von KI-Modellen zu schaffen .

Ein zentrales Element der Methodik war die Verfeinerung der Datenaufbereitungsphase, die in drei Hauptschritte unterteilt wurde:

- **Kuratierung:** Dieser Schritt umfasste die Auswahl der sinnvollen Daten aus den verfügbaren Datensätzen. Diese Phase ist entscheidend, um sicherzustellen, dass nur relevante und qualitativ hochwertige Daten für die weiteren Prozessschritte verwendet werden.
- **Labeling:** In diesem Schritt wurden die ausgewählten Daten maschinenlesbar gekennzeichnet, um ihre Interpretation zu erleichtern. Eine präzise Kennzeichnung der Daten ist unerlässlich für das Training von KI-Modellen.
- **Augmentierung:** Hierbei wurde die Datenmenge durch automatisierte, mathematisch getriebene Algorithmik vergrößert. Dieser Prozess hilft dabei, die Vielfalt und die Menge der Daten zu erhöhen, was zu robusteren und genaueren Modellen führen kann.

Weiterhin wurde auch die Überführung der entwickelten KI-Modelle in eingebettete Systeme in Betracht gezogen. Dies erfolgte jedoch nicht direkt im Rahmen der Beiträge von Infineon. Stattdessen lag der Fokus auf der Vorbereitung von Maßnahmen zum Monitoring der KI-Modelle im Betrieb. Das Ziel war es, statistische Verschiebungen in den Eingangsdaten zu erkennen, die ein erneutes Trainieren des Modells erforderlich machen könnten. Dieses Monitoring ist entscheidend, um die langfristige Leistungsfähigkeit und Genauigkeit der Modelle zu gewährleisten.

Gegen Ende der Projektlaufzeit wurde ein umfangreicher Qualitätsleitfaden erstellt und als "Best Practices" dokumentiert. Dieser Leitfaden stellt die Qualitätsschritte der Entwicklung klar dar und wurde im Rahmen eines Whitepapers (62) mit den Partnern im Use Case #4 veröffentlicht und abgeschlossen. Zusätzlich wurde eine technische Unterstützung zur Erhaltung der Qualität im Rahmen der prototypischen Umsetzung vorbereitet, und der Beitrag wurde damit abgeschlossen. Diese Maßnahmen tragen dazu bei, die Standards und die Konsistenz in der Entwicklung von KI-Lösungen sicherzustellen.

3.4 Arbeitspaket 4: Erstellung Teilplattformen (#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 #2 nachgewiesen werden.

Zunächst wurden - in enger Abhängigkeit von den Arbeiten und den Ergebnissen aus AP3 die Plattformausprägung #2 auf die jeweiligen Wertschöpfungsteilketten 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. Schaltungsentwurf für eine Anwendung MicroContoller/integrierter Sensor) evaluiert. Das daraus gewonnene Feedback wurde genutzt, um eine weitere Iteration der Plattformausprägungen #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 angeschlossenen 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 Plattformausprägungen #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 Plattformausprägungen für die Anwendungsbereiche #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
- Überprüfung, ob die erstellten KI-Module und deren Plattformausprägungen 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:

- Es wurde eine KI-Teilplattform (Technologiereifegrad TRL6) für die Anwendungsebene #2 entwickelt. Anwendungsbezogene Use Cases und Referenzsysteme im Hardwarebereich dienten 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 4.2: KI-Plattform Anwendungsebene #2 IC-Entwurf/Sensorik

Der Einsatz von Methoden der KI in Werkzeugen zur Beschleunigung des IC-Entwurfs in der Mikroelektronik und Sensortechnik (|First Time Right| und |Time2Market|) ist für die künftige Entwicklung von IC-Hardware von entscheidender Bedeutung für die Erhöhung der Wettbewerbsfähigkeit deutscher Unternehmen. Hier wird durch die hohe Komplexität des Entwurfs eine deutliche Wirkung des KI-Einsatzes im Hinblick auf funktionale Sicherheit für die nachfolgenden Entwicklungsaufgaben auf der Ebene des Systementwurfs erwartet.

Zukünftige Herausforderungen wie IoT und noch stärker die Elektrifizierung des Automobils führen zu einer erheblich höheren Heterogenität von IC. Diese müssen bereits heute eine Fülle von integrierten Funktionen abbilden, wie zum Beispiel Energiemanagement und lokale Vorverarbeitung von Sensordaten. Dazu kommt, dass diese auch in erheblichem Maße nicht

funktionalen Anforderungen genügen müssen, wie z.B. geringe Leistungsaufnahme gepaart mit hoher Reaktionsgeschwindigkeit.

Dies hat zur Folge, dass sehr ausgeprägtes Expertenwissen in Zukunft bei der IC-Entwicklung genutzt werden muss. Allerdings ist dieses Expertenwissen sehr schwer zu skalieren. Die immer kürzer werdenden Marktzyklen erschweren diese Skalierung zusätzlich.

Dem gegenüber steht allerdings, dass auch vieles an Erfahrung einzelner Experten nach wie vor auch nur in den Köpfen dieser Experten sitzt, und damit bei einer steigenden Nachfrage von heterogenen Produkten zum Flaschenhals werden kann. Vieles dieser Erfahrung muss zukünftig durch KI-Lösungen erfasst werden und leichter wiederverwendet werden, um die gesamte Teamerfahrung auf eine höhere Stufe zu bringen.

Allerdings fehlt es an einer systematischen Erfassung dieser Erfahrung. Beispielsweise werden in einer produktiven Entwicklung meist nur die erfolgreichen Entwurfsschritte versioniert – auch zur Wahrung von diversen Qualitätsnormen, wie den unterschiedlichen ISO-Standards. Allerdings werden Vorversuche und Experimente, die zu diesen Ergebnissen geführt haben, nicht erfasst und auch nicht umfangreich dokumentiert. Dieses Wissen könnte gesichert werden (erfassen/dokumentieren/archivieren/KI-gerecht aufbereiten), wenn eine systematische Erfassung von unterschiedlichen Objekten während der Entwicklung erfolgt. So ließe sich beispielsweise erkennen, mit welchen Werkzeugkonfigurationen früher Erfolge erzielt werden können, wenn man den gesamten Verlauf kennen würde.

Es war also notwendig, entlang des IC-Entwurfsprozesses Entwurfsobjekte (und deren Varianten) sowie Berichte zum Werkzeugeinsatz + Ergebnisse zu erfassen und daraus dann wertvolle Daten für einen KI-Einsatz zu generieren.

Teilbeitrag 4.2.3: Prototyp Implementierung der Erfassung von Entwurfsdaten + Verknüpfung mit KI-Entwicklungsumgebungen + Anwendungstests (TRL6) (03-IFAG)

Ziele

Die Ziele des Beitrags sind:

- Entwicklung eines Prototyps zur Spezifizierung und Erfassung von Entwicklungsschrittdaten, Entkoppelung von Datenkollektion und –speicherung
- Definition eines Datenmodells
- Untersuchung von Datenhaltungsverfahren
- Entwicklung einer Zugriffsschnittstelle für strukturierten Zugriff auf Entwicklungsdaten
- Demonstration der Nutzung der gesammelten Daten für KI-Algorithmen.

Problemstellung

Die Problemstellung besteht darin, dass Entwicklungsschritte in der Halbleitertechnologie viele Daten erzeugen, die effizient gespeichert und verwaltet werden müssen, um sie für KI-Algorithmen nutzbar zu machen. Die Herausforderung liegt in der Entkoppelung von Datenkollektion und -speicherung, der Definition eines geeigneten Datenmodells und der Entwicklung einer Zugriffsschnittstelle für strukturierten Zugriff auf die Daten.

Lösungsweg und Ergebnisse

Zunächst wurde der Projektweite UseCase #4 definiert, um die Wiederverwendbarkeit von vor-trainierten KI-Netzen für die IC-Entwicklung zu analysieren. Der Schwerpunkt lag auf dem effizienten Austausch von Netzen zwischen Partnern und der Analyse von Trainingsdaten-Eigenschaften auf die

skalierbare Anwendbarkeit von KI-Lösungen. Mit der Definition des UseCases sowie der Durchführung der Kooperation konnten die Anforderungen an Datenhaltung, Modellqualität, KI Entwicklungsmethodik umfänglich analysiert werden und innerhalb der einzelnen Beiträge von Infineon als Rahmen berücksichtigt werden.

Neben UseCase#4 lag der Schwerpunkt dieses Beitrags auf der Erstellung eines ersten Prototyps für eine skalierbare Kollektions- und Verwaltungsinfrastruktur für IC Entwicklungsdaten auf Basis der Konzepte aus Beitrag 2.1.3.

Der Prototyp für die Erfassung von Entwicklungsdaten konzentriert sich auf die physikalische Implementierung im Chip-Entwurfsprozess und soll später - nach Ende des Projektes - auf andere Domänen erweitert werden. Der Prototyp umfasst die Identifizierung wichtiger Datenarten, die Entwicklung von Extraktoren und die Speicherung von Daten im Parquet-Format.

Durch automatische Generierung von Testdaten und einen Probebetrieb, konnten der Speicherverlauf und das Versionierungskonzept des Datenmodells, sowie die automatisierte Kollektion der Daten untersucht und verbessert werden. Mit Hilfe des Prototyps konnten zudem Verbesserungsmöglichkeiten identifiziert und umgesetzt werden mit Hinblick auf die Gestaltung der Zugriffsschnittstellen für die gesammelten Daten. Mitunter konnten mehrminütige Zugriffszeiten auf wenige Sekunden reduziert werden um somit auch die Nützbarkeit bei stetig wachsendem Datenvolumen sichern zu können.

Zudem wurde erkannt, dass die kontinuierliche Datenerfassung oft Datenpunkte erzeugt, die keinen Informationsgewinn darstellen. Zum Beispiel, Datenpunkte, die durch einen irrtümlichen Start eines CAD-Werkzeugs entstehen. Daher muss der Prototyp um Schnittstellen und pipelining Strukturen ergänzt werden um eine automatisierte Kuratierung der Gesammelten Daten zu ermöglichen. Dies erforderte zudem, dass eine Netzwerk-fähige Schnittstelle entwickelt werden musste, um die Daten weiterverarbeiten zu können. Durch diese Schnittstelle können unterschiedliche Systeme entkoppelt werden. Die gewonnenen Erkenntnisse werden in Zukunft genutzt, um die Erweiterbarkeit des Datensystems zu verbessern.

Darüber hinaus wurden im Prototyp Prozessierketten umgesetzt, um die Belastbarkeit des Systems zu überprüfen. Das bereits entwickelte Datenmodell/Schema wurde erweitert, um die Erfassung von weiteren Datenarten aus dem Bereich der physikalischen Implementierung. Es wurden geometrische Design-Daten ergänzt, die einen zusätzlichen Informationslevel bieten, um beispielsweise die Genauigkeit von Bildverarbeitenden KI-Lösungen zu erhöhen. Des Weiteren wurden Datenkollektoren hinzugefügt, welche die Daten aus Werkzeugen wie Layoutgenerierung, Low-Power-Analyse und Codelintern extrahieren.

Prototypische Übersichtsdarstellungen wurden erstellt, um einen schnellen Überblick über die gesammelten Daten zu erhalten. Die Dashboards wurden zu einem Navigationsdashboard hochaggregiert, das sich automatisch an neue Chip-Varianten innerhalb einer Familie anpasst. Schließlich wurde die Systemperformanz der Dateninfrastruktur verbessert, wodurch die Latenz zwischen der Entstehung eines Datenpunktes und seiner Sichtbarkeit im System von einigen Stunden auf 30 Minuten reduziert werden konnte.

Die Analyse- und Darstellungsverfahren wurden erweitert, um die Navigierbarkeit und Aggregation von Daten zu verbessern. Detailansichten in den Dashboards bieten Einblicke in den aktuellen Datenstand und extrahierte Metriken. Geometrische Darstellungen des Chiplayouts können erstellt werden, um mögliche Probleme transparent zu machen.

Der entwickelte Prototyp wurde getestet, mit Hinblick auf alle vorgesehenen Verbindungsarten und Transaktionen, insbesondere die nahtlose Kommunikation zwischen Linux-Cluster-Umgebungen und Cloud-Umgebungen für die Datenprozessierung und -haltung.

In der Endphase des Projekts wurde zudem der Demonstrator für die Anwendungsebene IC gemeinsam mit den Partnern aus UC#4 erstellt. Ziel war es, die Modularität der Plattformkomponenten zu analysieren und sie miteinander in Betrieb zu nehmen. Hierbei konzentrierten sich die Aufgabenstellungen auf die Integration der Datenanalyse-Plattform SIMMR innerhalb der Infineon-Umgebung für die Bearbeitung von Trainingsdatensätzen. Es wurde auch überprüft, ob die erzeugten Sätze auf die KI-Service-Plattform der Partner HSHL/FIT geladen werden können und ein Training eines KI-Modells durchgeführt werden kann.

Die Ergebnisse wurden in einem white paper „Best Practices for MLOps in IC Design: A Case Study" https://www.researchgate.net/publication/386134735_Best_Practices_for_MLOps_in_IC_Design_A_Case_Study [71] veröffentlicht.

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. Infineon war Teil dieses Projektteams und übernahm die Führung des Workpackage 4 und des Use-Case #4.

3.5.1 Teilbeitrag 5.1.3 Leitung Teilvorhaben

3.5.1.1 Geplanter Partnerbeitrag

Aufbau der Strukturen für das Projektmanagement bei Infineon und im Projekt (Leitung WP4). Management der Aktivitäten bei Infineon und im Projekt (WP4; TA4.2; Deliverables; Berichte).

3.5.1.2 Ergebnisse

Die Projektstruktur und die Kommunikationsstruktur wurden für die Ausführung und das Monitoring aufgesetzt. Rollen wurden soweit dies noch notwendig war besetzt bzw. neu besetzt.

Frau Manuela Neyer hat die Rolle der WP4 Leitung und der Usecase #4 Leitung übernommen.

Die Leiter der Partner in WP4 traffen sich am Anfang 2-wöchentlich in sog. POT meetings, um die Strategie und die nächsten Schritte abzustimmen. Das erweiterte Team, inklusive von Studenten und weiteren Forschern bei Infineon treffen sich ebenfalls in 2-wöchentlichem Rythmus, um gemeinsam an den Themen zu arbeiten, dabei werden alle 6 Wochen Ergebnisse präsentiert.

Im Gesamtprojekttreffen in Hannover im Dezember 22 wurde eine Projektvision erstellt.

Später wurde die meetings etwas gestrafft weitergeführt. Das Team traf sich sich nun in 2-wöchentlichem Rythmus als erweitertes Team, inklusive der Leiter der partner, Studenten und weiteren Forschern, um gemeinsam an den Themen zu arbeiten, dabei werden die Ergebnisse in einer „DEMO" an eine erweiterte audience (projectoffice +PT) präsentiert.

Im Gesamtprojekttreffen in Karlsruhe im April 23 wurde der AP4 WS abgehalten. Die Ergebnisse wurden im Deliverable D5.2-Q09-10 festgehalten.

Im Gesamtprojekttreffen in Hamburg im August 23 wurde der UC4 Fortschritt und die nächsten Schritte festgelegt, innerhalb der Partner des UCs aligned and die Aufgaben verteilt. Ausserdem wurde eine „fish bowl“ Diskussion zu generative AI innerhalb des Gesamkonsortiums durchgeführt.

Die Ergebnisse wurden unter anderem im Deliverable D2.1-Q09-08 festgehalten.

Die weiteren 2-wöchentlichem Meetings wurden genutzt um die UC#4 DEMO beim 2. progressivKI Tag vorzubereiten, das UC#4 whitepaper fertigzustellen, und die DEMO beim Abschlußtreffen vorzubereiten.

4 Verwertung und voraussichtlicher Nutzen

03-IFAG

Ausgangslage

Zu Projektbeginn stellte sich für Infineon insbesondere die Skalierbare Anwendbarkeit von KI innerhalb der hochkomplexen Entwicklungsprozesse von ICs als Herausforderung dar. Viele KI Ansätze konnten nur mit sehr hohem Aufwand auf Unternehmensniveau skaliert werden, insbesondere weil die Sicherstellung von ausreichenden Trainingsdaten mit extrem hohem Aufwand verbunden war. Aus diesen Gründen hat Infineon innerhalb ProgressivKI, auf der Ebene des IC-Entwurfs folgende Ziele verfolgt:

- Entwicklung einer systematischen Erfassung und Verwaltung von Entwurfsdaten mit der Möglichkeit diese in die hoch automatisierten Entwurfsprozesse zu integrieren
- Entwurfsmethodik für KI Lösungen zur Sicherstellung von Qualität sowie einer homogenisierten Vorgehenweise und Vergleichbarkeit der KI Lösungsentwicklung
- Entwicklung einer Klassifikation von KI-Methoden für die schnelle Erfassung von konsolidierten Absicherungsmaßnahmen

Ergebnisse in progressivKI

Im Rahmen der Teilnahme von Infineon bei ProgressivKI konnten folgende Ergebnisse erzielt werden:

- Prototyp Infrastruktur umgesetzt für die Entwurfsdatenerfassung-, Verwaltung, und Prozessierung im Rahmen der Domäne physikalischer Entwurf (z.B. Layouterstellung)
- Entwurfsmethodik für KI Lösungen welche als Grundlage für die Erstellung einer KI Entwicklungsumgebung dient
- Klassifikation von KI-Lösungen und grobe Definition von Qualitätssicherungsmaßnahmen nach entsprechender Klassifikation als Grundlage für Entwurfsprozessdefinitionen für die KI-Entwicklung

Nutzen und Verwertbarkeit Für Infineon stellen die erzielten Ergebnisse von ProgressivKI einen grundlegenden Schritt in Richtung Digitalisierung dar. Insbesondere konnte durch einen Testbetrieb der Infrastruktur zur Entwurfsdatenerfassung, - Verwaltung, und –Prozessierung, das Potenzial und der Nutzen der Technologie sehr gut erfasst werden, so dass sowohl eine Weiterentwicklung und Verbreiterung der Infrastruktur geplant sind als auch eine schrittweise Integration in die qualifizierten Chip-, sowie Systementwicklungsumgebungen von Infineon (Geplante Integration Chipentwicklungs-umgebung 3 Jahre, Systementwurfsumgebung 5 Jahre). Nur durch letzteres kann eine langfristige Verwertung erfolgen.

Bei der Integration und Verbreiterung ist innerhalb der nächsten drei Jahre geplant über weitere Entwicklungsprojekte die Ergebnisse zunächst in der Mikrokontroller-Entwicklung in der Automobilelektronik zu pilotieren. Im Anschluss an diese Verwertung (4-6 Jahre) ist die breitere Verwertung in anderen Bereichen wie Power und Sensorik geplant.

Die Ergebnisse zur Entwurfsmethodik und Klassifikation von KI-Lösungen werden durch schrittweise Integration in Prozessdefinitionen und sowie über die Erweiterung einer neuen KI-Entwicklungsumgebung innerhalb der nächsten 3 Jahre verwertet werden. Mit Hilfe dieser Entwicklungsumgebungen sollen KI-Lösungen für den Einsatz im Chip- und Systementwurf umgesetzt werden und in die qualifizierten Chip- und Systementwurfsumgebungen integriert werden (5 Jahre). Auch hier wird der Fokus zunächst auf KI-Lösungen für die Entwicklung von Automobilelektroniksystemen liegen.

5 Veröffentlichungen

2021

[1] Nadine Knur: „Künstliche Intelligenz für Elektroniksysteme – HOOD im Forschungsteam progressivKI“, HOOD-Blogartikel, 18.05.2021, https://blog.hood-group.com/blog/2021/05/18/kuenstliche-intelligenz-fuer-elektroniksysteme-hood-im-forschungsteam-progressivki/

[2] Michael Jastram: „Die 11 Fallen im Machine Learning“, HOOD-Blog-Artikel, 27.05.2021, https://blog.hood-group.com/blog/2021/05/27/11-fallen-im-machine-learning/

2022

[3] Julian Withöft, Werner John, Emre Ecik, Ralf Brüning, and Jürgen Götze: „AI Models for Supporting SI Analysis on PCB Net Structures: Comparing Linear and Non-Linear Data Sources“

[4] Emre Ecik, Werner John, JulianWithöft, and Jürgen Götze: „Anomaly Detection with Decision Trees for AI Assisted Evaluation of Signal Integrity on PCB Transmission Lines“, xxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxx

[5] Nima Ghafarian Shoaee, Zouhair Nezhi, Werner John, Ralf Brüning, and Jürgen Götze: „Generating AI Modules for Decoupling Capacitor Placement Using Simulation“, xxxxxxxxxxxxxxx, xxxxxxxxxxxxxxxxxxxxxxx

[6] Jan Ebert: „Requirements- und Systems-Engineering für künstlich intelligente Systeme”, Vortrag auf der REConf 2022, 26.04.2022, München

[7] Markus Eberhardt und Jan Ebert: „KI4RE- Wie künstliche Intelligenz das Requirements Engineering unterstützen kann“, Vortrag auf dem Tag des Systems Engineering 2022, 17.11.2022, Paderborn

[8] Ralf Brüning, Rainer Assfalg: „KI: Ausweg aus dem PCB-Entwurfsdilemma? Bestandsaufnahme im Rahmen des BMWK-Förderprojektes progressivKI“

[9] W. John, J. Withöft, E. Ecik, R. Brüning and J. Götze, "A Practical Approach Based on Machine Learning to Support Signal Integrity Design," 2022 International Symposium on Electromagnetic Compatibility – EMC Europe, Gothenburg, Sweden, 2022, pp. 623-628, doi: 10.1109/EMCEurope51680.2022.9901213.

[10] J. Maalouly et al., "AI Assisted Interference Classification to Improve EMC Troubleshooting in Electronic System Development," Kleinheubacher Tagung 2022 (Vortrag)

[11] J. Maalouly et al., "AI Assisted Interference Classification to Improve EMC Troubleshooting in Electronic System Development," 2022 Kleinheubach Conference, Miltenberg, Germany, 2022, pp. 1-4.

[12] W.John, J.Withöft; E.Ecik, J.Götze, R.Brüning, „ML Based SI-Design Support: Outlook to AI enhanced PCB Design Processes – a Practical Approach“, EMC Europe 2022

[13] N. G. Shoaee, W. John, J. Götze, Z. Nezhi, R. Brüning, „Datengenerierung und -analyse zur Entwicklung von KI-Modulen für die Platzierung von Entkopplungskondensatoren mittels Simulation“, Kleinheubacher Tagung 2022

[14] I. Cahani, M. Stiemer, „Graph Neural Networks to Support an Automated Design of PCBs“, Kleinheubacher Tagung 2022

[15] Z. Nezhi, N. Ghafarian, M. Stiemer, „Zur Platzierung von Entkopplungskondensatoren mittels Optimierungsalgorithmen und ANN-Bewertung der PDN-Impedanz“, Kleinheubacher Tagung 2022
[16] Bartels, Choy, Brüning, Stube, „KI basierte DeCaps Platzierung“, Kleinheubacher Tagung 2022
[17] Marcel Olbrich, Michael Kleinen, Dr.-Ing. Sebastian Jeschke, „KI-gestützte Entstörungsmethodik zur Verbesserung der elektromagnetischen Verträglichkeit von Fahrzeugelektroniksystemen“, Dortmunder Autotag 2022
[18] Sven Lange, Ivan Kaufmann, Dominik Schröder, Christian Hedayat, "Generierung von Trainingsdaten für die Entwicklung eines KI-basierten Verfahrens zur Analyse von EMV-Problematiken im Bereich Automotive", Dortmunder Autotag 2022
[19] Daniela Sánchez Lopera, Lorenzo Servadei, Gamze Naz Kiprit, Robert Wille, Wolfgang Ecker, „A Comprehensive Survey on Electronic Design Automation and Graph Neural Networks: Theory and Applications“, Journal-TODAES, Juni 2022
[20] Daniela Sánchez Lopera, Lorenzo Servadei, Sebastian Prebeck, Wolfgang Ecker, „Early RTL Delay Prediction Using Neural Networks“, Journal-MICPRO, Oktober 2022
[21] Christian Lück, Daniela Sánchez Lopera, Sven Wenzek, and Wolfgang Ecker, „Industrial Experience with Open-Source EDA Tools“, MLCAD22, September 2022
[22] Daniela Sánchez Lopera and Wolfgang Ecker, „Applying GNNs to Timing Estimation at RTL“, ICCAD22, November 2022
[23] Daniela Sánchez Lopera, Prajwal Kashyap, Nicolas Gerlin, Sven Wenzek, Wolfgang Ecker, „Using Open-Source EDA Tools in an Industrial Design Flow“, DVCON22, Dezember 2022

2023

[24] Hichem Bouricha: „Besseres Requirements Engineering durch NLP?”, HOOD-Blogartikel, 25.01.2023, https://blog.hood-group.com/blog/2023/01/25/besseres-requirements-engineering-durch-nlp/
[25] Markus Eberhardt, Jan Ebert, Hichem Bouricha, Philip Stolz, Andreas Kress: „RE für KI-Systeme: KI & maschinelles Lernen: Neue Herausforderungen für das RE“, Fachartikel im IT-Spektrum 02/2023, 24.02.2023
[26] Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infrastructures and Management
[27] C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231
[28] J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274407.
[29] E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274174.

[30] E. Ecik; J. Withöft; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN) „Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach“, EMC Europe 2023
[31] J. Withöft; E. Ecik; J. Götze (17-TUDO); W.John (PYRAMIDE2525), „AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning“, EMC Europe 2023
[32] E. Ecik; J. Withöft; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R.Brüning (04-ZUKEN) „Analyse von Entwurfsräumen für den SI-gerechten PCB-Entwurf mit Hilfe von Entscheidungsbäumen“ Kleinheubacher Tagung 2023 (VORTRAG)
[33] J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN), „Unterstützung des signalintegritätsgerechten Entwurfs von PCB-Leitungsstrukturen mithilfe von Reinforcement Learning“, Kleinheubacher Tagung 2023 (VORTRAG)
[34] N. G. Shoaee; J. Götze (17-TUDO); Z. Nehzi (18-HSU); W. John (PYRAMIDE2525); R.Brüning (04-ZUKEN), „KI-basierte Optimierung von Stromversorgungs-Strukturen auf Leiterplatten“, Kleinheubacher Tagung 2023 (VORTRAG)
[35] J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMIDE2525); R. Brüning (04-ZUKEN), „AI Models for Supporting SI Analysis on PCB Net Structures: Comparing Linear and Non-Linear Data Sources“, Advances in Radio Science - Journal
[36] N. G. Shoaee; J.Götze (17-TUDO); W. John (PYRAMIDE2525) Z.Nehzi (18-HSU); R.Brüning (04-ZUKEN), „Generating AI Modules for Decoupling Capacitor Placement Using Simulation“, Advances in Radio Science - Journal
[37] E. Ecik; J.Withoeft; J. Götze (17-TUDO); W. John (PYRAMI-DE2525) „Anomaly Detection with Decision Trees for AI Assisted Evaluation of Signal Integrity Effects on PCB Transmission Lines“, Advances in Radio Science - Journal
[38] J. Withöft; E. Ecik; J. Götze (17-TUDO); W. John (PYRAMI-DE2525); R. Brüning (04-ZUKEN), „Optimization of a Daisy Chain PCB Memory System through Reinforcement Learning under Consideration of Signal Integrity Constraints“, Kleinheubacher Tagung 2023 (IEEE Xplore)
[39] N. G. Shoaee; B. Hua; J.Götze (17-TUDO); W.John (PYRA-MIDE2525) Z.Nehzi (18-HSU); R.Brüning (04-ZUKEN), „AI-based Optimization of Power Delivery Networks on Printed Circuit Boards“, Kleinheubacher Tagung 2023 (IEEE Xplore)
[40] I. Cahani and M. Stiemer, „Autoencoders in the Machine Learning Supported Design of PCBs“, 2023 Kleinheubach Conference. IEEE, 2023.
[41] Z. Nezhi, M. Stiemer, M. Schierholz and Ch. Schuster, „Dimensional Reduction by Auto-Encoders in Machine Learning Based Power Integrity Analysis“ in 28th IEEE Workshop on Signal and Power Integrity, 2024 (accepted).
[42] M. Schierholz, Z. Nezhi, M. Stiemer and Ch. Schuster, „PCB based Power Deliver Network Analysis Using Transfer Learning and Artificial Neural Networks“, in Proc. 28th IEEE Workshop on Signal and Power Integrity 2024 (submitted).
[43] M. Stiemer, R. Ueltzen, I. Cahani, Z. Nezhi, M. Hagel, H. Mathis, D. Hemker and J. Maalouly, „Automated model selection in an AI platform to support PCB design“, oral presentation at 2023 Kleinheubacher Tagung, 2023.
[44] Z. Nezhi, N. Ghafarian Shoaee and M. Stiemer, „Multi-Agent Reinforcement Learning for Decoupling Capacitor Placement Optimization in Power Distribution Networks“, oral presentation at 2023 Kleinheubacher Tagung, 2023.
[45] N. Ghafarian Shoaee, Z. Nezhi, W. John, R. Brüning and J. Götze, „KI-basierte Optimierung von Stromversorgungs-Strukturen auf Leiterplatten“, oral presentation at 2023 Kleinheubacher Tagung, 2023.

[46] Sanchez Lopera, Daniela, Ishwor Subedi and Wolfgang Ecker, „Using Graph Neural Networks for Timing Estimations of RTL Intermediate Representations“, MLCAD 09.2023
[47] E. S. Alcorta et al., „Special Session: Machine Learning for Embedded System Design“, CODES+ISSS
[48] Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infra-structures and Management
[49] C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231
[50] J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electro-magnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EM-CEurope57790.2023.10274407.
[51] E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EM-CEurope57790.2023.10274174.
[52] D. Hemker, J.Maalouly , H. Mathis, R. Klos, E. Ravanan: "From Schematics to Netlists - Electrical Circuit Analysis Using Deep Learning Methods", Kleinheubacher Tagung 2023
[53] Jad Maalouly, Dennis Hemker, Christian Hedayat, Marcel Olbrich, Sven Lange, and Harald Mathis: “Using Autoencoders to Classify EMC Problems in Electronic System Development”, Kleinheubacher Tagung 2023 (Vortrag)
[54] Dennis Hemker, Stefan Kreutter and Harald Mathis: „On Reducing Complexity in AI Pipelines: Modularisation to Retain Control“, ERCIM News 133, April 2023, Special theme: Data Infrastructures and Management
[55] C. Grob, F. Gehring and O. Bringmann, "Towards Sustainable Energy Communities: Local Optimization of Battery Usage in P2P Energy Trading," in 2023 IEEE International Conference on Omni-layer Intelligent Systems (COINS), Berlin, Germany, 2023 pp. 1-7. doi: 10.1109/COINS57856.2023.10189231
[56] J. Withöft, W. John, E. Ecik and J. Götze, "AI-Based SI-Compliant PCB Design Support for DDR Technology Enhanced by Transfer Learning," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274407.
[57] E. Ecik, W. John, J. Withöft, R. Brüning and J. Götze, "Signal Integrity Design of PCB Transmission Paths using a Decision Tree Approach," 2023 International Symposium on Electromagnetic Compatibility – EMC Europe, Krakow, Poland, 2023, pp. 1-6, doi: 10.1109/EMCEurope57790.2023.10274174.
[58] Öffentlichkeitsarbeit über eigene Website; Jürgen Kutter, Michael Kemkes: https://www.innozent-owl.de/foerderprojekte-erkunden/progressivki/
[59] OWL GmbH Solutions Veranstaltungsreihe: https://www.ostwestfalenlippe.de/owl-gmbh/innovation-und-wissen/solutions/morgenist-jetzt-transformation-leben-39-solutions-veranstaltungen-bieten-impulseloesungen-und-kontakte/
[60] Marcel Olbrich, Michael Kleinen, Dr.-Ing. Sebastian Jeschke, “AI assisted interference suppression – Provision of EMC domain knowledge for AI training and test processes”, Posterbeitrag, progressivKI Projekttreffen, Karlsruhe, 04/2023

2024

[61] Novacek, Aharie, Müller, Reiter, Viehl, Bringmann. „Ontology-supported AI Model and Dataset Management.“ ICIT24 [Im Review]

[62] Marcel Olbrich, Sven Lange, Dennis Hemker, Jad Maalouly, Jürgen Kutter, “AI Assisted EMC Interference Recognition”, 2. progressivKI Tag, Hamm, 28.02.2024

[63] Sven Lange, Marcel Olbrich, Dennis Hemker, Jad Maalouly, Jürgen Kutter, Dominik Schröder, Christian Hedayat, Michael Kleinen, Andreas Grünwaldt, Jörg Bärenfänger, Harald Mathis, Harald Kuhn, “A Hybrid Data Generation Approach for the Development of an AI-based EMC Interference Recognition Method”, 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 09/2024

[64] Dennis Hemker, Jad Maalouly, Harald Mathis, Rainer Klos, and Eranyan Ravanan: “From Schematics to Netlists – Electrical Circuit Analysis Using Deep-Learning Methods”, Adv. Radio Sci., 22, 61–75, https://doi.org/10.5194/ars-22-61-2024, 2024

[65] Jad Maalouly, Dennis Hemker, Christian Hedayat, Marcel Olbrich, Sven Lange, and Harald Mathis: “Using Autoencoders to Classify EMC Problems in Electronic System Development”, Adv. Radio Sci., 22, 53–59, https://doi.org/10.5194/ars-22-53-2024, 2024J.

[66] Maalouly, D. Hemker, S. Lange, M. Olbrich, C. Hedayat, J. Kutter, H. Mathis: “Evaluation of simulated and real measurement data for ai-based interference classification in emc applications”. 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 2024 (Vortrag).

[67] J. Maalouly, D. Hemker, S. Lange, M. Olbrich, C. Hedayat, J. Kutter, H. Mathis: “Evaluation of simulated and real measurement data for ai-based interference classification in emc applications”. 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, Bruges, Belgium, 2024.

[68] H. Mathis, D. Hemker, J. Maalouly, C. Goretzky, W. Gaertner, I. Ghosh, S. Lange, and C. Hedayat: "Applications of Artificial Intelligence to Support Electronic System Development". In: Mathematics in Industry. Springer Nature (2024). Accepted.

[69] Choy, D., Bartels, T. S., Pucic, A., Schröder, B., & Stube, B. (2024). AI Driven Power Integrity Compliant Design of High-Speed PCB. 2024 International Symposium on Electromagnetic Compatibility – EMC Europe, 146–150. https://doi.org/10.1109/emceurope59828.2024.10722162

[70] Bartels, T., Choy, D., Schröder, B., Stube, B., & Pucic, A. (2024). P13 - AI-supported PDN design for PCBs in automotive applications. The Poster, 157–160. https://doi.org/10.5162/iccc2024/p13

[71] D. Hemker , J. Maalouly, P. Brus , C. Garaza , V. Esen , A. Ahari , J. Novacek , S. Reiter, T. Müller , R. Ueltzen: „Best Practices for MLOps in IC Design: A Case Study” https://www.researchgate.net/publication/386134735_Best_Practices_for_MLOps_in_IC_Design_A_Case_Study

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).

[Coüasnon] Coüasnon, 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. Retreived 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 Aufla-ge, 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. Retreived 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 „Integrationstechnolgien für autonome Sensorsysteme“, https://www.binder-elektronik.de/referenzen#itas-integrationtechnologien-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.

[KIcdn] AI / Machine Learning Solutions; https://www.cadence.com/ko_KR/home/solutions/machine-learning.html

[KIment] 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

[KIsyn] 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

[Miloševic] Miloševic, 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) 1633-1685Submitted 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. Retreived 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.

[ZhangJua] Zhang, L., Juang, J., Kiguradze, Z., Pu, B., Jin, S., Wu, S., Yang, Z., Fan, J., & Hwang, C. (2021). Fast impedance prediction for power distribution network using deep learning. International Journal of Numerical Modelling Electronic Networks Devices and Fields, 35(2). https://doi.org/10.1002/jnm.2956

[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 Inteligence, 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-figure

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: Dateninfrastruktur für eine KI-Entwicklungsumgebung von ICs

4. Autor(en) [Name(n), Vorname(n)]	5. Abschlussdatum des Vorhabens
Esen Volkan Neyer Manuela	30.09.2024
	6. Veröffentlichungsdatum 13.12.2024
	7. Form der Publikation Schlussbericht
8. Durchführende Institution(en) (Name, Adresse) Infineon Technologies AG - 85579 Neubiberg	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 19A21006C
	11. Seitenzahl 81
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. Literaturangaben 1
	14. Tabellen 4
	15. Abbildungen 10

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.

Thematisch und organisatorisch wurden die F+E-Arbeiten mittels der Anwendungsebenen #1: PCB-Entwurf und #2: IC-Entwurf/Sensorik adressiert. Die Infineon Technologies AG hat sich dabei vor allem auf die Anwendungsebene #2 (IC-Entwurf/ Sensorik) fokussiert.

Ziel war, die Erforschung von Methoden welche eine skalierbare, hoch-qualitative KI-Methodenentwicklung ermöglichen, zur Beschleunigung des IC-Entwurfs in der Mikroelektronik und Sensortechnik durch

1) Entwicklung eines Prototyps zur Spezifizierung und Erfassung von Entwicklungsschrittdaten, Entkoppelung von Datenkollektion und –speicherung
2) Definition eines Datenmodells
3) Untersuchung von Datenhaltungsverfahren
4) Entwicklung einer Zugriffsschnittstelle für strukturierten Zugriff auf Entwicklungsdaten
5) Demonstration der Nutzung der gesammelten Daten für KI-Algorithmen.

19. Schlagwörter
EDA, Mikroelektronik, Halbleiterindustrie, Fahrzeugentwicklung, Künstliche Intelligenz (KI), Machine Learning, MLOps, IC Design, Automation, Digitalisierung

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: Data infrastructure for an AI development environment of ICs

4. author(s) (family name, first name(s))	5. end of project
Esen Volkan Neyer Manuela	30.09.2024
	6. publication date 13.12.2024
	7. form of publication Final Report
8. performing organization(s) (name, address) Infineon Technologies AG - 85579 Neubiberg	9. originator's report no.
	10. reference no. 19A21006C
	11. no. of pages 81
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 53107 Bonn	13. no. of references 1
	14. no. of tables 4
	15. no. of figures 10

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".

Thematically and organisationally, the R&D work was addressed by means of the application levels #1: PCB design and #2: IC design/sensor technology. Infineon Technologies AG focussed primarily on application level #2.

The aim was to research methods that enable scalable, high-quality AI models to accelerate IC design in microelectronics and sensor technology through

1) Development of a prototype for the specification and collection of development step data, decoupling of data collection and storage
2) Definition of a data model
3) Investigation of data storage procedures
4) Development of an access interface for structured access to development data
5) Demonstration of the use of the collected data for AI algorithms

19. keywords
EDA (Electronic Design Automation), Microelectronics, Semiconductor Industry, Vehicle Development, Artificial Intelligence (AI), Machine Learning, MLOps, IC Design, Automation, Digitalisation

20. publisher	21. price